



UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE
CENTRO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA
ELÉTRICA E DE COMPUTAÇÃO



**INTELIGÊNCIA ARTIFICIAL APLICADA AO ECOSISTEMA DE REGULAÇÃO
DO ESTADO RIO GRANDE DO NORTE (REGULARN): ANÁLISES BASEADAS
EM *MACHINE LEARNING* EM LEITOS COVID-19 E LEITOS GERAIS**

TIAGO DE OLIVEIRA BARRETO

Orientador: Ricardo Alexsandro de Medeiros Valentim

Tese de doutorado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e de Computação da UFRN (área de concentração: Engenharia de Computação) como parte dos requisitos para obtenção do título de Doutor em Engenharia Elétrica e Computação.

Setembro

2024

Universidade Federal do Rio Grande do Norte - UFRN
Sistema de Bibliotecas - SISBI
Catalogação de Publicação na Fonte. UFRN - Biblioteca Central Zila Mamede

Barreto, Tiago de Oliveira.

Inteligência artificial aplicada ao ecossistema de regulação do Estado Rio Grande do Norte (RegulaRN): análises baseadas em machine learning em leitos Covid-19 e leitos gerais / Tiago de Oliveira Barreto. - 2024.

135f.: il.

Tese (doutorado) - Universidade Federal do Rio Grande do Norte, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica e de Computação, Natal, 2024.

Orientação: Prof. Dr. Ricardo Alexsandro de Medeiros Valentim.

1. Regulação de leitos - Tese. 2. RegulaRN - Tese. 3. Inteligência Artificial - Tese. 4. Modelos Computacionais - Tese. 5. Saúde digital - Tese. I. Valentim, Ricardo Alexsandro de Medeiros. II. Título.

RN/UF/BCZM

CDU 004:61

Elaborado por Jackeline dos Santos Pinheiro da Silva Maia
Cavalcanti - CRB-15/317

Agradecimentos

Agradeço primeiramente a Deus por iluminar os meus caminhos em toda a minha jornada formativa desde a graduação até o doutorado.

A toda a minha família que foram peças fundamentais em cada passo que eu dei ao longo dos aproximados dez anos de formação contínua na Universidade Federal do Rio Grande do Norte. Em especial a minha mãe que sempre me incentivou a construir uma carreira acadêmica e à minha esposa pelo apoio de todas as horas, motivação e paciência em todos os momentos dessa jornada.

Ao meu orientador, Dr. Ricardo Valentim, por todos os ensinamentos prestados para com o perfil docente e pesquisador da minha formação, e principalmente por ter plantado em mim a ideia do desenvolvimento da ciência com impacto social e amor ao próximo.

Ao Laboratório de Inovação Tecnológica em Saúde (LAIS/UFRN) e a Secretaria de Saúde Pública (SESAP/RN) por fornecerem toda a infraestrutura e ferramentas necessárias para que esta pesquisa pudesse existir.

A todos os meus amigos do LAIS, em especial ao Núcleo de Incorporação Tecnológica, no qual pude fazer parte ao longo dos últimos quatro anos, desenvolvendo trabalhos e projetos importantíssimos para a saúde do Rio Grande do Norte e Brasil.

Resumo

O processo de regulação de leitos está entre um dos processos mais relevantes para o sistema de saúde público brasileiro. Ele contempla todo o processo de gestão e monitoramento de um paciente que necessita de internação, desde a solicitação até o seu devido internamento. Contudo, ainda é uma área que possui pouco investimento em sistemas de saúde digitais e outros recursos que possam favorecer a melhor condução do processo regulatório. Desse modo, este trabalho objetiva incluir a área de inteligência artificial dentro da área de regulação de leitos públicos, a fim potencializar e auxiliar o processo de tomada de decisão durante a regulação de leitos. Nesse sentido, foram utilizados dados de regulação de leitos de dois módulos da plataforma adotada no Rio Grande do Norte, RegulaRN COVID-19 e RegulaRN Leitos Gerais, a fim de classificar os dados e prever o desfecho do paciente. Ao todo, foram analisados cerca de 72.422 dados de regulação de leitos em diferentes recortes temporais, além disso, foi utilizado um *pipeline* de caracterização, pré-processamento, correlação de dados, definição de métricas para avaliação, balanceamento dos dados, definição de dados de treinamento e validação, definição de modelos computacionais para classificação dos dados e seleção dos hiperparâmetros. Para a plataforma RegulaRN COVID-19, os resultados mostraram melhor desempenho para as métricas de acurácia (84,01%), precisão (79,57%) e F1-score (81,00%) no modelo Multilayer Perceptron com otimizador Stochastic Gradient Descent (SGD). Já para as métricas revogação (84,67%), especificidade (84,67%) e ROC-AUC (91,6%) os melhores resultados foram obtidos pela Root Mean Squared Propagation (RMSProp). Quanto aos dados do RegulaRN Leitos Gerais, as análises foram feitas com dois conjuntos de dados: adultos e pediátricos e neonatais. Para o primeiro conjunto o Extreme Gradient Boosting (XGBoost) apresentou melhores valores de acurácia (87,77%) e revogação (87,77%), Random Forest melhor precisão (87,05%), Gradient Boosting melhor F1 Score (87,56%) e para a especificidade (82,94%) foi obtido pelo SGD. Já para os dados de neonatos, obteve-se melhores valores de acurácia (87,50%), revogação (87,50%) e F1-Score(88,48%) o classificador Decision Tree, melhor precisão (90,75%) o AdaBoost e melhor especificidade o PMC Adam. Os resultados permitiram identificar os melhores modelos para auxiliar os profissionais de saúde durante o processo de

regulação de leitos, assim como, os achados científicos deste trabalho acadêmico demonstram que os métodos computacionais utilizados aplicados por meio de uma solução de saúde digital podem auxiliar na tomada de decisão de reguladores médicos e instituições governamentais a fim de fortalecer o desempenho da saúde pública brasileira.

Palavras chaves: Regulação de leitos. RegulaRN. Inteligência Artificial. Modelos Computacionais. Saúde digital.

Abstract

The process of bed regulations is among the most relevant processes for the Brazilian public health system. It encompasses the entire process of managing and monitoring a patient who requires hospitalization, from the request to their proper admission. However, it is still an area that has little investment in digital health systems and other resources that can favor the better management of the regulatory process. Thus, this work aims to include the area of artificial intelligence within the area of regulating public beds, in order to enhance and assist the decision-making process during bed regulation. In this sense, bed regulation data from two modules of the platform adopted in Rio Grande do Norte, RegulaRN COVID-19 and RegulaRN Leitos Gerais, were used in order to classify the data and predict the patient's outcome. In total, approximately 72,422 bed regulation data were analyzed in different time frames. In addition, a pipeline of characterization, preprocessing, data correlation, definition of metrics for evaluation, data balancing, definition of training and validation data, definition of computational models for data classification and selection of hyperparameters was used. For the RegulaRN COVID-19 platform, the results showed better performance for the accuracy (84.01%), precision (79.57%) and F1-score (81.00%) metrics in the Multilayer Perceptron (MLP) model with Stochastic Gradient Descent (SGD) optimizer. For the recall (84.67%), specificity (84.67%) and ROC-AUC (91.6%) metrics, the best results were obtained by Root Mean Squared Propagation (RMSProp). As for the RegulaRN Leitos Gerais data, the analyses were performed with two datasets: adults and pediatric and neonatal. For the first set, Extreme Gradient Boosting (XGBoost) presented the best accuracy (87.77%) and recall (87.77%) values, Random Forest had the best precision (87.05%), Gradient Boosting had the best F1 Score (87.56%) and for specificity (82.94%) it was obtained by SGD. For the newborn data, the best accuracy (87.50%), recall (87.50%) and F1-Score (88.48%) values were obtained by the Decision Tree classifier, the best precision (90.75%) by Adaboost and the best specificity by MLP Adam. The results allowed us to identify the best models to assist health professionals during the bed regulation process, as well as the scientific findings of this academic work demonstrate that the computational methods used applied through a

digital health solution can assist in the decision-making of medical regulators and government institutions in order to strengthen the performance of Brazilian public health.

Keywords: Bed Regulation. RegulaRN. Artificial Intelligence. Computational Models. Digital Health.

Sumário

Capítulo 1	14
Introdução	14
1.1 - Exposição do tema e problema de pesquisa	14
1.2 - Objetivos	17
1.2.1 - Objetivo principal	17
1.2.2 - Objetivos secundários	17
1.3 - Justificativa	17
Capítulo 2	24
Mapeamento Sistemático da Literatura	24
2.1 - Protocolo do mapeamento sistemático	25
2.1.1 Questões de pesquisa	25
2.1.2 Processo de pesquisa	26
2.1.3 Resultados do mapeamento sistemático	29
Capítulo 3	31
Saúde Digital: Desafios e Oportunidades	31
Capítulo 4	34
Regulação de Leitos no Sistema Único de Saúde	34
Capítulo 5	37
Revolução Digital na Regulação de Leitos do RN: O RegulaRN	37
5.1 - Ecossistema tecnológico de combate à COVID-19	37
5.2 - RegulaRN COVID-19	38
5.3 - RegulaRN Leitos Gerais	42
Capítulo 6	44
Inteligência Artificial em Saúde	44
Capítulo 7	47
Materiais e Métodos	47
7.1 - Caracterização do método de pesquisa	47
7.2 - Método de aplicação da pesquisa	51
7.2.1 - Extração, avaliação, caracterização e pré-processamento	51
7.2.1.1 - RegulaRN COVID-19	51
7.2.1.2 - RegulaRN Leitos Gerais - Adulto e Pediátrico	53
7.2.1.3 - RegulaRN Leitos Gerais - Neonatal	54
7.2.2 Análise, correlação entre features do dataset e validação estatística	58
7.2.3 Métricas de avaliação	59
7.2.4 Balanceamento de dados	61
7.2.5 Dados de treinamento e validação	61

7.2.6 Definição de modelos para classificação dos dados	62
7.2.6.1 - RegulaRN COVID-19	62
7.2.6.2 - RegulaRN Leitos Gerais	63
7.2.7 Hiperparâmetros para definição do melhor modelo	63
Capítulo 8	69
Resultados	69
8.1 - Análise geral dos dados para a plataforma RegulaRN COVID-19	69
8.2 - Resultados dos modelos computacionais para a plataforma RegulaRN COVID-19	76
8.3 - Análise geral dos dados para a plataforma RegulaRN Leitos Gerais	80
8.3.1 - Dados de adultos e pediátricos	80
8.3.2 - Dados de neonatais	94
8.4 - Resultados dos modelos computacionais para a plataforma RegulaRN Leitos Gerais	103
8.4.1 - RegulaRN Leitos Gerais adultos e pediátricos	103
8.4.2 - RegulaRN Leitos Gerais neonatais	107
8.5 - Análise geral dos resultados	110
Capítulo 9	113
Discussão	113
Capítulo 10	118
Conclusões	118
Referências Bibliográficas	120

Lista de Figuras

Figura 1 - Quantitativo de publicações na base de dados SCOPUS	18
Figura 2 - Distribuição de publicações por área do conhecimento.	19
Figura 3 - Distribuição de publicações por países.	20
Figura 4 - Distribuição de publicações pelo tipo.	21
Figura 5 - Ilustração temática da apresentação dos capítulos desta pesquisa	23
Figura 6 - Distribuição das regiões de saúde no Rio Grande do Norte	36
Figura 7 - Caracterização do método de pesquisa	51
Figura 8 - Delineamento de tratamento e seleção de dados	58
Figura 9 - Representação da matriz de confusão	59
Figura 10 - Matriz geral de correlação Phik para os dados de COVID-19	73
Figura 11 - Matriz de correlação Phik, com desfecho alta, para os dados de COVID-19	74
Figura 12 - Matriz de correlação Phik, com desfecho óbito, para os dados de COVID-19	75
Figura 13 - Importância das características para classificação dos modelos de árvore para os dados de COVID-19	78
Figura 14 - Importância das características para classificação dos modelos do perceptron multicamadas para os dados de COVID-19	79
Figura 15 - Curva ROC-AUC para os modelos que utilizaram dados do COVID-19.	80
Figura 16 - Matriz geral de correlação Phik com os dados do RegulaRN Leitos Gerais pediátrico e adulto.	92
Figura 17 - Matriz de correlação Phik, com dados de alta, do RegulaRN Leitos Gerais pediátrico e adulto.	93
Figura 18 - Matriz de correlação Phik, com dados de óbitos, do RegulaRN Leitos Gerais pediátrico e adulto.	94
Figura 19 - Matriz geral de correlação Phik com os dados do RegulaRN Leitos Gerais neonatais.	101
Figura 20 - Matriz de correlação Phik, com dados de altas, do RegulaRN Leitos Gerais neonatais.	102
Figura 21 - Matriz de correlação Phik, com dados de óbitos, do RegulaRN Leitos Gerais neonatais.	103
Figura 22 - Importância das características para classificação dos modelos de árvore e ensemble para os dados de Leitos Gerais adultos e pediátricos	106
Figura 23 - Importância das características para classificação dos modelos perceptron para os dados de Leitos Gerais adultos e pediátricos	106
Figura 24 - Curva ROC-AUC para os modelos que utilizaram dados dos Leitos Gerais adultos e pediátricos	107
Figura 25 - Importância das características para classificação dos modelos de árvore e ensemble para os dados de Leitos Gerais neonatais.	109
Figura 26 - Importância das características para classificação dos modelos perceptron para os dados de Leitos Gerais neonatais.	109
Figura 27 - Curva ROC-AUC para os modelos que utilizaram dados dos Leitos Gerais neonatais	110

Lista de Quadros e Tabelas

Quadro 1 – Questões de pesquisa da MSL	25
Quadro 2 – Strings de busca para a MSL	26
Quadro 3 – Bases utilizadas e quantidade de artigos retornados	26
Quadro 4 - Critérios de inclusão desenvolvidos	26
Quadro 5 – Bases e artigos selecionados após a aplicação dos critérios de inclusão	27
Quadro 6 – Critérios de exclusão	27
Quadro 7 - Apresentação de informações dos trabalhos correlatos	29
Quadro 8 - Indicadores e descrições do RegulaRN COVID-19	39
Quadro 9 - Indicadores e descrições do RegulaRN Leitos Gerais	42
Tabela 1 - Campos e descrição de dados do RegulaRN	55
Tabela 2 - Seleção de hiperparâmetros e valores para cada modelo	66
Tabela 3 - Distribuição de características de acordo com o desfecho	69
Tabela 4 - Desempenho assistencial das regiões de saúde com dados de COVID-19	76
Tabela 5 - Desempenho dos modelos de acordo com as métricas da matriz de confusão - RegulaRN COVID-19.	77
Tabela 6 - Perfil de dados do dataset do RegulaRN Leitos Gerais adultos e pediátricos	81
Tabela 7 - Registros dos CIDs mais recorrentes na base de dados do RegulaRN Leitos Gerais adulto e pediátrico	87
Tabela 8 - Registro de CIDs, no RegulaRN Leitos Gerais adultos e pediátricos, que geram maior número de altas e óbitos.	89
Tabela 9 - Distribuição de frequências de altas e óbitos por CID e tipo do leito, para o RegulaRN Leitos Gerais adulto e pediátrico.	90
Tabela 10 - Perfil de dados do dataset do RegulaRN Leitos Gerais neonatal	95
Tabela 11 - Registros dos CIDs mais recorrentes na base de dados do RegulaRN Leitos Gerais neonatais	96
Tabela 12 - Registro de CIDs, no RegulaRN Leitos Gerais neonatais, que geram maior número de altas e óbitos.	98
Tabela 13 - Distribuição de frequências de altas e óbitos por CID e tipo do leito, para o RegulaRN Leitos Gerais neonatal.	99
Tabela 14 - Desempenho dos modelos de acordo com as métricas da matriz de confusão - RegulaRN Leitos Gerais adultos e pediátricos.	104
Tabela 15 - Desempenho dos modelos de acordo com as métricas da matriz de confusão - RegulaRN Leitos Gerais neonatal.	108

Lista de Símbolos e Abreviaturas

AUC	<i>Area Under the Curve</i>
CER	Central Estadual de Regulação
CID	Código Internacional de Doenças
ESD28	Estratégia de Saúde Digital para o Brasil 2020-2028
EUP	Escore Unificado de Priorização
LAIS	Laboratório de Inovação Tecnológica em Saúde
MP	Ministério Público Estadual
MPF	Ministério Público Federal
MSL	Mapeamento Sistemático da Literatura
PMC	Perceptron Multicamadas
RNDS	Rede Nacional de Dados em Saúde
RMSProp	<i>Root Mean Square Propagation</i>
RN	Rio Grande do Norte
ROC	<i>Receiver Operating Characteristic</i>
SESAP	Secretaria de Saúde Pública do Estado
SGD	<i>Stochastic Gradient Descent</i>
SISREG	Sistema Regulador Nacional
SMOTE	<i>Synthetic Minority Over-sampling Technique</i>
SOFA	<i>Sequential Organ Failure Assessment</i>
SUS	Sistema Único de Saúde
UTI	Unidade de Terapia Intensiva

Produção Acadêmica

Publicações em periódicos relacionadas à tese

- Título:** Artificial intelligence applied to analyzes during the pandemic: COVID-19 beds occupancy in the state of Rio Grande do Norte, Brazil.
Periódico: Frontiers in Artificial Intelligence.
Status: Publicado.
Fator de impacto: 3,0
Citescore: 6,21
Como citar: BARRETO, Tiago de Oliveira et al. Artificial intelligence applied to analyzes during the pandemic: COVID-19 beds occupancy in the state of Rio Grande do Norte, Brazil. Frontiers in Artificial Intelligence, v. 6, p. 1290022, 2023. DOI: <https://doi.org/10.3389/frai.2023.1290022>.

Registro de software relacionado à tese

- Registro de Software:** RegulaRN
Processo N°: BR512020002366-5.
Status: Expedido em 2020

Publicações em periódicos e capítulo de livros durante o percurso acadêmico

- Título:** Application of the QFD-fuzzy-SERVQUAL methodology as a quality planning tool at the surgical centre of a public teaching hospital
Periódico: BMC Medical Informatics and Decision Making
Status: Publicado.
Qualis Capes: A2
Fator de impacto: 3,3
Citescore: 4,6
Como citar: JUNIOR, Jurandir Barreto Galdino et al. Application of the QFD-fuzzy-SERVQUAL methodology as a quality planning tool at the surgical centre of a public teaching hospital. BMC Medical Informatics and Decision Making, v. 22, n. 1, p. 8, 2022. DOI: <https://doi.org/10.1186/s12911-022-01746-4>
- Título:** Analysis of Maintenance Events in Medical Equipment in the Largest Trauma Hospital in Natal/RN
Série do livro: IFMBE Proceedings, volume 101.
Livro: IX Latin American Congress on Biomedical Engineering and XXVIII Brazilian Congress on Biomedical Engineering
Status: Publicado.
Como citar: PAZ, Lyssandra et al. Analysis of Maintenance Events in Medical Equipment in the Largest Trauma Hospital in Natal/RN. In: Latin American

Conference on Biomedical Engineering. Cham: Springer Nature Switzerland, 2022. p. 139-149.

Registro de software durante o percurso acadêmico

1. **Registro de Software:** RN+Vacina.
Processo N°: BR512021001478-2.
Status: Expedido em 2021.
2. **Registro de Software:** Salus 2.0.
Processo N°: BR512022002956-1.
Status: Expedido em 2022.
3. **Registro de Software:** Vacina e Confia ES.
Processo N°: BR512023002069-9.
Status: Expedido em 2023.
4. **Registro de Software:** SARES - Solução Digital Aplicada à Regulação do Espírito Santo.
Processo N°: BR512024001694-5.
Status: Expedido em 2024.

Capítulo 1

Introdução

1.1 - Exposição do tema e problema de pesquisa

O processo de manutenção dos direitos do Sistema Único de Saúde (SUS) brasileiro, de modo a garantir os pilares da universalidade, integralidade e equidade consideram-se dispostos, ao longo de muitos anos, de muitas atribuições e barreiras. Desse modo, instituído pela Constituição Federal de 1988, o SUS representa uma conquista social importante, sendo um dos maiores sistemas públicos de saúde do mundo. Ele é responsável por assegurar o acesso integral, universal e igualitário às ações e serviços para promoção, proteção e recuperação da saúde. Entretanto, as desigualdades socioeconômicas e regionais, juntamente com a escassez de recursos e a fragmentação dos serviços, continuam a desafiar a plena realização desses princípios fundamentais (Brasil, 1988; Vilarins; Shimizu; Gutierrez, 2012; Paim, 2018).

Nesse sentido, a utilização do processo regulatório pode ser vista como um instrumento fundamental para reduzir as desigualdades entre os setores públicos e privados da saúde. A regulação é uma ferramenta que, quando bem aplicada, pode equilibrar a distribuição de recursos e serviços de saúde, garantindo que as necessidades da população sejam atendidas de maneira justa e eficiente. Para alguns autores, o termo “Regulação” é utilizado quando determinados serviços funcionam sob concessão do Estado para atender diferentes necessidades da população em geral. Vale ressaltar que, embora exista uma controvérsia sobre a autoridade do processo de regulação, seja ela pelo Estado ou Município, ela é compreendida em três níveis: regulação sobre sistemas de saúde; regulação da atenção à saúde e regulação assistencial (Brasil, 2008; Vilarins; Shimizu; Gutierrez, 2012; Dutra; Lenzi; Lisiesky, 2022).

Destacando a regulação assistencial, ela incorre na promoção da equidade do acesso aos serviços de saúde, garantindo a integralidade da assistência e permitindo ajustar a oferta

assistencial disponível às necessidades imediatas do cidadão, de forma equânime, ordenada, oportuna e racional. É nesse contexto que se enquadra a regulação de leitos, como uma atividade essencial dentro da gestão de saúde pública. Nessa perspectiva, o processo de regulação de leitos é uma atividade crítica dentro da gestão de saúde pública, pois atua diretamente na gestão de setores que podem impactar a vida dos pacientes, principalmente aqueles que necessitam de internação em casos emergenciais (Maldonado et al., 2021).

No Rio Grande do Norte, a Central Estadual de Regulação (CER/RN), pertencente à Secretaria de Saúde Pública do Estado (SESAP), é a unidade responsável por gerir o processo de regulação de leitos públicos da região. Com a chegada da pandemia de COVID-19, em 2020, o estado enfrentou uma série de problemas que expôs as fragilidades do sistema de saúde. A rápida disseminação do vírus levou a um aumento exponencial no número de casos e hospitalizações, o que resultou em uma sobrecarga do sistema de saúde, escassez de leitos, equipamentos e insumos médicos essenciais. Diante desse cenário, a SESAP, em parceria com o Laboratório de Inovação Tecnológica em Saúde (LAIS) da Universidade Federal do Rio Grande do Norte (UFRN), desenvolveu um ecossistema de enfrentamento à pandemia para minimizar seus impactos. Nesse contexto, foram elaboradas diversas plataformas de combate aos efeitos da COVID-19, resultando na criação do RegulaRN (Valentim et al., 2021; Bezerra, 2023; Andrade, 2023; Barreto et al., 2023).

O RegulaRN é uma plataforma de saúde digital desenvolvida com o objetivo de gerenciar e otimizar a regulação de leitos hospitalares no estado do Rio Grande do Norte. Essa plataforma permite uma visão integrada e atualizada da disponibilidade de leitos e das necessidades dos pacientes, possibilitando uma gestão mais eficiente e eficaz dos recursos de saúde. Desse modo, os profissionais de saúde conseguem atuar com mais segurança em todo o processo assistencial e de regulação, ademais, a plataforma também oferece suporte para a tomada de decisões estratégicas, auxiliando-os a lidar com a complexidade do processo de internação hospitalar. A regulação de leitos por meio do RegulaRN trouxe avanços significativos para o sistema de saúde do estado, como a otimização da ocupação dos leitos e a melhoria do fluxo de informações entre as unidades de saúde e a central de regulação (Valentim et al., 2021; Bezerra, 2023; Andrade, 2023; Barreto et al., 2023).

Frente ao contexto de saúde digital, a plataforma RegulaRN já traz por si só um contexto de inovação. Contudo, é possível ampliar ainda mais o seu potencial, tendo em vista as fragilidades existentes no processo de tomada de decisão durante a regulação de leitos. Em surtos epidêmicos, como foi o da COVID-19, a pressão por leitos exigia a melhor tomada de decisão por parte da central de regulação. Uma indicação equivocada, poderia não só

comprometer o giro de leito, como também provocar óbitos de pacientes que teriam chances de sobrevivência. Naturalmente, é dada ao profissional de saúde a soberania da indicação, todavia, a inclusão de métodos computacionais inteligentes pode auxiliar na melhor tomada de decisão em vários contextos de saúde, inclusive na regulação de leitos (Chen; Liu; Peng, 2018; Habbeh; Gohel, 2021; Toh; Brody, 2021; Valentim et al., 2021; Barreto et al., 2023).

Nessa perspectiva, há uma tendência global de utilização de métodos computacionais inteligentes no serviço de saúde integrados às práticas clínicas, tendo em vista a necessidade de melhorar a eficiência e a precisão assistencial. Na saúde, modelos de inteligência artificial já abrangem previsão de diagnóstico, avaliações de imagens e identificações de padrões de doenças, por exemplo (Mahmood et al., 2021; Elemento et al., 2021). Ademais, conforme reforça Moulaei et al. (2022), os algoritmos de aprendizado de máquina contribuem para a redução de incertezas, ambiguidades, lacunas subjetivas e melhor suporte à tomada de decisão. Haja vista que, em muitos casos, a assistência em saúde enfrenta desafios significativos devido à sobrecarga de trabalho e à falta de informações padronizadas (Debnath et al., 2020). Assim sendo, para garantir o pleno desenvolvimento de um sistema público de saúde brasileiro moderno e vanguardista, é mister que seus sistemas utilizados na assistência façam a incorporação de sistemas de inteligência artificial (Lemes; Lemos, 2020; Nogueira et al, 2022).

Haja vista que, sendo o sistema público de saúde brasileiro carente em várias dores, pode ser questionável optar por investir em inteligência artificial, quando em muitas redes hospitalares faltam insumos básicos, infraestrutura de qualidade e quantitativo insuficiente de profissionais de saúde. Entretanto, o atual déficit brasileiro está associado ao reflexo de longos anos de subfinanciamento e má gestão na saúde pública. Desse modo, investir em recursos tecnológicos, como ferramentas de inteligência artificial, não deve ser visto como desvio de recurso ou algo inapropriado ao momento, mas sim como uma ferramenta estratégica para otimizar o uso dos recursos existentes e melhorar a eficiência do sistema (Soares et al., 2023; Lima, 2023).

Tendo como base o que foi apresentado e considerando a necessidade de aprimorar, cada vez mais, os recursos tecnológicos na área da saúde e, especificamente, no campo da regulação de leitos, apresenta-se a pergunta norteadora desta pesquisa:

Até que ponto é possível incluir métodos computacionais de inteligência artificial no processo de regulação de leitos do sistema único de saúde e como isso pode favorecer a tomada de decisão por parte dos profissionais de saúde e governantes institucionais?

A formulação da hipótese para a questão de pesquisa foi elaborada a partir de uma avaliação do estado da arte acerca de regulação de leitos no escopo da saúde pública brasileira e internacional, assim como, examinação dos dados obtidos pelas plataformas RegulaRN COVID-19 e RegulaRN Leitos Gerais, e principalmente pela análise da utilização da equipe técnica de regulação de leitos do Estado do Rio Grande do Norte.

1.2 - Objetivos

1.2.1 - Objetivo principal

Analisar o conjunto de dados gerados pelo RegulaRN e aplicar diferentes métodos computacionais de inteligência artificial a fim de potencializar o processo de tomada de decisão de profissionais de saúde reguladores e governantes institucionais.

1.2.2 - Objetivos secundários

- Realizar análise comparativa e estatística dos dados de regulação das plataformas RegulaRN COVID-19 e Leitos Gerais.
- Selecionar os melhores dados da plataforma para previsão de desfecho hospitalar.
- Utilizar diferentes modelos de *machine learning* e *deep learning* nos dados selecionados.
- Comparar os resultados obtidos com base em métricas de predição.
- Analisar como os resultados obtidos podem favorecer a tomada de decisão no processo de trabalho de médicos reguladores.

1.3 - Justificativa

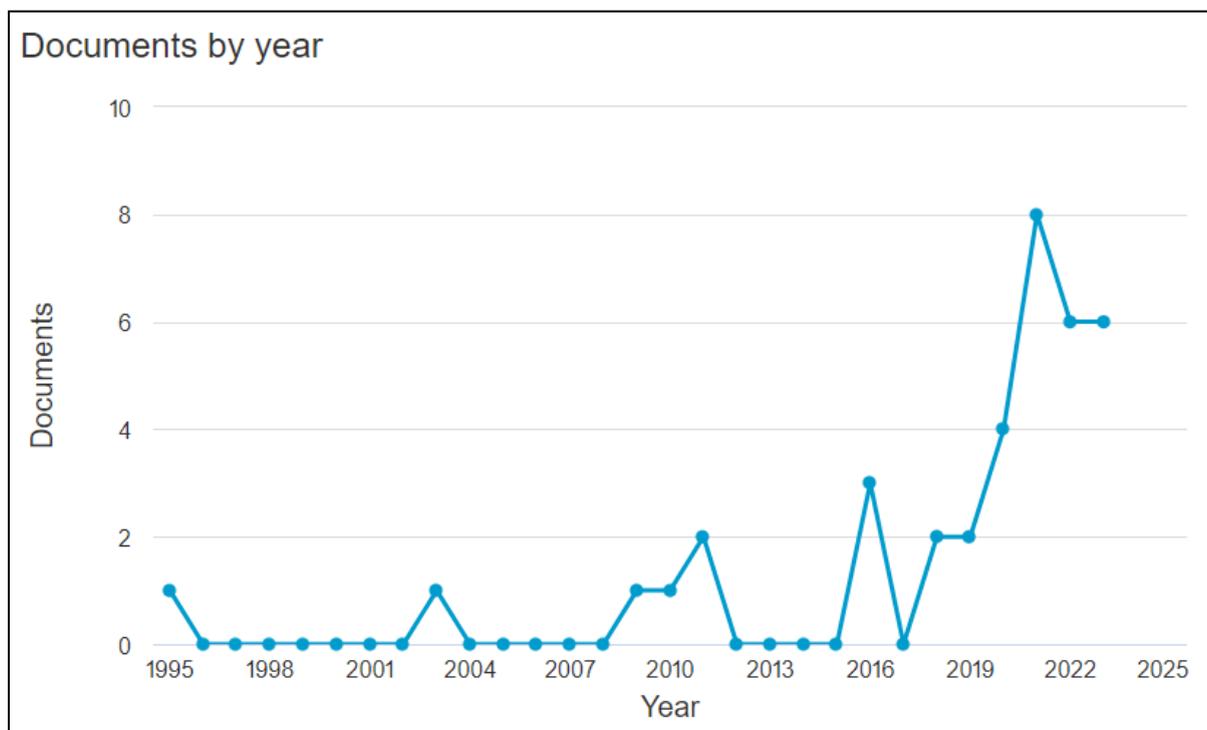
De forma detalhada, a abordagem desta justificativa se dará sob a perspectiva dos três eixos fundamentais: academia, empresa e sociedade, respectivamente.

Para abrir a discussão a respeito da justificativa desta pesquisa, foi realizado um levantamento dos principais trabalhos que estão sendo discutidos na área. Essa investigação foi obtida a partir da base de dados SCOPUS, base de dados da ELSEVIER, tendo em vista que essa base oferece um detalhamento das publicações mais qualificadas em todo o mundo. Nesse contexto, é possível realizar o levantamento de tendências acerca de maior ou menor contribuição de trabalhos nesse tema. Sendo assim, foi feita uma avaliação utilizando as

palavras chaves: ("artificial intelligence" OR "machine learning" OR "computational methods" OR "deep learning") AND ("bed regulation" OR "bed occupancy").

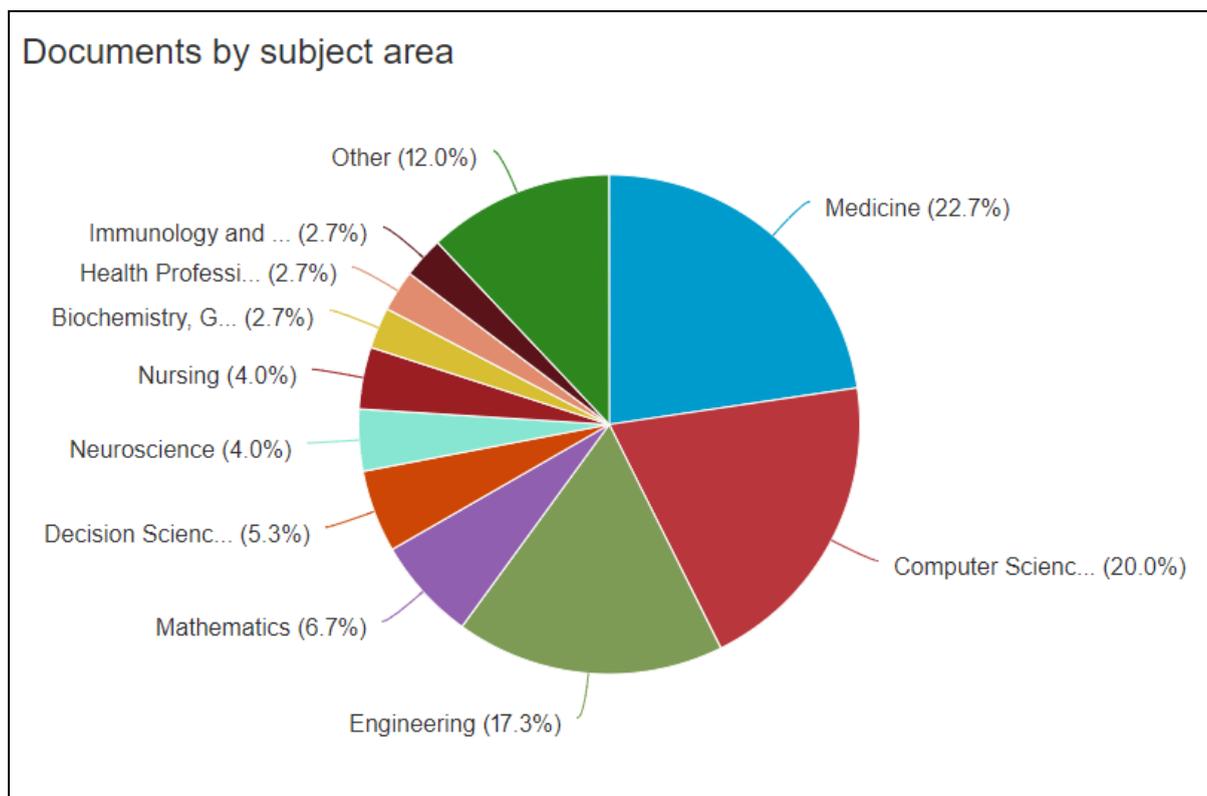
Na consulta realizada em janeiro de 2024, o resultado retornou cerca de 37 trabalhos acadêmicos envolvendo as palavras-chaves. A Figura 1 apresenta a quantidade de contribuições acadêmicas publicadas na base SCOPUS. Ao longo do período de 1995 até 2024, é possível identificar uma tendência de crescimento de pesquisas na área, principalmente após 2017. O ano de 2021 representou o maior quantitativo de publicações, com aproximadamente 8 trabalhos, contudo, para os anos que sucederam, há um ritmo de publicações similar e com tendências progressivas de publicações.

Figura 1 - Quantitativo de publicações na base de dados SCOPUS



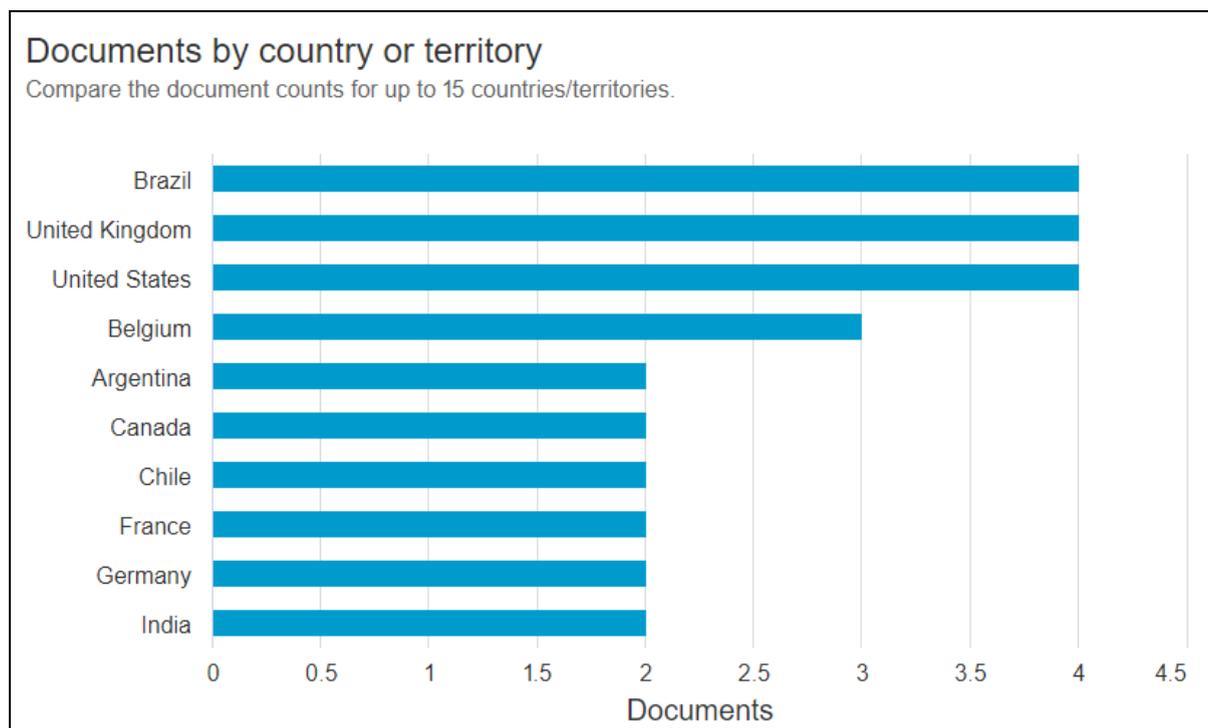
Fonte: Scopus (2024)

Em uma análise mais detalhada, avaliando as principais áreas de interesse de pesquisa (Figura 2), mais de 22,7% tratam de publicações na área médica, dado esse previsível, tendo em vista que o objeto de estudo impacta massivamente o setor de saúde. A área envolvendo ciência da computação abrange aproximadamente 20% dos trabalhos selecionados, e a área da engenharia segue logo em seguida com 17,3%. Desse modo, é possível atestar que há um nicho maior para ser explorado para a área da computação, engenharia e avaliação de dados.

Figura 2 - Distribuição de publicações por área do conhecimento.

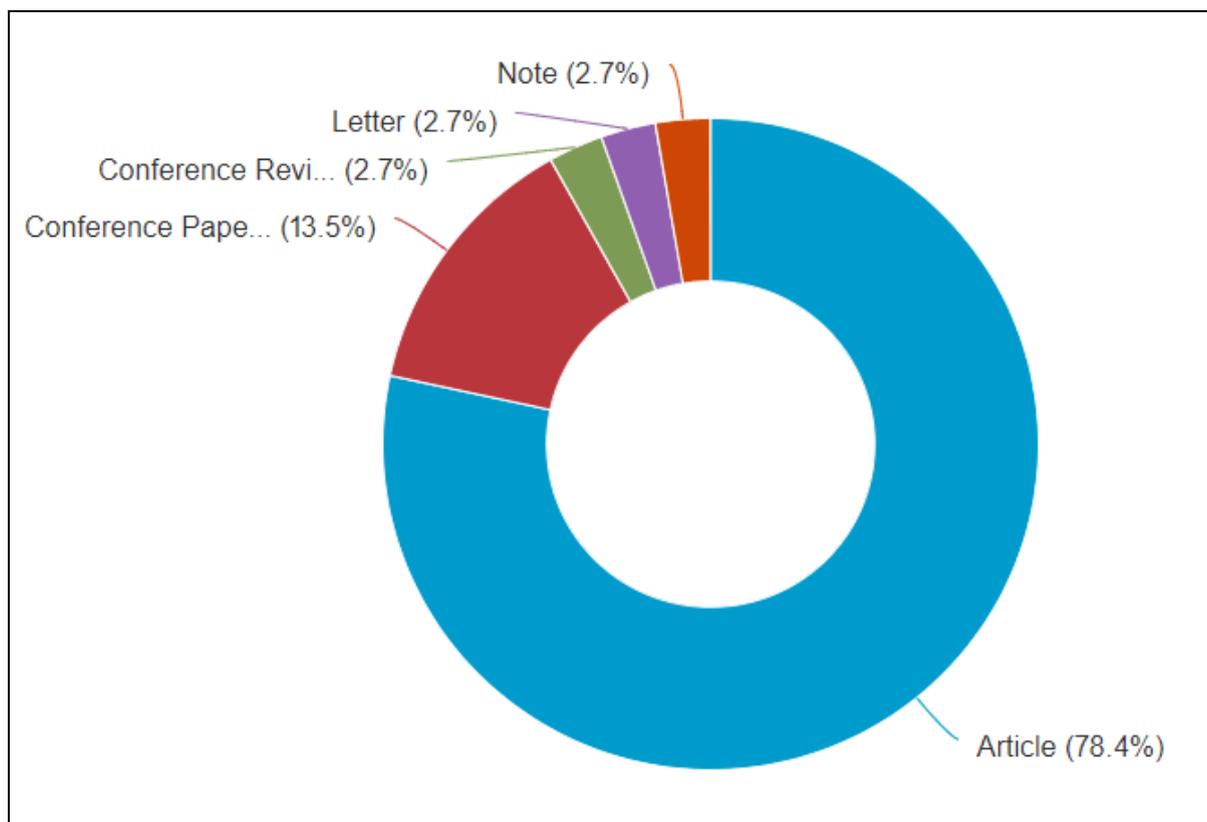
Fonte: Scopus (2024)

Com relação aos locais que mais publicam sobre o tema (Figura 3), Brasil, Estados Unidos e Reino Unido lideram o ranking com quatro publicações. Esse dado mostra que, embora não exista um ritmo numericamente expressivo de publicações, há um interesse nacional por essa temática, de maneira similar a encontrada em grandes nações desenvolvidas que despendem alto investimento em saúde.

Figura 3 - Distribuição de publicações por países.

Fonte: Scopus (2024)

Com relação ao impacto das publicações, há uma expressividade de artigos científicos sobre essa temática, cerca de 78,4% dos documentos apresentados (Figura 4), enquanto 13,5% são artigos de congresso e 2,7% artigos de congresso de revisão. Isso destaca a relevância e originalidade das produções acerca do tema pesquisado.

Figura 4 - Distribuição de publicações pelo tipo.

Fonte: Scopus (2024)

Após a realização dessa análise sistemática, é possível atestar a relevância da temática que será abordada neste trabalho perante dados acadêmicos. Muito embora não haja uma expressividade significativa de publicações acerca do tema, é possível notar um interesse acadêmico, tendo em vista o direcionamento de um aumento em potencial de publicações nos próximos anos. Além disso, a análise mostra que utilizar dados de inteligência artificial em regulação e ocupação de leitos é um tema pouco explorado, possibilitando o ineditismo acadêmico e a possibilidade de promoção de uma nova composição científica. A avaliação mais acurada dos trabalhos publicados será apresentada no próximo capítulo deste trabalho, na qual foi realizado um mapeamento sistemático de todos os trabalhos em algumas bases acadêmicas.

Quanto ao impacto para o mercado, esta pesquisa promove uma contribuição secundária. Isso porque melhorando o processo de regulação de leitos, tornando ele mais efetivo, eficiente e eficaz, o sistema público de saúde evolui institucionalmente e tecnologicamente, desse modo, consegue prover uma assistência à saúde de melhor qualidade. Dessa maneira, o setor de saúde privado precisará se articular para conseguir

manter uma parcela do mercado, tendo em vista que o setor público, seu único concorrente, consegue promover uma assistência de melhor qualidade. Por fim, a sociedade está incluída como umas das principais beneficiadas do processo, tendo em vista que este trabalho sugere uma evolução no sistema de regulação de leitos, incluindo no seu processo de trabalho mecanismos inovadores para apoio à tomada de decisão.

1.4 - Estrutura de apresentação do trabalho

A estrutura de apresentação deste trabalho acadêmico consiste em 10 capítulos. O primeiro capítulo intitulado de introdução, elucida a exposição do tema e o problema de pesquisa, assim como há uma seção de justificativa e apresentação dos objetivos do trabalho. O capítulo dois apresenta o mapeamento sistemático da literatura, a fim de transmitir quais os trabalhos correlatos existentes na literatura atual. O terceiro capítulo aborda aspectos relevantes da saúde digital, apresentando desafios e oportunidades no contexto mundial e brasileiro. O capítulo quatro aborda como funciona o processo de regulação de leitos no SUS, com enfoque no Estado do RN. O capítulo cinco se refere à revolução de saúde digital para a área de regulação de leitos no RN com o sistema RegulaRN, apresentando o que levou a sua concepção, como foi estruturada e seus impactos. O capítulo seis menciona a utilização de inteligência artificial na área da saúde, de modo a apontar quais os benefícios e direcionamentos futuros. O capítulo sete apresenta os materiais e métodos, elucidando a caracterização do método que compõe esta pesquisa e o *pipeline* de análise de dados e seleção dos modelos de inteligência artificial utilizados. O capítulo oito apresenta os resultados obtidos nas análises feitas nas bases de dados e desempenho dos modelos de aprendizado de máquina. No capítulo 9, os resultados são devidamente discutidos, principalmente quanto ao impacto na saúde pública, e por fim, o capítulo 10 apresenta as devidas conclusões, limitações e sugestões de trabalhos futuros. A Figura 5 ilustra tematicamente a estrutura do trabalho.

Figura 5 - Ilustração temática da apresentação dos capítulos desta pesquisa



Capítulo 2

Mapeamento Sistemático da Literatura

A regulação de leitos, como já mencionado, é uma atividade crítica na gestão de saúde pública. No Brasil, ganhou ainda mais destaque com a pandemia da COVID-19, em 2020, em meio a necessidade de existirem investimentos tecnológicos que possam apoiar o processo regulatório. Desse modo, a utilização de soluções digitais considerando métodos computacionais inteligentes se faz essencial no sistema de saúde pública, como elemento que poderá garantir maior eficiência no processo. O presente Mapeamento Sistemático da Literatura (MSL) buscou explorar e sintetizar o conhecimento existente e disponível na literatura acerca da utilização de métodos computacionais de inteligência artificial no processo de regulação de leitos para apoiar a tomada de decisão de profissionais de saúde reguladores.

A metodologia deste mapeamento envolveu uma revisão da literatura disponível em bases de dados que realizam publicação de artigos de considerável impacto acadêmico, *Scopus*, *Web of Science*, *Pubmed* e a *Scielo*, utilizando *strings* específicas de busca, com intuito de garantir a inclusão de estudos relevantes. Foram selecionados artigos que abordavam diretamente a utilização de métodos computacionais de inteligência artificial em regulação ou ocupação de leitos. Para a construção do MSL, foram utilizadas as diretrizes de Kitchenham e Charters (2007), as quais apresentam um protocolo que tem sido bastante utilizado na área deste estudo.

Ao final deste mapeamento, esperou-se não apenas identificar se haveria contribuições importantes envolvendo inteligência artificial e regulação de leitos, mas também fornecer informações para pesquisadores e profissionais da área da saúde interessados em implementar abordagens inovadoras para melhorar a regulação de leitos em instituições públicas de saúde.

2.1 - Protocolo do mapeamento sistemático

A primeira etapa realizada para conduzir o mapeamento sistemático da literatura neste estudo foi a definição do protocolo de pesquisa, o qual foi elaborado conforme as diretrizes estabelecidas por Kitchenham e Charters (2007). Essas diretrizes destacam os elementos fundamentais de um protocolo de MSL: a questão de pesquisa, de natureza descritiva, a categorização dos estudos identificados, o uso de termos gerais de busca, os critérios de inclusão e exclusão, e a interpretação dos resultados. Neste MSL, o objetivo consiste em realizar um mapeamento do campo de estudo objetivando oferecer uma visão geral, holística e abrangente dos estudos relacionados ao tema abordado. Ademais, a escolha por realizar um mapeamento sistemático da literatura foi motivada pela indicação de que esta é uma abordagem adequada para pesquisas com poucas evidências na literatura, o que é o caso deste estudo. Desse modo, foi detalhado o desenvolvimento do protocolo de pesquisa, abrangendo os tópicos: questões de pesquisa, processo de pesquisa, seleção de estudos, resultados e análise dos dados.

2.1.1 Questões de pesquisa

As questões de pesquisa elaboradas para nortear a busca por estudos relacionados ao tema principal desta pesquisa consideram a necessidade de evidenciar, cada vez mais, as aplicações de métodos computacionais inteligentes na área da saúde e, especificamente, no campo da regulação de leitos públicos. O Quadro 1 apresenta as duas questões de pesquisa desenvolvidas.

Quadro 1 – Questões de pesquisa da MSL

Questão	Descrição
QP1	Quais estudos existem sobre a utilização de inteligência artificial no processo de regulação em saúde de leitos públicos?
QP2	Quais os principais objetivos existentes, nos estudos encontrados, em utilizar inteligência artificial no processo de regulação em saúde leitos públicos?

2.1.2 Processo de pesquisa

Para iniciar o processo de busca por trabalhos relacionados ao tema deste estudo, foi definida a *string* de busca, apresentada no Quadro 2, com termos que pudessem contemplar as questões de pesquisa.

Quadro 2 – Strings de busca para a MSL

("artificial intelligence" OR "machine learning" OR "computational methods" OR "deep learning") AND ("bed regulation" OR "bed occupancy")

Posteriormente, deu-se início às pesquisas nas bases de dados. Foram escolhidas as bases acadêmicas *Scopus*, *Web of Science*, *Pubmed* e *Scielo*, por serem locais de busca que referenciam trabalhos acadêmicos com alto fator de impacto no mundo todo.

Os filtros utilizados para registrar a pesquisa a fim de encontrar textos que tratassem sobre o tema foram: artigos publicados até o período de 2023, escritos em inglês e em português, publicados em qualquer área do conhecimento. O Quadro 3 apresenta a quantidade de artigos retornados em cada base de pesquisa, de acordo com a *string* utilizada.

Quadro 3 – Bases utilizadas e quantidade de artigos retornados

Base	Artigos retornados
<i>Scopus</i>	37 artigos
<i>Web of Science</i>	23 artigos
<i>Pubmed</i>	12 artigos
<i>Scielo</i>	Não retornou nenhum artigo

Após a pesquisa nas bases escolhidas foram retornados 72 artigos. Organizou-se os artigos retornados para cumprimento de duas etapas. Na primeira considerou-se os artigos de maneira mais geral, fazendo-se uma pré-seleção. Essa pré-seleção foi feita de acordo com os três critérios de inclusão, apresentados no Quadro 4, após a leitura do título, do resumo e das palavras chaves, com o intuito de excluir trabalhos que não apresentassem os termos associados diretamente ao tema de investigação deste mapeamento sistemático.

Quadro 4 - Critérios de inclusão desenvolvidos

- I1. Artigos publicados em periódicos ou conferência *Open Acess*.
- I2. Artigos publicados até 2023.

I3. Artigos que mencionassem no título, no resumo ou nas palavras-chave os termos da *string* de busca: ("*artificial intelligence*" OR "*machine learning*" OR "*computational methods*" OR "*deep learning*") AND ("*bed regulation*" OR "*bed occupancy*").

Na segunda fase, chamada de seleção, após a leitura dos trabalhos pelo título e resumo, aplicação dos critérios de inclusão (Quadro 5) e aplicação dos critérios de exclusão (Quadro 6), foram considerados apenas sete trabalhos para a realização da leitura integral dos artigos.

Quadro 5 – Bases e artigos selecionados após a aplicação dos critérios de inclusão

Base	Artigos retornados
<i>Scopus</i>	28 artigos
<i>Web of Science</i>	19 artigos
<i>Pubmed</i>	3 artigos
<i>Scielo</i>	Não retornou nenhum artigo

Quadro 6 – Critérios de exclusão

E1. Estudos que não atendem os critérios de inclusão.	22
E2. Estudos duplicados.	9
E3. Estudos que não fosse possível acessar o texto completo.	9
E4. Estudos/pesquisas que não contemplem o tema pesquisado.	24

Realizando a leitura dos oito artigos selecionados, após todo o método de seleção aplicado, analisou-se que o trabalho de Cuadrado et al. 2023 aborda a utilização de modelos de inteligência artificial exclusivamente para previsão do tempo necessário para altas hospitalares, assim, o principal objetivo do trabalho consiste em desenvolver um modelo híbrido que combine previsões de tempo de permanência e dias de altas. Além disso, a pesquisa não deixa claro se os dados utilizados envolvem hospitais públicos ou particulares dos Estados Unidos. Dentre as limitações do estudo, a utilização da abordagem híbrida exigindo a combinação de modelos para alcançar os seus objetivos, assim como, utilizou dados no período de 2014 a 2015, o que pode não refletir mais a atual necessidade do local avaliado.

A pesquisa de Mahmoudian, Nemati e Safaei (2023) utiliza modelos de inteligência artificial em dados de um único hospital público do Irã para prever a capacidade de leitos

hospitalares, objetivando incluir o quantitativo de pacientes hospitalizados e o tempo de internação, contudo, a utilidade da aplicação não possui relação direta com o processo de regulação de leitos e classificação de desfecho hospitalar.

O trabalho elaborado por Wang et al. (2023) objetiva a realização de previsão de admissão em leitos em um hospital de Pequim, China. A abordagem utiliza previsões do tempo de permanência para otimizar a alocação de leitos hospitalares de maneira mais eficiente. Contudo, a pesquisa não é articulada em leitos públicos e é focada em leitos eletivos, isto é, quando há agendamento. Ademais, uma das limitações apresentadas neste trabalho é a disponibilidade apenas de variáveis bastante específicas para a aplicação, não incluindo outras características que poderiam melhorar o desempenho do modelo.

O artigo de Bouhamed, Hamdi e Gargouri (2022) utilizou dados de 15 países diferentes para elaborar um modelo de previsão para estimar a ocupação de leitos. E desse modo, possibilitar que os tomadores de decisões responsáveis pudessem alocar leitos e recursos disponíveis durante a pandemia de COVID-19. Uma das limitações do trabalho é que utilizou dados apenas no período de contaminação da Ômicron, o que pode não possibilitar a mesma reprodutibilidade em outras variantes.

De maneira similar, o trabalho de Valente, Roiati e Pugliese (2022) também utilizou dados da COVID-19 para previsão de ocupação hospitalar, no entanto, o foco do trabalho era realizar previsões de disponibilidade de leitos com base em dados de mobilidade e não exclusivamente dados de fontes hospitalares.

O trabalho de Schiele, Koperna e Brunner (2021) objetiva desenvolver um modelo de previsão para a ocupação de leitos em unidades de terapia intensiva para auxiliar no agendamento integrado de salas cirúrgicas em um hospital terciário da Alemanha, bem como, analisar o impacto desse processo nos demais setores. De modo geral, é possível identificar uma diferença de proposta com o que é apontado por esta tese. De maneira similar, os trabalhos de Souza Junior et al. (2021) e Kutafina et al (2019) buscam prever a ocupação de leitos em um hospital, brasileiro e alemão, respectivamente.

É possível identificar similaridade entre os trabalhos de Souza Junior et al. (2021), Valente, Roiati e Pugliesi (2022) e Bouhamed, Hamdi e Gargouri (2022) por terem objetivos de aplicação em dados da COVID-19. Isso demonstra que há um direcionamento científico em utilizar métodos computacionais inteligentes nos dados obtidos durante a pandemia, concordando com o que foi elaborado por Barreto et al. (2023), artigo fruto desta tese. Ademais, os artigos de Kutafina et al. (2019), Schiele, Koperna e Brunner (2021), Wang et al. (2023), Mahmoudian, Nemati e Safaei (2023) e Cuadrado et al. (2023) possuem o

direcionamento comum consistindo em elaborar métodos para prever ou otimizar a ocupação de leitos hospitalares em diferentes aspectos. Por fim, todos os trabalhos apresentam estratégia de regressão para análise de dados, diferenciando do que é proposto por esta tese.

Assim, é possível confirmar que os trabalhos correlatos encontrados na literatura possuem delineamento e objetivos mais voltados para o processo de previsão de disponibilidade ou ocupação de leitos, tornando-os diferentes com o que é proposto neste trabalho. O Quadro 7 apresenta informações mais detalhadas dos trabalhos correlatos.

2.1.3 Resultados do mapeamento sistemático

No início da busca por trabalhos correlatos, foram retornados, nas bases acadêmicas escolhidas, 72 artigos, após a aplicação dos critérios de inclusão e exclusão, foram selecionados, dos 72, apenas 8. Posteriormente, realizando a leitura completa dos 8 artigos selecionados, foi possível identificar que nenhum dos trabalhos presentes na literatura aborda sistematicamente a utilização de modelos computacionais de inteligência artificial na regulação de leitos públicos hospitalares para previsão de desfecho. O único registro possível com base na pesquisa elaborada é um dos artigos fruto deste trabalho publicado por Barreto et al. (2023). Sendo assim, há poucas contribuições acadêmicas que abordam esse tema, e desse modo, este trabalho pretende contribuir academicamente com uma pesquisa voltada para a área inteligência artificial direcionada a área de regulação de leitos públicos. Além disso, as perguntas de pesquisas que foram norteadoras para a MSL ficam em aberto para serem respondidas conforme a apresentação dos resultados deste trabalho acadêmico.

Quadro 7 - Apresentação de informações dos trabalhos correlatos

Autor	País de publicação	Objetivo	Abordagem		Modelos utilizados	Métricas utilizadas
			Classificação	Regressão		
Cuadrado et al. 2023	Espanha	Melhorar a previsão de alta utilizando inteligência artificial		X	Random Forest, XGBoost e lightGBM	RMSE e MAE
Mahmoudian, Nemati e	Irã	Realizar a previsão da capacidade de leitos		X	Bayesian network, K-nearest neighbor,	RMSE

Safaei. 2023		hospitalares utilizando <i>machine learning</i> e <i>deep learning</i> a partir do tempo de internação.			Support vector machine, Decision Tree, e Regressão Linear	
Wang et al. 2023	China	Melhorar a previsão de alta de pacientes para otimizar os custos com internação.		X	Regressão Linear, Regressão Ridge, Regressão LASSO, Random Forest, XGBoost e LightGBM.	RMSE, teste KS, teste BP e teste HD.
Bouha med, Hamdi e Gargouri. 2022	Tunísia	Previsão de ocupação de leitos durante a COVID-19		X	SRNN, LSTM e GRU	R2 Score
Valente, Roiati e Pugliese. 2022	Itália	Prever a disponibilidade de leitos durante a COVID-19.		X	LSTM e LSTM bidirecional	RMSE e MAE
Schiele, Kopern a e Brunner 2021	Alemanha	Previsão de ocupação de leitos em agendamento cirurgico.		X	Redes neurais, Random Forest, Decision Tree, K-nearest neighbor e Support Vector Machine	RMSE
Souza Junior et al., 2021	Brasil	Previsão de ocupação de leitos		X	Redes neurais	Precisão
Kutafina et al. 2019	Alemanha	Prever ocupação de leitos		X	Nonlinear Autoregressive Model with Exogenous Terms (NARX)	RMSE, MAE, MAPE, GE e MAX

Capítulo 3

Saúde Digital: Desafios e Oportunidades

No contexto da saúde, um tema que vem ganhando cada vez mais espaço é a inclusão de mecanismos informativos digitais e sistemas de informação dentro da assistência em saúde. Isso porque investir cada vez mais em sistemas de informação eficientes aprimora a qualidade da assistência ao permitir a coleta, análise e uso de dados médicos e de pacientes com mais qualidade, segurança, fidedignidade e em tempo real. Desse modo, esses sistemas possibilitam uma melhor coordenação dos cuidados de saúde, garantindo, não somente, que os profissionais tenham acesso a informações precisas, mas também que todo o ecossistema de saúde tenha uma compreensão ampla dos principais gargalos que acometem uma determinada região (Mathews et al. 2019; Fatehi; Samadbeik; Kazemi, 2020 Chen; Wang, 2023).

De uma maneira geral, a saúde digital pode ser definida como uso de tecnologias de informação e comunicação para melhorar a saúde humana, os serviços de saúde e o bem-estar de indivíduos e populações (Kostkova, 2015). O conceito de saúde digital abrange um conjunto muito amplo de representações e tecnologias científicas, incluindo genômica, sistemas informação para saúde, inteligência artificial, dispositivos vestíveis, aplicações móveis, análise preditiva com *big data*, telemedicina e telessaúde (Labrique et al., 2018; Mathews et al., 2019; Modolo; Carvalho; Dias, 2023). Assim sendo, para que seja possível realizar uma contínua integração entre diferentes plataformas, sistemas, arquiteturas e bases de dados é necessário que haja uma ampla articulação envolvendo diversas instituições para integrar e interoperar as várias ferramentas existentes. Todavia, para regiões que possuem uma alta variabilidade de sistemas distintos, desenvolvidos em arquiteturas e projetos diferentes, com modelos ultrapassados, esse processo de integração e interoperabilidade para a digitalização da saúde pode ser um grande desafio (Iroju et al. 2013; Lehne et al., 2019; Neto; Coelho, 2019; Oemig; Blobel, 2022).

Dentre os problemas mais comuns enfrentados pelo processo de digitalização da saúde encontram-se: problema de integração entre diferentes plataformas; falta de

regulamentação adequada para orquestrar a digitalização da saúde; dificuldade em manter a transparência dos dados dos pacientes com segurança; aumento da desigualdade social da população com menos recurso e dificuldade de colaboração multidisciplinar entre cientistas da computação e profissionais de saúde para criar soluções efetivas (Kostkova, 2015; Mathews et al., 2019; Alami; Gagnon; Fortin, 2017; Brewer et al., 2020). E para setores de saúde pública, em que geralmente os recursos são mais escassos, surgem outros agravantes como a limitação de cooperação entre setor público e privado, falta de autofinanciamento sustentável e resistência à adoção e integração dessas tecnologias nos sistemas de saúde, mesmo em países desenvolvidos (Kotenko; Bohnhardt, 2021; Gunazekeran et al., 2021; Parajuli et al., 2022).

No Brasil, um estudo realizado por Cruz et al. (2020) acerca da avaliação da maturidade da saúde digital no país aponta que nos eixos avaliados: liderança; estratégia e investimento; legislação, política e normas; recursos humanos; padrões e interoperabilidade; infraestrutura; serviços e aplicações; e cidadania, sustentabilidade e economia do conhecimento, há maior nível de maturidade no eixo de recursos humanos, mostrando que no país há mão de obra suficiente para evolução digital, mas apresenta incipiência nos eixos de estratégia e investimentos, mostrando que é um país carente de investimentos, similar a outros no mundo, assim como, também é incipiente quanto ao padrão de interoperabilidade e principalmente em questões que envolve cidadania, inclusão e acessibilidade. Ressalta-se que essa fragilidade é ainda maior no setor de Atenção Primária em Saúde, visto que os maiores investimentos são focados em média e alta complexidade (Cruz; Lopes e Pisa, 2021).

Dentre as iniciativas realizadas pelo Brasil, a principal delas se refere à Estratégia de Saúde Digital para o Brasil 2020-2028 (ESD28) que envolve um conjunto de planos de ações, vinculados a diversas instituições do Governo Federal associadas ao Ministério da Saúde para fortalecer a digitalização em saúde do país. As sete prioridades proposta no plano de ação envolvem: I) governança e liderança para a ESD; II) informatização dos três níveis de atenção; III) suporte à melhoria da atenção à saúde; IV) usuário como protagonista; V) formação e capacitação de recursos humanos; VI) ambiente de interconectividade e VII) ecossistema de inovação (Brasil, 2020a; Souza-Zinader, 2020; Moura-Junior, 2021; Barbalho et al., 2022; Barbalho et al., 2023).

Um dos programas que está associado a essa iniciativa é o Meu SUS Digital (anteriormente conhecido como Conecte SUS), coordenado pelo DATASUS (Departamento de Informática do SUS) com objetivo de informatizar a atenção à saúde e integrar estabelecimentos de saúde públicos e privados, órgãos de gestão em saúde e entes federados,

garantindo o acesso à informação em saúde necessária para continuidade do cuidado do cidadão. Nesse sentido, o Conecte SUS possui vários objetivos, conforme descritos nos incisos I ao IV do 2º Artigo da Portaria nº 1434 de 28 de maio de 2020, a saber: I) implantar a Rede Nacional de Dados em Saúde (RNDS); II) apoiar a informatização dos estabelecimentos de saúde que compõem os pontos de atenção à saúde, iniciando pela Atenção Primária à Saúde; III) promover o acesso do cidadão, dos estabelecimentos de saúde, dos profissionais de saúde e dos gestores de saúde às informações em saúde por meio de plataforma móvel e de serviços digitais do Ministério da Saúde e IV) implementar outras iniciativas para a consecução das finalidades do Programa Conecte SUS (Brasil, 2020b; Bertotti; Blanchet, 2021; Rachid et al., 2023).

Ainda sobre a RNDS, o artigo 254 institui que será de responsabilidade da RNDS a integração de informações relativas à atenção à saúde, em sua integralidade; vigilância em saúde e gestão em saúde. Ademais, as informações da RNDS poderão ser utilizadas para fins clínicos e assistenciais; epidemiológicos e de vigilância em saúde; estatísticos e de pesquisas; gestão; regulatórios e de subsídio à formulação, à execução, ao monitoramento e à avaliação das políticas de saúde (Brasil, 2020b).

Para garantir o contínuo avanço da saúde digital, seja no Brasil ou no mundo, há a necessidade de se aumentar investimentos nas áreas que podem gerar maiores frutos com a digitalização da saúde. Incentivos governamentais e parceria entre instituições públicas e privadas estão entre os principais elementos para angariar maiores recursos, mas além disso, realizar integração entre plataformas e utilizar mecanismos de inteligência artificial e *big data* como elemento de apoio diagnóstico e de tomada de decisão também é um fator imprescindível (Franco; Gomes, 2017; Rachid et al., 2023). Vale ressaltar que este é um momento não apenas de trazer apenas para o digital tudo aquilo que se mantém em papel dentro das unidades de saúde, mas é uma maneira de fortalecer a saúde pública como um todo, tornando-a agente principal e exemplo maior de assistência à saúde (Lopes; Oliveira; Maia, 2019; Modolo; Carvalho; Dias, 2023; Boni; Falcão; Murtinho, 2023).

No próximo capítulo abordaremos o cenário de saúde a qual esse trabalho está associado, apresentando os principais aspectos sobre regulação de leitos com enfoque no Estado do Rio Grande do Norte. No capítulo seguinte, abordaremos de maneira mais aprofundada o sistema RegulaRN que consolidou a compreensão de saúde digital dentro da área de regulação de leitos no RN.

Capítulo 4

Regulação de Leitos no Sistema Único de Saúde

O processo de regulação é um condicionante indispensável dentro do serviço público, isso porque, cai sobre ele a responsabilidade de gerir e controlar decisões de cunho público a fim de garantir o melhor bem-estar dos interesses sociais/institucionais e o correto desempenho das normativas públicas com os recursos corretos (Bastos et al., 2020).

Na área da saúde, o processo de regulação no Brasil é importante para a condução correta do acesso ao nível de atenção especializada, prezando pela garantia da Lei nº 8.080/1990 que estabelece a universalidade do acesso aos diferentes serviços de saúde em todos os níveis, integralidade, igualdade, direito à informação, divulgação de informações quanto ao potencial dos serviços, descentralização político administrativa, conjugação dos recursos financeiros, tecnológicos, materiais e humanos (Brasil, 1990; Bezerra, 2023).

Em 2008, a Política Nacional de Regulação do Sistema Único de Saúde foi estabelecida por meio da Portaria nº 1.559 e consolidada pela Portaria nº 02/2017. A Portaria nº 02/2017, no inciso três do artigo dois, relata que são objetos da regulação do acesso a organização, o controle, o gerenciamento e a priorização do acesso e dos fluxos assistenciais no âmbito do SUS, e como sujeitos, seus respectivos gestores, sendo estabelecida pelo complexo de regulação abrangendo a regulação médica, esta que possui autoridade sanitária para garantir o acesso com base em protocolos, classificação de risco e demais critérios de priorização (Brasil, 2017; Bezerra, 2023).

Desse modo, os mecanismos de regulação são estruturados em complexos e centrais de regulação, que atuam como principal orquestrador entre as necessidades do SUS, formando uma rede estadual integrada, entre as centrais de internação, consultas, exames especializados, cirurgias eletivas, urgência e várias outras (Bastos et al., 2020). Além disso, o processo de regulação consiste em uma ação de nível de gestão com atuação direta no setor assistencial, isto é, há uma ligação linear entre os dois setores extremos da saúde. Desse modo, por envolver interesses do serviço público, dos setores privados contratualizados, dos profissionais envolvidos e pacientes, há uma complexidade incessante para com a sua gestão (Gawryszewski; Oliveira; Gomes, 2012; Barbosa; Guimarães, 2021).

Em regulação assistencial de leitos, principalmente na realidade do Rio Grande do Norte, há o papel de três atores fundamentais, além da figura do regulador, responsável por direcionar as regulações, possuem também as unidades que solicitam um leito e as unidades prestadoras do leito. Na grande maioria dos casos, a unidade que realiza a solicitação é uma unidade assistencial com menos recursos ou infraestrutura e não possui capacidade de realizar a internação, em outros casos, pode ser apenas que a demanda de um determinado paciente não seja especialidade daquela determinada unidade de saúde. Já a unidade prestadora, será aquela que irá receber o paciente para internação e irá tratá-la até que a internação tenha um desfecho.

No Rio Grande do Norte, a responsabilidade de conduzir a Política Estadual de Regulação, isto é, o processo de condução de regulação de leitos, é a Central Estadual de Regulação (CER), vinculada à Secretaria de Saúde Pública (SESAP), com o objetivo de organizar as redes e fluxos assistenciais, promovendo acesso equânime, integral e qualificado aos serviços de saúde no Sistema Único de Saúde (Bezerra, 2023).

Atualmente, o RN possui duas centrais estaduais: a central metropolitana, localizada em Natal, e a central-oeste, localizada no município de Mossoró. Levando em consideração a distribuição regional de saúde do RN em oito regiões de saúde (Figura 6). A central metropolitana é responsável por gerir a 1^o, 3^a, 4^a, 5^a e 7^a região (totalizando 104 municípios e uma população 2,6 milhões de habitantes), já a central oeste é responsável por gerir a 2^a, 6^a e 8^a (com cerca de 63 municípios e cerca de 901 mil habitantes).

Capítulo 5

Revolução Digital na Regulação de Leitos do RN: O RegulaRN

Este capítulo apresenta maiores detalhes a respeito da plataforma de regulação de leitos adotada pelo RN, o RegulaRN, inicialmente apresentando o ecossistema a qual a plataforma está inserida e em seguida abordando detalhes sobre a plataforma. O sistema surgiu a partir da necessidade da central de regulação do estado obter informações a respeito da situação dos seus leitos em tempo real durante o período da pandemia de COVID-19. Até então o SISREG, sistema de regulação criado em 2001 e fornecido pelo Ministério da Saúde, era uma das ferramentas disponíveis, contudo, devido às suas limitações, obsolescência, indisponibilidade de integrações e ausência de transparência, não atendia as necessidades da central de regulação (Cordeiro, 2015; Moreira-Junior; Souza-Junior, 2024). Após adoção do RegulaRN para regulação de pacientes COVID-19, houve a expansão da plataforma para regulação de leitos gerais, regulação ambulatorial e cirurgias vasculares. Para este trabalho, serão abordados aspectos gerais do RegulaRN COVID-19 e RegulaRN Leitos Gerais.

5.1 - Ecossistema tecnológico de combate à COVID-19

O ecossistema tecnológico de combate à COVID-19 do Rio Grande do Norte foi criado em resposta ao surgimento da pandemia no Estado, a partir da necessidade de adaptar os sistemas de saúde para lidar com a crise sanitária. Em 2020, o governo, em parceria com SESAP, UFRN, LAIS, Núcleo de Estudos de Saúde Coletiva da UFRN (NESC), o Núcleo Avançado de Inovação Tecnológica (NAVI) do Instituto Federal de Educação, Ciência e Tecnologia do Rio Grande do Norte (IFRN) e o corpo executivo da Secretaria Municipal de Saúde de Natal (SMS/ Natal), desenvolveram um ecossistema digital que integra diferentes sistemas de informação em saúde (Valentim et al., 2021).

O principal objetivo era fortalecer a capacidade de monitoramento, controle e tomada de decisão, unindo vigilância epidemiológica, gestão hospitalar e comunicação com a sociedade. Além disso, o ecossistema buscava proporcionar maior transparência e eficiência

na gestão dos recursos hospitalares, especialmente os leitos de UTI, fundamentais para o atendimento aos pacientes mais graves (Valentim et al., 2021).

Ao todo foram elaboradas 13 plataformas para o combate à COVID-19, todavia neste trabalho será considerado apenas o RegulaRN. O RegulaRN é uma plataforma que gerencia a alocação e a regulação dos leitos hospitalares, especialmente os destinados ao tratamento da COVID-19. Integrado a sistemas nacionais como o e-SUS Notifica, o RegulaRN desempenhou um papel decisivo ao garantir que a ocupação dos leitos ocorresse de maneira transparente e ágil, atendendo às necessidades em tempo real (Valentim et al., 2021).

A plataforma possibilitou o acompanhamento da disponibilidade de leitos e a gestão eficiente de novos pacientes, evitando o colapso do sistema de saúde. Com isso, o ecossistema e o RegulaRN atuaram como ferramentas centrais na mitigação dos impactos da pandemia, permitindo uma resposta rápida e integrada que beneficiou tanto os gestores de saúde quanto a população em geral. Nas próximas seções serão detalhadas com mais profundidade aspectos do RegulaRN e principalmente seus desdobramentos para atender não somente a COVID-19, mas também as demais necessidades do RN.

5.2 - RegulaRN COVID-19

A plataforma RegulaRN COVID-19 foi desenvolvida durante o início do período da pandemia de COVID-19. A plataforma foi elaborada a partir de uma cooperação técnico-científica entre a Secretaria de Saúde Pública do Rio Grande do Norte, Laboratório de Inovação Tecnológica em Saúde (LAIS) e o Núcleo Técnico-científico de Telessaúde do Rio Grande do Norte. Até então, as centrais de regulação de leitos do RN não possuíam sistemas informatizados para articular a gestão de leitos no âmbito do SUS. Os métodos utilizados até então, eram controles de solicitações e internações realizados em planilhas eletrônicas, e-mails e contato telefônico (Valentim et al. 2021; Bezerra, 2023; Andrade, 2023).

Nos primeiros meses de contaminação da COVID-19 (entre de dezembro de 2019 até março de 2020), o cenário mundial apresentava um grande tensionamento nos serviços de saúde, para que eles se adequassem com melhores infraestruturas, equipamentos e profissionais para potencializar a qualidade assistencial frente ao grande número de pacientes que precisariam de internação. Para a maioria dos estados brasileiros, com destaque aos estados do nordeste, as perspectivas eram muito negativas, isso porque, historicamente, o sistema de saúde pública já passava por problemas de menor disposição assistencial e

infraestrutura (Lino et al., 2020; Cotrim-Junior et al., 2020). Desse modo, além da necessidade de ter-se maior investimento na contratação de novos profissionais de saúde, oferta de leitos, transportes sanitários e infraestrutura hospitalar, o sistema regulatório deveria ser potencializado. Foi nesse cenário que, em abril de 2020, surgiu o RegulaRN, a primeira plataforma de regulação de leitos voltada para atender a regulação do acesso de solicitações COVID-19 no Estado do RN.

Vale salientar que a ampla adesão da plataforma entre os municípios envolvidos se deu principalmente pela cooperação do governo do estado em recomendar fortemente a utilização da ferramenta, assim como, o apoio de instituições de controle como o Ministério Público Federal (MPF/RN) e Ministério Público Estadual (MP/RN). A recomendação dessas instituições induziu o engajamento de todos os 167 municípios, tornando a implantação mais célere e eficiente (Valentim et al., 2021, Andrade, 2023).

Dessa maneira, o RegulaRN foi uma ferramenta importante para uma condução positiva, frente ao governo do estado, para enfrentamento da COVID-19. O monitoramento dos leitos era realizado em tempo real, e a partir da sala pública de situação (https://regulacao.saude.rn.gov.br/sala-situacao/sala_publica/), foi dada a devida publicidade e transparência ao processo regulatório. A sala de situação do RegulaRN foi reformulada ao longo da sua utilização, atendendo às diferentes demandas que surgiam no decorrer da pandemia. Ao todo foram elaborados 27 parâmetros interativos que contam a história da pandemia no RN. O Quadro 8 apresenta quais indicadores foram elaborados, com suas respectivas descrições.

Quadro 8 - Indicadores e descrições do RegulaRN COVID-19

Indicador	Descrição
Número de vidas salvas, leitos críticos e leitos clínicos	Acumulado de vidas salvas e quantitativo de leitos, sejam disponíveis, bloqueados ou ocupados; do tipo crítico ou clínico.
Rotas das Regulações	Representação do mapa do estado do RN com a origem dos pacientes e seu respectivo destino, além do tempo médio de transferência entre estabelecimentos solicitante e prestador.
Pacientes na lista de regulação	Gráfico de barras apresenta o total de pacientes que aguardam avaliação da central de regulação e aceite do

	prestador de leito, além do total de pacientes que se encontram à espera do transporte.
Série histórica das solicitações por leitos covid-19	Quantitativo de solicitações de leitos covid-19 realizadas ao longo do tempo.
Série Histórica das Solicitações Canceladas por Motivo	Quantitativo de solicitações canceladas e classificadas pelo motivo.
Série Histórica do Total de Liberação de Leito por Motivo	Quantitativo de liberações de leitos classificadas pelo motivo.
Tempo médio de classificação, regulação e transferência	Apresenta o tempo médio que um paciente deve levar em cada etapa do fluxo de regulação de leito.
Total de internações, regulações e ocupações diretas	Quantidade de internações de pacientes, seja através de ocupação direta ou obedecendo o fluxo normal de regulação.
Série história de hospitalizações <i>versus</i> disponibilizações	Gráfico de linhas exibindo a relação entre a disponibilidade de leitos e o número de hospitalizações, em virtude de ocorrência de alta, óbito do paciente, ao longo do tempo.
Série Histórica das Regulações por Tipo de Leito	Quantitativo de regulações classificadas por tipo de leito.
Taxa de Ocupação dos Leitos Críticos por Prestador	Indica o percentual de ocupação de leitos críticos por prestador
Taxa de ocupação dos leitos de críticos por região	Indica a taxa de ocupação dos leitos críticos, dispostos por região de saúde e prestador.
Total de Solicitações Canceladas por Motivo	Quantitativo total de solicitações canceladas dispostas pelo motivo.
Série Histórica da Taxa de Ocupação dos Leitos Críticos por Região	Gráfico de linhas exibindo a relação da taxa de ocupação por região.

Série Histórica da Taxa de Ocupação dos Leitos Críticos por Prestador	Gráfico de linhas exibindo a relação entre a taxa de ocupação e o prestador.
Série Histórica do Total de Leitos Críticos Bloqueados por Região	Gráfico de linhas exibindo a relação histórica do número de leitos bloqueados por região.
Série Histórica do Total de Leitos Críticos Bloqueados por Prestador	Gráfico de linhas exibindo a relação histórica do número de leitos bloqueados por prestador.
Leitos Críticos por Prestador	Quantitativo de leitos críticos agrupado por prestador.
Tempo de Avaliação da Indicação de Prestador	Gráfico em colunas apresentando o tempo médio entre a regulação indicar o paciente e o prestador avaliar.
Total de Indicações de Pacientes com Situação EXPIRADA	Gráfico em colunas apresentando o quantitativo de pacientes com solicitação expirada, por prestador.
Leitos Críticos Inativados por Prestador	Gráfico em colunas apresentando o quantitativo de leitos inativos por prestador.
Tempo Médio de Internação em Leitos Críticos	Gráfico em colunas apresentando o tempo médio de internação em leitos críticos estruturados pelo desfecho.
Tempo Médio de Internação em Leitos Críticos por Faixa Etária	Gráfico em colunas apresentando o tempo médio de internação em leito crítico por faixa etária. Além disso, o gráfico separa por alta e óbito.
Distribuição por Motivo de Bloqueio para Leitos Críticos	Gráfico em pizza apresentando o quantitativo de leitos críticos bloqueados e seus respectivos motivos.
Série Histórica dos leitos Críticos Operacionais	Gráfico em linhas apresentando o quantitativo de leitos críticos operacionais ao longo do tempo.
Série Histórica dos Leitos Críticos Operacionais por Prestador	Gráfico em linhas apresentando o quantitativo de leitos críticos operacionais, divididos por prestador, ao longo do tempo.
Percentual de Ocupação de Leitos Críticos por Grupo	Gráfico em colunas apresentando o percentual de ocupação de leitos críticos por grupo etário, dividido por

Etário	idoso e não idoso.
--------	--------------------

5.3 - RegulaRN Leitos Gerais

O RegulaRN Leitos Gerais surgiu a partir da necessidade de ampliar o sistema de regulação criado no contexto da COVID-19 para as demais doenças existentes. Isto é, o RegulaRN Leitos Gerais foi uma expansão do RegulaRN COVID-19 para todas as necessidades de regulação de leitos do Estado. A plataforma foi inaugurada em setembro de 2021 e as novidades trazidas por essa nova aplicação foram: inclusão do fluxo de regulação neonatal; inclusão do fluxo de regulação vascular, este que envolvia diversas particularidades; divisão de tipos de leitos em adulto, pediátrico e neonatal; nova aba de solicitação para pacientes com COVID-19 e divisão dos leitos por sexo e faixa etária.

Na etapa inicial de implantação da plataforma RegulaRN Leitos Gerais, os principais indicadores da sala pública foram os mesmos utilizados na plataforma COVID-19 (conforme mostrado no Quadro 8), no entanto, houve uma reformulação da sala de situação apresentando informações mais objetivas e assertivas. O Quadro 9 ilustra os indicadores do RegulaRN Leitos Gerais.

Quadro 9 - Indicadores e descrições do RegulaRN Leitos Gerais

Indicador	Descrição
Número de Leitos Cadastrados	Número de leitos cadastrados divididos por regiões de saúde e nas categorias adulto, pediátrico e neonatal.
Número de Leitos por Tipo	Números de leitos categorizados como adulto, pediátrico e neonatal, e cada um subdividido em Enfermaria e UTI.
Número de leitos por hospitais prestadores	Número de leitos por hospitais prestadores, subdivididos em Enfermaria e UTI.
Ocupação de leitos por CID e região de saúde	Número de ocupações em leitos de Enfermaria e UTI por regiões de saúde de acordo com um determinado CID
Ocupação de leitos por CID e município	Número de ocupações em leitos de Enfermaria e UTI por município de acordo com um determinado CID

Incidência de doença nos pacientes internados	Taxa de incidência das dezenove doenças mais prevalentes de acordo com o CID
Série histórica de regulações	Série histórica do total de solicitações de regulação divididas por meses e pelas classificações adulto, pediátrico e neonatal.

Capítulo 6

Inteligência Artificial em Saúde

A inteligência artificial pode ser definida como o estudo de diferentes agentes que recebem diferentes percepções do ambiente e executam diferentes ações. Cada agente implementa uma funcionalidade que mapeia sequências de percepções em ações tais como sistemas de produção, agentes reativos, planejadores condicionais em tempo real, redes neurais e sistemas de teoria de decisão (Russel; Norvig, 2016).

O primeiro pesquisador a articular uma visão consistente sobre inteligência artificial foi Alan Turing, em 1950 com o seu artigo intitulado *Computing machinery and intelligence*. No artigo ele propôs o teste de Turing, no qual um interrogador deveria interagir com uma outra entidade a partir de perguntas em texto. Passaria no teste de Turing o sistema em que o interrogador não consiga determinar se as respostas vêm de um humano ou computador (Gomes, 2010; Russel; Norvig, 2016; Gonçalves, 2023; Mei et al., 2024).

Ao longo dos anos, métodos computacionais de inteligência artificial começaram a obter algoritmos cada vez mais inovadores, assim como, ganhou popularidade em diversos setores do mundo. Termos como *machine learning*, *deep learning* e *neural networks* começaram a se tornar mais populares nas áreas jurídicas, finanças, comércio, comunicação, educação, gestão, saúde e em várias outras (Tang et al, 2023; Li et al., 2023; Dhillon; Sing, 2019; Dun; Sun; Zhang, 2024).

Na saúde a utilização de inteligência objetiva circunstancialmente a necessidade de sistema de apoio à assistência em seus diferentes níveis, isso porque a utilização de sistemas dessa natureza não só são eficientes para auxiliar profissionais de saúde na tomada de decisão, mas são bastantes precisos na identificação de padrões de doenças, assim, como os provedores assistenciais geram uma grande quantidade de dados e informações heterogêneas diariamente, há uma dificuldade para analisar e processar dados pelos métodos tradicionais de análise de dados (Shailaja et al., 2018; Alanazi, 2023).

De acordo com os trabalhos de Shailaja et al., 2018, e ratificado pelas pesquisas de An et al., 2023 e Alanazi, 2023, as principais contribuições de *machine learning* na área da saúde

são: análise preditiva de dados de saúde, nas quais os modelos podem classificar ou prever determinado resultados específicos; diagnóstico e tratamento, principalmente na área de imagens médicas, em que os modelos auxiliam diagnósticos a partir de imagens de raio x ou tomografia computadorizada; medicina personalizada, na qual é possível analisar tratamentos têm maior probabilidade de serem eficazes para um determinado paciente com base em suas características individuais; suporte à decisão clínica, auxiliando profissionais de saúde a tomar decisões com melhor embasamento; e gestão da saúde populacional, a fim de analisar dados e identificar tendências. Desse modo, é mister para que haja uma constante evolução da assistência médica exista a colaboração entre a saúde e a computação, utilizando mecanismos de aprendizado de máquina de forma ética e responsável atrelado ao trabalho assistencial (An et al., 2023).

Retomando teoricamente termos da aprendizagem de máquina, existe o conceito de aprendizado indutivo, isto é, a possibilidade de inferir de maneira lógica a relação entre um conjunto particular de exemplos. Para o aprendizado indutivo há duas classificações: supervisionado e não supervisionado. Na aprendizagem supervisionada, como o nome já sugere, existe um supervisor responsável por auxiliar o processo de aprendizagem. Em geral, para cada exemplo existe uma rotulagem, e assim sendo, para rótulos de classe discretas, esse problema é denominado classificação e para valores contínuos regressão (Monard, 2003). No contexto deste trabalho, de acordo com os resultados que deseja-se estimar, foram utilizados modelos de classificação. Dessa forma, segue uma súmula dos principais algoritmos de classificação que são trabalhados nesta tese:

- **Decision Tree:** a árvore de decisão utiliza o algoritmo C4.5, na qual suas ramificações vão sendo formadas a partir de uma estratégia de dividir e conquistar. De modo que se todas as instâncias pertencem à mesma classe, ela mantém uma folha com uma determinada classe como o rótulo. No entanto, caso as instâncias não sejam da mesma classe, um método de divisão é utilizado para separar a porcentagem de dados a partir do seu rótulo. A árvore tem como raiz um nó especificando o teste e, para cada resultado por sua vez, a subárvore correspondente é obtida aplicando o mesmo procedimento ao subconjunto de instâncias com esse resultado (Quilan, 1996; Chauhan; Chauhan, 2013).
- **Random Forest:** é um modelo refinado do modelo de árvore única, na qual utiliza-se da randomização para criar um grande número de árvores de decisão. A saída dessas árvores é agregada em uma única saída usando votação para problemas de classificação ou média para problemas de regressão (Rigatti, 2017).

- Perceptron Multicamadas: é um modelo de rede neural, na qual a informação é repassada a partir de neurônios de entrada para um neurônios de saída a partir de uma rede de camadas. Na maioria das aplicações o processo de treinamento do perceptron multicamadas pode ocorrer pela técnica de avanço (*Feedforward*, em inglês) ou retroprogração (*Backpropagation*, em inglês). No primeiro modelo, as informações são repassadas do neurônio anterior para o próximo, sem que haja a possibilidade de retorno. Já no segundo, há uma retroalimentação dos neurônios, de maneira em que cada neurônio calcula a taxa de erro e reajusta os pesos nas camadas (Popescu et al., 2009)
- Gradient Boosting: é um algoritmo da classe dos *ensembles* denominado *boosting*, o qual é utilizado para a previsão de preditores fracos, com o objetivo de produzir um melhor modelo preditivo. Esse algoritmo cria uma corrente de modelos fracos, onde cada um tem como objetivo minimizar o erro do modelo anterior, por meio de uma função de custo, e desse modo melhorar a capacidade de classificação (Friedman, 2002; Fafalios; Tsamardinos, 2020).
- AdaBoost: também é um algoritmo *boosting*, ou seja, também utiliza modelos de aprendizagem fracos para criar um modelo de aprendizagem forte. Ele é um modelo adaptável, no sentido de que as classificações seguintes são ajustadas a favor das instâncias classificadas negativamente por classificações anteriores (Schapire, 2013).
- XGBoost: também está na categoria de *boosting*, e funciona como um algoritmo que apresenta melhor desempenho, quando comparado com outros *ensembles*. Nesse algoritmo foram feitas algumas adaptações para que ele consiga diminuir significativamente a função de perda, possibilitando uma predição mais assertiva (Chen; Guestrin, 2016).

Capítulo 7

Materiais e Métodos

Neste capítulo serão abordados os principais aspectos metodológicos que serviram para o andamento e desenvolvimento desta pesquisa. A primeira parte apresenta a caracterização do método da pesquisa escolhido, com o intuito de demonstrar os principais direcionamentos da literatura acadêmica que foram utilizados para desenvolver este trabalho. Em seguida, é apresentada a visão geral de coleta e análise dos dados, sendo exposto quais decisões foram tomadas para seleção dos dados utilizados. Ao final, foi elaborado um *pipeline* de pré-processamento, definição de modelos de *machine learning* e seleção dos melhores hiperparâmetros.

7.1 - Caracterização do método de pesquisa

A pesquisa científica pode ser compreendida como a atuação incessante de encontrar explicações para fenômenos e acontecimentos que ocorrem no mundo. Nesse sentido, o processo de reflexão e atuação sobre problemas existentes, conforme aponta o contexto da pesquisa científica, está intrinsecamente ligado ao desenvolvimento social. Destacando assim, a necessidade de se manter o investimento e o incentivo nessa atividade, por parte das principais instituições financiadoras (Moresi, 2003; Zanella, 2006; Vilca, 2010).

Nessa perspectiva, a caracterização do método de pesquisa deste trabalho segue as considerações da metodologia da pesquisa encontradas nos trabalhos de Gil (2002), Moresi (2003), Thiollent (2011), Zanella (2006), Wazlawick (2009) e Turrioni e Melo (2012). Quando se trata de pesquisa científica, embora a nomenclatura possa variar de acordo com a obra, substancialmente são encontradas quatro classificações do método da pesquisa, sendo elas: natureza, abordagem, objetivos e métodos. Essencialmente, os ideais de cada uma dessas classificações são explorados em conjunto com a contribuição de outros autores desse segmento.

Quanto à natureza, a pesquisa pode ser dividida em dois segmentos: básica ou aplicada. A pesquisa básica objetiva gerar novos conhecimentos que podem contribuir de maneira útil para o avanço da ciência sem que haja a necessidade de aplicação prática. Já a aplicada considera a geração de conhecimento para aplicação prática relacionada à solução de problemas específicos (Moresi, 2003; Appolinário, 2007; Turrioni e Melo, 2012). Dessa forma, esta pesquisa é caracterizada, quanto à sua natureza, como uma pesquisa aplicada, tendo em vista que os dados dos processos de trabalho da Central Estadual de Regulação foram utilizados em modelos de inteligência artificial com o objetivo de otimizar a tomada de decisão de profissionais de saúde reguladores.

Quanto à abordagem, as pesquisas científicas são classificadas como quantitativa e qualitativa. A pesquisa quantitativa considera que as informações trabalhadas podem ser quantizadas por dados representativos e objetivos, ou seja, analisadas com ferramentas estatísticas. Já a pesquisa qualitativa surgiu a partir da necessidade da comunidade científica atender à subjetividade da avaliação, considerando todo o ambiente em que é avaliado e outros fatores que pudessem estar intrinsecamente relacionados aos resultados. Vale ressaltar que a pesquisa qualitativa não está isenta de dados, isto é, não há ausência de dados e quantificação, contudo, a ênfase do estudo está no indivíduo que está sendo estudado (Mussi et al., 2019; Sampieri; Collado; Lucio, 2013; Cauchick Miguel et al., 2012). Desse modo, esta pesquisa é considerada quantitativa porque nela é realizada uma análise estatística dos dados do RegulaRN, com o intuito de entender o cenário da regulação de leitos no período da pandemia de COVID-19 e após esse período envolvendo os leitos gerais.

Quanto aos objetivos, a pesquisa pode se estruturar em três categorias: descritiva, exploratória e explicativa. A pesquisa descritiva tem como objetivo principal a descrição de características de determinada população, fenômeno ou o estabelecimento de relações entre variáveis. Já a pesquisa exploratória tem como principal objetivo desenvolver, esclarecer e modificar conceitos e ideias, com vistas à formulação de problemas mais precisos ou hipóteses para estudos posteriores. A pesquisa explicativa procura identificar os fatores que contribuem para ocorrência de determinados fenômenos, é um ramo que está mais associado ao aprofundamento do impacto do conhecimento na realidade (Gil, 2002; Caleffe; Moreira, 2006; Lehmann, 2010; Swedberg, 2020). Nesse sentido, esta pesquisa é caracterizada como descritiva porque apresenta com detalhes a descrição populacional dos dados de regulação utilizados, como os dados devidamente se relacionam e os principais impactos gerados, assim como, exploratória por incluir no processo de trabalho de reguladores a utilização de métodos

computacionais que irá favorecer o processo de trabalho e impactará todo o ecossistema de saúde pública.

Quanto aos métodos, ou procedimentos técnicos de uma pesquisa, Gil (2002) classifica-os em dois grupos, relacionando-os de acordo com o procedimento de coleta de dados. O primeiro grupo relaciona os procedimentos que necessitam de fontes de papéis ou arquivos para obtenção de dados, sendo eles a pesquisa bibliográfica e documental. Já no segundo grupo concentram-se as pesquisas experimentais, tais como: a pesquisa *ex-postfacto*, o levantamento, o estudo de caso, pesquisa-ação e pesquisa participante.

Assim, a pesquisa bibliográfica consiste na utilização de material já elaborado, constituído principalmente por livros, artigos científicos ou jornais de publicação periódica e materiais em geral. Essa vertente permite que o investigador possa analisar uma gama de contribuições e ter uma noção mais adequada sobre diferentes posicionamentos de linhas de pesquisas. Já a pesquisa documental é similar a bibliográfica, no entanto, diferem na natureza da fonte; a pesquisa documental não está integralmente direcionada a analisar documentos e materiais que possuam tratamento analítico (Caleffe; Moreira, 2006; Sá-Silva et al., 2009, Kripka; Scheller; Bonotto, 2015; Garcia, 2016; Souza; Oliveira; Alves, 2021).

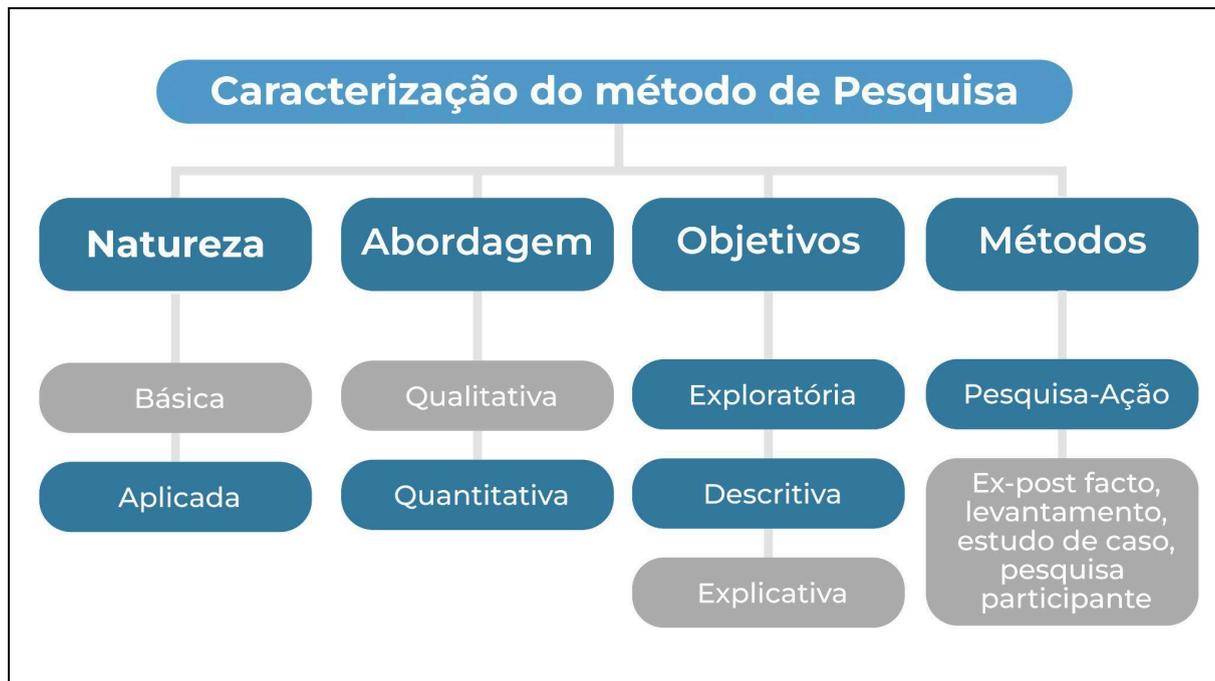
No campo das pesquisas experimentais, há a necessidade de determinar como algumas variantes podem impactar ou produzir um determinado fenômeno. Nesse sentido, a pesquisa *ex-post facto*, que se enquadra entre as pesquisas experimentais, realiza o estudo após a ocorrência de variações na variável dependente no curso natural dos acontecimentos. Para esse tipo de pesquisa o pesquisador não possui controle das variáveis independentes porque o fato já ocorreu, sendo assim, ele irá trabalhar em cima desses resultados a fim de obter alguma resposta (Gil, 2002; Silveira; Córdova, 2009).

Ainda seguindo a linha do campo de pesquisas experimentais, o levantamento caracteriza-se pela interrogação direta das pessoas cujo comportamento se deseja conhecer. Sistemáticamente consiste na obtenção de informações de um grupo estudado e a partir de dados quantitativos obterem conclusões correspondentes. Já o estudo de coorte, relaciona-se com a avaliação de um grupo de indivíduos que possuem alguma característica em comum, constituindo uma amostra para ser acompanhada em um período preestabelecido. Esses estudos podem também ser categorizados como prospectivos: que é elaborado com dados no período presente do estudo; ou retrospectivo: que é desenvolvido com base em dados passados que possam ter repercussão no presente (Gil, 2002; Carvalho; Lopes; 2005; Oliveira; Vellarde; Sá, 2015).

Concluindo com os elementos da pesquisa experimental, o estudo de caso é uma modalidade bastante adotada na área das ciências médicas e sociais. Consiste é um instrumento de raciocínio, reflexão, argumentação e negociação acerca de um determinado caso específico (Camargo, Daros, 2018). Devido a sua flexibilidade de atuação e menor rigor metodológico, muitos pesquisadores condicionam a esse tipo de estudo uma alta possibilidade de viés e baixa reprodutibilidade. No entanto, vale ressaltar que a imputação de viés é possível em qualquer método de pesquisa (Gil, 2002; Ventura, 2007; Martins, 2008 Yin, 2015).

Seguindo com a pesquisa experimental, há a pesquisa-ação, a qual Thiollent (2022) define como um método de pesquisa que envolve a participação do pesquisador em uma problemática social, na qual o pesquisador está imerso no processo. Desse modo, os frutos da pesquisa já podem ser incluídos na atividade social entrelaçando os objetivos da ação e os objetivos do conhecimento. Por fim, há a pesquisa participante que se caracteriza, assim como a pesquisa-ação, pela interação entre pesquisadores e membros a serem investigados, contudo, é importante diferenciá-las: a pesquisa participante associa-se à manutenção do sistema vigente e a pesquisa-ação à manutenção do conhecimento e senso comum (Engel, 2000; Gil, 2002; Tripp, 2005; Thiollent, 2022). Dessa maneira, quanto ao método, esta pesquisa se caracteriza como uma pesquisa-ação, visto que o todo o processo realizado pelo projeto RegulaRN ocorre diretamente com os profissionais de saúde reguladores da SESAP, desde o entendimento de todos os processos regulatórios, assim como formação e extração de novos dados. Além disso, os frutos dessa pesquisa possuem relevante impacto não somente no processo de tomada de decisão dos reguladores, mas também na qualidade da assistência com regulações mais efetivas. A Figura 7 representa estruturalmente a composição dos métodos de pesquisa científica.

Figura 7 - Caracterização do método de pesquisa



7.2 - Método de aplicação da pesquisa

O direcionamento metodológico da aplicação deste trabalho consistiu em duas etapas: a etapa de análise, nas quais os dados foram extraídos de duas plataformas de dados, RegulaRN COVID-19 e RegulaRN Leitos Gerais, em seguida, esses dados foram avaliados, caracterizados, pré-processados e, por fim, correlacionados. A etapa de aplicação nos modelos computacionais, na qual foram elaboradas cinco fases: 1) definição de métricas de avaliação, 2) balanceamento dos dados, 3) segmentação dos dados de treinamento e validação, 4) definição dos modelos para classificação dos dados e 5) definição dos hiperparâmetros para treinamento, consonante ao método proposto por Barreto et al. (2023).

7.2.1 - Extração, avaliação, caracterização e pré-processamento

7.2.1.1 - RegulaRN COVID-19

Ao utilizar duas diferentes bases de dados foi adotada uma análise minuciosa, separada para cada uma das bases de dados utilizadas. A base de dados do RegulaRN COVID-19 foi extraída em 02/08/2022, quando o sistema possuía cerca de 25.366

regulações, considerando as duas centrais regulatórias do estado (Metropolitana e Oeste). Nesse sentido, a extração de dados abrangeu o período de abril de 2020 a agosto de 2022.

A extração dos dados do RegulaRN COVID-19 abrangeu vinte características, sendo elas: a) data de solicitação; b) município do paciente; c) unidade federativa do paciente; d) gestante (sim ou não); e) idade gestacional; f) idade do paciente; g) tipo do caso; h) escore unificado de priorização (EUP); i) se em intubação orotraqueal; j) tipo de leito solicitado; k) data de entrada no leito; l) tipo de leito de entrada; m) data de saída do leito; n) tipo de leito de saída; o) tempo de internação; p) unidade de saúde solicitante; q) município da unidade de saúde solicitante; r) unidade de saúde prestadora; s) município da unidade de saúde prestadora e t) desfecho.

Contudo, de acordo com a análise realizada, foi necessário remover as características que não tinham impacto com o desfecho da internação, isto é, informações que não estavam associadas ao quadro clínico do paciente ou que não se relacionavam com o registro de localidade, sendo elas: data da solicitação; município do paciente; unidade federativa do paciente; gestante (sim ou não), idade gestacional, data de entrada no leito, data de saída do leito, unidade hospitalar solicitante, município da unidade hospitalar solicitante, unidade hospitalar fornecedora e município do hospital fornecedor.

Durante o processo de preparação dos dados, foi realizada uma normalização e padronização das informações. Isso envolveu a eliminação de linhas do banco de dados que apresentavam informações faltantes ou incorretas. Inicialmente, a variável “desfecho” poderia indicar três resultados diferentes: alta, óbito e transferência. No entanto, o status “Transferência” se referia apenas à mudança de um hospital ou leito e não revela o resultado final da internação. Portanto, foram removidas todas as entradas com o desfecho “Transferência” e a análise final foi focada em uma classificação binária de “alta” ou “óbito”. Com essas alterações, 74,37% dos dados iniciais foram mantidos, o que representa 18.865 casos de pacientes internados.

Uma outra consideração importante é que durante o pré-processamento dos dados foi necessário realizar um ajuste na base de dados para que os modelos conseguissem compreender dados categóricos (não numéricos). Desse modo, todas as características que possuíam apenas dois valores possíveis como resposta, como por exemplo “Tipo de Leito” que pode ser segmentado em enfermaria ou UTI, foi realizado o *label encoder*. Esta técnica consiste em converter os valores categóricos em unidades de 0 ou 1 (Scikit-learn, 2024a). Já para características que possuíam mais de dois valores possíveis foi adotada a técnica *one hot encoder*, este que atribui novas colunas à base de dados representada por numeração binária

(Rodrigues et al., 2018; Okada; Ohzeki; Taguchi 2019; Scikit-learn, 2024b). Ademais, para garantir a reprodutibilidade do experimento, o banco de dados com todas as informações pré-processadas está disponível no seguinte repositório: <https://zenodo.org/record/8122564>.

7.2.1.2 - RegulaRN Leitos Gerais - Adulto e Pediátrico

A base de dados do RegulaRN Leitos Gerais contemplou o período de outubro de 2021 a janeiro de 2024, com cerca de 47.056 regulações realizadas nas duas centrais de regulação do estado (Metropolitana e Oeste). Desse total, foi necessário dividir as regulações que estavam associadas aos recém-nascidos das demais que contemplavam o atendimento adulto e pediátrico. Essa divisão foi necessária porque os protocolos de avaliação clínica utilizados possuíam critérios diferentes, não contendo o mesmo rigor regulatório dos outros pacientes. Assim sendo, 1.868 solicitações de regulação de leitos foram avaliadas apenas no contexto neonatal e 45.188 solicitações para as demais demandas.

A extração inicial dos dados, na plataforma RegulaRN Leitos Gerais, contemplou vinte e quatro características, sendo elas: a) data da solicitação; b) tipo de ocupação; c) tipo de caso; d) escore unificado de priorização; e) escala *Sequential Organ Failure Assessment* (SOFA); f) tipo leito solicitado; g) data de entrada; h) tipo do leito de entrada; i) data de saída; j) tipo de leito de saída; k) número do cartão nacional de saúde; l) sexo; m) município do paciente; n) unidade federativa do paciente; o) gestante (sim ou não); p) idade gestacional; q) idade; r) identificação do regulador; s) desfecho; t) unidade de saúde solicitante; u) município da unidade de saúde solicitante; v) unidade de saúde prestadora; w) município da unidade de saúde prestadora e x) CID.

Nessa perspectiva, foram removidas as características que não se associam ao quadro clínico do paciente, que não impactam no desfecho ou que se relacionam com o registro de localidade: data da solicitação, número do cartão nacional de saúde, unidade federativa do paciente, município do paciente, identificação do regulador, unidade de saúde solicitante, município da unidade de saúde solicitante e município da unidade de saúde prestadora. Além disso, também foram removidas as *features* que possuíam apenas um único registro possível ou que as informações eram insuficientes: tipo de ocupação, tipo do caso, gestante (sim ou não) e idade gestacional.

Desse modo, apenas 12 características foram selecionadas: EUP, escala SOFA, tipo do leito solicitado, data de entrada, tipo do leito de entrada, data de saída, tipo de leito de saída,

sexo, idade, desfecho, unidade de saúde prestadora e CID. A partir das *features* data de entrada e data de saída foi possível conceber o tempo de internação do paciente (a partir da diferença entre a data de saída e entrada no leito). Dessa maneira, 11 características foram mantidas para o processo de classificação. A Tabela 1 apresenta a descrição de todos os tipos de dados extraídos no RegulaRN (nos módulos COVID-19 e Leitos Gerais).

Após a extração de dados, avaliou-se os valores contidos em todas as colunas de dados e, com intuito de garantir a integridade da análise, removeu-se as linhas que estavam com dados em branco ou informações inconclusivas. Além disso, verificou-se que a coluna alvo “desfecho” possuía seis valores possíveis: por alta, por óbito, por outros motivos, por permanência, por procedimento de parto e por transferência. Como esses quatro últimos desfechos não indicam devidamente um encerramento positivo ou negativo da regulação, assim como, possuíam um número pouco expressivo de recorrência, com 7.151 regulações, eles foram removidos. Mantendo-se, assim, uma classificação binária (por alta - positivo, ou por óbito - negativo) para os modelos computacionais. Por fim, foram selecionadas 38.023 registros de regulações efetivas para aplicação nos modelos de inteligência artificial. A base de dados do Leitos Gerais adulto e pediátrico também foi disponibilizada no Zenodo pelo link <https://zenodo.org/records/11387710>. A Figura 8 apresenta o delineamento realizado para tratamento e seleção dos dados.

Ressalta-se que como os dados do RegulaRN COVID-19 e RegulaRN Leitos Gerais tiveram momentos e objetivos distintos de aplicação, a estrutura de algumas colunas do banco de dados das aplicações tiveram alterações, desse modo, algumas das características que foram consideradas em uma das aplicações não foram utilizadas em outras. A exemplo disso são as datas de entrada e saída do leito, que são utilizadas para geração do tempo de internação na plataforma RegulaRN Leitos Gerais, mas que foram dispensadas na plataforma RegulaRN COVID-19, tendo em vista este já possuir a informação de tempo de internação. A mesma consideração pode ser obtida para manter a unidade de saúde prestadora na plataforma de regulação geral, pois agrega maior correlação com o desfecho, e suprimida na plataforma da COVID-19.

7.2.1.3 - RegulaRN Leitos Gerais - Neonatal

Os dados de regulações neonatais deste estudo contemplam o mesmo período utilizado para o RegulaRN Leitos Gerais - Adulto e Pediátrico, e possibilitaram a análise de 1.868 solicitações. Das 24 características apresentadas pela base de dados, foram

selecionadas: data de entrada, data de saída, tipo de leito solicitado, tipo de leito de entrada, tipo de leito de saída, hospital prestador, CID e desfecho. Da mesma maneira que foi realizado anteriormente, o tempo de internação do paciente no leito foi apurado a partir da diferença entre a data de entrada e a data de saída do leito.

Quanto aos dados removidos, foram retiradas as mesmas colunas de dados do adulto e do pediátrico tendo como pressuposto as mesmas justificativas, contudo, para os dados neonatais foram removidos os dados clínicos EUP e SOFA, isso porque, de acordo com os registros na base de dados, esses pacientes não obtiveram pontuações para essas escalas. Além disso também foram removidas a idade do paciente, devido aos dados terem sido disponibilizados apenas em anos e não em dias ou meses de nascido e, por fim, o sexo do recém-nascido também não estava incluída na base de dados obtida.

Após extração, também foi preferível manter uma classificação binária dos desfechos, haja vista que para as regulações de pacientes neonatos também estavam incluídos os seis desfechos possíveis: por alta, por óbito, por outros motivos, por permanência, por procedimento de parto, por transferência. Ao manter apenas os desfechos de alta e óbito foram removidos 231 registros de regulação que apresentavam outros resultados e, ao final, foram selecionadas 1.637 solicitações de regulação de leitos. O link para acesso aos dados está disponível em: <https://zenodo.org/records/13624936>.

Tabela 1 - Campos e descrição de dados do RegulaRN

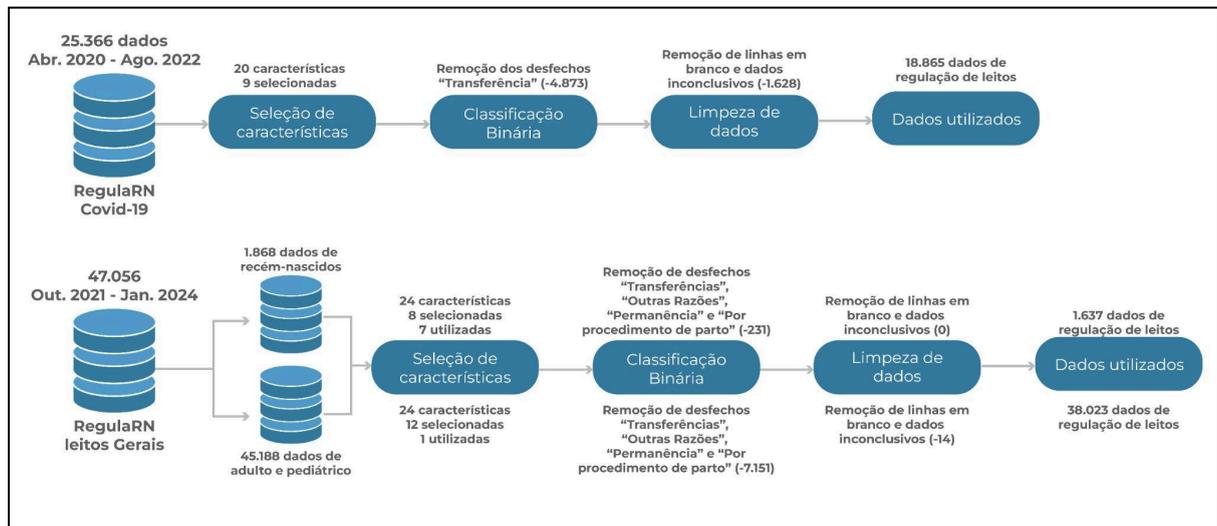
Descrição da base de dados do RegulaRN	
Dados COVID-19	
Campo	Descrição
data da solicitação	Representa a data em que uma solicitação de leito foi registrada.
município do paciente	Representa o município do paciente.
unidade federativa do paciente	Representa a unidade federativa do paciente.
grávida	Representa se a paciente está grávida.
idade gestacional	Descreve o tempo de gravidez, mensurado em semanas.
idade	Representa a idade do paciente.
tipo do caso	Representa se o paciente foi categorizado como “suspeito”,

	“confirmado” ou “descartado” para COVID-19.
EUP*	Representa o valor do escore EUP.
IOT	Representa se o paciente estava ou não em intubação orotraqueal ao solicitar um leito.
tipo de leito solicitado	Representa o tipo de leito que foi selecionado pela central de regulação para um paciente.
data de entrada	Representa a data em que o paciente foi alocado no leito na unidade de saúde prestadora.
tipo de leito de entrada	Representa o tipo de leito que o paciente foi alocado na unidade de saúde prestadora.
data de saída	Representa a data em que o paciente saiu do leito após o desfecho.
tipo de leito de saída	Representa o tipo de leito em que o paciente estava antes do desfecho.
tempo de internação	Representa o tempo de internação hospitalar, mensurado em dias..
desfecho	Representa o desfecho final do paciente no leito.
unidade de saúde solicitante	Representa a unidade de saúde que solicitou um leito para o paciente.
município da unidade solicitante	Representa o município da unidade de saúde que solicitou um leito para um paciente.
unidade de saúde prestadora	Representa a unidade de saúde que recebe e interna o paciente no leito
município da unidade prestadora	Representa o município da unidade de saúde que recebe e interna o paciente no leito.
Dados Leitos Gerais	
data da solicitação	Representa a data em que uma solicitação de leito foi registrada.
tipo de ocupação	Representa o tipo de ocupação da solicitação de regulação de leito.
tipo do caso	Representa os resultados de testes de pacientes com suspeita de Covid-19. Os resultados podem ser: positivo, negativo, inconclusivo ou nulo.
EUP	Representa o valor do escore EUP.
escala SOFA	Representa o valor de priorização do paciente de acordo com os valores desta escala.

tipo de leito solicitado	Representa o tipo de leito que foi selecionado pela central de regulação para um paciente.
data de entrada	Representa a data em que o paciente foi alocado no leito na unidade de saúde prestadora.
tipo de leito de entrada	Representa o tipo de leito que o paciente foi alocado na unidade de saúde prestadora.
data de saída	Representa a data em que o paciente saiu do leito após o desfecho.
tipo de leito de saída	Representa o tipo de leito em que o paciente estava antes do desfecho.
número do cartão SUS	Representa o número do cartão SUS de cada paciente.
sexo	Representa o sexo do paciente.
município do paciente	Representa o município do paciente.
unidade federativa do paciente	Representa a unidade federativa do paciente.
grávida	Representa se a paciente está grávida.
idade gestacional	Descreve o tempo de gravidez, mensurado em semanas.
idade	Representa a idade do paciente.
regulador	Representa o regulador responsável pela regulação.
desfecho	Representa o desfecho final do paciente no leito.
unidade de saúde solicitante	Representa a unidade de saúde que solicitou um leito para o paciente.
município da unidade solicitante	Representa o município da unidade de saúde que solicitou um leito para um paciente.
unidade de saúde prestadora	Representa a unidade de saúde que recebe e interna o paciente no leito
município da unidade prestadora	Representa o município da unidade de saúde que recebe e interna o paciente no leito.
CID	Representa o código internacional de doenças para regulação de leitos

*O EUP foi proposto pelo Conselho Regional de Medicina de Pernambuco (CREME), maiores detalhes acerca do escore podem ser consultados em Cremepe (2020) e Bezerra et al. (2021).

Figura 8 - Delineamento de tratamento e seleção de dados



7.2.2 Análise, correlação entre *features* do dataset e validação estatística

Uma das maneiras de identificar se há alguma relação entre as variáveis de estudo é utilizar métodos de correlação entre elas, de modo que ela poderá identificar se há uma convergência direta ou inversa, forte ou fraca, entre duas instâncias da sua base de dados. Na área de análise de dados e estatística é comum e coerente utilizar a correlação de Pearson para essa atividade (Pearson, 1985). No entanto, essa correlação possui limitações quando os dados utilizados não estão distribuídos em intervalos numéricos, necessitando, assim, de outras ferramentas de correlação para relacionar dados categóricos. Nessa perspectiva, a correlação de Phik, proposta por Baak et al. (2020), busca remover essa limitação, conseguindo consolidar correlação entre variáveis numéricas e categóricas.

A correlação de phik é derivada do teste de contingência χ^2 de Pearson, que consiste no teste de hipótese de independência entre duas ou mais variáveis em uma tabela de contingência denominada superposição de fatoração. Nessa relação, cada elemento da linha da tabela se relaciona com um elemento da coluna, de modo em que a correlação entre os elementos varia de 0 a 1, na qual 0 apresenta uma correlação baixa, e 1 alta. Desse modo, a correlação de Phik é similar a de Pearson, no entanto, engloba uma distribuição normal bivariada, capturando relações lineares e não lineares (Baak et al., 2020).

Outrossim, a fim de verificar se os resultados obtidos teriam significância estatística, foi realizada uma avaliação de qui-quadrado envolvendo a distribuição dos dados reais e

preditos pelos modelos computacionais selecionados. Para isso, foi elaborada uma tabela de contingência a partir do módulo *stats* da biblioteca *scipy* do python. O módulo contém um grande número de funcionalidades para cálculo de distribuição de probabilidade, estatística de resumo e frequência, correlações, testes estatísticos e várias outras (Scipy, 2024). A função *chi2_contingency()* permite obter o valor de qui-quadrado e do valor p a partir de uma tabela de contingência, elaborada pela função *crossstab* do pandas (Pandas, 2024).

7.2.3 Métricas de avaliação

Um dos objetivos deste trabalho é classificar dados de regulação de leitos, obtidos pelo RegulaRN Leitos Gerais e COVID-19, com intuito de prever o desfecho positivo ou negativo de um paciente, com base nos parâmetros selecionados. Contudo, tão importante quanto compreender o desfecho do paciente, analisar o desempenho dos modelos utilizados também é de suma importância. Além de prever o desfecho com maior taxa de assertividade, faz-se necessário verificar a taxa de registros falsos positivos ou falsos negativos. Para isso são utilizadas diferentes métricas para apurar as potencialidades de um determinado modelo de classificação.

Essas métricas surgem a partir da matriz de confusão, uma ferramenta fundamental para a avaliação de modelos de classificação. A matriz de confusão compara os valores reais com os valores previstos pelo modelo, organizando-os em uma tabela cujas dimensões variam conforme o número de categorias do alvo. Em implementações binárias, onde o alvo pode assumir apenas dois valores, a matriz assume a forma de uma tabela 2x2. Nesta configuração, a matriz exibe a quantidade de verdadeiros positivos, verdadeiros negativos, falsos positivos e falsos negativos (Haghighi et al, 2019; Liang, 2022). A Figura 9 apresenta de maneira ilustrativa a matriz de confusão.

Figura 9 - Representação da matriz de confusão

		Valor Predito	
		Positivo	Negativo
Valor Real	Positivo	Verdadeiro Positivo (VP)	Falso Negativo (FN)
	Negativo	Falso Positivo (FP)	Verdadeiro Negativo (VN)

Fonte: Adaptado de Liang (2022)

Desse modo, em um contexto de ocupação de leitos hospitalares, saber se um determinado modelo está classificando mais ou menos pacientes que tiveram alta ou óbito de maneira equivocada é tão importante quanto a simples classificação assertiva. Para isso, é necessário incluir não somente a acurácia, mas também, a precisão, revogação, especificidade, F1-Score e ROC-AUC de modo similar que são encontrados nos trabalhos de Iwendi et al. 2020, Aljameel et al., 2021, Abouelyazid e Xiang (2021), Mehbodniya et al. (2022) e Endo et al., 2022.

O valor da acurácia consiste no conjunto de dados com previsões corretas (verdadeiro positivo e verdadeiro negativo) dividido pela somatória de todas as previsões realizadas pelo modelo (verdadeiro positivo, verdadeiro negativo, falso positivo, falso negativo) (Equação 1):

$$\text{Acurácia} = \frac{VP + VN}{VP + FP + FN + VN} \quad (1)$$

A precisão consiste na divisão da taxa de verdadeiros positivos pela soma da taxa de verdadeiros positivos e falsos positivos (Equação 2).

$$\text{Precisão} = \frac{VP}{VP + FP} \quad (2)$$

A revogação envolve a taxa de verdadeiros positivos dividido pela taxa de verdadeiros positivos mais falsos negativos (Equação 3).

$$\text{Revogação} = \frac{VP}{VP + FN} \quad (3)$$

A especificidade remete a predição de verdadeiros negativos dividido pela soma dos verdadeiros negativos com falsos positivos (Equação 4).

$$\text{Especificidade} = \frac{VN}{VN + FP} \quad (4)$$

O F1-Score é a média harmônica de precisão e revogação. A fórmula envolve o produto entre precisão e revogação dividido pela somatória dessas métricas, multiplicadas por 2 (Equação 5).

$$\text{F1-Score} = 2 \times \frac{\text{Precisão} \times \text{Revogação}}{\text{Precisão} + \text{Revogação}} \quad (5)$$

ROC-AUC pode ser obtida pelo revogação dividido pelo valor complementar da especificidade (Equação 6).

$$\text{ROC-AUC} = \frac{\text{Revogação}}{1 - \text{Especificidade}} \quad (6)$$

7.2.4 Balanceamento de dados

Os dados do RegulaRN tratam-se de elementos do mundo real, isto é, dados que foram obtidos diretamente de condições reais de atendimento e hospitalização. Desse modo, já era esperado que existisse um desbalanceamento positivo das regulações entre os desfechos possíveis (alta ou óbito). Para o RegulaRN COVID-19, na base aferida de 18.865 dados, cerca de 72% dos registros possuem desfecho de alta, e 28% de óbitos. Já na plataforma RegulaRN Leitos Gerais adultos e pediátricos, dos 38.023 dados extraídos, 82,6% foram classificados como altas e 17,4% óbitos. Para os dados neonatais, dos 1.637 dados, 90,3% de altas e 9,6% óbitos.

O problema gerado em trabalhar modelos de *machine learning* ou *deep learning* com dados desbalanceados consiste na possibilidade de ocorrência enviesamento de aprendizagem dos modelos para a categoria que possui maior prevalência entre os valores possíveis. Isto é, para um modelo que classifica de maneira equivocada todos os valores como positivos, em determinadas amostragens na qual o valor positivo for dominante acarretará em métricas mais altas, atribuindo falsa exatidão para um determinado modelo.

Para resolver esse problema, uma das técnicas mais comuns é o uso do método SMOTE (*Synthetic Minority Oversampling Technique*, em inglês, ou Técnica de Sobreamostragem de Minoría Sintética, em português), que aumenta o número de dados da classe minoritária. O algoritmo do SMOTE primeiro identifica a classe minoritária e, em seguida, no espaço vetorial das características, localiza os k vizinhos mais próximos dessa classe (normalmente k é igual a 5). Finalmente, uma nova instância da classe minoritária é gerada selecionando aleatoriamente valores no espaço vetorial entre uma instância da classe minoritária e seus vizinhos mais próximos identificados. Esse processo é repetido até que a base de dados esteja totalmente equilibrada (Chawla et al., 2002; Blagus; Lusa, 2013; Fernandez et al., 2018).

7.2.5 Dados de treinamento e validação

O elemento chave para o melhor desempenho de aprendizagem de qualquer modelo de *machine learning* ou *deep learning* é a seleção de dados para treinamento e teste. A

qualidade integral e desempenho de um modelo pode variar significativamente a partir da seleção realizada (Uçar et al., 2020; Tao et al., 2020). De acordo com a literatura acadêmica, é preferível que o percentual de dados de treinamento seja igual ou superior aos de teste, em uma proporção 50/50, 55/45, 60/40, 65/35, 70/30, 75/25, 80/20, 85/15, 90/10 ou 95/5, respectivamente (Uçar et al., 2020).

Para este estudo, a divisão dos dados em conjuntos de treinamento e validação está alinhada com os procedimentos metodológicos de outros trabalhos similares que lidaram com grandes volumes de dados. Por exemplo, Endo et al. (2022) utilizaram aproximadamente 11.382 registros de dados em modelos de classificação para prever a disseminação de informações sobre a COVID-19. Vaughan et al. (2023) analisaram mais de 10.849 amostras de águas residuais de várias regiões da Europa para prever a contaminação por COVID-19. Yu et al. (2021) trabalharam com 5.471 dados de pacientes com COVID-19 para prever mortalidade e necessidade de ventilação mecânica. Zhai et al. (2020) utilizaram cerca de 1.706 registros de internação para predição de alta e óbito de pacientes. Portanto, dado o volume significativo de dados e a abordagem científica de separar 80% dos dados para treinamento e 20% para teste, o mesmo método foi aplicado neste estudo.

7.2.6 Definição de modelos para classificação dos dados

Para seleção dos modelos de classificação de dados foi realizada uma avaliação na literatura acadêmica dos modelos que lidavam melhor com um número significativo de dados (Hanafy; Ming, 2021; Charbuty; Abdulazeez, 2021; Liu et al., 2020; Hamida et al., 2020). Após isso, foram selecionados diferentes modelos para classificar os dados do RegulaRN COVID-19 e RegulaRN Leitos Gerais, isto porque ao empregar múltiplos modelos, pode-se explorar uma gama mais ampla de padrões e relações nos dados, aumentando a probabilidade de identificar o modelo que melhor se ajusta ao problema específico, assim como amplia a consistência dos dados obtidos.

7.2.6.1 - RegulaRN COVID-19

Para a plataforma de regulação que utiliza dados da COVID-19 os modelos selecionados para classificação de dados foram os clássicos: Decision Tree, Random Forest e o algoritmo Perceptron Multicamadas (PMC), propostos inicialmente por Quinlan (1996), Breiman (2001) e Rumelhart, Hinton e Williams (1986), respectivamente. Para o PMC, para obter um desempenho computacional mais eficiente, especialmente devido ao grande volume

de dados combinado com o número de variáveis (o que aumenta as dimensões no hiperplano), é necessário escolher algoritmos otimizadores na etapa de treinamento (Sutskever et al., 2013; Yu et al., 2021). Esses algoritmos são usados para aprimorar o tempo e a precisão no processo de classificação de dados. Assim, os seguintes algoritmos de otimização foram selecionados: Stochastic Gradient Descent (SGD) (Kaoudi et al., 2017; Zhang et al., 2018), Adam (Kingma e Ba, 2014; Bock et al., 2019), Adagrad (Duchi et al., 2011) e Root Mean Square Propagation (RMSProp) (Dauphin et al., 2015; Babu et al., 2020; Uppal et al., 2023).

7.2.6.2 - RegulaRN Leitos Gerais

Para a plataforma de Leitos Gerais foram selecionados os algoritmos: Decision Tree (Charbuty; Abdulazeez, 2021), Random Forest (Rigatti, 2017), Gradient Boosting (Friedman, 2002; Breiman, 2004; Fafalios; Charonyktakis; Tsamardinos, 2020), AdaBoost (Schapire, 2017), XGBoost (Chen et al., 2015; Sheng; Yu, 2022) e Perceptron Multicamadas. Para o PMC, foram selecionados os otimizadores SGD e Adam.

7.2.7 Hiperparâmetros para definição do melhor modelo

Os algoritmos modernos de aprendizado de máquina supervisionado envolvem hiperparâmetros que precisam ser definidos antes de serem executados para obter melhores resultados nos modelos. Para selecionar os melhores hiperparâmetros, o pesquisador poderá recorrer a valores padrão de hiperparâmetros especificados na implementação de diferentes pacotes ou bibliotecas disponíveis para treinamento de modelos, ou configurá-las manualmente com base nas recomendações da literatura ou tentativa e erro (Wang; Gong, 2018; Probst; Boulesteix; Bischl, 2019; Yang et al., 2020).

No presente trabalho foram selecionados diferentes modelos de classificação e diferentes hiperparâmetros, reforçando a necessidade de criar diferentes ambientes de aprendizagem para os classificadores selecionados a fim de identificar quais combinações potencializam boas métricas. Destaca-se que todo o processo de seleção e afinação, conhecido como *tuning* em inglês, foi realizado com a linguagem Python e as bibliotecas Scikit-learn (Pedregosa et al., 2011) e Keras (Chollet, 2018).

Na plataforma RegulaRN COVID-19, para o modelo Decision Tree (utilizando o Decision Tree Classifier), foram selecionados os seguintes hiperparâmetros: *criterion*, *max depth of the tree*, *min samples leaf* e *max features*. De acordo com o Scikit-learn

(<https://scikit-learn.org/>) o *criterion* mensura a qualidade da divisão da árvore, os valores selecionados para esse classificador foram *gini* ou *entropy*; *max depth of the tree* determina a profundidade máxima que a árvore pode alcançar; *min samples leaf* consiste no número mínimo de amostras necessárias para estar em um nó de um ramo (folha); *max features* considera o número de recursos a serem considerados ao procurar a melhor divisão. Para Random Forest (utilizado o *RandomForestClassifier*), foram selecionados hiperparâmetros similares ao da Decision Tree (*criterion*, *max depth of the tree* e *max features*) com adição do parâmetro *number estimators*, que de acordo com o Scikit-learn, considera o número de árvores da floresta.

Ainda na plataforma de COVID-19, para os modelos do perceptron multicamadas o processo de treinamento e seleção dos hiperparâmetros foi elaborado a partir da biblioteca Keras do python (<https://keras.io/>). Dentre os motivos para seleção dessa biblioteca está na necessidade de ajustar e ampliar o número de hiperparâmetros possíveis, tendo em vista que o *MLPClassifier* (classificador do perceptron multicamada) do Scikit-learn possui limitações na seleção de otimizadores, número de nós e camadas. Nesse sentido, os hiperparâmetros selecionados foram: *number of neurons*, *dropout*, *batch size*, e *epochs*. O primeiro parâmetro representa o número de neurônios possíveis em cada camada oculta do classificador; já o segundo atua na seleção do número de neurônios que estarão definitivamente ativos em uma camada oculta; o terceiro envolve o número de exemplos utilizados para estimar o gradiente de erro antes de realizar atualização para o próximo parâmetro do modelo; por fim, o quarto, relaciona o número de passagens completas pelo conjunto de dados antes que o processo de treinamento seja encerrado.

Já para a plataforma Leitos Gerais, conforme já anteriormente destacado, prezou-se por ampliar o quantitativo de classificadores dentre os ofertados pela Scikit-learn. Para os classificadores Decision Tree e Random Forest foram mantidos os mesmo hiperparâmetros utilizados nos dados da COVID-19, no entanto, para o Gradient Boosting (*GradientBoostingClassifier*) foram selecionados: *criterion*, *max depth*, *number estimators* e *max features*, estes que possuem as mesmas definições dos classificadores já mencionados. Para AdaBoost (*AdaboostClassifier*) foram selecionados: *learning rate*, *number estimators* e *algorithm*. O *learning rate* está associado a uma taxa de aprendizagem, na qual, há um peso aplicado a cada iteração de reforço; já o *algorithm* possibilita a seleção do SAMME ou SAMME.R que são elementos de otimização de classificação proposto por Hastie et al. (2009). Quanto ao PMC, para os dados do Leitos Gerais, foi preferível utilizar o *MLPClassifier* disponível na própria biblioteca do Scikit-learn, porque embora tenha algumas

diferenças do proposto pelo Keras, faz-se necessário avaliar o desempenho desse classificador em uma outra biblioteca para fins de comparação. Para esse classificador foram selecionados os seguintes hiperparâmetros: *hidden layer size*, *activation*, e *batch size*. O *hidden layer size* representa o número de camadas possíveis para o modelo, já o *activation* representa qual a função de ativação do modelo, o *batch size* mantém a mesma consideração que foi realizada anteriormente.

O XGBoost trata-se de um classificador fruto de uma melhoria do algoritmo Gradient Boosting, destaca-se que o Scikit-learn ainda não possui um este classificador no seu rol de modelo computacionais. Sendo assim foi utilizada a biblioteca XGBoost (Xgboost, 2022) que possui portabilidade com as métricas e funcionalidades do Scikit-learn. Para esse classificador utilizamos o *XGBClassifier* com os seguintes hiperparâmetros: *learning rate*, *number estimators*, *max depth of the tree* e *colsample by tree*. O *colsample by tree* está associado a fração de recursos, selecionados aleatoriamente, que serão utilizados para treinar cada árvore.

Após selecionar os hiperparâmetros faz-se necessário definir qual será o modelo de iteração que irá realizar o ajuste fino dos parâmetros durante o treinamento, assim sendo, os modelos mais adotados são *GridSearchCV* e *RandomizedSearchCV* (ambas estão disponíveis na Scikit-learn). O *RandomizedSearchCV* é uma ferramenta que realiza, de maneira aleatória, a combinação de hiperparâmetros utilizados para treinamento dos classificadores, de modo que o pesquisador poderá determinar o número máximo de iterações. A vantagem deste método é que quando há grande variabilidade de parâmetros ele exige menos esforço computacional e realiza o treinamento de maneira mais rápida. Contudo, se o objetivo da pesquisa é avaliar todas as combinações possíveis independentemente do custo computacional, deverá selecionar o *GridSearchCV*. Desse modo, objetivando garantir a seleção das melhores configurações possíveis, foi optado por utilizar o *GridSearchCV* neste estudo (Paper, 2020; Kiran; Ozyldirim, 2022; Agrawal, 2021; Puslecki; Walkowiak, 2023; Padhy, 2024).

Ainda nessa perspectiva, o *GridSearchCV* do Scikit-learn possui um método denominado *cross validation* na qual realiza uma divisão proporcional de dados de treinamento e teste de maneira aleatória. Esse recurso permite que haja maior variabilidade entre os dados do dataset para evitar qualquer viés. Assim sendo, foi definido um valor de 10 divisões, em consonância do que foi encontrado na literatura (Fushiki, 2011; Berrar, 2019 Malhotra; Meena, 2021). Ademais, os modelos foram treinados cinco vezes, similar ao elaborado por Ahsan et al., 2020 a fim de determinar com maior precisão o melhor conjunto

de hiperparâmetros. A Tabela 2 apresenta o detalhamento dos hiperparâmetros selecionados e seus respectivos valores para o RegulaRN COVID-19 e Leitos Gerais adulto e pediátrico e neonatal.

Tabela 2 - Seleção de hiperparâmetros e valores para cada modelo

Modelo	Hiperparâmetro	Faixa e melhores valores
RegulaRN COVID-19		
Decision Tree	criterion	gini ou entropy
	max depth of the tree	[10 , 50, 100]
	min samples leaf	range [1,2, 3 ,4]
	max features	[sqrt , log2]
Random Forest	criterion	gini ou entropy ;
	max depth of the tree	[10 , 50, 100]
	min samples leaf	[100 , 200, 400]
	max features	[sqrt , log2]
PMC SGD*	number of neurons	[5, 20, 100]
	dropout	[0.5 , 0.9]
	batch size	[16 , 32, 64]
	epochs	[10, 50 , 100]
PMC Adam*	number of neurons	[5, 20, 100]
	dropout	[0.5 , 0.9]
	batch size	[16 , 32, 64]
	epochs	[10, 50, 100]
PMC RMSProp*	number of neurons	[5, 20, 100]
	dropout	[0.5 , 0.9]
	batch size	[16 , 32, 64]
	epochs	[10, 50 , 100]
PMC Adagrad*	number of neurons	[5, 20, 100]
	dropout	[0.5 , 0.9]
	batch size	[16 , 32, 64]
	epochs	[10, 50, 100]
RegulaRN Leitos Gerais - Adulto e pediátrico		
Decision Tree	criterion	gini ou entropy
	max depth of the tree	[10, 50 , 100]
	min samples leaf	range [1 ,2,3,4]
	max features	[sqrt , log2]
Random Forest	criterion	gini ou entropy
	max depth of the tree	[10, 50 , 100]
	number estimators	[100, 200, 400]
	max features	[sqrt , log2]

Gradient Boosting	criterion max depth number estimators max features	friedman_mse or squared_error ; [10 , 50, 100] [10, 50 , 100] [sqrt , log2]
AdaBoost	learning rate number estimators algorithm	[0.1, 0.5, 1.0] [100, 200, 400] [samme, samme.r]
XGBoost	learning rate number estimators max depth colsample by tree	[0.1 , 0.5, 1.0] [100, 200 , 400] [10, 50 , 100] [0.1, 0.5, 1.0]
PMC SGD**	hidden_layer_sizes activation batch_size	[5, 25, 70] tanh or relu [16, 32 , 64]
PMC Adam**	hidden_layer_sizes activation batch_size	[5, 25, 70] tanh or relu [16, 32 , 64]

RegulaRN Leitos Gerais - Neonatal

Decision Tree	criterion max depth of the tree min samples leaf max features	gini ou entropy [10, 50 , 100] range [1 ,2,3,4] [sqrt , log2]
Random Forest	criterion max depth of the tree number estimators max features	gini ou entropy [10, 50 , 100] [100, 200, 400] [sqrt , log2]
Gradient Boosting	criterion max depth number estimators max features	friedman_mse or squared_error ; [10 , 50, 100] [10, 50 , 100] [sqrt , log2]
AdaBoost	learning rate number estimators algorithm	[0.1, 0.5, 1.0] [100, 200, 400] [samme, samme.r]
XGBoost	learning rate number estimators max depth colsample by tree	[0.1 , 0.5, 1.0] [100 , 200, 400] [10, 50 , 100] [0.1, 0.5 , 1.0]
PMC SGD**	hidden_layer_sizes	[5, 25, 70]

	activation	tanh or relu
	batch_size	[16 , 32, 64]
PMC Adam**	hidden_layer_sizes	[5, 25, 70]
	activation	tanh or relu
	batch_size	[16 , 32, 64]

* Perceptron multicamadas disponível pelo Keras

** Perceptron multicamadas disponível pelo Scikit-learn

Capítulo 8

Resultados

O presente capítulo apresenta os resultados obtidos de duas maneiras, na primeira delas será apresentada uma análise geral dos dados utilizados e em seguida os resultados obtidos a partir dos modelos de inteligência artificial. A seção é estruturada de maneira a apresentar inicialmente os resultados obtidos pela plataforma RegulaRN COVID-19 e, em seguida, RegulaRN Leitos Gerais, subdividindo os dados de adultos e pediátricos dos neonatais.

8.1 - Análise geral dos dados para a plataforma RegulaRN COVID-19

A primeira etapa de análise geral dos dados é compreender como os dados estão divididos. Como o objetivo geral deste trabalho envolve a predição de desfecho de um paciente internado após regulação, foi realizado uma estratificação desses dados de acordo com a característica da base de dados, seus valores possíveis e o quantitativo por alta e óbito, conforme apresenta a Tabela 3.

Tabela 3 - Distribuição de características de acordo com o desfecho

Característica		Valores (N = 18.865), n (%)	Desfecho, n (%)
Idade	≥ 60	9.116 (48,3%)	Alta: 5.599 (61.4%), Óbito: 3.517(38.6%)
	< 60	9.749 (51,7%)	Alta: 8.016 (82.2%), Óbito: 1.733 (17.8%)
Tipo do Caso	Confirmado	13.235 (70,2%)	Alta: 9.158 (69.1%), Óbito: 4.077 (30.9%)
	Suspeito	5.150 (27,3%)	Alta: 4.100 (79.6%), Óbito: 1.050 (20.4%)

	Descartado	480 (2,5%)	Alta: 357 (74.4%), Óbito: 123 (25.6%)
EUP	2	9.100 (48,2%)	Alta: 7.259 (79.8%), Óbito: 1.839 (20.2%)
	3	4.138 (21,9%)	Alta: 3.088 (74.6%), Óbito: 1.050 (25.4%)
	4	2.554 (13,5%)	Alta: 1.698 (66.5%), Óbito: 856 (33.5%)
	5	2.056 (10,8%)	Alta: 1.118 (54.4%), Óbito: 938 (45.6%)
	6	781 (4,1%)	Alta: 359 (46%), Óbito: 422 (54%)
	7	190 (1%)	Alta: 72 (37.9%), Óbito: 118 (62.1%)
	8	46 (0,2%)	Alta: 20 (43.5%), Óbito: 26 (56.5%)
	IOT	Não	17.634 (93,4%)
Sim		1.231 (6,5%)	Alta: 183 (14.9%), Óbito: 1.048 (85.1%)
Leito Solicitado	Enfermaria	11.289 (59,8%)	Alta: 10.064 (89.1%), Óbito: 1.225 (10.9%)
	UTI	7.576 (40,2%)	Alta: 3.551 (46.9%), Óbito: 4.025 (53.1%)
Leito de Entrada	Enfermaria	9.753 (51,7%)	Alta: 8.800 (90.2%), Óbito: 953 (9.8%)
	UTI	9.112 (48,3%)	Alta: 4.815 (52.8%), Óbito: 4.297 (47.2%)
Leito de Saída	Enfermaria	10.511 (55,7%)	Alta: 10.077 (95.9%), Óbito: 434 (4.1%)
	UTI	8.354 (44,3%)	Alta: 3.538 (42.4%), Óbito: 4,816 (57.6%)
Tempo de Internação	< 7	11.852 (62,8%)	Alta: 9.293 (78.4%), Óbito: 2.559 (21.6%)
	$7 \leq t_i \leq 14$	5.038 (26,7%)	Alta: 3.365 (66.8%),

			Óbito: 1,673 (33.2%)
	> 14	1.975 (10,5%)	Alta: 957 (48.5%), Óbito: 1,018 (51.5%)
Desfecho	Alta	13.615 (72,1%)	-
	Óbito	5.250 (27,9%)	-

Fonte: Barreto et al. (2023)

De modo geral é possível identificar que a maior parte dos pacientes internados por COVID-19 no período de abril de 2020 até agosto de 2022 eram menores de 60 anos, com tipo do caso confirmado, EUP com valor 2, não deram entrada no leito em intubação orotraqueal, mantiveram-se em leitos de enfermaria na solicitação, entrada e saída, com tempo de internação inferior a sete dias e desfecho de alta. Por outro lado, os pacientes que tiveram maior quantitativo de desfechos negativos eram maiores de 60 anos, com caso confirmado, maior período de internação em leitos de UTI e tempo de internação inferior a sete dias.

Para uma análise estatística faz-se necessário dividir essa investigação em grupos. Desse modo, foi separado no conjunto de dados totais, conjunto de dados com desfecho de alta e conjunto de dados com desfecho óbito. O objetivo dessa divisão é avaliar a existência de fatores que possam influenciar no desfecho. Para o grupo geral o valor médio das idades dos pacientes que se internaram por COVID-19 foi de 55,8 anos com desvio padrão de 23,7 anos e mediana de 59 anos; já o EUP obteve valor médio de 3,04 com desvio padrão de 1,28 e mediana de 3; ademais, o tempo de internação obteve média de 6,85 dias com desvio padrão de 7 dias e mediana de 5 dias.

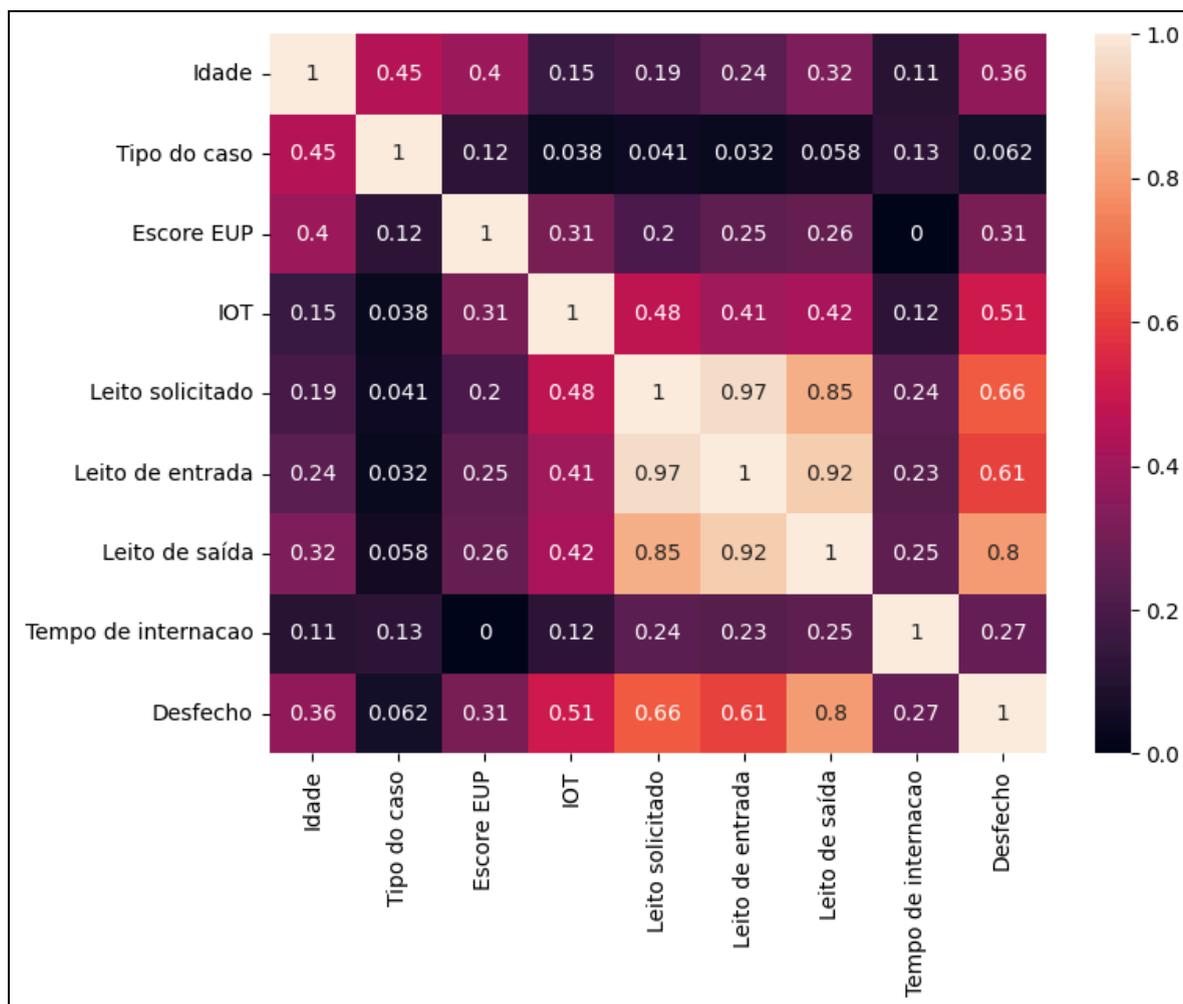
No grupo de pacientes que tiveram desfecho positivo o valor médio da idade é de 55,7 anos, com desvio padrão de 24,4 e mediana de 55; EUP médio de 2,86 com desvio padrão de 1,15 e mediana de 2; e tempo de internação médio de 6,10 dias com desvio padrão de 6,20 dias e mediana de 5 dias. Já no grupo com o desfecho negativo apresenta-se idade média de 66,7 anos com desvio padrão de 17,8 anos e mediana de 68; EUP de 3,52 com desvio padrão de 1,46 e mediana de 3; e tempo de internação de 8,78 dias com desvio padrão de 8,58 com mediana de 7.

Em síntese, é possível identificar que a base de dados de regulação para COVID-19 do estado norte riograndense possui um perfil de óbitos característico conforme apontado pela Organização Mundial da Saúde (OMS) e literatura (WHO, 2020; Cucinotta et al., 2020;

Horwitz et al. 2021), isto é, pacientes idosos, com maior fragilidade de saúde (posicionados com valor acima de 2 no Escore Unificado de Priorização) e tiveram um prazo de internação mais longo. Naturalmente essa tendência amostral poderá variar de acordo com diversos fatores, principalmente relacionados a idade populacional, condições de acesso à saúde e capacidade assistencial e fatores socio-regionais.

Quanto a correlação geral dos dados a associação das variáveis também foi dividida por grupos: correlação geral de dados, correlação entre dados com desfecho alta, correlação com dados com desfecho óbito. Nos dados gerais, a ferramenta Phik apresenta que há maior correlação com os desfecho, as variáveis “Leito de saída”, “Leitos solicitado”, “Leito de entrada” e “IOT”, superando uma correlação de 50%. Todavia, é possível identificar também uma correlação considerável entre as características “Idade”, “EUP” e “Tempo de Internação” (entre 27% a 36%), já “Tipo do caso” não possui grande significância para o desfecho (Figura 10).

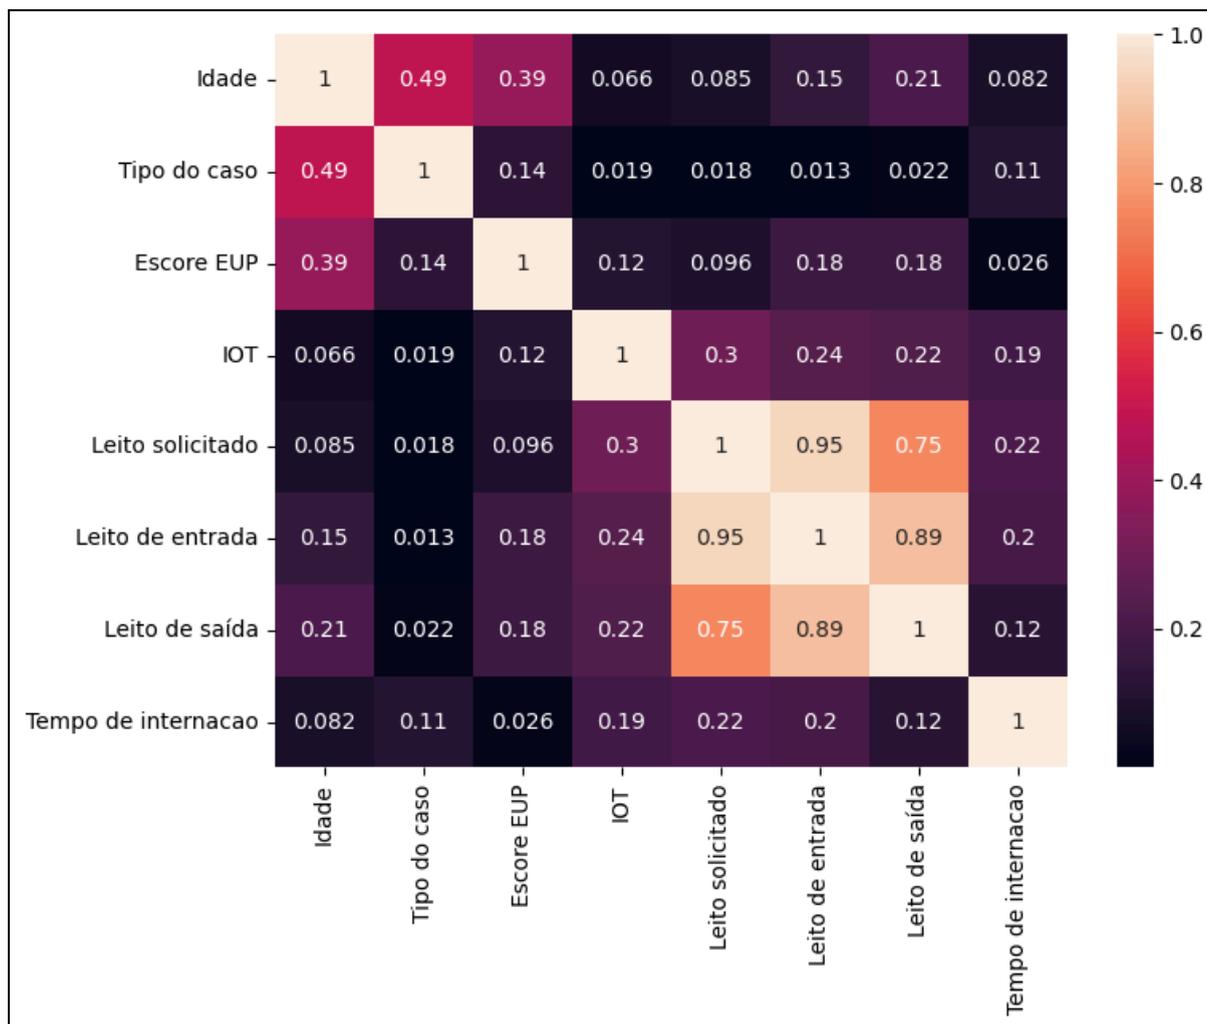
Figura 10 - Matriz geral de correlação Phik para os dados de COVID-19



Fonte: Adaptado de Barreto et al. (2023)

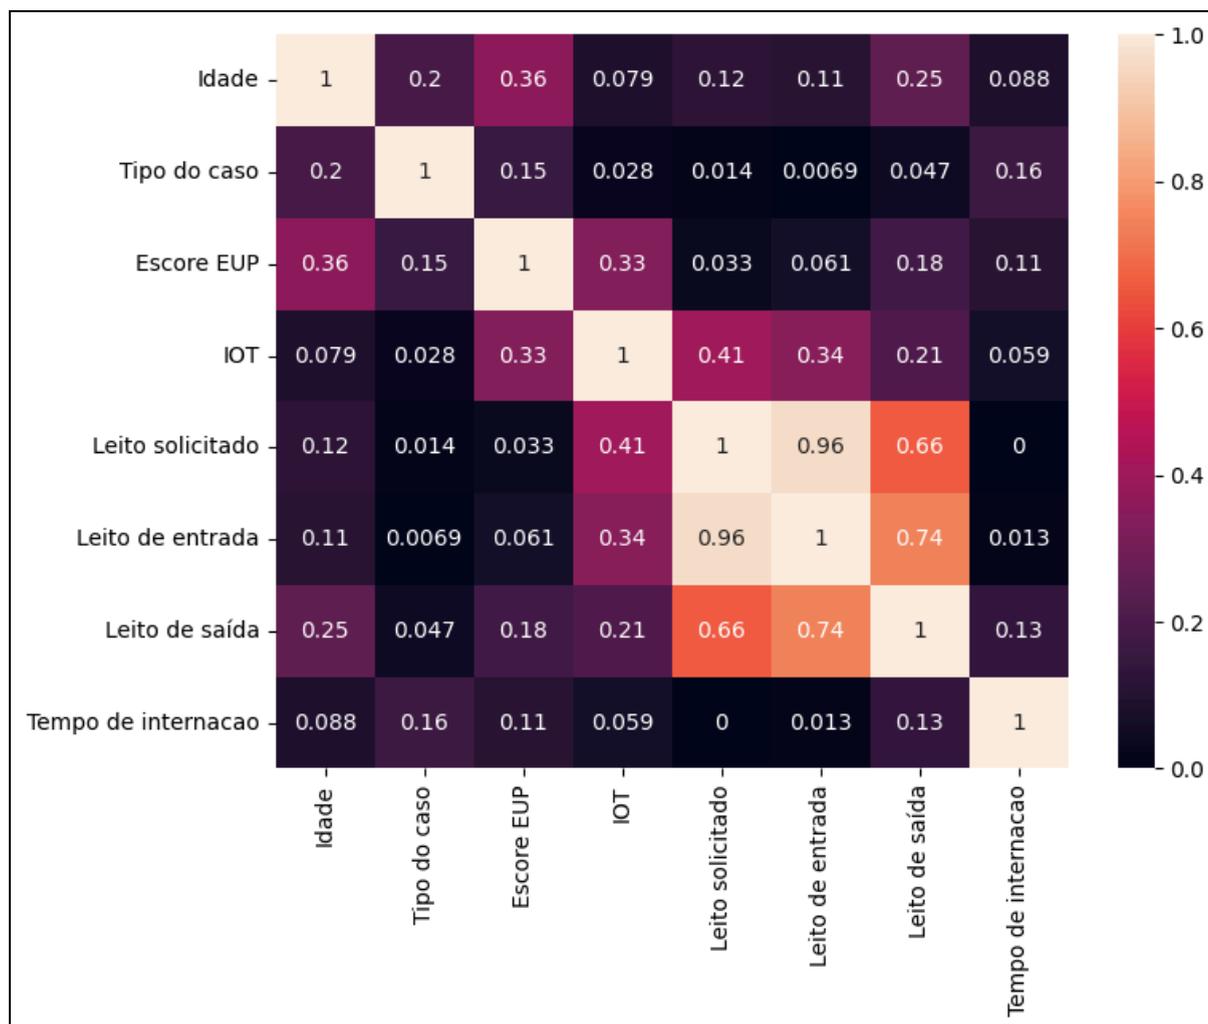
Ao avaliar a correlação entre os grupos similares de desfecho, os pacientes que tiveram desfecho de alta (Figura 11) apresentaram maior destaque entre as correlações da característica “Idade” com as variáveis “Tipo do caso”, “EUP” e “Leito de saída”, respectivamente com 49%, 39% e 21%. Assim como uma forte correlação esperada entre as variáveis “Leito solicitado”, “Leito de entrada” e “Leito de saída” que assumem valores similares e com forte indução ao desfecho. Este mesmo comportamento também é identificado na matriz de correlação por desfecho óbito (Figura 12). Na categoria de óbitos “IOT” relaciona-se com maior afinco com o “Leito Solicitado”, “Leito de entrada”, “Leito de saída” e “EUP”, relação também já esperada, tendo em vista que pacientes que deram entrada com intubação orotraqueal em leitos de UTI e com maiores pontuações do EUP tiveram maior desfecho óbito.

Figura 11 - Matriz de correlação Phik, com desfecho alta, para os dados de COVID-19



Fonte: Adaptado de Barreto et al. (2023)

Figura 12 - Matriz de correlação Phik, com desfecho óbito, para os dados de COVID-19



Fonte: Adaptado de Barreto et al. (2023)

Uma consideração importante para essa análise é o desempenho das regiões de saúde do RN quanto ao acolhimento, tratamento e desfecho das regulações de COVID-19. Assim sendo, de acordo com a Tabela 4 é possível verificar que a primeira e terceira região de saúde obtiveram uma taxa de conversão mais efetiva, quando comparada com as demais regiões. Da mesma forma, a sexta região de saúde apresentou pior desempenho, com maior percentual de óbitos. Vale salientar que para essa análise não foi considerado o tipo do leito, condições assistenciais e de infraestrutura que podem impactar na qualidade assistencial. Todavia, é uma forma de analisar o desempenho da assistência à saúde em determinadas regiões de saúde do estado.

Tabela 4 - Desempenho assistencial das regiões de saúde com dados de COVID-19

Região de Saúde	Altas	Óbitos	Alta/Total	Óbitos/Total
Primeira	83	17	83%	17%
Segunda	2943	1236	70,4%	29,6%
Terceira	489	113	81,2%	18,8%
Quarta	1606	629	71,86%	28,1%
Quinta	264	107	71,15%	28,85%
Sexta	820	421	66,07%	33,93%
Sétima	7085	2629	72,94%	27,06%
Oitava	325	98	76,84%	23,16%

8.2 - Resultados dos modelos computacionais para a plataforma RegulaRN COVID-19

A Tabela 2, localizada no capítulo anterior, listou os hiperparâmetros escolhidos e seus respectivos valores. Os hiperparâmetros mais eficazes foram destacados em negrito, permitindo uma comparação entre parâmetros semelhantes nos diferentes modelos. Nos modelos Decision Tree e Random Forest, os melhores resultados foram obtidos com os mesmos níveis de *criterion*, *max depth of the tree* e *max features*. Esse padrão de semelhança também foi observado nos modelos do perceptron multicamadas, onde houve uma escolha similar nos parâmetros *number of neurons*, *dropout* e *batch size* entre todos os otimizadores.

Em relação às métricas de avaliação (Tabela 5), entre os modelos utilizados, o Random Forest obteve a melhor acurácia (82,97%), precisão (79,35%), revogação (84,80%), F1-score (80,74%) e especificidade (84,79%), apresentando também os menores valores de desvio-padrão. No que diz respeito aos modelos do Keras, o PMC SGD alcançou a maior acurácia (84,01%), precisão (79,57%) e F1-score (81%), enquanto o PMC RMSProp se destacou com o maior pontuação de revogação (84,67%) e especificidade (84,67%). Observa-se que há uma variação significativa no desvio-padrão entre os modelos de redes neurais.

Tabela 5 - Desempenho dos modelos de acordo com as métricas da matriz de confusão - RegulaRN COVID-19.

Modelo	Acurácia	Precisão	Revogação	F1-Score	Especificidade
Decision Tree	82,06(+0,29)	78,41 (+0,21)	83,72(+0,26)	79,73 (0,26)	84,38 (+0,85)
Random Forest	82,97(+0,11)	79,35 (+0,12)	84,80 (+0,16)	80,74 (+0,12)	84,79 (+0,19)
PMC SGD	84,01 (+0,25)	79,57 (+0,46)	84,16 (+0,13)	81,00 (+0,49)	84,16 (+0,12)
PMC Adam	82,84 (+0,34)	79,20 (0,20)	84,57(+0,22)	80,58(+0,2 4)	84,57(+0,23)
PMC RMSProp	82,43(+0,25)	78,97 (+0,20)	84,67 (+0,18)	80,28 (+0,24)	84,67 (+0,18)
PMC Adagrad	83,11 (+0,43)	79,38 (+0,29)	84,59 (+0,18)	80,80 (+0,35)	84,59(+0,18)

.Fonte: Adaptado de Barreto et al. (2023)

Uma outra análise importante a respeito dos modelos de aprendizagem de máquina e aprendizagem de máquina profunda são as importâncias das características (*features importances*, em inglês). Esse procedimento apresenta qual a relevância de determinadas características para a classificação do modelo, isto é, quanto uma coluna da base de dados é capaz de influenciar no resultado final (Wojtas; Chen, 2020; Stiglic et al., 2020; König et al., 2021). O cálculo do valor das importâncias das características de cada modelo foi obtido a partir do método *feature_importances_* do scikit-learn. Para os modelos Decision Tree e Random Forest as características “Leito de saída”, “Idade” e “Tempo de internação” estão entre as mais importantes para seleção dos modelos, seguidos de “Leito de entrada” e “EUP” que também apresentam alguma representatividade (Figura 13). As variantes para o “Tipo do caso” apresentam menor consistência na tomada de decisão. Nos modelos PMC (Figura 14), às características “Tipo de leito solicitado”, “Leito de entrada” e “Leito de saída” estão entre as características de maior relevância para RMSProp e Adagrad. Por outro lado, SGD e Adam consideram “Leito de saída”, “Leito solicitado” e “Idade” como mais importantes. Em todos os modelos, a variável "Tipo do caso (descartado)" é a menos significativa para a determinação do desfecho.

Ao comparar os resultados das *features importances* com a correlação de Phik, os modelos PMC apresentaram maior aproximação na escolha das características do que os

modelos de árvores. “Leito Solicitado”, “Leito de entrada” e “Leito de saída” estão entre as mais relevantes para PMC RMSProp e Adagrad, já “Leito de saída” e “Leito solicitado” aparecem entre as mais relevantes para os otimizadores SGD e Adam.

Figura 13 - Importância das características para classificação dos modelos de árvore para os dados de COVID-19

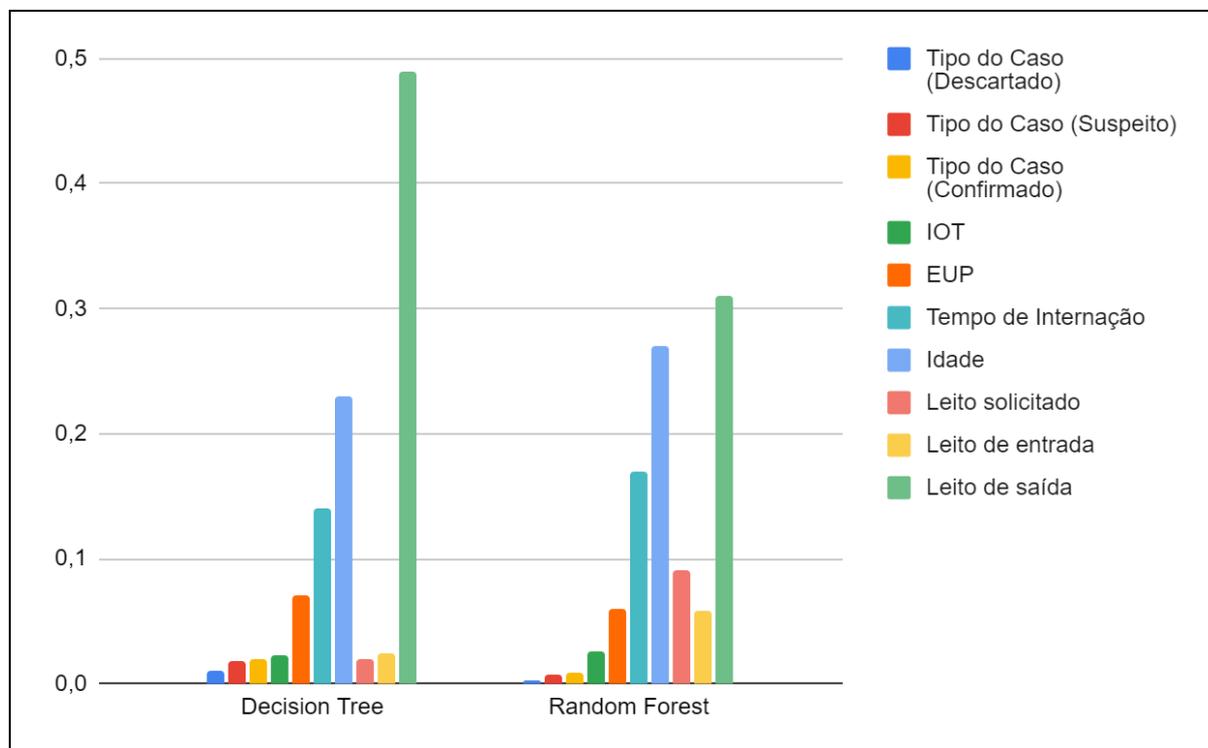
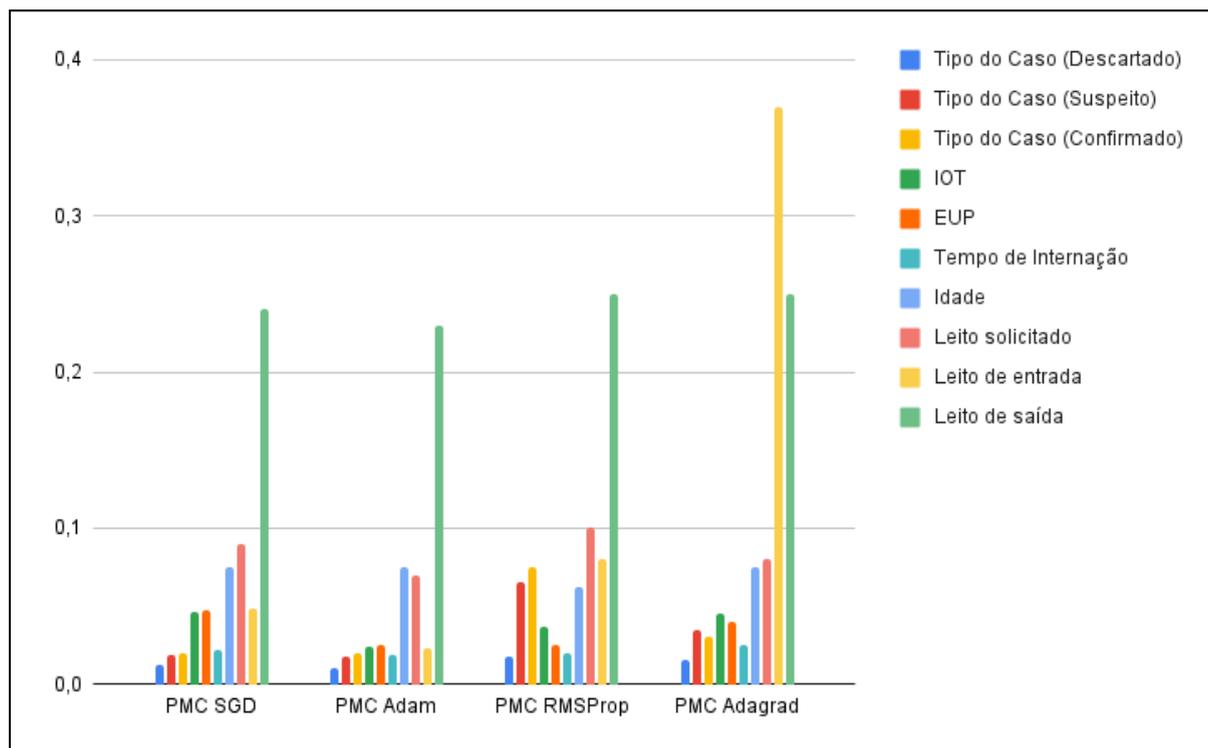


Figura 14 - Importância das características para classificação dos modelos do perceptron multicamadas para os dados de COVID-19

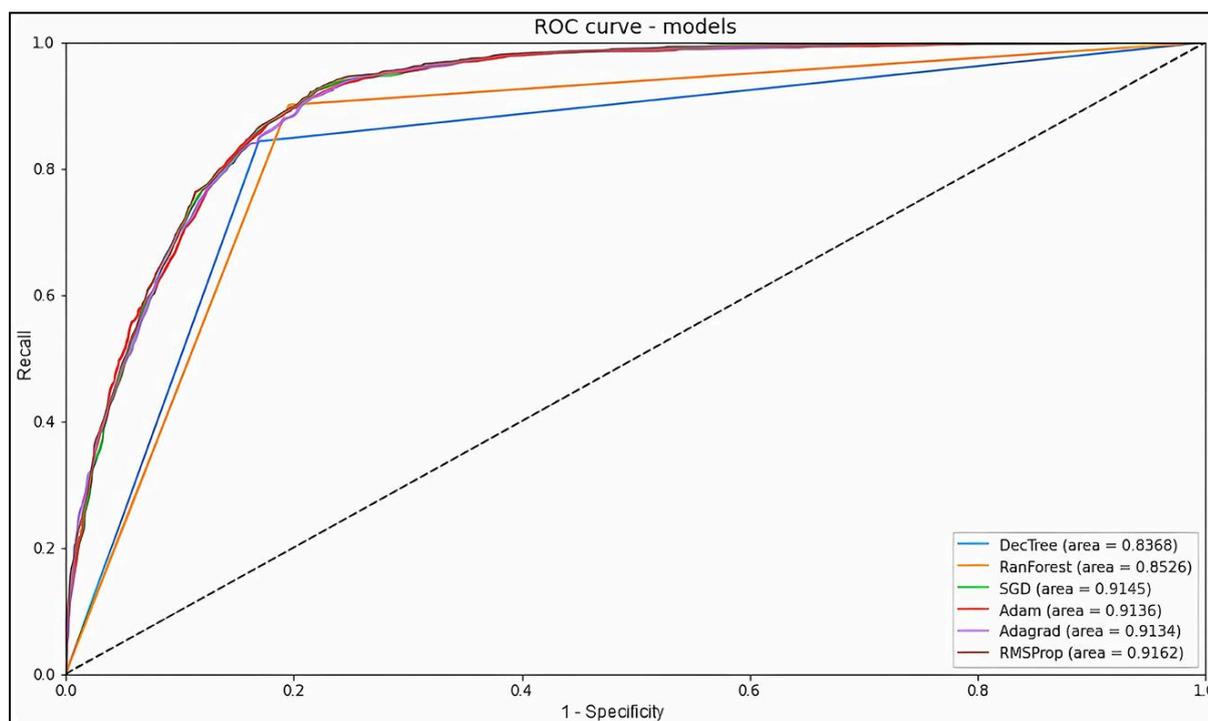


Por fim, para consolidar esta análise em regulações de COVID-19 foi necessário calcular o desempenho dos modelos pela curva de Características Operacionais do Receptor, também conhecida como ROC (*receiver operating characteristic*), assim como o valor da área sob a curva (denominada *area under the curve*, AUC). A ROC é formada a partir da taxa de falsos positivos, ou $1 - \text{especificidade}$ (traçada no eixo horizontal), versus sua sensibilidade (traçada no eixo vertical). Cada ponto na curva representa a sensibilidade e a taxa de falsos positivos em um limiar de decisão diferente (Obuchowski, 2005). Essa curva ajuda a visualizar o desempenho de classificadores, com o objetivo de escolher um ponto operacional adequado ou um limite de decisão (Bradley, 1997; Clark; Webster-Clark, 2008; Mandrekar, 2010; Yang; Berdine, 2017; Obuchowski; Bullen, 2018). A capacidade discriminativa é frequentemente medida pela área sob a curva (AUC) ao prever um evento binário. Essa métrica está relacionada à variação entre as taxas de verdadeiros positivos e falsos positivos previstas pelos modelos, com resultados variando de 0 a 1. Embora não haja um consenso absoluto na literatura, muitos estudos que utilizam essa ferramenta consideram uma AUC entre 0,7 e 0,8 como boa e aceitável, e entre 0,8 e 0,9 como muito boa (Obuchowski, 2005; Hond; Steyerberg; Van Calster, 2022; Nahm, 2022).

Para os dados da COVID-19, o modelo Decision Tree apresentou um valor de ROC-AUC de 83,68%, seguido de Random Forest com 85,26%. Já os modelos do perceptron

tiveram pontuações de 91,34% para Adagrad, 91,36% para Adam, 91,45% para SGD e 91,62% para RMSProp (Figura 15). Embora as margens de valores obtidas tenham sido aproximadas, esses dados mostram que o RMSProp é um classificador mais estável para as classificações positivas e negativas.

Figura 15 - Curva ROC-AUC para os modelos que utilizaram dados do COVID-19.



Fonte: Barreto et al. (2023)

8.3 - Análise geral dos dados para a plataforma RegulaRN Leitos Gerais

8.3.1 - Dados de adultos e pediátricos

A mesma estratificação de dados realizada na base de dados anterior também foi realizada na base de dados dos Leitos Gerais (Tabela 6). Realizando uma análise de maneira geral a maior parcela de pacientes que precisaram ser regulados não é de idosos, são do sexo masculino, foram classificados com EUP 2, escala SOFA 1, maior quantidade de internações em leitos de enfermaria e tempo de internação menor de sete dias. Para essa base de dados foi disponibilizado a quantidade de altas e óbitos por hospital prestador, isso porque para essa base de dados o hospital prestador apresenta significância nos desfechos.

Tabela 6 - Perfil de dados do dataset do RegulaRN Leitos Gerais adultos e pediátricos

Características		Valores (N = 38.023), n (%)	Desfecho, n (%)
Idade	≥ 60	18.641 (49,03%)	Alta: 13.549 (72,68%) Óbito: 5.092 (27,32%)
	< 60	19.382 (50,97%)	Alta: 17.860 (92,15%) Óbito: 1.522 (7,85%)
Sexo	Masculino	20.325 (53,45%)	Alta: 16.941 (83,35%) Óbito: 3.384 (16,65%)
	Feminino	17.698 (46,55%)	Alta: 14.468 (81,75%) Óbito: 3.230 (18,25%)
EUP	2	17.572 (46,21%)	Alta: 16.668 (94,86%) Óbito: 904 (5,14%)
	3	7.279 (19,14%)	Alta: 6.176 (84,85%) Óbito: 1.103 (15,15%)
	4	5.468 (14,38%)	Alta: 4.113 (75,22%) Óbito: 1.355 (24,78%)
	5	5.485 (14,43%)	Alta: 3.543 (64,59%) Óbito: 1.942 (35,41%)
	6	1.765 (4,64%)	Alta: 770 (43,63%) Óbito: 995 (56,37%)
	7	367 (0,96%)	Alta: 120 (32,70%) Óbito: 247 (67,30%)
	8	87 (0,23%)	Alta: 19 (21,84%)

			Óbito: 68 (78,16%)
SOFA	1	29.699 (78,11%)	Alta: 26.070 (87,78%) Óbito: 3.629 (12,22%)
	2	6.816 (17,93%)	Alta: 4.652 (68,25%) Óbito: 2.164 (31,75%)
	3	1.179 (3,10%)	Alta: 598 (50,72%) Óbito: 581 (49,28%)
	4	329 (0,87%)	Alta: 89 (27,05%) Óbito: 240 (72,95%)
Leito Solicitado	Enfermaria	23.863 (62,76%)	Alta: 21.878 (91,68%) Óbito: 1.985 (8,32%)
	UTI	14.160 (37,24%)	Alta: 9.531 (67,31%) Óbito: 4.629 (32,69%)
Leito de Entrada	Enfermaria	23.858 (62,75%)	Alta: 21.851 (91,59%) Óbito: 2.007 (8,41%)
	UTI	14.165 (37,25%)	Alta: 9.558 (67,48%) Óbito: 4.607 (32,52%)
Leito de Saída	Enfermaria	28.137 (74,00%)	Alta: 26.233 (93,23%) Óbito: 1.904 (6,77%)
	UTI	9.886 (26,00%)	Alta: 5.176 (52,36%) Óbito: 4.710 (47,64%)
Prestador	Hospital Prestador 1	1.234 (3,25%)	Altas: 1.061 (85,98%) Óbitos: 173 (14,02%)

Hospital Prestador 2	794 (2,08%)	Altas:554 (69,77%) Óbitos: 240 (30,23%)
Hospital Prestador 3	299 (0,79%)	Altas: 213 (77,26%) Óbitos: 86 (28,76%)
Hospital Prestador 4	225 (0,59%)	Altas: 154 (68,44%) Óbitos: 71 (31,56%)
Hospital Prestador 5	367 (0,97%)	Altas: 227 (61,85%) Óbitos:140 (38,15%)
Hospital Prestador 6	2.104 (5,53%)	Altas: 1.722 (81,84%) Óbitos: 382 (18,16%)
Hospital Prestador 7	2.865 (7,53%)	Altas: 2.341 (81,71%) Óbitos: 524 (18,29%)
Hospital Prestador 8	2.331 (6,13%)	Altas: 1.971 (84,56%) Óbitos: 360 (15,44%)
Hospital Prestador 9	112 (0,29%)	Altas: 104 (92,86%) Óbitos:8 (7,14%)
Hospital Prestador 10	8 (0,02%)	Altas: 7 (87,50%) Óbito: 1 (12,50%)
Hospital Prestador 11	2.138 (5,62%)	Altas: 2.094 (97,94%) Óbitos: 44 (2,05%)
Hospital Prestador 12	703 (1,85%)	Altas: 625 (88,90%) Óbitos: 78 (11,10%)
Hospital Prestador 13	101 (0,27%)	Altas: 56 (55,45%) Óbitos: 45 (44,55%)
Hospital Prestador 14	11 (0,02%)	Altas: 11 (100%) Óbitos: 0 (0,00%)
Hospital Prestador 15	422 (1,11%)	Altas: 225 (53,31%) Óbitos: 197 (46,68%)

Hospital Prestador 16	94 (0,24%)	Altas: 86 (91,49%) Óbitos: 8 (85,11%)
Hospital Prestador 17	5 (0,01%)	Altas: 3 (60,00%) Óbitos: 2 (40,00%)
Hospital Prestador 18	385 (1,01%)	Altas: 233 (60,52%) Óbitos: 152 (39,48%)
Hospital Prestador 19	703 (1,84%)	Altas: 703 (100%) Óbitos: 0 (0,00%)
Hospital Prestador 20	253 (0,67%)	Altas: 211 (83,40%) Óbitos: 42 (16,60%)
Hospital Prestador 21	2.825 (7,43%)	Altas: 2.646 (93,66%) Óbitos: 179 (6,34%)
Hospital Prestador 22	1.000 (2,63%)	Altas: 778 (77,80%) Óbitos: 222 (22,20%)
Hospital Prestador 23	586 (1,54%)	Altas: 373 (63,65%) Óbitos: 213 (36,35%)
Hospital Prestador 24	739 (1,94%)	Altas: 608 (82,27%) Óbitos: 131 (17,73%)
Hospital Prestador 25	737 (1,94%)	Altas: 631 (85,62%) Óbitos: 106 (14,38%)
Hospital Prestador 26	34 (0,09%)	Altas: 23 (67,65%) Óbitos: 11 (32,35%)
Hospital Prestador 27	396 (1,04%)	Altas: 173 (43,69%) Óbitos: 223 (56,31%)
Hospital Prestador 28	5.192 (13,65%)	Altas: 4.320 (83,20%) Óbitos: 872 (16,80%)
Hospital Prestador 29	740 (1,95%)	Altas: 662 (89,46%) Óbitos: 78 (10,54%)
Hospital Prestador	1.000 (2,63%)	Altas: 850 (85,00%)

	30		Óbitos: 150 (15,00%)
	Hospital Prestador 31	598 (1,57%)	Altas: 438 (73,24%) Óbitos: 160 (26,76%)
	Hospital Prestador 32	2.183 (5,74%)	Altas: 1.590 (72,84%) Óbitos: 593 (27,16%)
	Hospital Prestador 33	395 (1,04%)	Altas: 240 (60,76%) Óbitos: 155 (39,24%)
	Hospital Prestador 34	443 (1,17%)	Altas: 233 (52,60%) Óbitos: 210 (47,40%)
	Hospital Prestador 35	193 (0,51%)	Altas: 193 (100%) Óbitos: 0 (0,00%)
	Hospital Prestador 36	4.181 (11,00%)	Altas: 3.774 (90,27%) Óbitos: 407 (9,73%)
	Hospital Prestador 37	422 (1,11%)	Altas: 422 (100%) Óbitos: 0 (0,00%)
	Hospital Prestador 38	12 (0,03%)	Altas: 12 (100%) Óbitos: 0 (0,00%)
	Hospital Prestador 39	522 (1,37%)	Altas: 467 (89,46%) Óbitos: 55 (10,54%)
	Hospital Prestador 40	161 (0,42%)	Altas: 119 (73,91%) Óbitos: 42 (26,09%)
	Hospital Prestador 41	510 (1,34%)	Altas: 256 (50,20%) Óbitos: 254 (49,80%)
Tempo de Internação	< 7	16.693 (43,90%)	Altas: 13.658 (81,82%) Óbitos: 3.035 (18,18%)
	$7 \leq TI \leq 14$	11.499 (30,24%)	Altas: 9.824 (85,43%) Óbitos: 1.675 (14,57%)

	> 14	9.831 (25,86%)	Altas: 7.927 (80,63%) Óbitos: 1.904 (19,37%)
Desfecho	Alta	31.409 (82,61%)	
	Óbito	6.614 (17,39%)	

Quanto ao perfil estatístico, o valor médio das idades foi de 59 anos, com desvio padrão de 26,83 e mediana de 59. Já o EUP médio foi de 3,16, desvio padrão de 1,33 e mediana de 3. Para a escala SOFA, o valor médio foi de 1,26, com variação de 0,55 e mediana de 1. Para o tempo de internação, o valor médio foi de 12,96 com desvio padrão de 17,68 e mediana de 7 dias. Assim sendo, é possível afirmar que o público médio que precisa utilizar o sistema de regulação de leitos para internação é um público não idoso, com menores índices de fragilidades (devido ao EUP e SOFA serem mais baixos), e com tempo de internação médio de 12,96 dias. Para o tempo de internação, como nessa análise foram avaliadas diversos CIDs diferentes, cada doença possui sua especificidade para o devido tempo de recuperação. Assim sendo, naturalmente algumas doenças precisaram de mais tempo e outras menos. Todavia, de uma forma geral ter a compreensão média total é um indicador importante para que as entidades governamentais tenham percepção de quanto tempo um leito ficará ocupado e quais os custos médios poderão ser repassados ao estado.

Quanto aos hospitais prestadores, deve-se evidenciar que cada um deles possui suas devidas especialidades de atendimento a depender da classificação da doença do paciente. Assim sendo, como existem doenças com diferentes graus de mortalidade, uma apreciação mais minuciosa é requerida para sugerir quais unidades prestadores possuem melhores condições de tratamento.

Quanto aos indicadores EUP e SOFA, os dados mostram uma estratificação de prioridade maior na escala EUP do que na SOFA. Enquanto a SOFA possui 78% dos dados na categorizados com valor 1, o EUP apresenta essa mesma faixa de porcentagem nos valores 2 (46,2%), 3 (19,1%) e 4 (14,3%). Nesse sentido, o EUP segmenta em mais elementos as solicitações, enquanto o SOFA mantém uma parcela majoritária com o mesmo valor. Como a base de dados apresenta diferentes doenças em diferentes perfis de pacientes, um classificador de categorização mais ampla parece ser mais prudente de ser adotado.

Quanto ao CID, foram lastreados 2.055 diferentes doenças registradas, na base de dados. Analisar esse indicador é importante para compreender qual o perfil de recorrência de

doenças no estado do RN e principalmente como essas doenças podem estar distribuídas, assim como, seu nível de mortalidade. Isso porque, algumas doenças podem acometer uma parcela da população por falta de acompanhamento na atenção primária, desse modo, o estado se responsabiliza por tratar pacientes que poderiam não ter agravado a partir de uma atenção à saúde primária eficiente. Dessa forma, a Tabela 7 apresenta os dez registros mais recorrentes, seguidos dos municípios com maior incidência e hospitais que mais atendem. O município de Natal, capital do Estado, possui mais de 890 mil habitantes, seguido de Mossoró, com mais de 300 mil habitantes, possuem maior incidência entre os 6 e 4, respectivamente, dos registros de doenças mais frequentes. Um ponto de destaque é que não há expressividade de solicitações para essas doenças entre os municípios de Parnamirim (mais de 267 mil habitantes), São Gonçalo do Amarante (mais de 115 mil habitantes) e Macaíba (mais de 81 mil habitantes), que estão entre os próximos municípios de maior expressividade populacional.

Tabela 7 - Registros dos CIDs mais recorrentes na base de dados do RegulaRN Leitoss Gerais adulto e pediátrico

Código	Nome	Frequência	Município com maior incidência (Solicitante)	Hospitais que mais tratam
J18.9	Pneumonia Não Especificada	4284	Natal: 1437 Mossoró: 763 Santo Antônio: 278	Hospital Prestador 28: 504 Hospital Prestador 6: 344 Hospital Prestador 11: 333
I21.9	Infarto Agudo do Miocárdio Não Especificado	1738	Mossoró 781 Natal: 150 Currais Novos:97	Hospital Prestador 36: 910 Hospital Prestador 6: 158 Hospital Prestador 7: 119
I64	Acidente Vascular Cerebral, Não Especificado Como Hemorrágico ou Isquêmico	1540	Mossoró: 1010 Caicó: 150 Natal: 148	Hospital Prestador 28: 969 Hospital Prestador 32: 164 Hospital Prestador 6: 73
N39.0	Infecção do Trato Urinário de Localização Não Especificada	965	Natal: 408 Mossoró: 83 Parnamirim: 79	Hospital Prestador 21: 125 Hospital Prestador 41: 102 Hospital Prestador 30: 67

I50.0	Insuficiência Cardíaca Congestiva	905	Natal: 243 Mossoró: 196 Currais Novos: 97	Hospital Prestador 6: 134 Hospital Prestador 28: 73 Hospital Prestador 21: 68
I20.0	Angina Instável	677	Mossoró: 531 Natal: 53 Currais Novos: 8	Hospital Prestador 36: 529 Hospital Prestador 6: 30 Hospital Prestador 21: 13
F20.8	Outras Esquizofrenias	587	Natal: 292 Parnamirim: 50 Ceará-Mirim: 34	Hospital Prestador 21: 293 Hospital Prestador 7: 272 Hospital Prestador 6: 9
A46	Erisipela	546	Natal: 180 Mossoró: 70 Caicó: 62	Hospital Prestador 21: 85 Hospital Prestador 32: 64 Hospital Prestador 39: 33
A41.9	Septicemia Não Especificada	542	Natal: 151 Mossoró: 115 Caicó: 67	Hospital Prestador 32: 81 Hospital Prestador 28: 72 Hospital Prestador 6: 38
I25.2	Infarto Antigo do Miocárdio	510	Mossoró: 373 Natal: 31 João Câmara: 19	Hospital Prestador 36: 374 Hospital Prestador 7: 19 Hospital Prestador 25: 17

Ainda sobre os CIDs, avaliar quais doenças ocorrem mais em óbito ou alta também é um importante indicador de saúde pública. A transparência desse tipo de informação é salutar para que as instituições governamentais responsáveis possam interferir positivamente com as ações e recursos necessários para o melhor desenvolvimento da saúde pública. Em acordo com os dados obtidos a Tabela 8 apresenta os CIDs que mais resultaram em altas e óbitos. No consolidado geral de frequência a Pneumonia Não Especificada (J18.9) apresenta maior representatividade entre o número de altas (75,4%) e óbitos (24,5%), uma outra doença que também aparece nas duas categorias é Insuficiência Cardíaca Congestiva (I50.0) com 72,7% de registros de altas e 27,3% óbitos. Os demais registros de doenças que tiveram maior número de altas foram Infarto Agudo do Miocárdio Não Especificado (I21.9), Acidente Vascular Cerebral, Não especificado como Hemorrágico ou Isquêmico (I64) e Infecção do Trato Urinário de Localização Não Especificada (N39.0) com resultados respectivos de 87,4%, 76,3% e 78,8%. Já no contexto de óbitos Septicemia Não Especificada (A41.9), Broncopneumonia Não Especificada (J18.0) e Infarto Agudo do Miocárdio Não Especificado

(I21.9) estão entre as mais frequentes com taxa de mortalidade de 50,5%, 24,8% e 12,6% das ocorrências.

Tabela 8 - Registro de CIDs, no RegulaRN Leitos Gerais adultos e pediátricos, que geram maior número de altas e óbitos.

Código	Nome	Frequência	Frequência/Total de incidência (%)
Altas			
J18.9	Pneumonia Não Especificada	3232	75,4%
I21.9	Infarto Agudo do Miocárdio não especificado	1519	87,4%
I64	Acidente Vascular Cerebral, Não especificado como Hemorrágico ou Isquêmico	1175	76,3%
N39.0	Infecção do Trato Urinário de Localização Não Especificada	760	78,8%
I50.0	Insuficiência Cardíaca Congestiva	658	72,7%
Óbitos			
J18.9	Pneumonia Não Especificada	1052	24,5%
A41.9	Septicemia Não Especificada	279	50,5%
I50.0	Insuficiência Cardíaca Congestiva	247	27,3%
J18.0	Broncopneumonia Não Especificada	110	24,8%
I21.9	Infarto Agudo do Miocárdio Não Especificado	94	12,6%

Ao analisar efetividade por leito (veja a Tabela 9), as doenças mais frequentes que registraram altas em leitos de UTI foram as doenças de códigos I21.9, J18.9, I20.0, I64 e O14.1, com incidências respectivas de 74,6%, 40,2%, 88,8%, 41,6% e 100%. Já os óbitos mais frequentes para esse tipo de leitos foram J18.9, I64, A41.9, I50.0 e I21.9 com incidência de 59,8%, 58,4%, 72,3%, 55,1% e 25,4%. Já para os leitos de enfermaria as doenças de código J18.9, I64, N39.0, F20.8 e A46 refletiram uma frequência de altas de 86%, 93,7%, 83,9%, 99,7% e 95,5%; e quanto aos óbitos as maiores frequências foram apuradas por J18.9, N39.0, I64, A41.9 e J18.0 com percentuais de 14%, 16,1%, 6,3%, 23,5% e 11,7%.

Considerações que podem ser apontadas nesse contexto é que a doença mais prevalente no RN para internação, independente do leito, é a Pneumonia Não Especificada (J18.9) que possui uma considerável taxa de altas, principalmente se for tratada em leitos de enfermaria, mas possui um percentual considerável de óbitos se o paciente já iniciar a alocação em leito de UTI. Ademais, Pré-Eclâmpsia Grave (O14.1) é a doença com maior taxa de alta, mesmo tendo um valor considerável de frequência para leitos de UTI e Septicemia Não Especificada (A41.9) possui maior taxa de mortalidade. Além disso, doenças de cunho cardiovascular também apresentam expressividade de frequência entre leitos de Enfermaria e UTI.

Tabela 9 - Distribuição de frequências de altas e óbitos por CID e tipo do leito, para o RegulaRN Leitos Gerais adulto e pediátrico.

Leito	Código	Nome	Frequência	Frequência/Total de incidência (%)
Altas				
UTI	I21.9	Infarto Agudo do Miocárdio Não especificado	580	74,6%
	J18.9	Pneumonia Não Especificada	370	40,2%
	I20.0	Angina instável	238	88,8%
	I64	Acidente Vascular Cerebral, Não Especificado Como Hemorrágico ou Isquêmico	202	41,6%
	O14.1	Pré-Eclâmpsia Grave	172	100%
Óbitos				
UTI	J18.9	Pneumonia Não Especificada	551	59,8%
	I64	Acidente Vascular Cerebral, Não Especificado Como Hemorrágico ou Isquêmico	283	58,4%
	A41.9	Septicemia Não Especificada	227	72,3%
	I50.0	Insuficiência Cardíaca Congestiva	199	55,1%
	I21.9	Infarto Agudo do Miocárdio Não Especificado	197	25,4%
Altas				

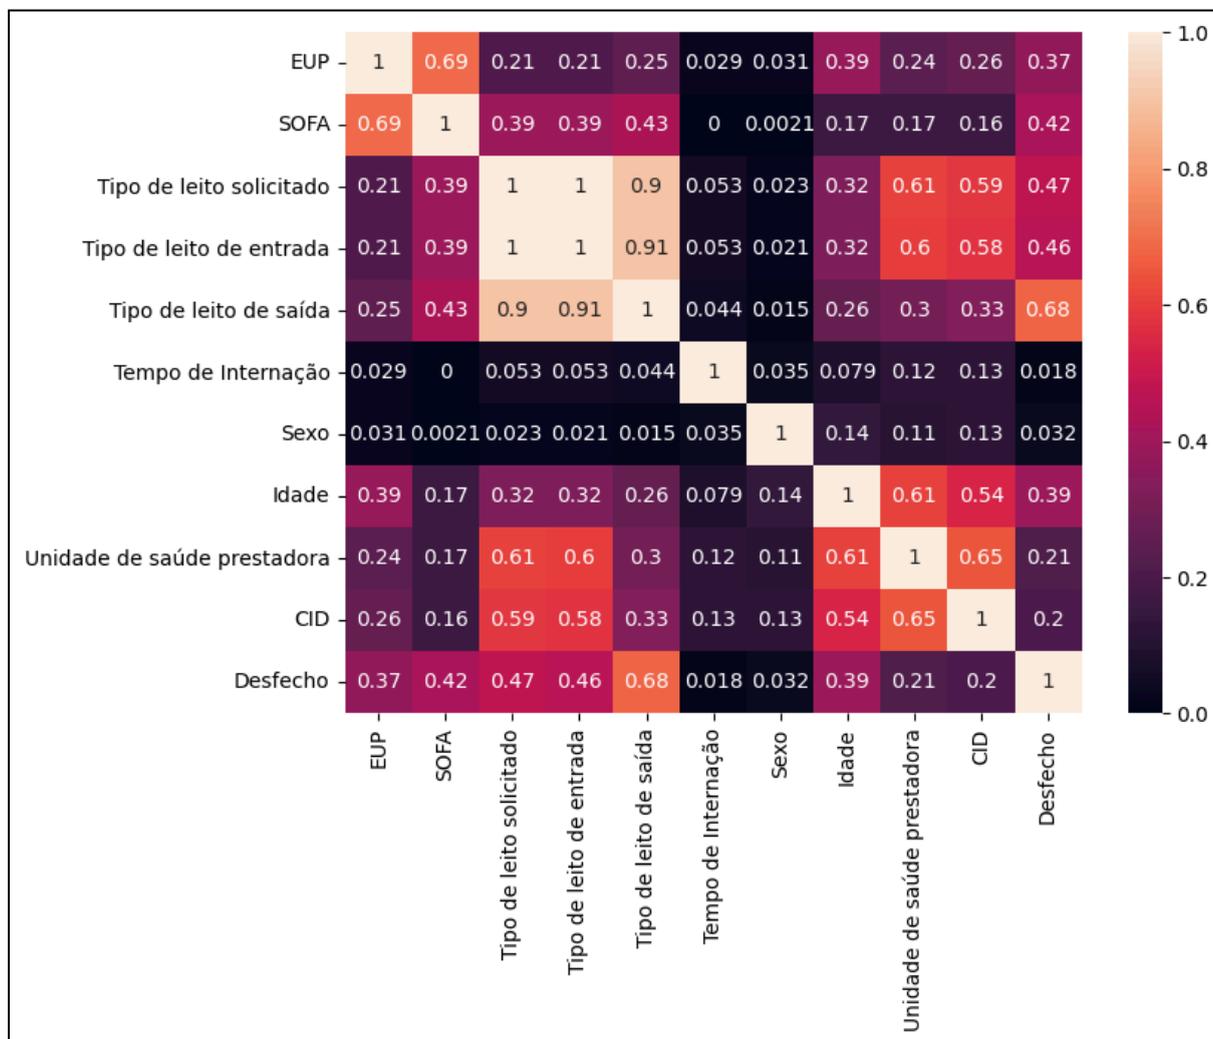
Enferm aria	J18.9	Pneumonia Não Especificada	2.589	86%
	I64	Acidente Vascular Cerebral, Não Especificado Como Hemorrágico ou Isquêmico	900	93,7%
	N39.0	Infecção do Trato Urinário de Localização Não Especificada	697	83,9%
	F20.8	Outras Esquizofrenias	585	99,7%
	A46	Erisipela	485	95,5%

Óbitos

Enferm aria	J18.9	Pneumonia Não especificada	422	14%
	N39.0	Infecção do Trato Urinário de Localização Não Especificada	134	16,1%
	I64	Acidente Vascular Cerebral, Não Especificado Como Hemorrágico ou Isquêmico	61	6,3%
	A41.9	Septicemia Não Especificada	36	23,5%
	J18.0	Broncopneumonia não especificada	36	11,7%

Quanto à correlação dos dados, a ferramenta Phik demonstrou que as colunas que possuem maior correlação com o alvo desejado são tipo de “Tipo de leito de saída” (correlação de 68%), “Tipo de leito solicitado” (correlação de 47%), “Tipo de leito de entrada” (correlação de 46%), “SOFA” (correlação de 42%), “Idade” (correlação de 39%), “EUP” (correlação de 37%), “Unidade de saúde prestadora” (correlação de 21%) e “CID” (correlação de 20%) (Figura 16). Um ponto de destaque é que para a ferramenta, as características tempo de internação e sexo não apresentam uma correlação significativa com o desfecho, ambas apresentaram correlação inferior a 1%.

Figura 16 - Matriz geral de correlação Phik com os dados do RegularN Leitos Gerais pediátrico e adulto.



Analisando os valores de correlação só por alta ou óbito, conforme apresentado nas Figuras 17 e 18, como todas as características apontam para o mesmo desfecho é importante analisar as variações existentes entre as próprias características. Quando compara-se a categoria óbito com a de altas é possível identificar uma diminuição da correspondência do “CID” com os tipos de leito, assim como, do parâmetro “idade” com o “CID”. Ainda sobre diminuição de correspondência, para a matriz de óbito, verifica-se esse fenômeno também entre a “unidade de saúde prestadora” e o “tipo de leito solicitado” e “tipo de leito de entrada”. Quanto aos aumentos de correspondência, ocorreu este fenômeno entre a SOFA e os tipos de leitos.

Figura 17 - Matriz de correlação Phik, com dados de alta, do RegulaRN Leitos Gerais pediátrico e adulto.

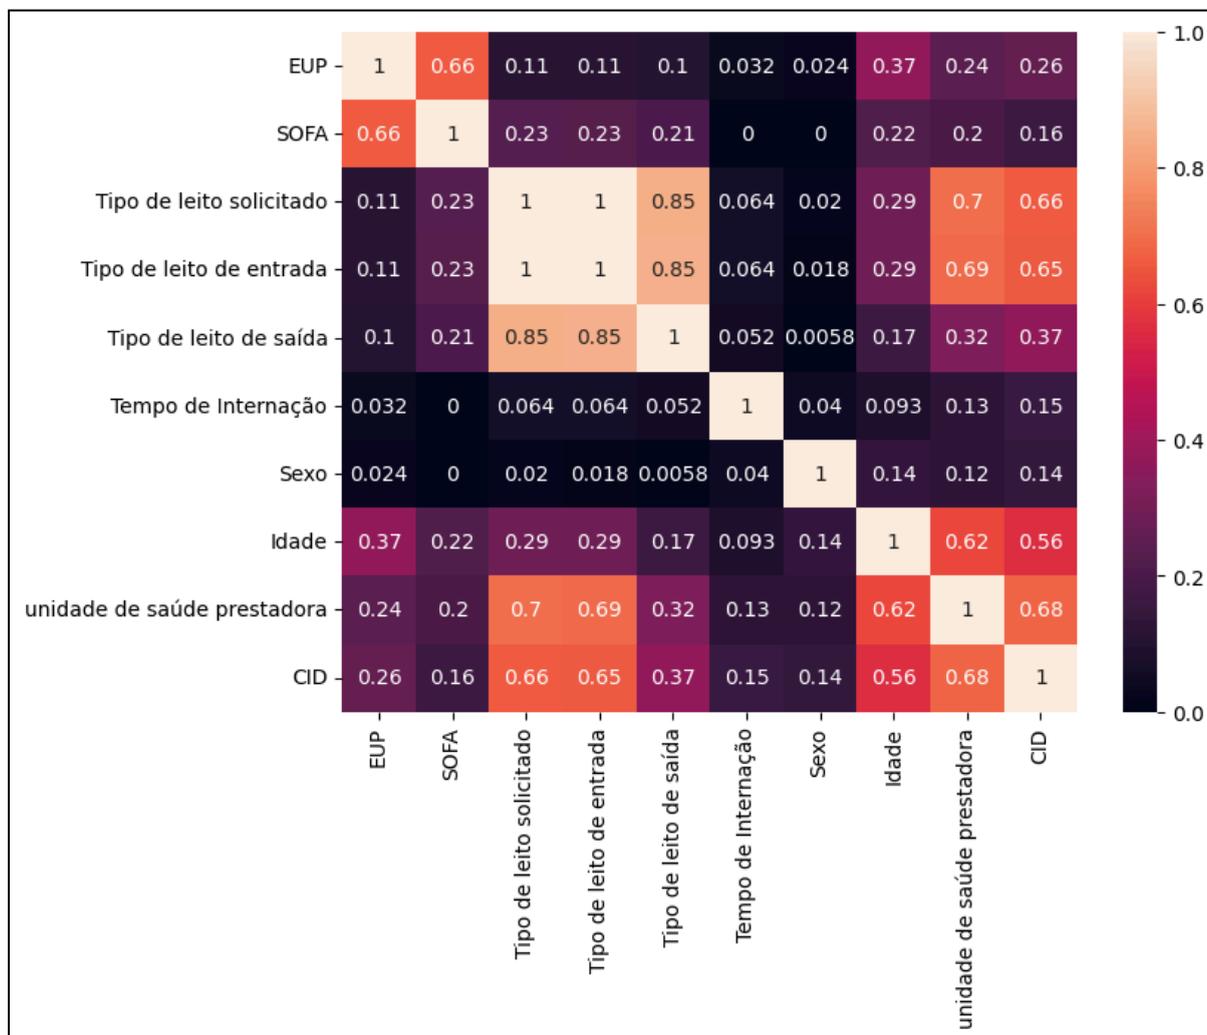
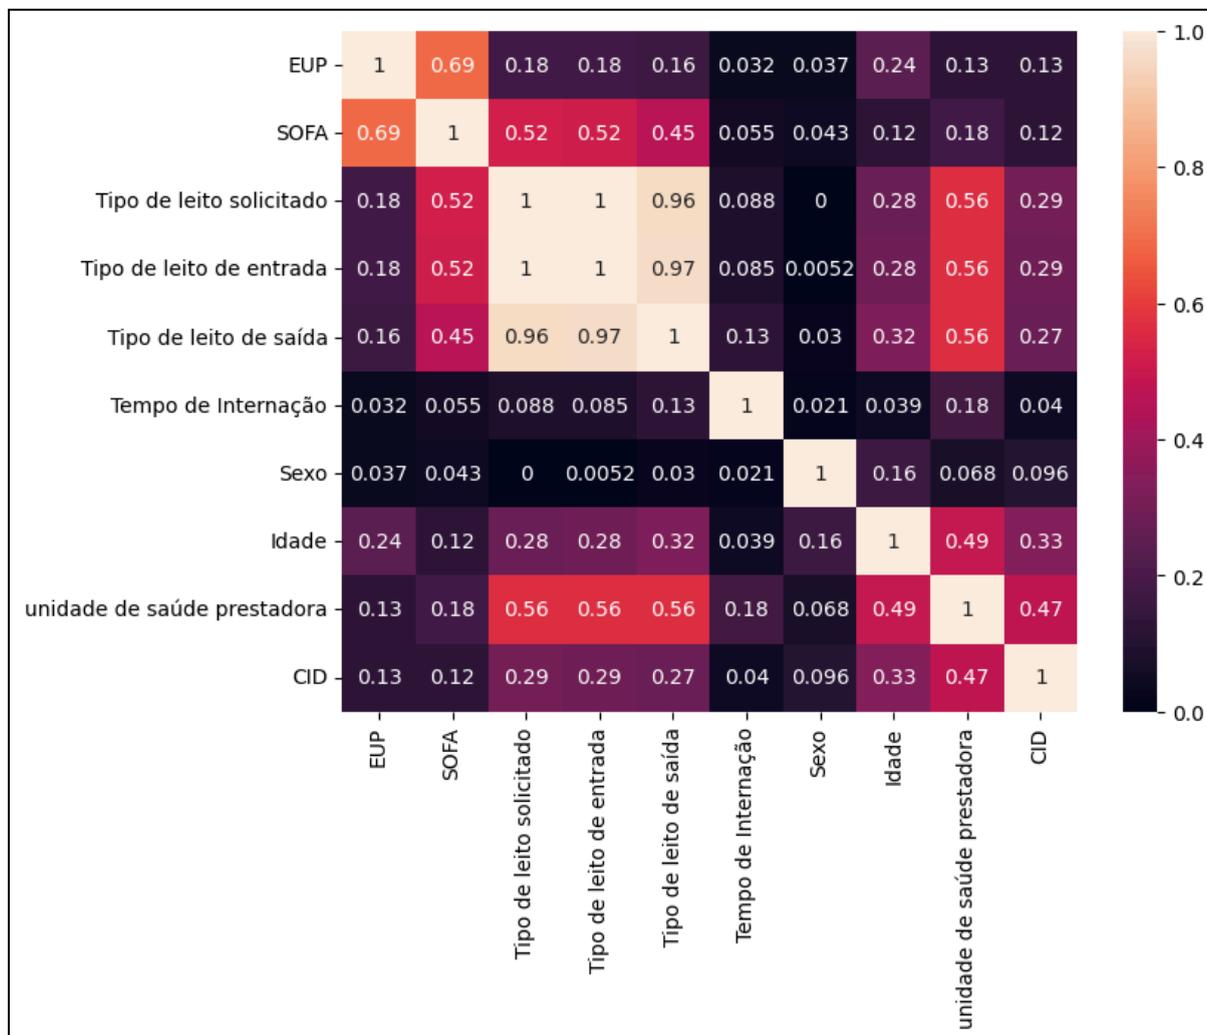


Figura 18 - Matriz de correlação Phik, com dados de óbitos, do RegulaRN Leitos Gerais pediátrico e adulto.



8.3.2 - Dados de neonatais

Nos dados de pacientes neonatais (menos de 28 dias de vida) observa-se uma inversão no tipo de leito, isto é, o maior número de solicitações para as categorias “Tipo de leito solicitado”, “Tipo de de entrada” e “Tipo de leito de saída” são de leito de UTI. Para admissões em leitos de enfermaria, a taxa de mortalidade representa 0,001% do quantitativo total, com apenas um registro de óbito. Quanto ao tempo de internação, é possível identificar uma distribuição normalizada entre os dados dos grupos de tempo de internação, todavia,

identifica-se que há maior frequência de óbitos em pacientes que possuem desfecho em menos de sete dias. A Tabela 10 apresenta o perfil de dados.

Tabela 10 - Perfil de dados do dataset do RegulaRN Leitos Gerais neonatal

Característica		Valor	Desfecho
Tipo de leito Solicitado	Enfermaria	73 (4,46%)	Alta: 73 (100%) Óbito: 0 (0,00%)
	UTI	1564 (95,54%)	Alta: 1408 (90,03%) Óbito: 156 (9,97%)
Tipo de leito de Entrada	Enfermaria	78 (4,76%)	Alta: 77 (98,72%) Óbito: 1 (1,28%)
	UTI	1559 (95,24%)	Alta: 1402 (89,93%) Óbito: 157 (10,07%)
Tipo de leito de Saída	Enfermaria	515 (31,46%)	Alta: 515 (100%) Óbito: 0 (0,00%)
	UTI	1122 (68,54%)	Alta: 964 (85,92%) Óbito: 158 (14,08%)
Unidade de Saúde Prestadora	Hospital prestador 1	88 (5,38%)	Alta: 85 (96,59%) Óbito: 3 (3,41%)
	Hospital prestador 5	277 (16,92%)	Alta: 258 (93,14%) Óbito: 19 (6,86%)
	Hospital prestador 9	217 (13,26%)	Alta: 191 (88,02%) Óbito: 26 (11,98%)
	Hospital prestador 11	150 (9,16%)	Alta: 129 (86,00%) Óbito: 21 (14,00%)
	Hospital prestador 12	668 (40,81%)	Alta: 585 (87,57%) Óbito: 83 (12,43%)
	Hospital prestador 14	59 (3,60%)	Alta: 57 (96,61%) Óbito: 2 (3,39%)
	Hospital prestador 19	17 (1,04%)	Alta: 17 (100%) Óbito: 0 (0,00%)
	Hospital prestador 35	144 (8,80%)	Alta: 140 (97,22%) Óbito: 4 (2,78%)
	Hospital prestador	9 (0,55%)	Alta: 9 (100%)

	37		Óbito: 0 (0,00%)
	Hospital prestador 38	8 (0,49%)	Alta: 8 (100%) Óbito: 0 (0,00%)
Tempo de Internação	< 7	607 (37,08%)	Alta: 497 (81,88%) Óbito: 110 (18,12%)
	$7 \leq ti \leq 14$	521 (31,83%)	Altas: 505 (96,93%) Óbitos: 16 (3,07%)
	> 14	509 (31,09%)	Altas: 477 (93,71%) Óbitos: 32 (6,29%)
Desfecho	Altas	1479 (90,35%)	
	Óbitos	158 (9,65%)	

Devido a não disponibilidade de outros dados, não foi possível traçar um perfil estatístico contundente para avaliação. Isso porque para os dados que foram extraídos no período já destacado, a plataforma não registrava valor para EUP ou SOFA, assim como, a idade não há estratificação para dias (considerando que são recém-nascidos), mas sim por anos, e por fim, o sexo também não foi possível extrair. Desse modo, para o tempo de internação, que foi a única variável elegível para avaliação, obteve-se valor médio de 14,11 dias com 16,17 dias de desvio padrão e mediana de 9 dias.

Quanto aos CIDs mais frequentes em recém-nascidos (Tabela 11), doenças de cunho respiratório estão entre as mais frequentes, sendo elas: outros desconfortos respiratórios do recém-nascido (P22.8) e desconforto respiratório não especificado do recém-nascido (P22.9), com maiores registros de incidência nos municípios de Mossoró, Natal e Santa Cruz. Uma consideração interessante é que a cidade de Mossoró possui maior incidência na maioria das doenças de maior prevalência, seguido de Natal, capital do estado.

Tabela 11 - Registros dos CIDs mais recorrentes na base de dados do RegulaRN Leitos Gerais neonatais

Código	Nome	Frequência	Município com maior incidência (Solicitante)	Hospitais que mais tratam
P22.8	Outros desconfortos respiratórios do recém-nascido	431	Mossoró: 208 Natal: 157 Santa Cruz: 28	Hospital Prestador 12: 211 Hospital Prestador 5: 75 Hospital Prestador 9: 51

P22.9	Desconforto Respiratório Não Especificado do Recém-Nascido	309	Natal: 183 Mossoró: 65 Santa Cruz: 27	Hospital Prestador 5: 84 Hospital Prestador 12: 67 Hospital Prestador 9: 46
P07.2	Imaturidade Extrema	112	Mossoró: 74 Natal: 24 Pau dos ferros: 9	Hospital Prestador 12: 83 Hospital Prestador 5: 24 Hospital Prestador 9: 2
J96.0	Insuficiência Respiratória Aguda	97	Mossoró: 84 Pau dos Ferros: 7 Natal: 3	Hospital Prestador 12: 92 Hospital Prestador 5: 2
P22.1	Taquipnéia Transitória do Recém-nascido	53	Mossoró: 48 Natal: 3 Outros*: 1	Hospital Prestador 12: 48 Hospital Prestador 5: 2
P07.3	Outros Recém-nascidos de Pré-termo	47	Natal: 21 Mossoró: 8 Santa Cruz: 4	Hospital Prestador 5: 13 Hospital Prestador 12: 10 Hospital Prestador 9: 8
P01.1	Feto e Recém-nascido Afetados Por Ruptura Prematura Das Membranas	38	Mossoró: 24 Natal: 10 Outros*: 1	Hospital Prestador 12: 25 Hospital Prestador 5: 9 Hospital Prestador 35: 2
P28.5	Insuficiência Respiratória do Recém-nascido	38	Mossoró: 18 Natal: 11 Santa Cruz: 4	Hospital Prestador 12: 21 Hospital Prestador 1: 4 Hospital Prestador 35: 4
P70.4	Outras Hipoglicemias Neonatais	35	Natal: 20 Santa Cruz: 6 Mossoró: 5	Hospital Prestador 5: 11 Hospital Prestador 35: 7 Hospital Prestador 12: 6
P90	Convulsões do Recém-nascido	25	Natal: 9 Ceará-Mirim: 6 Mossoró: 2	Hospital Prestador 1: 7 Hospital Prestador 9: 6 Hospital Maria Alice Fernandes: 5

* existem vários com o mesmo número de registros, sendo preferível suprimir

Quanto ao registro de letalidade geral (Tabela 12), Outros Desconfortos Respiratórios do Recém-nascido (P22.8), Desconforto Respiratório Não Especificado do Recém-nascido (P22.9), Insuficiência Respiratória Aguda (J96.0), Imaturidade Extrema (P07.2) e Taquipneia

Transitória do Recém-Nascido (P22.1) foram as doenças que tiveram maior registro de altas, de modo que P22.1 possui o maior percentual de recuperação positiva (98,1%) já P07.2 possui o percentual mais baixo (73,2%) dos apresentados.

Tabela 12 - Registro de CIDs, no RegulaRN Leitos Gerais neonatais, que geram maior número de altas e óbitos.

Código	Nome	Frequência	Frequência/Total de incidência (%)
Altas			
P22.8	Outros Desconfortos Respiratórios do Recém-nascido	404	93,7%
P22.9	Desconforto Respiratório Não Especificado do Recém-nascido	290	93,8%
J96.0	Insuficiência Respiratória Aguda	86	88,6%
P07.2	Imaturidade Extrema	82	73,2%
P22.1	Taquipneia Transitória do Recém Nascido	52	98,1%
Óbitos			
P07.2	Imaturidade Extrema	30	26,8%
P22.8	Outros Desconfortos Respiratórios do Recém-nascido	27	6,3%
P22.9	Desconforto Respiratório Não Especificado do Recém-nascido	19	6,1%
J96.0	Insuficiência Respiratória Aguda	11	11,3%
P22.0	Síndrome da Angústia Respiratória do Recém-nascido	7	28%

Quanto se avalia pelo tipo de leito (Tabela 13), verifica-se que P22.1 e P07.2 se apresentam ainda como maior e menor taxa de altas, respectivamente (97,8% e 66,3%) para tratamentos em leitos de terapia intensiva. Já as doenças mais prevalentes para esse tipo de leito com desfecho positivo são P22.8 e P22.9 com 91,3% e 91,4%. Esse dado mostra que as unidades hospitalares do estado possuem bons resultados no tratamento de doenças de cunho respiratório. Para as doenças que tiveram tratamento total em leito de enfermagem Sífilis Congênita Não Especificada (A50.9) é a doença mais prevalente com 13 casos, seguida de

Icterícia Neonatal Não Especificada (P59.9) com 9 casos, Onfalite do Recém-nascido Com ou Sem Hemorragia Leve (P38) com 4 registros e Sífilis Não Especificada (A53.9) e Conjuntivite e Dacriocistite Neonatais (P39.1), ambas com 3 registros. Um ponto de destaque é que não houve nenhum registro de óbito para pacientes neonatais que tiveram tratamento geral em leito de enfermaria. Isso demonstra assertividade nos protocolos de cuidados utilizados pela equipe assistencial dos hospitais estaduais.

Tabela 13 - Distribuição de frequências de altas e óbitos por CID e tipo do leito, para o RegulaRN Leitos Gerais neonatal.

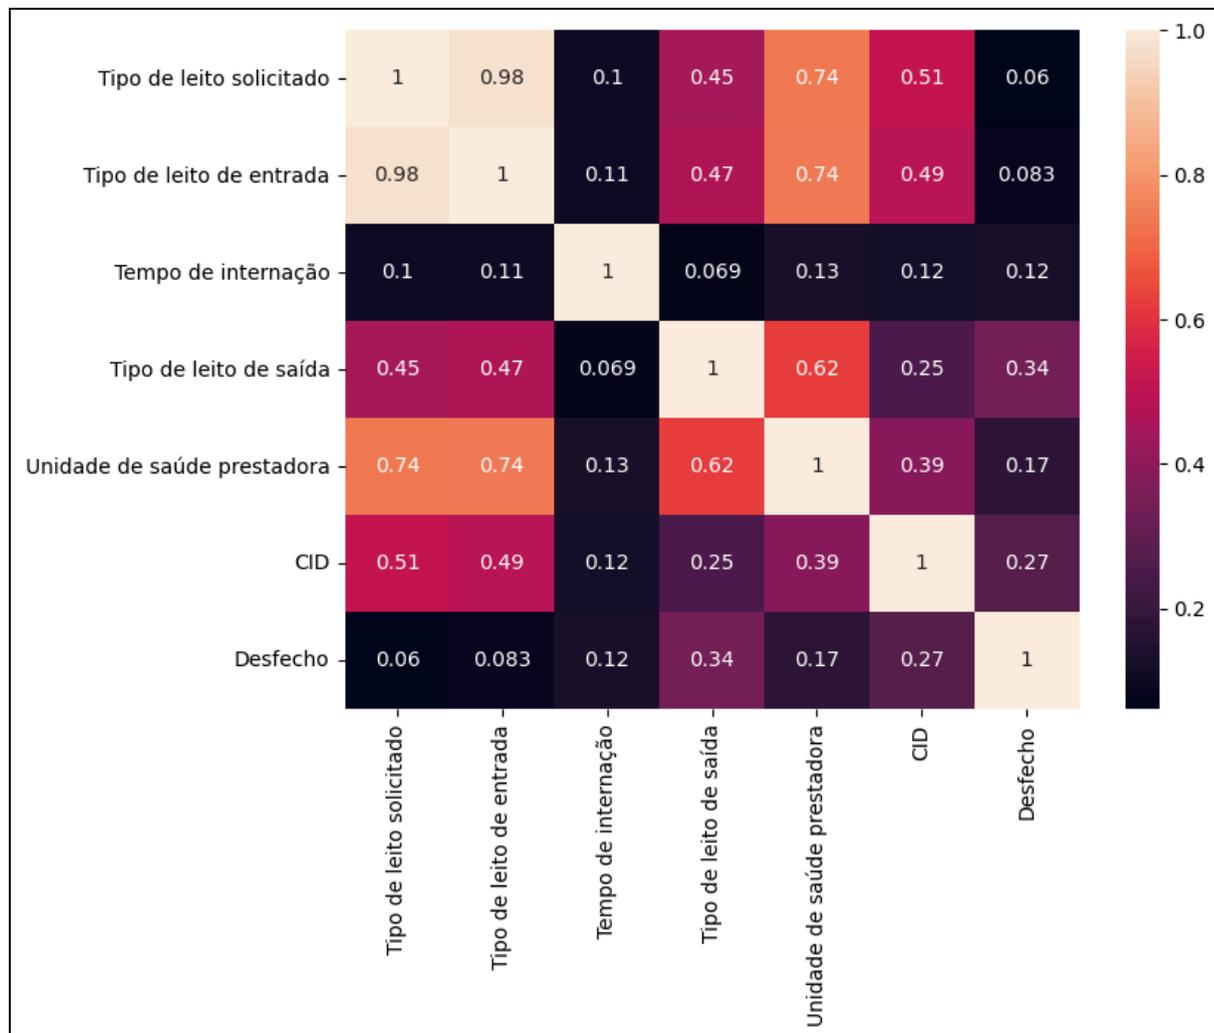
Leito	Código	Nome	Frequência	Frequência/Total de incidência (%)
Altas				
UTI	P22.8	Outros Desconfortos Respiratórios do Recém-nascido	285	91,3%
	P22.9	Desconforto Respiratório Não Especificado do Recém-nascido	201	91,4%
	P07.2	Imaturidade extrema	59	66,3%
	P22.1	Taquipneia Transitória do Recém Nascido	45	97,8%
	J96.0	Insuficiência Respiratória Aguda	42	79,2%
Óbitos				
UTI	P07.2	Imaturidade Extrema	30	33,7%
	P22.8	Outros Desconfortos Respiratórios do Recém-nascido	27	8,7%
	P22.9	Desconforto Respiratório Não Especificado do Recém-nascido	19	8,6%
	J96.0	Insuficiência Respiratória Aguda	11	20,8%
	P22.0	Síndrome da Angústia Respiratória do Recém-nascido	7	43,7%

Altas				
Enferm	A50.9	Sífilis Congênita Não Especificada	13	100%
aria	P59.9	Icterícia Neonatal Não Especificada	9	100%
	P38	Onfalite do Recém-nascido Com ou Sem Hemorragia Leve	4	100%
	A53.9	Sífilis Não Especificada	3	100%
	P39.1	Conjuntivite e Dacriocistite Neonatais	3	100%
Óbitos*				

* não há registros de CID na qual o leito solicitado, de entrada e saída registrou óbito

Quanto à correlação geral de dados dos leitos neonatais (veja a Figura 19), conforme identificado nas outras bases de dados, os tipos de leitos se correlacionam fortemente. E quanto às correlações com o desfecho apenas “Tipo de leito de saída”, “Unidade de saúde prestadora” e “CID” possuem alguma significância com o desfecho, as demais possuem correlação inferior a 12%. Outras correlações interessantes são entre o CID e os tipos de leitos, assim como, o tempo de internação e o tipo do leito. Para a ferramenta, o CID tem ligação direta com o tipo do leito, mas o tempo de internação não tem associação com o tipo do leito, ou seja, não há distinção de maior ou menor tempo de internação a depender de qual leito o paciente esteja.

Figura 19 - Matriz geral de correlação Phik com os dados do RegulaRN Leitos Gerais neonatais.



Ao estratificar a investigação por altas e óbitos (Figura 20 e 21), realizando a mesma correspondência feita anteriormente nota-se que como não houve registro de óbito na característica “Tipo de leito de saída” a matriz de óbitos apresenta uma linha e coluna a menos. Além disso, outro ponto de destaque é que na matriz de óbitos, ao comparar com a de altas, o “Tempo de internação” teve registro de correlação de 0 com as características “Tipo de leito solicitado” e “Tipo de leito de entrada”. Ainda sobre reduções, esse fenômeno aparece também na relação do “Tipo do leito solicitado” e “Tipo de leito de entrada” quando correspondido com “Unidade de saúde prestadora”. Por outro lado, ao examinar aumento de

correspondência, na matriz de óbitos há acréscimo da correlação do “Tempo de internação” com a “Unidade de saúde prestadora” e “Tipo de leito de entrada”.

Figura 20 - Matriz de correlação Phik, com dados de altas, do RegulaRN Leitos Gerais neonatais.

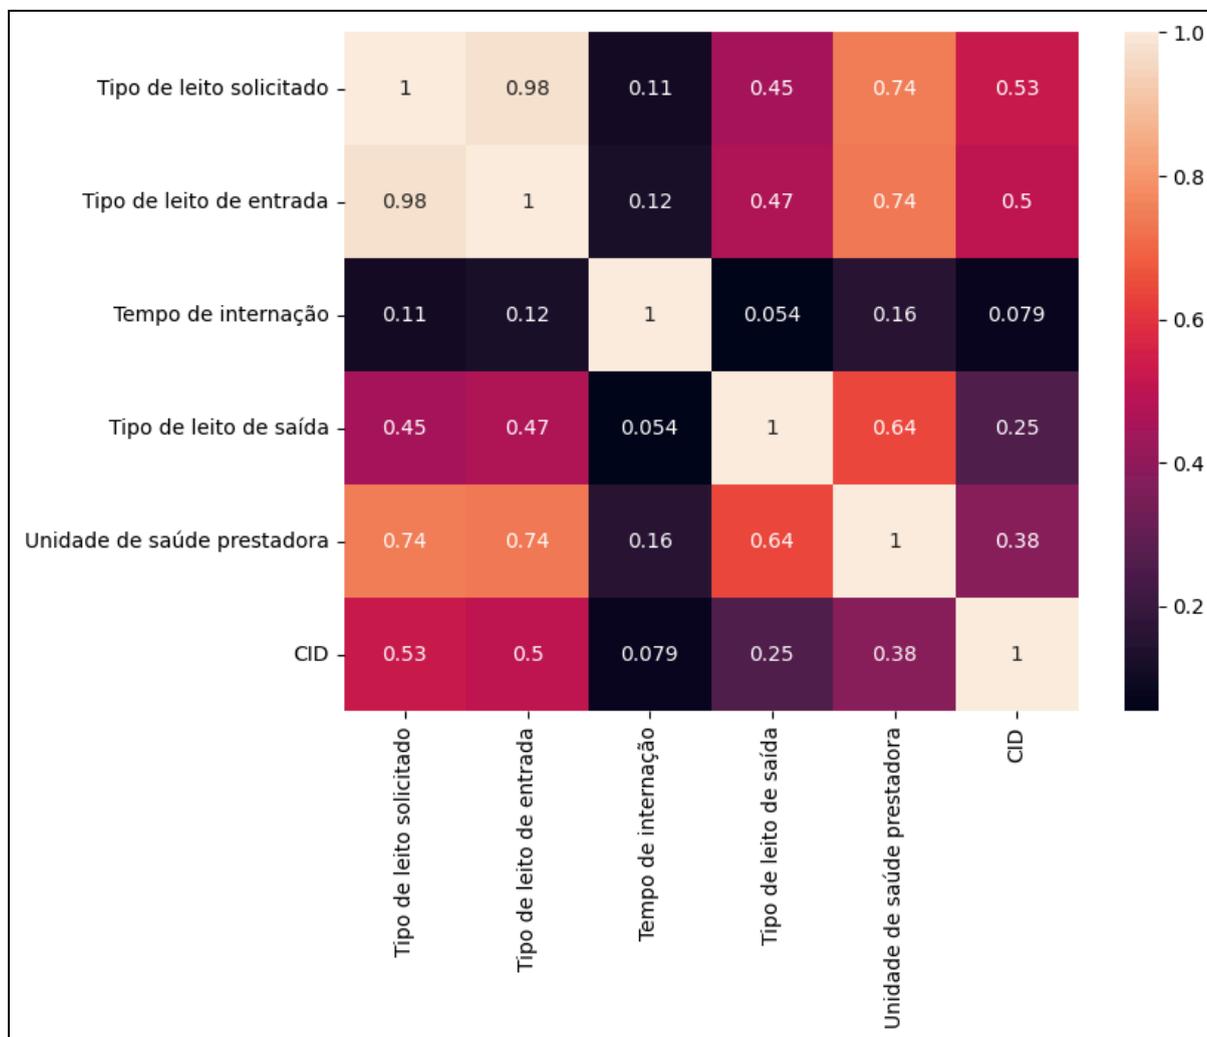
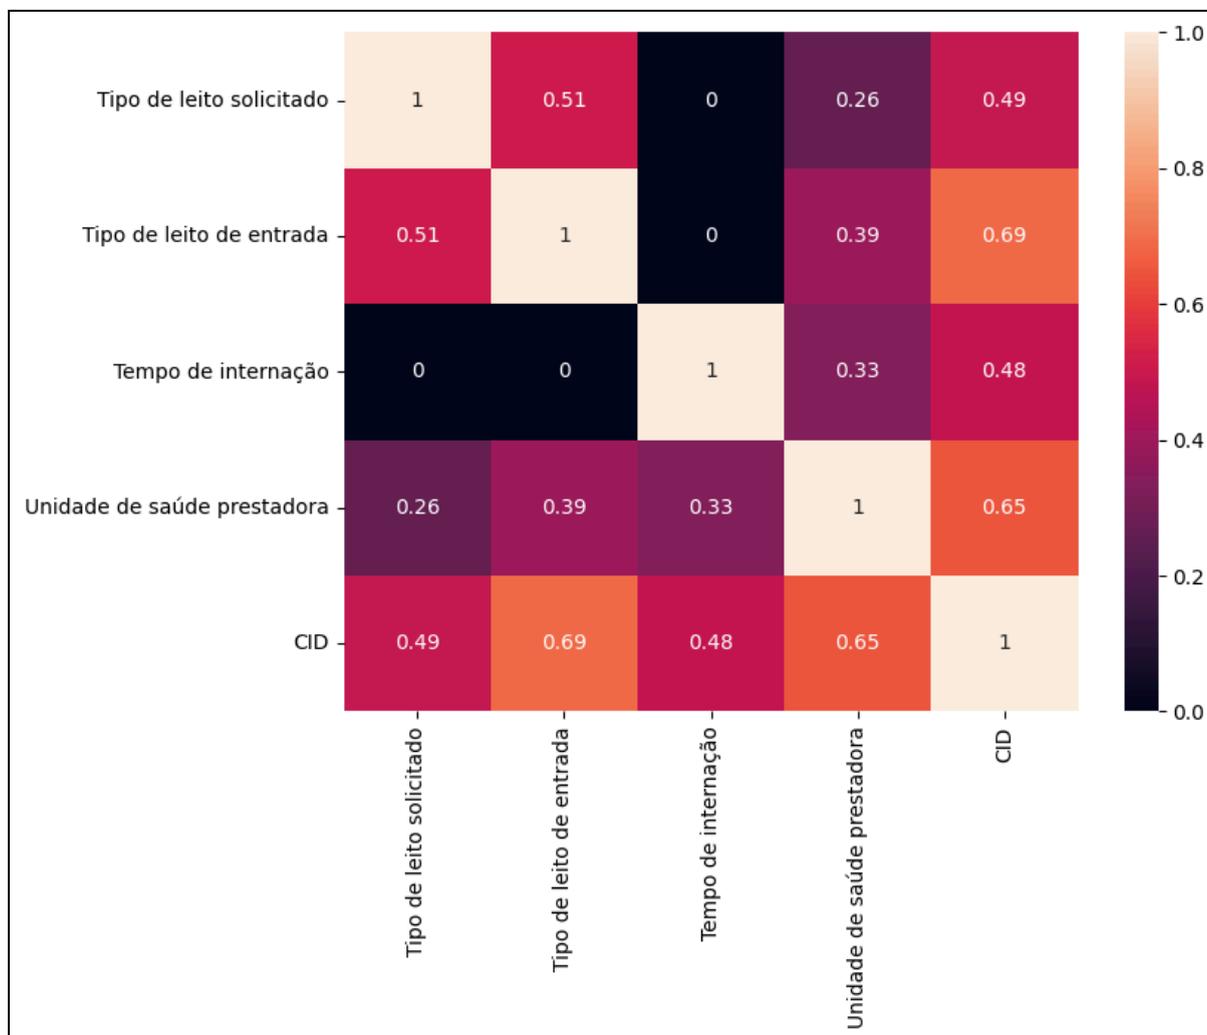


Figura 21 - Matriz de correlação Phik, com dados de óbitos, do RegulaRN Leitos Gerais neonatais.



8.4 - Resultados dos modelos computacionais para a plataforma RegulaRN Leitos Gerais

8.4.1 - RegulaRN Leitos Gerais adultos e pediátricos

Para apresentação dos resultados desta seção será seguido a mesma estrutura feita anteriormente, iniciando pela análise dos valores obtidos pelos modelos na Tabela 2. Para os classificadores Decision Tree e Random Forest, apresentaram os mesmos valores de melhores

parâmetros para *criterion* (valor de *entropy*), *max depth of the tree* (valor de 50) e *max features* (valor de *sqrt*). A mesma circunstância foi identificada no modelo perceptron multicamada com os otimizadores SGD e ADAM, com *hidden_layer_sizes*, *activation*, *batch_size* apresentando igualmente os melhores valores de 70, *relu* e 32, respectivamente. O Gradiente Boosting apresentou melhores valores de *criterion*, *max depth of the tree*, *number estimators* e *max features* com valores de *squared_error*, 10, 50 e *sqrt*, respectivamente. Para o classificador AdaBoost os hiperparâmetros com melhores desempenhos para *learning rate*, *number estimators*, *algorithm* foram 1.0, 400 e *samme.r*, respectivamente. Por fim, o XGBoost apresentou as seguintes melhores pontuações: 0.1 (*learning rate*), 200 (*number estimators*), 50 (*max depth*) e 1.0 (*colsample by tree*).

Sobre os resultados das métricas analisadas (Tabela 14), o modelo XGBoost obteve a maior pontuação em acurácia (87,77%) e revogação (87,77%). A precisão mais elevada foi alcançada pelo modelo Random Forest (87,85%), indicando que ele é o melhor na identificação de desfechos positivos. O valor mais alto de F1-Score foi registrado pelo modelo de Gradiente Boosting (87,56%). Em relação à especificidade, que mede a eficácia na classificação de desfechos negativos, os modelos de perceptron multicamadas se destacaram, com o SGD apresentando a maior pontuação (82,94%).

Tabela 14 - Desempenho dos modelos de acordo com as métricas da matriz de confusão - RegulaRN Leitos Gerais adultos e pediátricos.

Modelos	Acurácia	Precisão	Revogaçã o	F1-Score	Especifici dade
Decision Tree	82,97(+0,13)	84,26(+0,19)	82,96(+0,13)	83,51(+0,1 4)	64,36(+0,42)
Random Forest	87,20(+0,01)	87,85(+0,03)	87,20(+0,01)	87,47(+0,0 1)	72,98(+0,17)
Gradient Boosting	87,14(+0,05)	88,21(+0,03)	87,14(+0,05)	87,56(+0,0 3)	75,47(+0,24)
AdaBoost	86,69(+0,05)	87,76(+0,05)	86,69(+0,05)	87,12(+0,0 5)	74,25(+0,06)
XGBoost	87,77(+0,07)	87,46(0,04)	87,77(+0,07)	87,60(+0,1 0)	66,96(+0,04)
PMC SGD	83,36(+0,17)	88,10(+0,07)	83,36(+0,17)	84,73(0,13)	82,94(+0,50)
PMC ADAM	82,88(+0,76)	87,87(+0,13)	82,88(+0,76)	84,33(+0,6 1)	82,58(+0,62)

Para essa base de dados também foi analisada os valores das *features importances* de cada modelo. Assim, para Decision Tree as colunas “Tipo de leito de saída”, “Idade”, “Unidade de saúde prestadora” e “CID” são as categorias com maior correlação para o desfecho; e “Tipo de leito solicitado”, “Tipo de leito de entrada” e o SOFA com menor correlação. Para Random Forest, “Tipo de leito de saída”, “Idade”, “EUP”, “Unidade de saúde prestadora” e “CID” foram as características com maior correlação, mas “sexo” e “SOFA” foram as características menos pertinentes. No classificador Gradient Boosting, as variáveis mais relevantes foram “Tipo de leito de saída”, “Idade”, “EUP” e “Unidade de saúde prestadora”, enquanto “Sexo”, “Tipo de leito solicitado” e “Tipo de leito de entrada” tiveram menor importância. O AdaBoost considerou “Tempo de internação”, “Unidade de saúde prestadora”, “EUP” e “Idade” como as características principais, com “Sexo”, “Tipo de leito solicitado” e “Tipo de leito de entrada” como menos importantes. No caso do XGBoost, “Tipo de leito de saída”, “EUP” e “Tipo de leito de entrada” foram considerados mais significativos, enquanto “Sexo”, “SOFA” e “Tipo leito solicitado” foram menos relevantes. Para os modelos de PMC, o Adam destacou “Tipo leito de saída”, “Tipo leito solicitado”, “Unidade de saúde prestadora” e “Idade”, enquanto o SGD considerou “Tipo leito de saída”, “Unidade de saúde prestadora”, “Idade” e “CID” como mais importantes. As características menos significativas foram “Tipo leito de entrada” e “Sexo” no Adam, e “Sexo” e “Tipo de leito solicitado” no SGD. As Figuras 22 e 23 apresentam as *features importances* dos modelos dos dados do RegulaRN Leitos Gerais.

Figura 22 - Importância das características para classificação dos modelos de árvore e ensemble para os dados de Leitos Gerais adultos e pediátricos

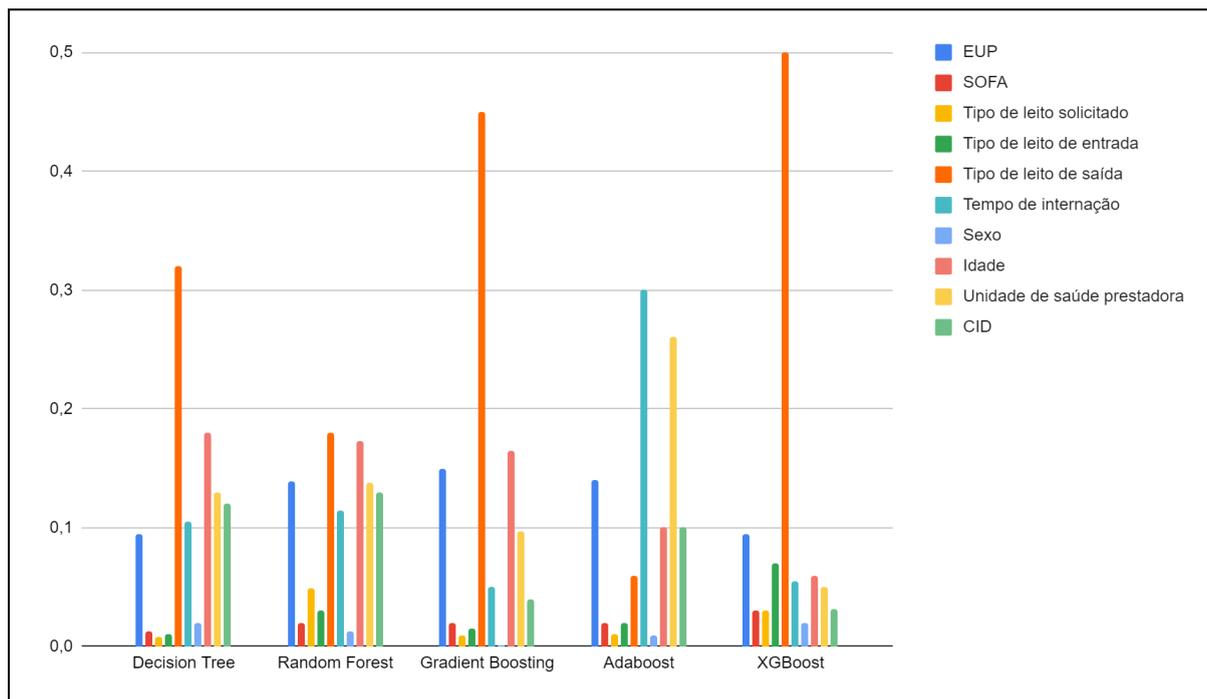
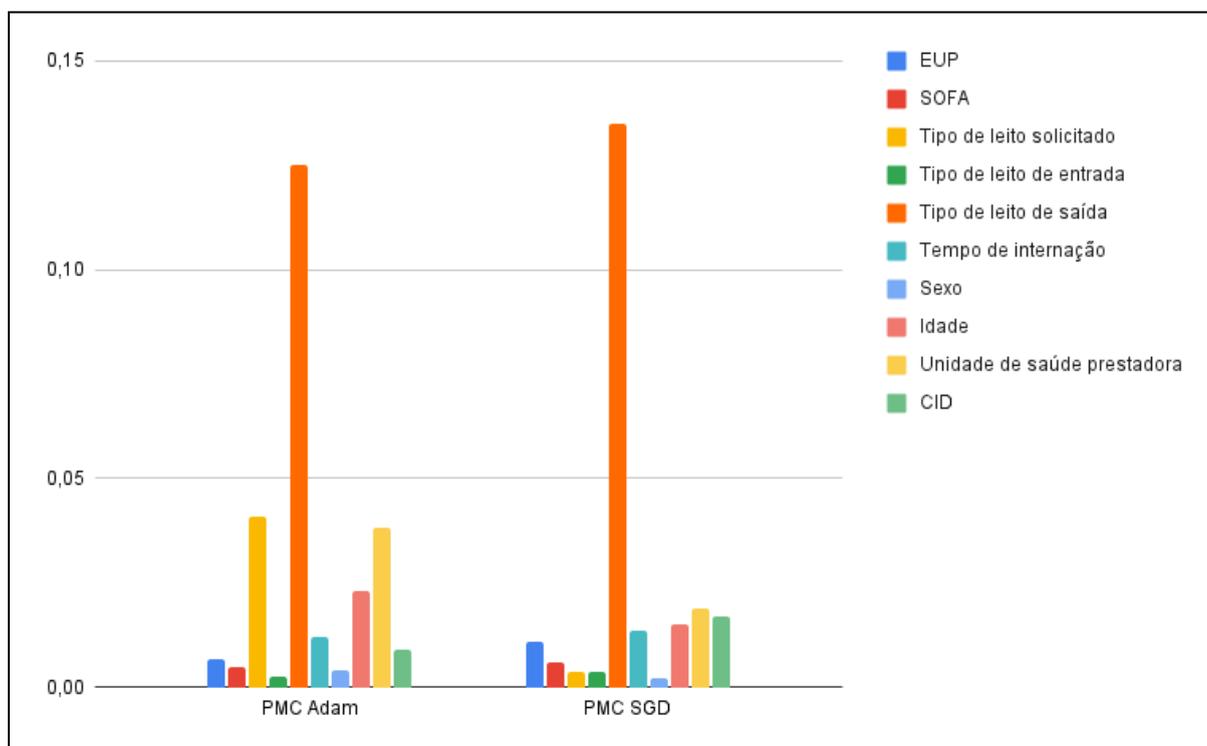


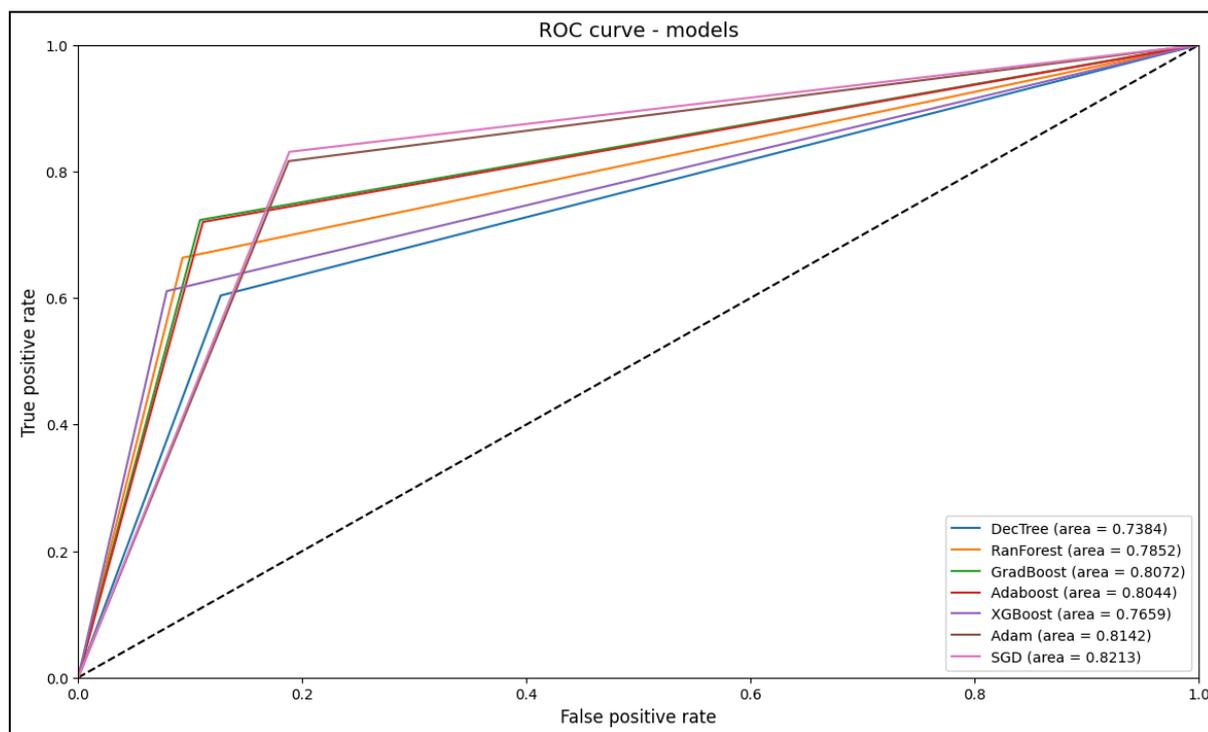
Figura 23 - Importância das características para classificação dos modelos perceptron para os dados de Leitos Gerais adultos e pediátricos



Por fim, foi gerada a curva ROC-AUC dos modelos, que tiveram os seguintes desempenhos: Decision Tree com $AUC = 0,738$, XGBoost com $AUC = 0,766$ e Random

Forest com $AUC = 0,785$, que de acordo com os trabalhos de Hond, Steyerberg e Van Calster (2022) e Nahm et al. (2022) são valores de uma margem considerada de bom desempenho. Já os modelos AdaBoost ($AUC = 0,804$), Adam ($AUC = 0,814$) e SGD ($AUC = 0,821$) obtiveram uma pontuação superior, classificando-os na categoria de muito bom desempenho (Figura 24).

Figura 24 - Curva ROC-AUC para os modelos que utilizaram dados dos Leitos Gerais adultos e pediátricos



8.4.2 - RegulaRN Leitos Gerais neonatais

Ao avaliar o desempenho dos modelos com os dados de recém-nascidos, Decision Tree foi o modelo que apresentou melhor acurácia (87,50%), revogação (87,50%) e F1 Score (88,48%). Já o melhor resultado de precisão foi obtido pelo AdaBoost, com 90,75%, e a melhor especificidade foi apurada pelo PMC Adam (69,41%). De acordo com esses resultados, ressalta-se que mesmo após a realização de métodos de balanceamento de dados e validação cruzada, a pouca quantidade de dados, principalmente para o desfecho negativo, impactou nas métricas do modelo para classificações negativas. Assim, seria necessário maior volume de dados, principalmente de dados de óbito, para que possivelmente os resultados de classificação minoritária tivessem desempenho melhor (Tabela 15).

Tabela 15 - Desempenho dos modelos de acordo com as métricas da matriz de confusão - RegulaRN Leitos Gerais neonatal.

Modelos	Acurácia	Precisão	Revogaçã o	F1-Score	Especifici dade
Decision Tree	87,50(+0,67)	89,68(+0,70)	87,50(+0,67))	88,48(+0,69)	46,20(+0,87)
Random Forest	86,89(+0,22)	90,27(+0,57)	86,89(+0,22))	88,32(+0,24)	53,18(+0,72)
Gradient Boosting	86,59(+0,09)	89,83(+0,25)	86,59(+0,09))	87,98(+0,11)	49,63(+0,34)
AdaBoost	83,54(+0,23)	90,75(+0,51)	83,54(+0,23))	86,30(0,37)	63,43(+0,69)
XGBoost	82,93(+0,28)	88,36(+0,38)	82,93(+0,28))	85,27(+0,35)	42,29(0,52)
PMC SGD	69,51(+0,49)	89,99(+0,50)	69,51(+0,49))	76,47(+0,51)	69,25(+1,01)
PMC ADAM	71,34(+0,44)	90,16(+1,47)	71,34(+0,44))	77,81(+0,56)	69,41(+0,67)

Avaliando quanto as *features importances* “Tipo de leito de saída” e “Tempo de internação” estão entre as características mais importantes para classificação dos modelos Decision Tree e Gradient Boosting. Já para Random Forest e AdaBoost, “tempo de internação” e “CID” foram as características mais pertinentes. O modelo XGBoost preconiza “Tipo de leito de saída” e “Unidade de saúde prestadora” como mais relevantes. Ademais, em todos os modelos, o “Tipo de leito de entrada” é a característica de menor importância para previsão do desfecho. Ademais, um ponto de destaque é que para quatro dos modelos, o “Tempo de internação” aparece como um dos critérios mais relevantes, contudo, ao comparar com o que é apresentado na correlação de Phik, em todos os cenários o “Tempo de internação” apresenta baixa correlação com o desfecho (Figura 25).

Já quando se observa o comportamento das *features importances* do perceptron, há uma inversão em comparação com os demais. “Tipo de leito solicitado” e “Tipo de leito de entrada” que eram variantes de baixa correspondência nos modelos de árvores e *ensemble* possuem maior significância para o perceptron. Outro ponto de destaque é que o “Tempo de internação” não aparece mais como preditor forte para classificação, fato esse que contraria os demais modelos, mas concorda com o direcionamento da correlação de Phik (Figura 26).

Figura 25 - Importância das características para classificação dos modelos de árvore e ensemble para os dados de Leitos Gerais neonatais.

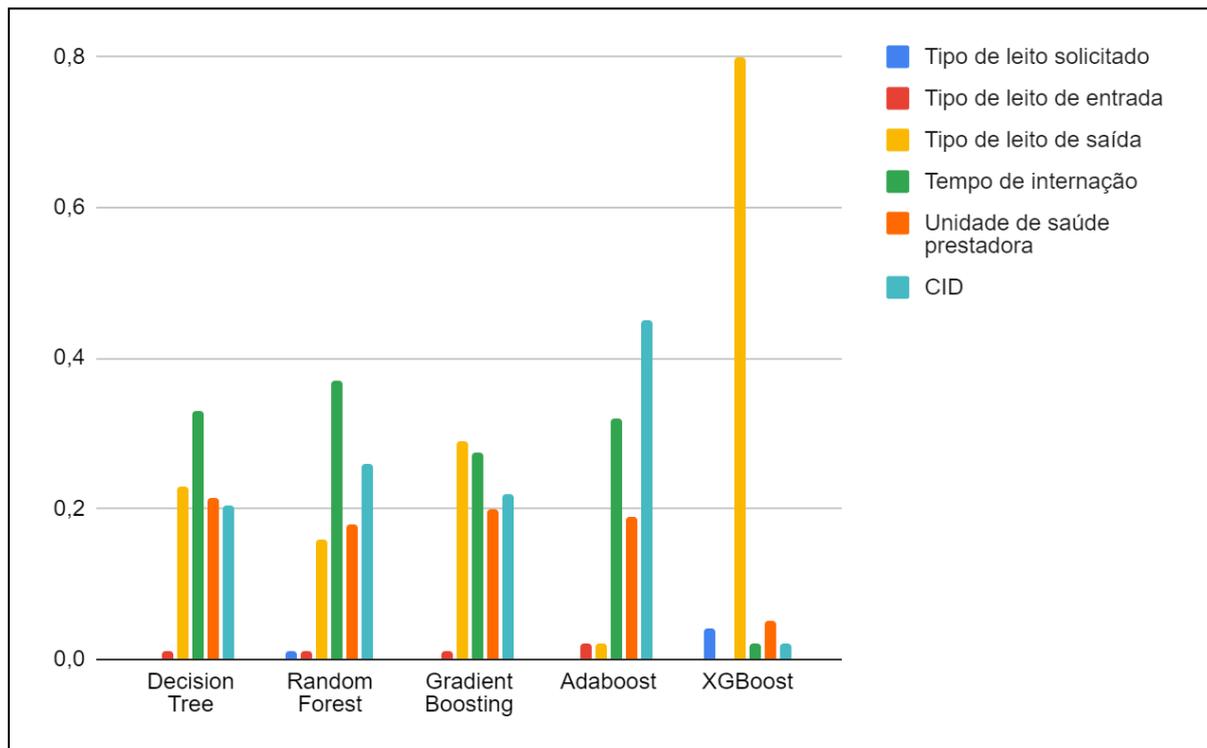
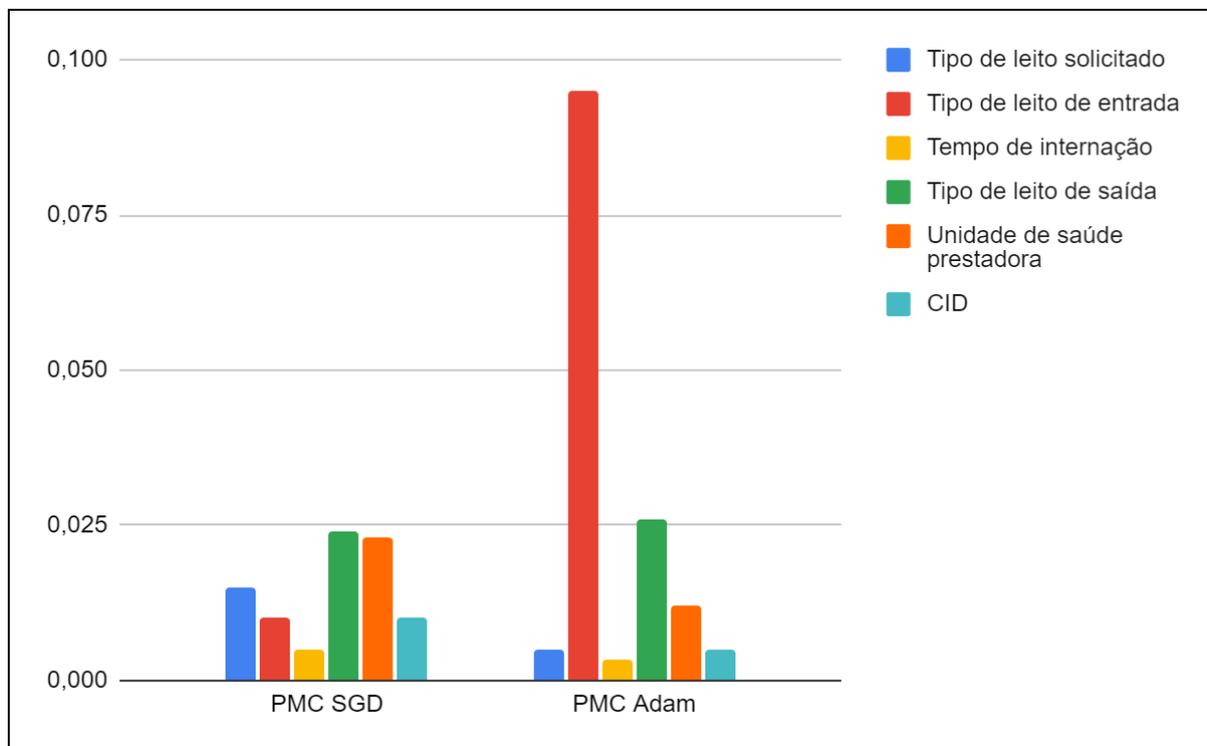
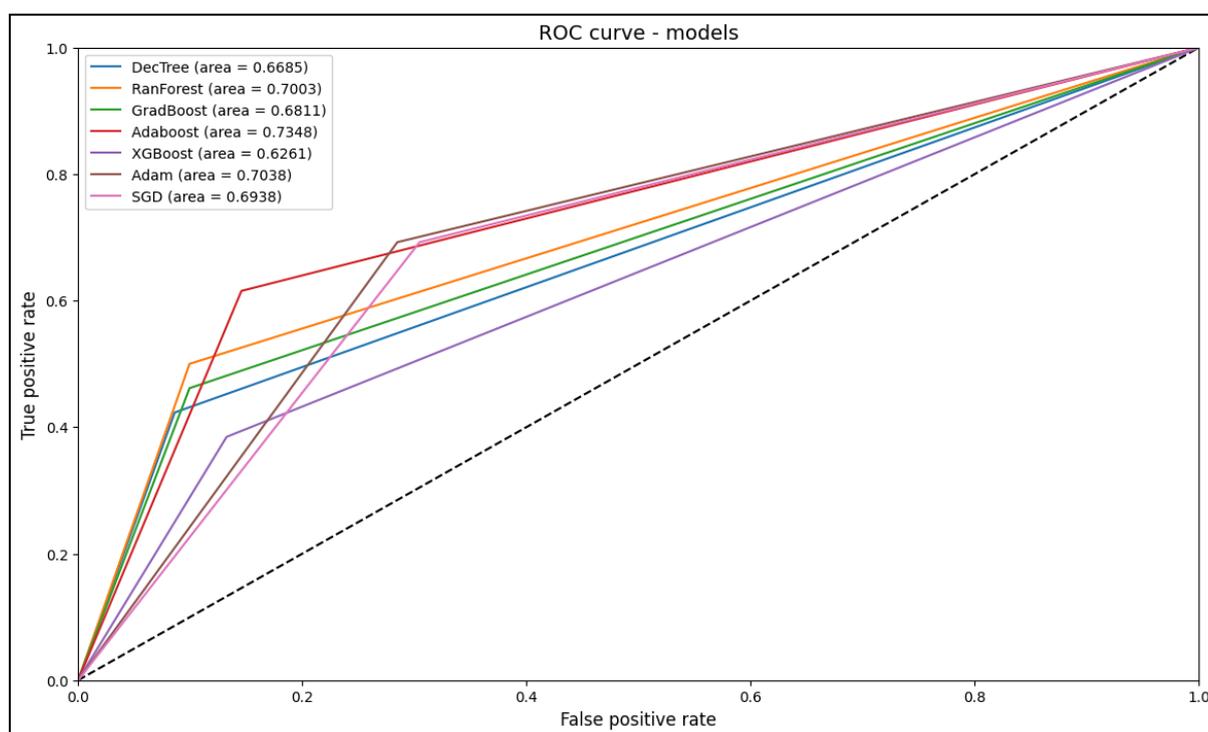


Figura 26 - Importância das características para classificação dos modelos perceptron para os dados de Leitos Gerais neonatais.



Ao gerar a curva ROC-AUC dos dados neonatos, encontra-se uma correspondência com o desempenho dos modelos. Um número baixo de variáveis para serem correlacionadas, assim como, a baixa quantidade de dados com classificação por óbito gerou um desempenho desfavorável na classificação de óbitos. Havendo respaldo em uma especificidade baixa e portanto um valor de curva roc mais baixo, quando comparado com outras bases de dados. Portanto, à vista disso, Random Forest, Adam e AdaBoost foram os modelos que conseguiram equilibrar melhor a taxa de verdadeiros positivos e falsos positivos, com valores acima de 70%.

Figura 27 - Curva ROC-AUC para os modelos que utilizaram dados dos Leitos Gerais neonatais



8.5 - Análise geral dos resultados

Investimentos em sistemas de saúde eficientes têm sido decisivos para o melhor desempenho de diversos setores e instituições, principalmente aquelas que ainda estão em fase de inovação digital, isto é, deixando de realizar seus registros em documentos físicos e trabalhando com recursos digitais. Além disso, conforme reforçado por várias vezes neste trabalho, incluir recursos de inteligência artificial contribuem significativamente para um melhor usufruto da ferramenta.

Nossos resultados compararam o desempenho de onze diferentes métodos computacionais, com três diferentes bases de dados, para a previsão da mortalidade de pacientes a partir de dados de regulação de leitos. Para os dados da COVID-19 o PMC SGD apresentou melhor desempenho de acurácia (84,01%), precisão (79,57%) e F1-Score (81,00%). Já os melhores desempenho em revogação (84,67%), especificidade (84,67%) e ROC-AUC (91,62%) foram obtidos pelo PMC RMSProp. Para os dados do Leitos Gerais adulto e pediátrico, houve maior variabilidade de métricas entre os modelos, isto é, melhores valores de acurácia (87,77%) e revogação (87,77%) foram obtidos pelo XGBoost, melhor precisão (87,85%) pelo Random Forest, melhor F1-Score (87,56%) pelo Gradient Boosting e melhor especificidade e ROC-AUC pelo PMC SGD com percentuais de 82,94% e 82,13%, respectivamente. Para os modelos dessa base de dados já é possível identificar um decaimento na taxa de especificidade entre os classificadores de árvores e *ensemble*, todavia, o perceptron, embora não tenha o melhor desempenho com as classificações positivas, apresenta maior estabilidade e melhor desempenho em classificar a classe negativa. Na base de dados neonatal, é possível identificar que o quantitativo inferior de dados interfere significativamente na classificação negativa, isso porque, embora tenham tido bons valores de acurácia (87,50%), revogação (87,50%), F1-Score(88,48%) em Decision Tree e precisão de 90,75% em AdaBoost, apresentando também maior ROC-AUC (73,48%). Já o maior valor de especificidade foi estimado em 69,71% pelo PMC Adam.

Ademais, a fim de analisar se os resultados dos modelos possuíam significância estatística, foi realizada uma validação de qui-quadrado relacionando os valores reais e previstos. Para isso, foi elaborada uma tabela de contingência com a distribuição dos valores reais e previstos de todos os modelos, nas diferentes bases de dados, e para todos os casos foi obtido um valor de $p < 0,01$.

Uma ressalva importante nesta análise é que para o processo de tomada de decisão, não somente é mais importante selecionar o desempenho daqueles modelos que apontam maiores percentuais para a classificação de altas, ou até mesmo para óbitos. Avaliar o desempenho dos falsos positivos e falsos negativos, que podem incorrer em piores cenários, também é crucial na seleção do classificador mais adequado. Um exemplo típico desse cenário, em situação de pressão por leito, é a regulação encaminhar um paciente que o modelo classificou como alta, mas na verdade ocorreria em óbito, isso porque, além de manter o leito ocupado por um paciente que não se recuperou, o tempo de espera pode

fragilizar os demais pacientes que teriam maiores chances de sobrevivência, este é um fenômeno que Bezerra (2023) chama de “escolha de sofia”.

Portanto, para os dados da COVID-19 se o objetivo for selecionar o modelo que determina melhor altas ou óbitos, em termos de assertividade, o PMC SGD é o melhor classificado. Todavia, se o objetivo do regulador é identificar quais das amostras totais selecionadas foram melhor classificadas, o RMSProp é o otimizador mais recomendado. Nesse mesmo direcionamento, para os dados dos Leitos Gerais Adulto e Pediátrico, o XGBoost apresenta melhor desempenho na classificação do desfecho positivo, assim como, nos dados que foram melhor classificados, já para a assertividade das classificações negativas, o PMC SGD é o mais indicado. Por fim, para os dados neonatais, Decision Tree é o melhor classificador positivo e PMC Adam é o melhor classificador negativo. Assim, para uma tomada de decisão mais assertiva, recomenda-se investigar a predição de todos os modelos anteriormente recomendados, a partir da sua melhor performance na base de dados específica.

Ademais, conforme é destacado por Barreto et al. (2023) os dados utilizados são elementos do mundo real, e nesse sentido, existem variáveis que não podem ser circunstancialmente definidas no momento que o paciente é regulado, sendo elas, tempo de internação e tipo do leito de saída. Por isso, foram realizados testes mantendo igual a zero o tempo de internação e atribuindo o leito de entrada equivalente ao de saída, e ainda assim, os modelos tiveram comportamentos similares aos apresentados.

Capítulo 9

Discussão

O processo de regulação do acesso aos serviços de saúde, como é o caso do acesso aos leitos públicos hospitalares, é uma atividade que requer um olhar atencioso dos complexos reguladores, que no Brasil, geralmente estão situados nas Secretarias Estaduais de Saúde. Todavia, é possível que esses complexos possam existir em algumas Secretarias Municipais de Saúde, especialmente, em municípios com maior número populacional, como Natal/RN por exemplo.

Realizar o empoderamento da regulação de leitos com maiores investimentos é um dos passos primordiais para que haja impactos positivos na assistência em saúde. Esse movimento favorece a qualificação e a eficiência da gestão do processo regulatório, aspecto necessário para mitigar a superlotação, e as filas para internação em hospitais públicos, principalmente em cenários onde há crises de saúde pública. Portanto, investir em sistemas inovadores, como o RegulaRN, é uma ação fundamental para cumprir com etapas importantes da transformação digital da saúde com foco em melhorar a qualidade assistencial do setor público (Kokol et al., 2022). Ademais, incluir inteligência artificial nesses sistemas potencializa ainda mais a eficiência do processo, auxiliando profissionais de saúde com a previsão e classificação de diversos cenários da saúde, implicando em uma tomada de decisão mais assertiva (Cavalcante; Oliveira, 2011; Vilarins et al., 2012; Motta, 2020; Nogueira, 2022; Pecqueux et al., 2022; Zhao et al., 2024).

O RegulaRN é uma ferramenta que possibilita a indução de política pública na saúde, fornecendo, desse modo, qualidade de dados e informações, transparência e equidade no atendimento e na regulação do acesso aos serviços de saúde no estado do Rio Grande do Norte. Trata-se, dessa maneira, de uma solução de saúde digital que pode ser incorporada pelo Sistema Único de Saúde (SUS) em todo o país (Valentim et al., 2021).

Em relação ao RegulaRN, este trabalho analisou três diferentes bases de dados gerados desta plataforma. A partir desses dados, os modelos de inteligência artificial selecionados apontaram percentuais aceitáveis em acordo com as métricas utilizadas. Assim

sendo, é possível afirmar que os modelos propostos e aplicados nesta tese de doutorado podem ser utilizados para auxiliar os processos de tomada de decisão no âmbito do Complexo Estadual de Regulação. Os modelos se mostraram eficientes, com valores de métricas acima de 80% para classificação de dados de regulação de leitos, dessa forma, podem contribuir para mitigar os aspectos subjetivos na indicação de leito, principalmente, em circunstâncias de pressões no qual existe alta demanda por leitos de UTI, como foi a pandemia de COVID-19. Cabe destacar, ainda, que as situações cotidianas vivenciadas nos complexos reguladores, recorrentemente, vivenciam demandas por grandes volumes de solicitações. Isso é recorrente, especialmente, nas redes assistenciais que envolvem os hospitais públicos (Bittencourt; Hortale, 2009; Silva Junior, 2020).

Assim, os modelos utilizados nesta pesquisa são recomendados para auxiliar a tomada de decisão de profissionais de saúde de regulação a partir das sugestões de classificação dos modelos para identificar quais solicitações teriam maior potencial de altas, óbitos, falsos positivos e falsos negativos. Ressalta-se que a avaliação médica é soberana frente às sugestões de qualquer modelo de inteligência artificial, independente da acurácia de classificação que um modelo possa empregar. Além disso, os modelos de aprendizagem de máquina são flexíveis quanto aos dados de entrada, por isso, caso surjam novas características que possam contribuir com a classificação dos modelos, elas poderão ser incorporadas (Barreto et al., 2023). Todavia, é importante destacar que o uso deste tipo de recurso computacional é um facilitador que tem se consolidado nas dimensões dos processos de trabalho no contexto da saúde, e que cada vez mais irá permear os diversos setores e áreas da saúde pública.

No Brasil, mesmo com crescentes iniciativas e investimentos em diferentes setores da saúde, a área da regulação ainda possui um leque amplo para novos investimentos e estudos. Como o Brasil ainda é um país de renda média, em desenvolvimento, com grandes desigualdades sociais, onde mais da metade da população brasileira vive somente com um salário mínimo, há uma quantidade significativa de usuários do Sistema Único de Saúde (SUS), os quais necessitam utilizar a rede assistencial disponível pelo sistema. Portanto, existe no SUS uma grande demanda assistencial, as quais são geralmente maiores do que a capacidade de atendimento dos municípios, estados e da união. Desse modo, os serviços assistenciais oferecidos pelo SUS necessitam constantemente de uma regulação qualificada em todas as suas dimensões. Aspecto que corrobora com os resultados alcançados por meio dos experimentos desta tese de doutorado, ficou demonstrado que é possível intervir de forma racional por meio da inovação tecnológica em saúde, com soluções de saúde digital como é o

caso do RegulaRN baseado na aplicação de Inteligência Artificial. Isso porque, os resultados indicaram por meio dos algoritmos, baseados em inteligência artificial, que a Plataforma RegulaRN contribui para qualificar os processos do complexo regulador da Secretaria de Estado de Saúde Pública do Rio Grande do Norte (SESAP/RN). Milhares de vidas foram salvas durante a pandemia de COVID-19 no RN, muito disso se deve a informação qualificada e oportuna entregue, por meio do RegulaRN, às autoridades sanitárias do estado.

Quanto às perspectivas de saúde digital no Brasil, iniciativas como o ESD28 pressionam todo o ecossistema de saúde pública para que ele se desenvolva de maneira sustentável, bem como, direcionam como os governantes devem adotar estratégias mais eficientes por meio da implementação de sistemas relevantes para atendimento populacional e tomada de decisão de agentes de saúde. A digitalização da saúde e interoperabilidade entre as plataformas é um agregador importante, juntamente com recursos de inteligência artificial, porque unifica a transferência de informações entre as redes de saúde e permite uma visão holística e abrangente das necessidades de saúde da população, facilitando a alocação precisa de recursos e a tomada de decisões.

Ademais, capacitar continuamente os profissionais de saúde é um fator crucial para o sucesso de qualquer processo em um ecossistema de regulação de leitos. É indispensável que médicos, enfermeiros, gestores e demais profissionais estejam sempre atualizados sobre as novas tecnologias e ferramentas disponíveis. Programas de treinamento e educação contínua podem ser implementados para garantir que esses profissionais saibam como utilizar as plataformas digitais de maneira eficaz. Isso não só contribuirá para a melhoria dos serviços ofertados, mas também promoverá um ambiente de trabalho mais eficiente e menos suscetível a erros, impactando positivamente a qualidade do atendimento ao paciente. Implementar uma cultura de inovação e aprendizado contínuo dentro dos ambientes de saúde pública pode transformar a maneira como os serviços de saúde são percebidos e utilizados pela população.

Assim, a pergunta norteadora e questões de pesquisas realizadas no início deste trabalho acadêmico são trazidas novamente à tona para considerar os resultados deste trabalho como respostas delas.

QP1: Quais estudos existem sobre a utilização de inteligência artificial no processo de regulação em saúde de leitos públicos?

Conforme abordado no capítulo 2 intitulado mapeamento sistemático da literatura, as contribuições existentes na temática do uso de inteligência artificial com a regulação de leitos públicos é um tema de baixa exploração acadêmica e vasta possibilidade de investigações.

Para a regulação de leitos, prever o tempo de internação, otimizar a ocupação de leitos e definir a capacidade de internação hospitalar estão entre as atividades mais encontradas na literatura (Cuadrado et al. 2023; Mahmoudian; Nemati; Safaei, 2023; Valente; Roiati; Pugliese, 2022), muito embora apenas os estudos de Mahmoudian, Nemati e Safaei (2023) e Souza Junior et al. (2021) deixem claro em seus trabalhos que utilizaram dados de unidades hospitalares públicas. Assim, conforme já reforçado anteriormente, o único trabalho publicado acerca de regulação de leitos em hospitais públicos que objetiva a classificação do desfecho, com a temática de inteligência artificial, é o proposto por Barreto et al. (2023), um dos frutos deste trabalho.

QP2: Quais os principais objetivos existentes, nos estudos encontrados, em utilizar inteligência artificial no processo de regulação em saúde leitos públicos?

O objetivo geral dos trabalhos avaliados são correspondentes, seus resultados apontam de maneira convergente em procedimentos de previsão capacidade ou ocupação de leitos, já nas discussões dos trabalhos existe um direcionamento que apontam para melhoria da prática clínica, tomada de decisões mais precisas e eficientes, fortalecimento assistencial, auxílio ao diagnóstico de doenças, assertividade diagnóstica, tendo em vista as exaustivas cargas horárias de atendimentos hospitalares. E como consequência direta, haverá disposição mais eficiente dos recursos utilizados para a manutenção da saúde pública.

QN: Até que ponto é possível incluir métodos computacionais de inteligência artificial no processo de regulação de leitos do sistema único de saúde, e como isso pode favorecer a tomada de decisão por parte dos profissionais de saúde e governantes institucionais?

De acordo com a avaliação de trabalhos correlatos elaborada pelo mapeamento sistemático da literatura é possível identificar que a inclusão de inteligência artificial no segmento de regulação de leitos é incipiente, mas que possui possibilidade de novas investigações. Ademais, conforme fora citado também, o sistema único de saúde do Brasil possui setores amplos de regulação que necessitam de métodos computacionais inteligentes para auxiliar os profissionais de saúde em suas atividades. Nos dados utilizados por este trabalho, os modelos conseguiram aprender com as amostras e obtiveram desempenhos acurados para a classificação de desfecho hospitalar. Em períodos de surtos epidêmicos, como foi o da COVID-19, ou de sazonais pressões por leitos, a utilização desses modelos possibilitam um desempenho superior da atividade da regulação, assim como, das entidades governamentais. Esta tese mostrou que é possível incluir métodos computacionais de

inteligência artificial em dados de regulação de leitos, atingindo aceitáveis valores de acurácia, precisão, revogação, F1-Score, especificidade e ROC-AUC para dados de COVID-19, e regulação de acesso aos leitos adultos e pediátricos e neonatais. Assim, este trabalho contribui sistematicamente com a adoção de modelos de classificação na classificação de dados de regulação de leitos em hospitais públicos do SUS.

Quanto às limitações deste estudo, embora os resultados obtidos tenham sido bastante promissores, a base de dados utilizada está voltada para o contexto regulatório do RN, podendo existir a necessidade de algumas adaptações para diferentes regiões do país. A inclusão de novas características pode aprimorar os resultados dos modelos selecionados, possibilitando aumento significativo nas métricas utilizadas, tendo em vista que a adição de novas características pode favorecer a melhor classificação dos modelos e melhorar suas métricas. Além disso, para os dados da COVID-19, existir interoperabilidade dos dados utilizados com a plataforma de vacinação também poderia contribuir com as métricas do modelo, haja vista que o processo de vacinação no Brasil começou a ocorrer a partir de janeiro de 2021, e desse modo, pessoas que foram imunizadas poderiam ter um desfecho diferente daquelas que não foram (Sales-Moilo et al., 2022; Barreto et al, 2023). Quanto aos dados neonatais, a disponibilidade de mais características e maior volume de dados também poderiam melhorar o desempenho dos modelos, principalmente na classificação do desfecho minoritário.

Capítulo 10

Conclusões

Ao longo dos últimos anos a área da saúde tem sido berço para crescentes ciclos de inovação por meio de sistemas de tecnologia de informação e comunicação. A utilização de ferramentas digitais são essenciais para garantir que pacientes, profissionais de saúde e gestores tenham acesso a informações e tratamentos qualificados, para tomada de decisões cada vez mais assertivas (Tavares; Santinha; Gonçalves, 2020). Nesse sentido, os métodos computacionais de inteligência artificial integrados aos sistemas de saúde digital podem potencializar suas utilização porque esses mecanismos podem incorporar relações entre diferentes variáveis que exijam maior complexidade, aprimorando os efeitos diagnósticos no rol da saúde (Panch; Szolovits; Atun, 2018).

Com o intuito de melhorar a problemática de regulação de leitos frente ao cenário da pandemia de COVID-19 o RegulaRN surge como uma plataforma de saúde digital para atender a necessidade regulação de leitos do Estado do RN de maneira eficiente. A partir dos dados gerados, foram incluídos em modelos de aprendizado de máquina para que fosse possível determinar novos desfechos e auxiliar na tomada de decisões. A contribuição deste trabalho se destaca por ser pioneira em utilizar inteligência artificial em dados de regulações de hospitais públicos, no Brasil, para classificação de desfecho hospitalar.

Este trabalho acadêmico considerou a utilização de diferentes modelos de inteligência artificial em dados de um nicho da saúde pública brasileira que não havia exploração significativa. Os modelos utilizados neste trabalho tiveram desempenho de 84,01% (acurácia), 79,57% (precisão), 84,67% (revogação), 81,00% (F1-Score), 84,67% (especificidade) e 91,62% (ROC-AUC) para os dados da COVID-19; 87,77% (acurácia), 87,85% (precisão), 87,77% (revogação), 87,56% (F1-Score), 82,94% (especificidade) e 82,13% (ROC-AUC) para os dados dos Leitos Gerais adulto e pediátrico; e 87,50% (acurácia), 90,75% (precisão), 87,50% (revogação), 88,48% (revogação), 69,71% (especificidade) e 73,48% (ROC-AUC) em dados neonatais. Métricas estas que são consideradas aceitáveis pelo seu percentual de classificação de dados e que contribuem para o

processo de tomada de decisão mais assertiva e fundamentada em previsões, colaborando com o melhor desempenho assistencial do SUS no âmbito da regulação de leitos.

Assim, é possível concluir que os resultados obtidos neste trabalho mostraram-se positivos e além disso compreendem benefícios diretos para a saúde pública, promovendo auxílio para a tomada de decisão no âmbito de regulação de leitos SUS. Ademais, os resultados obtidos por este trabalho validam a hipótese da questão norteadora desta pesquisa, na qual, autentica a possibilidade de utilizar inteligência artificial em dados de regulação de leitos públicos e apresenta quais os principais benefícios para profissionais de saúde e governantes institucionais no processo de tomada de decisão.

Quanto às sugestões de trabalhos futuros, recomenda-se que haja maior exploração na área de regulação de leitos, contemplando a realidade de outros estados brasileiros e suas respectivas individualidades quanto aos diferentes modos de condução da regulação e como a inserção de inteligência artificial poderá contribuir nas respectivas demandas assistenciais. Quanto aos desdobramentos deste trabalho, existem diversos segmentos na área de regulação que necessitam de uma avaliação, como por exemplo, a regulação ambulatorial e cirurgias vasculares, que podem também incluir novas pesquisas com aprendizado de máquina ou outros mecanismos computacionais de apoio à decisão.

Sem dúvidas os investimentos em sistemas universais de saúde promovem a inclusão, empoderamento do cidadão e a equidade na saúde, possibilitando a proteção da saúde dos cidadãos mais vulneráveis. No contexto da América Latina, o Brasil está entre os principais países com um sistema de saúde universal mais sustentável, e dessa forma, manter a sustentabilidade financeira do país é um fator importante para garantir o contínuo crescimento sustentável da assistência em saúde e garantir o acesso a todos (Atun et al., 2015).

Referências Bibliográficas

- Abouelyazid, Mahmoud; XIANG, Chen. Machine Learning-Assisted Approach for Fetal Health Status Prediction using Cardiotocogram Data. **International Journal of Applied Health Care Analytics**, v. 6, n. 4, p. 1-22, 2021.
- Agrawal, Tanay. Hyperparameter optimization using scikit-learn. Hyperparameter optimization in machine learning: make your machine learning and deep learning models more efficient, p. 31-51, 2021.
- Ahsan, Md Manjurul et al. Deep MLP-CNN model using mixed-data to distinguish between COVID-19 and Non-COVID-19 patients. **Symmetry**, v. 12, n. 9, p. 1526, 2020.
- Alami, Hassane; GAGNON, Marie-Pierre; FORTIN, Jean-Paul. Digital health and the challenge of health systems transformation. **Mhealth**, v. 3, 2017.
- Alanazi, Abdullah. Using machine learning for healthcare challenges and opportunities. **Informatics in Medicine Unlocked**, v. 30, p. 100924, 2022.
- Aljameel, Sumayh S. et al. Machine learning-based model to predict the disease severity and outcome in COVID-19 patients. **Scientific programming**, v. 2021, p. 1-10, 2021.
- Andrade, Filomena Marques Queiroz de. **Desenvolvimento de módulo educacional on-line para profissionais que atuam nos Núcleos Internos de Regulação dos estabelecimentos assistenciais de saúde brasileiros**. 2023. Dissertação de Mestrado. Universidade Federal do Rio Grande do Norte.
- Appolinário, Fábio. Dicionário de metodologia científica: um guia para a produção do conhecimento científico. In: Dicionário de metodologia científica: um guia para a produção do conhecimento científico. 2007. p. 300-300.
- An, Qi et al. A comprehensive review on machine learning in healthcare industry: classification, restrictions, opportunities and challenges. **Sensors**, v. 23, n. 9, p. 4178, 2023.
- Atun, Rifat et al. Health-system reform and universal health coverage in Latin America. **The Lancet**, v. 385, n. 9974, p. 1230-1247, 2015.

- Baak, Max et al. A new correlation coefficient between categorical, ordinal and interval variables with Pearson characteristics. **Computational Statistics & Data Analysis**, v. 152, p. 107043, 2020.
- Babu, D. Vijendra et al. Performance analysis of cost and accuracy for whale swarm and RMSprop optimizer. In: **IOP Conference Series: Materials Science and Engineering**. IOP Publishing, 2020. p. 012080.
- Barbalho, Ingridy MP et al. Electronic health records in Brazil: Prospects and technological challenges. **Frontiers in Public Health**, v. 10, p. 963841, 2022.
- Barbalho, Ingridy MP et al. Digital health solution for monitoring and surveillance of Amyotrophic Lateral Sclerosis in Brazil. **Frontiers in Public Health**, v. 11, p. 1209633, 2023.
- Barbosa, Deise Santana de Jesus; Guimarães, Maria do Carmo Lessa. Os atores da regulação assistencial no SUS: quem regula a rede?. **Saúde em Debate**, v. 45, p. 287-299, 2021.
- Bastos, Luzia Beatriz Rodrigues et al. Práticas e desafios da regulação do Sistema Único de Saúde. **Revista de Saúde Pública**, v. 54, 2020.
- Berrar, Daniel. Cross-Validation. **Encyclopedia of Bioinformatics and Computational Biology**, v. 1, n. April, p. 542-545, 2019.
- Bertotti, Bárbara Mendonça; BLANCHET, Luiz Alberto. Perspectivas e desafios à implementação de Saúde Digital no Sistema Único de Saúde: Perspectives and challenges to the implementation of Digital Health in the Unified Health System. **International Journal of Digital Law**, v. 2, n. 3, p. 93-111, 2021.
- Bezerra, Maria Valéria. **Análise da utilização da Escala Quick Sequential Organ Failure Assessment para tomada de decisão na regulação de leitos de UTI**. 2023. Dissertação de Mestrado. Universidade Federal do Rio Grande do Norte.
- Bezerra, Mirella Rebello et al. Priorização para garantir cuidado na pandemia COVID-19. **Revista Brasileira de Saúde Materno Infantil**, v. 21, p. 519-527, 2021.
- Bian, Jiang; Modave, François. The rapid growth of intelligent systems in health and health care. **Health Informatics Journal**, v. 26, n. 1, p. 5-7, 2020.
- Bittencourt, Roberto José; Hortale, Virginia Alonso. Intervenções para solucionar a superlotação nos serviços de emergência hospitalar: uma revisão sistemática. **Cadernos de Saúde Pública**, v. 25, n. 7, p. 1439-1454, 2009.

- Blagus, Rok; Lusa, Lara. SMOTE for high-dimensional class-imbalanced data. **BMC bioinformatics**, v. 14, p. 1-16, 2013.
- Bock, Sebastian; Weib, Martin. A proof of local convergence for the Adam optimizer. In: **2019 international joint conference on neural networks (IJCNN)**. IEEE, 2019. p. 1-8.
- Boni, Raquel Brandini de; Falcão, Matheus Zuliane; Murtinho, Rodrigo. Debatendo a saúde digital no Brasil. **Revista Eletrônica de Comunicação, Informação & Inovação em Saúde**, v. 17, n. 3, 2023.
- Bouhamed, Heni; Hamdi, Monia; Gargouri, Rahma. Covid-19 Patients' Hospital Occupancy Prediction During the Recent Omicron Wave via some Recurrent Deep Learning Architectures. **International Journal Of Computers Communications & Control**, v. 17, n. 3, 2022.
- Brasil. Portaria nº 1.559, de 1º de agosto de 2008. Institui a Política Nacional de Regulação do Sistema Único de Saúde-SUS. **Diário Oficial da União**, 2008.
- Brasil, Ministério da Saúde. Estratégia de Saúde Digital para o Brasil 2020-2028. 2020a. Disponível em: https://bvsms.saude.gov.br/bvs/publicacoes/estrategia_saude_digital_Brasil.pdf. Acesso em: 30 jan. 2024.
- Brasil. Ministério da Saúde. Portaria Nº 1.434, de 28 de maio de 2020b. Disponível em: <https://www.in.gov.br/en/web/dou/-/portaria-n-1.434-de-28-de-maio-de-2020-25914332>. Acesso em: 01 mar. 2024.
- Brasil, Senado Federal do. Constituição da república federativa do Brasil. Brasília: Senado Federal, Centro Gráfico, 1988.
- Bradley, Andrew P. The use of the area under the ROC curve in the evaluation of machine learning algorithms. **Pattern recognition**, v. 30, n. 7, p. 1145-1159, 1997.
- Breiman, Leo. Random forests. **Machine learning**, v. 45, p. 5-32, 2001.
- Breiman, Leo. Population theory for boosting ensembles. **The Annals of Statistics**, v. 32, n. 1, p. 1-11, 2004.
- Brewer, LaPrincess C. et al. Back to the future: achieving health equity through health informatics and digital health. **JMIR mHealth and uHealth**, v. 8, n. 1, p. e14512, 2020.

- Cauchick Miguel, Paulo Augusto, et al. Metodologia De Pesquisa Em Engenharia De Produção E Gestão De Operações. 2. ed. Rio de Janeiro: **Elsevier Editora Ltda**, 2012. 265 p.
- Caleffe, Luiz Gonzaga; MOREIRA, Herivelto. Metodologia da pesquisa para o professor pesquisador. **ILJ**, v. 17, p. 1, 2006.
- Camargo, Fausto; DAROS, Thuinie. A sala de aula inovadora-estratégias pedagógicas para fomentar o aprendizado ativo. **Penso Editora**, 2018.
- Carvalho, Marília Sá; LOPES, Claudia. Métodos em estudos de coorte. **Revista Brasileira de Epidemiologia**, v. 8, p. 234-235, 2005.
- Cavalcante, Claudiana Silva; Oliveira, Lúcia Conde de. Regulação assistencial: estratégia de publicização do acesso a leitos da Unidade de Terapia Intensiva em Fortaleza, Ceará. **Saúde em Debate**, v. 35, n. 89, p. 321-330, 2011.
- Charbuty, Bahzad; ABDULAZEEZ, Adnan. Classification based on decision tree algorithm for machine learning. **Journal of Applied Science and Technology Trends**, v. 2, n. 01, p. 20-28, 2021.
- Chauhan, Harvinder; CHAUHAN, Anu. Implementation of decision tree algorithm c4. 5. **International Journal of Scientific and Research Publications**, v. 3, n. 10, p. 1-3, 2013.
- Chawla, Nitesh V. et al. SMOTE: synthetic minority over-sampling technique. **Journal of artificial intelligence research**, v. 16, p. 321-357, 2002.
- Chen, Chuanrui; DING, Shichao; WANG, Joseph. Digital health for aging populations. **Nature medicine**, v. 29, n. 7, p. 1623-1630, 2023.
- Chen, Po-Hsuan Cameron; LIU, Yun; PENG, Lily. How to develop machine learning models for healthcare. **Nature materials**, v. 18, n. 5, p. 410-414, 2019.
- Chen, Tianqi et al. Xgboost: extreme gradient boosting. R package version 0.4-2, v. 1, n. 4, p. 1-4, 2015.
- Chollet, Francois. Deep learning mit python und keras: das praxis-handbuch vom entwickler der keras-bibliothek. **MITP-Verlags GmbH & Co. KG**, 2018.
- Clark, Robert D.; Webster-Clark, Daniel J. Managing bias in ROC curves. **Journal of computer-aided molecular design**, v. 22, p. 141-146, 2008.

- Cotrim Junior, Dorival Fagundes; CABRAL, Lucas Manoel da Silva. Crescimento dos leitos de UTI no país durante a pandemia de Covid-19: desigualdades entre o público x privado e iniquidades regionais. *Physis: Revista de Saúde Coletiva*, v. 30, 2020.
- Cordeiro, Michelle Ferreira. SISREG: uma ferramenta de desafios e avanços para a garantia do direito a saúde. 2015.
- Cremepe. Recomenda a utilização do Escore Unificado para Priorização (EUP-UTI) de acesso a leitos de terapia intensiva, assistência ventilatória e palição, como meio de hierarquização da gravidade dos pacientes, na ausência absoluta de leitos suficientes para atender a demanda terapêutica.. **Recomendação Cremepe Nº 05/2020**. 1. ed. Recife, PE, 27 abr. 2020.
- Cruz, Tatiana Patricia Farias da et al. Brazilian Digital Health Index (BDHI): avaliação da maturidade da saúde digital do Brasil. *Journal of Health Informatics*, v. 14, 2022.
- Cruz, Tatiana Patricia Farias da; LOPES, Paulo Roberto de Lima; PISA, Ivan Torres. Modelos de maturidade para Saúde Digital: revisão integrativa. 2021.
- Cuadrado, David; VALLS, Aida; RIAÑO, David. Predicting Intensive Care Unit Patients' Discharge Date with a Hybrid Machine Learning Model That Combines Length of Stay and Days to Discharge. *Mathematics*, v. 11, n. 23, p. 4773, 2023.
- Cucinotta, Domenico; VANELLI, Maurizio. WHO declares COVID-19 a pandemic. *Acta bio medica: Atenei parmensis*, v. 91, n. 1, p. 157, 2020.
- Dauphin, Yann; Vries, Harm de; Bengio, Yoshua. Equilibrated adaptive learning rates for non-convex optimization. *Advances in neural information processing systems*, v. 28, 2015.
- Debnath, Shubham et al. Machine learning to assist clinical decision-making during the COVID-19 pandemic. *Bioelectronic medicine*, v. 6, p. 1-8, 2020.
- Dhillon, Arwinder; SINGH, Ashima. Machine learning in healthcare data analysis: a survey. *Journal of Biology and Today's World*, v. 8, n. 6, p. 1-10, 2019.
- Du, Ning; Sun, Xin; Zhang, Yunfeng. The Significance of the Popularization and Promotion of Artificial Intelligence Technology (AI) in the Teaching of Medical Universities. *Contemporary Education and Teaching Research*, v. 5, n. 7, p. 523-258, 2024.
- Duchi, John; Hazan, Elad; Singer, Yoram. Adaptive subgradient methods for online learning and stochastic optimization. *Journal of machine learning research*, v. 12, n. 7, 2011.

- Dutra, João Gabriel Vitorino; Lenzi, Eduarda Letícia; Lisieski, Nadia. Regulação de leitos: número de pacientes no aguardo de leitos UTI COVID-19 no Estado de Santa Catarina. **Revista Recien-Revista Científica de Enfermagem**, v. 12, n. 38, p. 323-338, 2022.
- Elemento, Olivier et al. Artificial intelligence in cancer research, diagnosis and therapy. **Nature Reviews Cancer**, v. 21, n. 12, p. 747-752, 2021.
- Endo, Patricia Takako et al. Illusion of Truth: Analysing and Classifying COVID-19 Fake News in Brazilian Portuguese Language. **Big Data and Cognitive Computing**, v. 6, n. 2, p. 36, 2022.
- Engel, Guido Irineu. Pesquisa-ação. **Educar em Revista**, p. 181-191, 2000.
- Fafalios, Stefanos; Charonyktakis, Pavlos; Tsamardinos, Ioannis. Gradient boosting trees. **Gnosis Data Analysis PC**, v. 1, 2020.
- Fatehi, Farhad; Samadbeik, Mahnaz; Kazemi, Azar. What is digital health? Review of definitions. In: **Integrated Citizen Centered Digital Health and Social Care**. IOS Press, 2020. p. 67-71.
- Fernández, Alberto et al. SMOTE for learning from imbalanced data: progress and challenges, marking the 15-year anniversary. **Journal of artificial intelligence research**, v. 61, p. 863-905, 2018.
- Franco, Ana O.; GOMES, M. Gabriela M. Desafios e oportunidades na saúde digital. **Cadernos de Saúde Pública**, v. 33, n. 11, p. e00090417, 2017.
- Friedman, Jerome H. Stochastic gradient boosting. **Computational statistics & data analysis**, v. 38, n. 4, p. 367-378, 2002.
- Fushiki, Tadayoshi. Estimation of prediction error by using K-fold cross-validation. **Statistics and Computing**, v. 21, p. 137-146, 2011.
- Garcia, Elias. Pesquisa bibliográfica versus revisão bibliográfica-uma discussão necessária. **Línguas & Letras**, v. 17, n. 35, 2016.
- Gawryszewski, Ana Raquel Bonder; Oliveira, Denize Cristina; Gomes, Antonio Marcos Tosoli. Acesso ao SUS: representações e práticas de profissionais desenvolvidas nas Centrais de Regulação. Physis: **Revista de Saúde Coletiva**, v. 22, p. 119-140, 2012.
- Gil, Antônio Carlos. Metodologia da pesquisa. São Paulo: **Atlas**, 2002.

- Gochhait, Saikat et al. A machine learning solution for bed occupancy issue for smart healthcare sector. **Automatic Control and Computer Sciences**, v. 55, p. 546-556, 2021.
- Gomes, Dennis dos Santos. Inteligência Artificial: conceitos e aplicações. **Revista Olhar Científico**, v. 1, n. 2, p. 234-246, 2010.
- Gonçalves, Bernardo. The Turing test is a thought experiment. **Minds and Machines**, v. 33, n. 1, p. 1-31, 2023.
- Gunasekeran, Dinesh Visva et al. Applications of digital health for public health responses to COVID-19: a systematic scoping review of artificial intelligence, telehealth and related technologies. **NPJ digital medicine**, v. 4, n. 1, p. 40, 2021.
- Habehh, Hafsa; GOHEL, Suril. Machine learning in healthcare. **Current genomics**, v. 22, n. 4, p. 291, 2021.
- Haghighi, Sepand et al. PyCM: Multiclass confusion matrix library in Python. **Journal of Open Source Software**, v. 3, n. 25, p. 729, 2018.
- Hamida, Soufiane et al. Optimization of machine learning algorithms hyper-parameters for improving the prediction of patients infected with COVID-19. In: **2020 IEEE 2nd International Conference on Electronics, Control, Optimization and Computer Science (ICECOC)**. IEEE, 2020. p. 1-6.
- Hanafy, Mohamed; MING, Ruixing. Machine learning approaches for auto insurance big data. **Risks**, v. 9, n. 2, p. 42, 2021.
- Hastie, Trevor et al. Multi-class adaboost. **Statistics and its Interface**, v. 2, n. 3, p. 349-360, 2009.
- Hond, Anne Ah; Steyerberg, Ewout W.; Van Calster, Ben. Interpreting area under the receiver operating characteristic curve. **The Lancet Digital Health**, v. 4, n. 12, p. e853-e855, 2022.
- Horwitz, Leora I. et al. Trends in COVID-19 risk-adjusted mortality rates. **Journal of hospital medicine**, v. 16, n. 2, p. 90-92, 2021.
- Iroju, Olaronke et al. Interoperability in healthcare: benefits, challenges and resolutions. **International Journal of Innovation and Applied Studies**, v. 3, n. 1, p. 262-270, 2013.
- Iwendi, Celestine et al. COVID-19 patient health prediction using boosted random forest algorithm. **Frontiers in public health**, v. 8, p. 357, 2020.

- Kaoudi, Zoi et al. A cost-based optimizer for gradient descent optimization. In: **Proceedings of the 2017 ACM International Conference on Management of Data**. 2017. p. 977-992.
- Kingma, Diederik P.; BA, Jimmy. Adam: A method for stochastic optimization. **arXiv preprint arXiv:1412.6980**, 2014.
- Kiran, Mariam; OZYILDIRIM, Melis. Hyperparameter tuning for deep reinforcement learning applications. **arXiv preprint arXiv:2201.11182**, 2022.
- Kitchenham, Barbara et al. Guidelines for performing systematic literature reviews in software engineering version 2.3. **Engineering**, v. 45, n. 4ve, p. 1051, 2007.
- Kokol, Peter et al. Role of agile in digital public health transformation. **Frontiers in public health**, v. 10, p. 899874, 2022.
- König, Gunnar et al. Relative feature importance. In: **2020 25th International Conference on Pattern Recognition (ICPR)**. IEEE, 2021. p. 9318-9325.
- Kotenko, Natalia Viktorivna; Bohnhardt, Viktoriya. **Digital health projects financing: challenges and opportunities**. 2021.
- Kostkova, Patty. Grand challenges in digital health. **Frontiers in public health**, v. 3, p. 134, 2015.
- Kripka, Rosana Maria Luvezute; Scheller, Morgana; Bonotto, Danusa de Lara. Pesquisa documental na pesquisa qualitativa: conceitos e caracterização. **Revista de Investigaciones de la UNAD**, v. 14, n. 2, 2015.
- Kutafina, Ekaterina et al. Recursive neural networks in hospital bed occupancy forecasting. **BMC medical informatics and decision making**, v. 19, p. 1-10, 2019.
- Labrique, Alain et al. Digital health and health systems of the future. **Global Health: Science and Practice**, v. 6, n. Supplement 1, p. S1-S4, 2018.
- Lehmann, Hans. Research method: Grounded theory for descriptive and exploratory case studies. **The Dynamics of International Information Systems: Anatomy of a Grounded Theory Investigation**, p. 53-65, 2010.
- Lehne, Moritz et al. Why digital medicine depends on interoperability. **NPJ digital medicine**, v. 2, n. 1, p. 79, 2019.

- Lemes, Marcellle Martins; Lemos, Amanda Nunes Lopes Espiñeira. O uso da inteligência artificial na saúde pela Administração Pública brasileira. **Cadernos Ibero-Americanos de Direito Sanitário**, v. 9, n. 3, p. 166-182, 2020.
- Li, Nan et al. Automatic design of machine learning via evolutionary computation: A survey. **Applied Soft Computing**, v. 143, p. 110412, 2023.
- Lima, Jefferson da Costa. **Desafios para a adoção de Inteligência Artificial pelo Sistema Único de Saúde (SUS): ética, transparência e interpretabilidade**. 2022. Tese de Doutorado.
- Lino, Danielli Oliveira da Costa et al. Impact of lockdown on bed occupancy rate in a referral hospital during the COVID-19 pandemic in northeast Brazil. **Brazilian Journal of Infectious Diseases**, v. 24, p. 466-469, 2020.
- Liang, Jingsai. Confusion matrix: Machine learning. **POGIL Activity Clearinghouse**, v. 3, n. 4, 2022.
- Liu, Jiaming et al. Predictive analytics for blood glucose concentration: an empirical study using the tree-based ensemble approach. **Library Hi Tech**, v. 38, n. 4, p. 835-858, 2020.
- Lopes, Marcelo Antônio Cartaxo Queiroga; Oliveira, Gláucia Maria Moraes de; Maia, Luciano Mariz. Saúde digital, direito de todos, dever do Estado?. **Arquivos Brasileiros de Cardiologia**, v. 113, p. 429-434, 2019.
- Maldonado, R. N., Savio, R. O., Feijó, V. B. E. R., Aroni, P., Rossaneis, M. A., Haddad, M., et al. (2021). Hospital indicators after implementation of bed regulation strategies: an integrative review. **Rev. Brasil. de Enferm.** 74, e20200022. doi: 10.1590/0034-7167-2020-0022.
- Mahmood, Tahir et al. Accurate segmentation of nuclear regions with multi-organ histopathology images using artificial intelligence for cancer diagnosis in personalized medicine. **Journal of Personalized Medicine**, v. 11, n. 6, p. 515, 2021.
- Mahmoudian, Younes; Nemati, Arash; Safaei, Abdul Sattar. A forecasting approach for hospital bed capacity planning using machine learning and deep learning with application to public hospitals. **Healthcare Analytics**, v. 4, p. 100245, 2023.
- Malhotra, Ruchika; Meena, Shweta. Empirical validation of cross-version and 10-fold cross-validation for defect prediction. In: **2021 Second International Conference on Electronics and Sustainable Communication Systems (ICESC)**. IEEE, 2021. p. 431-438.

- Mandrekar, Jayawant N. Receiver operating characteristic curve in diagnostic test assessment. **Journal of Thoracic Oncology**, v. 5, n. 9, p. 1315-1316, 2010.
- Martins, Gilberto Andrade. Estudo de caso: uma reflexão sobre a aplicabilidade em pesquisa no Brasil. **Revista de Contabilidade e Organizações**, v. 2, n. 2, p. 9-18, 2008.
- Mathews, Simon C. et al. Digital health: a path to validation. **NPJ digital medicine**, v. 2, n. 1, p. 38, 2019.
- Mehbodniya, Abolfazl et al. Fetal health classification from cardiotocographic data using machine learning. **Expert Systems**, v. 39, n. 6, p. e12899, 2022.
- Mei, Qiaozhu et al. A Turing test of whether AI chatbots are behaviorally similar to humans. **Proceedings of the National Academy of Sciences**, v. 121, n. 9, p. e2313925121, 2024.
- Modolo, Leandro; Carvalho, Sergio; Dias, Thais. Questões da saúde digital para o SUS: a “saúde móvel” e a automação algorítmica do saber-poder da medicina. **Saúde e Sociedade**, v. 32, p. e220245pt, 2023.
- Monard, Maria Carolina; Baranauskas, José Augusto. Conceitos sobre aprendizado de máquina. **Sistemas inteligentes-Fundamentos e aplicações**, v. 1, n. 1, p. 32, 2003.
- Moreira-Junior, J. R. .; Souza-Junior , A. A. de .; Luz, A. E. de J. da . The impact of COVID-19 on the municipal Regulation System (SISREG) of Rio de Janeiro (RJ). **Research, Society and Development**, [S. l.], v. 13, n. 4, p. e5613445564, 2024.
- Moresi, Eduardo et al. Metodologia da pesquisa. **Brasília: Universidade Católica de Brasília**, v. 108, n. 24, p. 5, 2003.
- Motta, Oswaldo Jesus Rodrigues da. Inteligência Artificial Em Saúde Pública: Reflexões Bioéticas. **Revista da JOPIC**, v. 3, n. 6, 2020.
- Moulaei, Khadijeh et al. Comparing machine learning algorithms for predicting COVID-19 mortality. **BMC medical informatics and decision making**, v. 22, n. 1, p. 2, 2022.
- Moura-Júnior, Lincoln de Assis. A Estratégia de saúde digital para o Brasil 2020-2028. **Journal of Health Informatics**, v. 13, n. 1, 2021.
- Mussi, Ricardo Franklin de Freitas et al. Pesquisa Quantitativa e/ou Qualitativa: distanciamentos, aproximações e possibilidades. **Revista Sustinere**, v. 7, n. 2, p. 414-430, 2019.

- Nahm, Francis Sahngun. Receiver operating characteristic curve: overview and practical use for clinicians. **Korean journal of anesthesiology**, v. 75, n. 1, p. 25, 2022.
- Neto, Coelho; Cardoso, Giliate. Integração entre Sistemas de Informação em Saúde: o caso do e-SUS Atenção Básica. 2019.
- Nogueira, Aline. O uso da inteligência artificial como ferramenta de apoio à gestão das ações em saúde na Secretaria de Estado da Saúde de Goiás. **Revista Científica Da Escola Estadual De Saúde Pública De Goiás" Cândido Santiago"**, v. 8, p. 1-15 e80004, 2022.
- Obuchowski, Nancy A. ROC analysis. **American Journal of Roentgenology**, v. 184, n. 2, p. 364-372, 2005.
- Obuchowski, Nancy A.; Bullen, Jennifer A. Receiver operating characteristic (ROC) curves: review of methods with applications in diagnostic medicine. **Physics in Medicine & Biology**, v. 63, n. 7, p. 07TR01, 2018.
- Oemig, Frank; Blobel, Bernd. Modeling digital health systems to foster interoperability. **Frontiers in Medicine**, v. 9, p. 896670, 2022.
- Okada, Shuntaro; Ohzeki, Masayuki; Taguchi, Shinichiro. Efficient partition of integer optimization problems with one-hot encoding. **Scientific reports**, v. 9, n. 1, p. 13036, 2019.
- Oliveira, Marco Aurelio; Vellarde, Guillermo Coca; SÁ, Renato Augusto Moreira de. Entendendo a pesquisa clínica III: estudos de coorte. **Femina**, p. 105-110, 2015.
- Padhy, Sasmita. SMOTE-based Deep LSTM System with GridSearchCV Optimization for Intelligent Diabetes Diagnosis. **J. Electrical Systems**, v. 20, n. 7s, p. 804-815, 2024.
- Paim, Jairnilson Silva. Sistema Único de Saúde (SUS) aos 30 anos. **Ciência & Saúde Coletiva**, v. 23, p. 1723-1728, 2018.
- Panch, Trishan; Szolovits, Peter; Atun, Rifat. Artificial intelligence, machine learning and health systems. **Journal of global health**, v. 8, n. 2, 2018.
- Pandas. Pandas.crosstab. 2024. Disponível em: <https://pandas.pydata.org/docs/reference/api/pandas.crosstab.html>. Acesso em: 30 ago. 2024.
- Paper, David. Scikit-Learn Classifier Tuning from Simple Training Sets. Hands-on Scikit-Learn for Machine Learning Applications: Data Science Fundamentals with Python, p. 137-163, 2020.

- Parajuli, Rojina et al. Challenges and opportunities for implementing digital health interventions in Nepal: A rapid review. **Frontiers in Digital Health**, v. 4, p. 861019, 2022.
- Pearson, Karl. VII. Note on regression and inheritance in the case of two parents. **proceedings of the royal society of London**, v. 58, n. 347-352, p. 240-242, 1895.
- Pecqueux, Mathieu et al. The use and future perspective of Artificial Intelligence—A survey among German surgeons. **Frontiers in Public Health**, v. 10, p. 982335, 2022.
- Pedregosa, Fabian et al. Scikit-learn: Machine learning in Python. **the Journal of machine Learning research**, v. 12, p. 2825-2830, 2011.
- Popescu, Marius-Constantin et al. Multilayer perceptron and neural networks. **WSEAS Transactions on Circuits and Systems**, v. 8, n. 7, p. 579-588, 2009.
- Probst, Philipp; Boulesteix, Anne-Laure; Bischl, Bernd. Tunability: Importance of hyperparameters of machine learning algorithms. **Journal of Machine Learning Research**, v. 20, n. 53, p. 1-32, 2019.
- Puślecki, Tobiasz; Walkowiak, Krzysztof. Hyperparameters Optimization Using GridSearchCV Method for TinyML Models. In: **International Conference on Computer Recognition Systems**. Cham: Springer Nature Switzerland, 2023. p. 63-69.
- Quinlan, J.. Ross . Learning decision tree classifiers. **ACM Computing Surveys (CSUR)**, v. 28, n. 1, p. 71-72, 1996.
- Rachid, Raquel et al. Saúde digital e a plataforma do Estado brasileiro. **Ciência & Saúde Coletiva**, v. 28, p. 2143-2153, 2023.
- Rodríguez, Pau et al. Beyond one-hot encoding: Lower dimensional target embedding. **Image and Vision Computing**, v. 75, p. 21-31, 2018.
- Rigatti, Steven J. Random forest. **Journal of Insurance Medicine**, v. 47, n. 1, p. 31-39, 2017.
- Rumelhart, David E.; Hinton, Geoffrey E.; Williams, Ronald J. Learning representations by back-propagating errors. **Nature**, v. 323, n. 6088, p. 533-536, 1986.
- Russell, Stuart J.; NORVIG, Peter. Artificial intelligence: a modern approach. **Pearson**, 2016.
- Sales-Moioli, Ana Isabela L. et al. Effectiveness of COVID-19 vaccination on reduction of hospitalizations and deaths in elderly patients in Rio Grande do Norte, Brazil.

International journal of environmental research and public health, v. 19, n. 21, p. 13902, 2022.

Sampieri, R.; Collado, C.; Lucio, M. del. Definições dos enfoques quantitativo e qualitativo, suas semelhanças e diferenças. Porto Alegre, RS: **Penso**, 2013.

Sá-Silva, Jackson Ronie et al. Pesquisa documental: pistas teóricas e metodológicas. **Revista brasileira de história & ciências sociais**, v. 1, n. 1, p. 1-15, 2009.

Schapire, Robert E. Explaining adaboost. In: Empirical Inference: Festschrift in Honor of Vladimir N. Vapnik. Berlin, Heidelberg: **Springer Berlin Heidelberg**, 2013. p. 37-52.

Schiele, Julian; Koperna, Thomas; Brunner, Jens O. Predicting intensive care unit bed occupancy for integrated operating room scheduling via neural networks. **Naval Research Logistics (NRL)**, v. 68, n. 1, p. 65-88, 2021.

Scikit-learn. LabelEncoder. 2024a. Disponível em: <https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.LabelEncoder.html>. Acesso em: 03 mar. 2024.

Scikit-learn. OneHotEncoder. 2024b. Disponível em: <https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.OneHotEncoder.html>. Acesso em: 10 abr. 2024.

Scipy. Statistical functions. 2024. Disponível em: <https://docs.scipy.org/doc/scipy/reference/stats.html>. Acesso em: 30 ago. 2024.

Scopus. Analyze search results. 2024. Disponível em: scopus.com. Acesso em: 30 jan. 2024.

Shailaja, K.; Seetharamulu, Banoth; Jabbar, M. A. Machine learning in healthcare: A review. In: **2018 Second international conference on electronics, communication and aerospace technology (ICECA)**. IEEE, 2018. p. 910-914.

Sheng, Cheng; YU, Haizheng. An optimized prediction algorithm based on XGBoost. In: **2022 International Conference on Networking and Network Applications (NaNA)**. IEEE, 2022. p. 1-6.

Silveira, Denise Tolfo; Córdova, Fernanda Peixoto. A pesquisa científica. Métodos de pesquisa. Porto Alegre: **Editora da UFRGS**, 2009. p. 33-44, 2009.

Silva Júnior, Sergio Vital da et al. Superlotação dos serviços de urgência e emergência hospitalar. **Enfermagem Brasil**, v. 19, n. 1, 2020.

- Soares, Patrícia dos Santos Lopes et al. A Precariedade Da Saúde Pública No Brasil. **Revista Ibero-Americana de Humanidades**, Ciências e Educação, p. 17-61, 2023.
- Sousa, Angélica Silva de; Oliveira, Guilherme Saramago de ; Alves, Laís Hilário. A pesquisa bibliográfica: princípios e fundamentos. **Cadernos da FUCAMP**, v. 20, n. 43, 2021.
- Souza-Zinader, Juliana P. A Estratégia da Saúde Digital para o Brasil. **Journal of Health Informatics**, v. 12, n. 4, 2020.
- Souza Junior, Gilberto Nerino de et al. COVID-PA Bulletin: reports on artificial intelligence-based forecasting in coping with COVID-19 pandemic in the state of Pará, Brazil. **Epidemiologia e Serviços de Saúde**, v. 30, p. e2021098, 2021.
- Stiglic, Gregor et al. Interpretability of machine learning-based prediction models in healthcare. Wiley Interdisciplinary Reviews: **Data Mining and Knowledge Discovery**, v. 10, n. 5, p. e1379, 2020.
- Sutskever, Ilya et al. On the importance of initialization and momentum in deep learning. In: **International conference on machine learning**. PMLR, 2013. p. 1139-1147.
- Swedberg, Richard. The production of knowledge: Enhancing progress in social science. **Exploratory research**, v. 2, n. 1, p. 17-41, 2020.
- Tang, Shijia et al. Development and Evaluation of a Gesture Recognition-Based Artificial Intelligence Science Popularization System. **Advances in Educational Technology and Psychology**, v. 7, n. 7, p. 1-8, 2023.
- Tao, Hai et al. Training and testing data division influence on hybrid machine learning model process: application of river flow forecasting. **Complexity**, v. 2020, n. 1, p. 8844367, 2020.
- Tavares, Jéssica; Santinha, Gonçalo; Gonçalves, Luís Jorge. Tecnologias Digitais de Apoio à Tomada de Decisão em Saúde (Digital Technologies to Support Health Decision Making). **Journal of Digital Media and Interaction**, v. 3, n. 9, p. 40-53, 2020.
- Thiollent, Michel. Metodologia da pesquisa-ação. **Cortez Editora**, 2011.
- Thiollent, Michel. Metodologia da pesquisa-ação. **Cortez editora**, 2022.
- Toh, Christopher; BRODY, James P. Applications of machine learning in healthcare. **Smart manufacturing: When artificial intelligence meets the internet of things**, v. 65, 2021.

- Tripp, David. Pesquisa-ação: uma introdução metodológica. **Educação e pesquisa**, v. 31, p. 443-466, 2005.
- Uppal, Mudita et al. Enhancing accuracy in brain stroke detection: Multi-layer perceptron with Adadelta, RMSProp and AdaMax optimizers. **Frontiers in Bioengineering and Biotechnology**, v. 11, p. 1257591, 2023.
- Uçar, Muhammed Kürşad et al. The effect of training and testing process on machine learning in biomedical datasets. **Mathematical Problems in Engineering**, v. 2020, n. 1, p. 2836236, 2020.
- Valente, Emiliano; Roiati, Martina; Pugliese, Francesco. Forecasting the number of intensive care beds occupied by COVID-19 patients through the use of Recurrent Neural Networks, mobility habits and epidemic spread data. **Statistical Journal of the IAOS**, v. 38, n. 2, p. 385-397, 2022.
- Valentim, Ricardo Alexandro de Medeiros et al. The relevance a technology ecosystem in the Brazilian National Health Service's Covid-19 response: the case of Rio Grande do Norte, Brazil. **Ciência & Saúde Coletiva**, v. 26, p. 2035-2052, 2021.
- Vaughan, Liam et al. An exploration of challenges associated with machine learning for time series forecasting of COVID-19 community spread using wastewater-based epidemiological data. **Science of The Total Environment**, v. 858, p. 159748, 2023.
- Vekaria, Bindu et al. Hospital length of stay for COVID-19 patients: Data-driven methods for forward planning. **BMC Infectious Diseases**, v. 21, p. 1-15, 2021.
- Ventura, Magda Maria. O estudo de caso como modalidade de pesquisa. **Revista SoCERJ**, v. 20, n. 5, p. 383-386, 2007.
- Vilca, Marcio Luiz Correa. Pesquisa e ensino: considerações e reflexões. **e-escrita (Nilopolis)**, v. 1, n. 2, p. 59-74, 2010.
- Vilarins, Geisa Cristina Modesto; Shimizu, Helena Eri; Gutierrez, Maria Margarita Urdaneta. A regulação em saúde: aspectos conceituais e operacionais. **Saúde em Debate**, v. 36, p. 640-647, 2012.
- Wazlawick, Raul Sidnei. Metodologia de pesquisa para ciência da computação. **Rio de Janeiro: Elsevier**, 2009.
- Wang, Binghui; GONG, Neil Zhenqiang. Stealing hyperparameters in machine learning. In: **2018 IEEE symposium on security and privacy (SP)**. IEEE, 2018. p. 36-52.

- Wang, Ridong et al. Robust Elective Hospital Admissions With Contextual Information. **IEEE Transactions on Automation Science and Engineering**, 2023.
- Who, World Health Organization. COVID-19: vulnerable and high risk groups. 2019. Disponível em: <https://www.who.int/westernpacific/emergencies/covid-19/information/high-risk-groups>. Acesso em: 05 maio 2024.
- Wojtas, Maksymilian; Chen, Ke. Feature importance ranking for deep learning. **Advances in neural information processing systems**, v. 33, p. 5105-5114, 2020.
- Xgboost. XGBoost Documentation. 2022. Disponível em: <https://xgboost.readthedocs.io/en/stable/>. Acesso em: 05 jul. 2024.
- Yang, Li; Shami, Abdallah. On hyperparameter optimization of machine learning algorithms: Theory and practice. **Neurocomputing**, v. 415, p. 295-316, 2020.
- Yang, Shengping; Berdine, Gilbert. The receiver operating characteristic (ROC) curve. *The Southwest Respiratory and Critical Care Chronicles*, v. 5, n. 19, p. 34-36, 2017.
- Yin, Robert K. Estudo de Caso-: Planejamento e métodos. **Bookman editora**, 2015.
- Yu, Limin et al. Machine learning methods to predict mechanical ventilation and mortality in patients with COVID-19. **PLoS One**, v. 16, n. 4, p. e0249285, 2021.
- Zanella, Liane Carly Hermes et al. Metodologia da pesquisa. **Florianópolis: SEAD/UFSC**, 2006.
- Zhai, Qiangrong et al. Using machine learning tools to predict outcomes for emergency department intensive care unit patients. **Scientific reports**, v. 10, n. 1, p. 20919, 2020.
- Zhao Z, et al. A quantitative analysis of artificial intelligence research in cervical cancer: a bibliometric approach utilizing CiteSpace and VOSviewer. **Front. Onco**, v.14, 1431142, 2024. doi: 10.3389/fonc.2024.1431142..
- Zhang, Chiyuan et al. Theory of deep learning IIb: Optimization properties of SGD. **arXiv preprint arXiv:1801.02254**, 2018.