



UNIVERSIDADE  
ESTADUAL DE LONDRINA

---

LARISSA PADOIN LOPES

**USO DE ALGORITMOS DE *MACHINE LEARNING*:  
PREDIÇÃO DE SINAIS E SINTOMAS RELACIONADOS À  
EXPOSIÇÃO OCUPACIONAL DE TRABALHADORES  
DA SAÚDE À FUMAÇA CIRÚRGICA**

LARISSA PADOIN LOPES

**USO DE ALGORITMOS DE *MACHINE LEARNING*:  
PREDIÇÃO DE SINAIS E SINTOMAS RELACIONADOS À  
EXPOSIÇÃO OCUPACIONAL DE TRABALHADORES  
DA SAÚDE À FUMAÇA CIRÚRGICA**

Dissertação apresentada ao Programa de Pós-Graduação em Enfermagem da Universidade Estadual de Londrina (UEL), como requisito à obtenção do título de Mestre em Enfermagem.

Orientador: Profa. Dra. Renata Perfeito Ribeiro.

Londrina  
2025

Ficha de identificação da obra elaborada pelo autor, através do Programa de Geração Automática do Sistema de Bibliotecas da UEL

Lopes, Larissa Padoin.

USO DE ALGORITMOS DE MACHINE LEARNING: PREDIÇÃO DE SINAIS E SINTOMAS RELACIONADOS À EXPOSIÇÃO OCUPACIONAL DE TRABALHADORES DA SAÚDE À FUMAÇA CIRÚRGICA / Larissa Padoin Lopes. - Londrina, 2025.  
92 f.

Orientador: Renata Perfeito Ribeiro.

Dissertação (Mestrado em Enfermagem) - Universidade Estadual de Londrina, Centro de Ciências da Saúde, Programa de Pós-Graduação em Enfermagem, 2025.

Inclui bibliografia.

1. Algoritmos de Aprendizado de Máquina - Tese. 2. Saúde Ocupacional - Tese. 3. Sinais e Sintomas - Tese. 4. Trabalhadores da Saúde - Tese. I. Ribeiro, Renata Perfeito. II. Universidade Estadual de Londrina. Centro de Ciências da Saúde. Programa de Pós-Graduação em Enfermagem. III. Título.

CDU 616-083

LARISSA PADOIN LOPES

**USO DE ALGORITMOS DE *MACHINE LEARNING*:  
PREDIÇÃO DE SINAIS E SINTOMAS RELACIONADOS À  
EXPOSIÇÃO OCUPACIONAL DE TRABALHADORES  
DA SAÚDE À FUMAÇA CIRÚRGICA**

Dissertação apresentada ao Programa de Pós-Graduação em Enfermagem da Universidade Estadual de Londrina (UEL), como requisito à obtenção do título de Mestre em Enfermagem.

**BANCA EXAMINADORA**

---

Orientador: Profa. Dra. Renata Perfeito Ribeiro  
Universidade Estadual de Londrina – UEL

---

Profa. Dra. Helenize Ferreira Lima Leachi  
Universidade Estadual de Londrina – UEL

---

Prof. Dr. Alexandre Dias Porto  
Chiavegatto Filho  
Faculdade de Saúde Pública da USP – FSP-USP

Londrina, 03 de Setembro de 2025.

Dedico

À minha família, razão de todo o  
meu esforço e dedicação.

Por vocês, que sempre foram minha base, meu  
refúgio e minha maior motivação.

Cada passo dado nesta jornada foi impulsionado  
pelo amor, pelo apoio e pela confiança que sempre  
depositaram em mim.

Esta conquista é tanto minha quanto de vocês,  
pois foi sustentada pelo carinho e pela força que me  
ofereceram ao longo do caminho.

## AGRADECIMENTOS

Agradeço, primeiramente, a Deus, por me guiar, fortalecer e abençoar em cada etapa dessa jornada, dando-me forças nos momentos mais difíceis e inspirando-me a seguir em frente.

Ao meu esposo, Magno, que chegou no meio da minha caminhada e, desde então, tornou tudo mais leve e mais bonito. Obrigada por compartilhar a vida comigo, por todo amor, carinho e, sobretudo, pelo apoio incondicional que me permitiu chegar até aqui. Sua presença foi, e continua sendo, um dos maiores presentes desta jornada. Obrigada por estar ao meu lado nesta reta final e por me apoiar, com tanto amor e paciência, nos próximos desafios que ainda estão por vir.

À minha família, por todo amor, apoio e incentivo, que sempre me impulsionaram a seguir em busca dos meus sonhos. Em especial, à minha mãe, Silvania, que nunca mediu esforços para que eu pudesse conquistar cada um deles, sendo meu alicerce nas horas mais difíceis. Ao meu pai, Tarcísio, que mesmo longe, sempre torceu pela realização dos meus sonhos e me ensinou, com seus princípios, o valor do estudo e a crença de que tudo é possível quando se tem dedicação.

Aos meus amigos, em especial à Vitória, pelas risadas, amizade sincera e pelas palavras de incentivo, que sempre renovaram minha motivação nos momentos mais desafiadores. Vocês foram essenciais para aliviar a pressão e para que eu nunca perdesse o foco no que realmente importa.

À minha orientadora, Prof.<sup>a</sup> Dra. Renata, pela dedicação, paciência e pelas orientações valiosas que foram essenciais para o desenvolvimento desta dissertação. Agradeço também por me acompanhar desde o início da pós-graduação, sempre semeando ideias de pesquisa, incentivando a nunca me acomodar e a buscar constantemente mais conhecimento. Você é um exemplo de profissional e de pessoa, e sua orientação foi fundamental para o meu crescimento acadêmico e pessoal.

Agradeço também à Prof.<sup>a</sup> Helenize, que me acompanhou nessa jornada. Muito obrigada pelas parcerias, pelos conhecimentos compartilhados e pelos conselhos valiosos. Levarei comigo todos os seus ensinamentos, que contribuíram imensamente para a realização deste trabalho e para minha formação.

Ao aluno Carlos Eduardo, e aos professores Dr. André Luiz Salvat Moscato e Dr. João Paulino Lima Silva de Almeida, integrantes do laboratório Maker - Garagem dos Jacarezinhos (GaJac) do Instituto Federal do Paraná, por todo o suporte técnico, colaboração e contribuições fundamentais ao processo de desenvolvimento do algoritmo utilizado neste trabalho.

A todos que, de alguma forma, contribuíram para a realização deste projeto, minha eterna gratidão.

O que conta na vida não é o mero fato de termos vivido. É a diferença que fazemos na vida dos outros que determina o significado da vida que vivemos.

**(Nelson Mandela)**

LOPES, Larissa Padoin. **Uso de algoritmos de *Machine Learning***: predição de sinais e sintomas relacionados a exposição ocupacional de trabalhadores da saúde à fumaça cirúrgica. 2025. 89 p. Dissertação de Mestrado (Mestrado em Enfermagem) – Universidade Estadual de Londrina, Londrina, 2025.

## RESUMO

**Introdução:** A exposição à fumaça cirúrgica é um importante desafio para a saúde ocupacional em hospitais. A pesquisa busca evitar que os sinais e sintomas em trabalhadores expostos evoluam para doenças graves, e o uso de algoritmos de *Machine Learning* surge como uma estratégia inovadora para a detecção precoce e prevenção de adoecimentos ocupacionais. **Objetivo:** Investigar os impactos da exposição à fumaça cirúrgica na saúde ocupacional de trabalhadores de saúde que atuam em centros cirúrgicos, utilizando abordagens de *Machine Learning* para predição de sinais e sintomas. **Método:** A dissertação é composta por dois estudos. O primeiro é um estudo transversal com abordagem preditiva, realizado com dados coletados entre 2021 e 2023 em três instituições de saúde: duas no norte do Paraná e uma no centro do Rio Grande do Sul. A amostra incluiu 364 trabalhadores da saúde, com coleta de dados sociodemográficos, ocupacionais e de intensidade de sinais e sintomas relacionados à exposição ocupacional à fumaça cirúrgica. Para a análise quantitativa, foi utilizada uma Rede Neural Artificial, com o desempenho avaliado por métricas como acurácia, especificidade e sensibilidade. O segundo estudo é uma revisão sistemática, realizada em setembro de 2024, para identificar modelos de *Machine Learning* aplicados na predição de doenças em trabalhadores da saúde. A análise foi qualitativa, sintetizando os resultados de 14 artigos incluídos. **Resultados:** Os resultados do estudo quantitativo demonstraram que o modelo de Rede Neural Artificial foi eficaz na predição de sinais e sintomas. Para o sistema respiratório, o modelo alcançou uma acurácia média de 86,59% no treinamento e 76,50% em operação, apresentando uma alta especificidade de 96,36%, o que indica sua capacidade de identificar corretamente a ausência de sintomas. Para o sistema ocular, a acurácia foi de 77,87% no treinamento e 69,44% em operação, com especificidade de 84,06% e sensibilidade de 67,21%. O estudo de revisão sistemática (estudo qualitativo) revelou que as doenças mais preditas por modelos em trabalhadores da saúde são os transtornos psicossociais (50,0%), seguidos pelas doenças respiratórias (42,86%) e doenças neurológicas (7,14%). Os algoritmos com melhor desempenho foram o *Random Forest*, com valores de área sob a curva (AUC-ROC) de até 0,90, e as *Support Vector Machines*, com AUC-ROC de até 0,94. **Conclusão:** O modelo preditivo utilizado no primeiro estudo, demonstrou desempenho satisfatório, confirmando o potencial das Redes Neurais Artificiais para a identificação precoce de sinais e sintomas associados à exposição à fumaça cirúrgica, respondendo assim ao objetivo e lacuna da pesquisa. A revisão sistemática reforçou que algoritmos de *Machine Learning* têm um bom potencial na predição de doenças em trabalhadores da saúde, especialmente nas áreas mental e respiratória, embora a falta de padronização e a escassez de estudos em países latino-americanos sugiram a necessidade de mais pesquisas e validações de algoritmos em diferentes contextos ocupacionais.

**Palavras-chave:** Algoritmos de Aprendizado de Máquina; Saúde Ocupacional; Sinais e Sintomas; Trabalhadores da Saúde.

LOPES, Larissa Padoin. **Use of *Machine Learning* algorithms:** prediction of signs and symptoms related to occupational exposure of healthcare workers to surgical smoke. 2025. 89 p. Dissertação de Mestrado (Mestrado em Enfermagem) – Universidade Estadual de Londrina, Londrina, 2025.

## ABSTRACT

**Introduction:** Exposure to surgical smoke is a major challenge for occupational health in hospitals. The research aims to prevent the signs and symptoms in exposed workers from progressing to severe diseases, and the use of Machine Learning algorithms emerges as an innovative strategy for early detection and prevention of occupational illnesses. **Objective:** To investigate the impacts of exposure to surgical smoke on the occupational health of healthcare workers in operating rooms, using Machine Learning approaches to predict signs and symptoms. **Method:** The dissertation is composed of two studies. The first is a cross-sectional study with a predictive approach, conducted with data collected between 2021 and 2023 in three healthcare institutions: two in northern Paraná and one in central Rio Grande do Sul. The sample included 364 healthcare workers, with data collection on sociodemographic and occupational characteristics, as well as the intensity of signs and symptoms related to occupational exposure to surgical smoke. For quantitative analysis, an Artificial Neural Network was employed, with performance evaluated through metrics such as accuracy, specificity, and sensitivity. The second study is a systematic review, carried out in September 2024, to identify Machine Learning models applied to disease prediction in healthcare workers. The analysis was qualitative, synthesizing the results of 14 included articles. **Results:** The results of the quantitative study demonstrated that the Artificial Neural Network model was effective in predicting signs and symptoms. For the respiratory system, the model achieved an average accuracy of 86.59% in training and 76.50% in operation, with high specificity of 96.36%, indicating its ability to correctly identify the absence of symptoms. For the ocular system, accuracy was 77.87% in training and 69.44% in operation, with specificity of 84.06% and sensitivity of 67.21%. The systematic review (qualitative study) revealed that the most frequently predicted diseases by models in healthcare workers were psychosocial disorders (50.0%), followed by respiratory diseases (42.86%) and neurological diseases (7.14%). The best-performing algorithms were Random Forest, with area under the curve (AUC-ROC) values up to 0.90, and Support Vector Machines, with AUC-ROC values up to 0.94. **Conclusion:** The predictive model used in the first study demonstrated satisfactory performance, confirming the potential of Artificial Neural Networks for the early identification of signs and symptoms associated with exposure to surgical smoke, thus addressing the objective and research gap. The systematic review reinforced that Machine Learning algorithms hold strong potential for disease prediction in healthcare workers, particularly in mental and respiratory health. However, the lack of standardization and the scarcity of studies in Latin American countries suggest the need for further research and algorithm validation in different occupational contexts.

**Key-words:** Machine Learning Algorithms; Occupational Health; Signs and Symptoms; Health Workers.

## LISTA DE FIGURAS

### ESTUDO 1

- Figura 1** – Evolução da curva da função de perda do treinamento e da validação. Londrina – PR, Brasil, 2024.....33
- Figura 2** – Evolução do percentual de acertos ao longo das épocas do treinamento e validação. Londrina – PR, Brasil, 2024.....34
- Figura 3** – Matriz de confusão utilizada no treinamento da Rede Neural Artificial. Londrina – PR, Brasil, 2024 .....35

### ESTUDO 2

- Figura 1** – Estratégia de busca dos artigos por bases de dados, utilizando os vocabulários controlados de cada base de dados. Brasil, 2025 .....47
- Figura 2** – Fluxograma da revisão sistemática acerca de modelos machine learning aplicados a predição de doenças em trabalhadores da saúde de acordo com *Preferred Reporting Items for Systematic Reviews and Meta-Analyses*. Brasil, 2025. ....49

## LISTA DE TABELAS

### ESTUDO 1

- Tabela 1** – Configuração da Rede Neural Artificial para o sistema respiratório e ocular. Londrina - PR, Brasil, 2024. ....29
- Tabela 2** – Configuração da Rede Neural Artificial para os sistemas respiratório e ocular. Londrina - PR, Brasil, 2024 .....32

### ESTUDO 2

- Tabela 1** – Características relacionadas a autor, ano, país, periódico científico, desenho e amostra dos estudos incluídos na revisão sistemática sobre modelos *Machine Learning* aplicados a previsão de doenças em trabalhadores da saúde. Brasil, 2025.....50
- Tabela 2** – Modelos Machine Learning e métricas de desempenho dos estudos incluídos na Revisão Sistemática sobre modelos *Machine Learning* aplicados a previsão de doenças em trabalhadores da saúde. Brasil, 2025.....51
- Tabela 3** – Risco de viés e aplicabilidade dos estudos incluídos na Revisão Sistemática sobre modelos *Machine Learning* aplicados a previsão de doenças em trabalhadores da saúde de acordo com o *Prediction model Risk Of Bias Assessment Tool*. Brasil, 2025 .....54

## LISTA DE ABREVIATURAS E SIGLAS

AIC	Cr�terios de <i>Akaike</i>
AUC	�rea sob a Curva
BIC	Cr�terios Bayesiano
BVS	Biblioteca Virtual em Sa�de
CINAHL	<i>Cummulative Index to Nursing and Allied Health Literature</i>
CHARMS	<i>Critical Appraisal and Data Extraction for Systematic Reviews of Prediction Modelling Studies</i>
COVID-19	Coronav�rus SARS-CoV-2
DECS	Descritores em Ci�ncias da Sa�de
EASE	Escala para Avalia�o da Intensidade dos Sinais e Sintomas Relacionados � Exposi�o � Fuma�a Cir�rgica
ECG	Eletrocardiograma
EMBASE	<i>Excerpta Medica dataBase</i>
EPI	Equipamentos de Prote�o Individual
GEEST	Grupo de Estudos em Gest�o do Cuidado, Editora�o Cient�fica e Sa�de do Trabalhador
GAD-7	<i>Generalized Anxiety Disorder 7-item</i>
IA	Intelig�ncia Artificial
KNN	<i>K-nearest neighbor</i>
LDRT	Lista de Doen�as Relacionadas ao Trabalho
LILACS	Literatura Latino-Americana e do Caribe em Ci�ncias da Sa�de
LOSS	Evolu�o da curva de perda
MEDLINE	<i>Medical Literature Analysis and Retrieval System Online</i>
ML	<i>Machine Learning</i>
MESH	<i>Medical Subject Headings</i>

NR-01	Norma Regulamentadora-01
NR-32	Norma Regulamentadora 32
ODS	Objetivos de Desenvolvimento Sustentável
ONU	Organização das Nações Unidas
PET	Programa de Educação Tutorial
PRISMA	<i>Preferred Reporting Items for Systematic Reviews and Meta-Analyses</i>
PROBAST	<i>Prediction model Risk Of Bias Assessment Tool</i>
PROSPERO	<i>International Prospective Register of Systematic Reviews</i>
ROC	<i>Receiver Operating Characteristic</i>
RNA	Redes Neurais Artificiais
RS	Revisão Sistemática
SINAN	Sistema de Informação de Agravos de Notificação
SMOTE	<i>Synthetic Minority Oversampling Technique</i>
SST	Segurança e Saúde no Trabalho
SUS	Sistema Único de Saúde
SVM	Máquinas de Vetores de Suporte
TRIPOD	<i>Transparent Reporting of a Multivariable Prediction Model for Individual Prognosis or Diagnosis</i>
TRIPOD-SRMA	<i>Transparent Reporting of Multivariable Prediction Models for Individual Prognosis or Diagnosis: Checklist for Systematic Reviews and Meta-Analyses</i>

## SUMÁRIO

<b>1</b>	<b>APRESENTAÇÃO</b> .....	15
<b>2</b>	<b>CONTEXTUALIZAÇÃO</b> .....	16
<b>3</b>	<b>OBJETIVOS</b> .....	23
3.1	Objetivo geral.....	23
3.1.1	Objetivos específicos.....	23
<b>4</b>	<b>RESULTADOS</b> .....	24
4.1	<b>Estudo 1</b> .....	24
4.1.1	Título.....	24
4.1.2	Resumo .....	24
4.1.3	Abstract .....	25
4.1.4	Introdução .....	26
4.1.5	Material e método .....	27
4.1.6	Resultados .....	31
4.1.7	Discussão .....	35
4.1.8	Conclusão.....	38
4.1.9	Referências.....	39
<b>4.2.</b>	<b>Estudo 2</b> .....	42
4.2.1	Título.....	42
4.2.2	Resumo .....	43
4.2.3	Abstract.....	43
4.2.4	Introdução .....	44
4.2.5	Material e método .....	45
4.2.6	Resultados .....	48
4.2.7	Discussão .....	54
4.2.8	Conclusão.....	59
4.2.9	Referências.....	60
<b>5</b>	<b>CONCLUSÕES</b> .....	65

<b>REFERÊNCIAS</b> .....	67
<b>ANEXOS</b> .....	71
<b>ANEXO A</b> – Aprovação do Comitê de Ética .....	72
<b>ANEXO B</b> – A Escala para Avaliação da Intensidade dos Sinais e Sintomas relacionados a Exposição à Fumaça Cirúrgica (EASE).....	78
<b>ANEXO C</b> – <i>Transparent Reporting of a Multivariable Prediction Model for Individual Prognosis or Diagnosis (TRIPOD)</i> .....	81
<b>ANEXO D</b> – <i>Preferred Reporting Items for Systematic Reviews and Meta-Analyses (PRISMA)</i> .....	82
<b>ANEXO E</b> – <i>Checklist for reporting systematic reviews of prediction model studies (TRIPOD-SRMA)</i> .....	84
<b>ANEXO F</b> – <i>Critical Appraisal and Data Extraction for Systematic Reviews of Prediction Modelling Studies (CHARMS)</i> .....	85
<b>ANEXO G</b> – <i>Prediction model study Risk Of Bias Assessment Tool (PROBAST)</i> .....	87

## 1 APRESENTAÇÃO

Sou enfermeira formada pela Universidade Estadual de Maringá (2022), onde iniciei minha trajetória na área da saúde. Durante minha formação, atuei como bolsista no Programa de Educação Tutorial (PET), o que me proporcionou o primeiro contato com a pesquisa científica. Foi nesse ambiente que comecei minha carreira na pesquisa, por meio dos Projetos de Iniciação Científica.

Após minha graduação, busquei me especializar nas áreas de Gerência dos Serviços de Enfermagem, pela Universidade Estadual de Londrina (UEL/2024) e Auditoria dos Serviços de Saúde, pela Faculdade Fahol (Fahol/2023). Durante a especialização em Gerência dos Serviços de Enfermagem, fui introduzida à área de Saúde do Trabalhador pela Prof<sup>a</sup> Dra. Renata Perfeito Ribeiro. Foi com ela que comecei a entender os diversos aspectos relacionados à saúde ocupacional, especialmente no contexto da enfermagem e passei a frequentar o Grupo de Estudos em Gestão do Cuidado, Editoração Científica e Saúde do Trabalhador (GeeST), onde continuo durante a realização do mestrado.

Em 2024, ingressei no Mestrado em Enfermagem no Programa de Pós-Graduação em Enfermagem da UEL, onde pude aprofundar meus conhecimentos em áreas relacionadas à saúde do trabalhador e tecnologias aplicadas à enfermagem. Durante esse período, conciliei o mestrado com a prática profissional, atuando na assistência e na gestão de serviços de saúde. Essa experiência me proporcionou uma visão mais ampla dos reais desafios enfrentados pelos trabalhadores de enfermagem, além de permitir que eu amadurecesse na profissão e adquirisse novos *insights* sobre a realidade do campo de trabalho.

Esta dissertação faz parte do Projeto de Pesquisa "Riscos Ocupacionais em Trabalhadores de Saúde e Estratégias de Enfrentamento", no qual desenvolvi um algoritmo de *Machine Learning* para a predição de sinais e sintomas em trabalhadores da saúde expostos à fumaça cirúrgica de forma ocupacional. A dissertação é composta por dois estudos: o Estudo 1 – "Sinais e sintomas em trabalhadores expostos à fumaça cirúrgica: uma abordagem *Machine Learning*", submetido e aceito para publicação na Revista Texto e Contexto - Enfermagem, e o Estudo 2 – "Predição de doenças em trabalhadores da saúde com o uso de *Machine Learning*: revisão sistemática".

## 2 CONTEXTUALIZAÇÃO

### 2.1 Saúde do Trabalhador

A saúde do trabalhador pode ser definida como as relações entre o trabalho e o processo saúde e doença, bem como a prevenção de doenças e acidentes relacionados ao trabalho, sendo uma área da saúde dedicada à proteção e promoção da saúde dos trabalhadores (Mendes; Dias, 1991; Hurtado et al., 2022).

Essa área tem ganhado crescente visibilidade nos últimos anos, uma vez que a população trabalhadora tem sido mais exposta a condições que podem gerar doenças ocupacionais. O aumento das demandas de trabalho e a complexidade dos ambientes profissionais fazem com que a saúde dos trabalhadores se torne uma prioridade nas políticas públicas e no campo da pesquisa (Queiroz, 2023).

O ambiente de trabalho, por sua natureza, apresenta diversos riscos ocupacionais à saúde, sendo classificados em biológicos, físicos e químicos conforme a Norma Regulamentadora 01 (NR-01), que estabelece diretrizes e requisitos para o gerenciamento de riscos ocupacionais e as medidas de prevenção em Segurança e Saúde no Trabalho (SST) (Brasil, 2024).

Os riscos biológicos são classificados como microrganismos, parasitas ou materiais originados de organismos que, em função de sua natureza e do tipo de exposição, são capazes de acarretar lesão ou agravo à saúde do trabalhador, por exemplo: bactéria *Bacillus anthracis* e vírus linfotrópico da célula T humana (Brasil, 2024).

Os riscos físicos são classificados como qualquer forma de energia que, em função de sua natureza, intensidade e exposição, é capaz de causar lesão ou agravo à saúde do trabalhador, por exemplo: ruídos, vibrações, pressões anormais, temperaturas extremas, radiações ionizantes e radiações não ionizantes (Brasil, 2024).

Os riscos químicos são considerados substância ou misturas, em seu estado natural ou produzida, utilizada ou gerada no processo de trabalho, que em função de sua natureza, concentração e exposição é capaz de causar lesão ou agravo à saúde do trabalhador, por exemplo: fumos de cádmio, poeira mineral contendo sílica cristalina, vapores de tolueno, névoas de ácido sulfúrico (Brasil, 2024).

Esses riscos podem resultar no desenvolvimento de doenças ocupacionais e portanto, algumas doenças ocupacionais foram acrescentadas na Lista de Doenças Relacionadas ao Trabalho (LDRT), por meio da Portaria GM/MS nº 1999 de 27 de novembro de 2023, que agora conta com 347 doenças. Essa lista do Ministério da Saúde tem como objetivo qualificar

a atenção integral à saúde do trabalhador, permitindo diagnósticos mais precisos, tratamento adequado e promoção da saúde no ambiente de trabalho (Brasil, 2023).

O Sistema Único de Saúde (SUS) registrou cerca de 3 milhões de casos de doenças ocupacionais entre 2007 e 2022, de acordo com dados do Sistema de Informação de Agravos de Notificação (Sinan) do Ministério da Saúde. A maior parte das notificações (52,9%) foi relativa a acidentes de trabalho grave. A identificação precoce e o tratamento adequado dessas doenças são essenciais para minimizar seus efeitos no bem-estar dos trabalhadores e no desempenho das atividades laborais (Brasil, 2023).

Com o objetivo de promover ambientes de trabalho mais saudáveis, a Organização das Nações Unidas (ONU) estabeleceu os Objetivos de Desenvolvimento Sustentável (ODS). Entre eles, destacam-se o ODS 3 – Saúde e Bem-Estar, que visa garantir o acesso à saúde de qualidade e promover o bem-estar para todos, e o ODS 8 – Trabalho Decente e Crescimento Econômico, que busca fomentar o crescimento econômico inclusivo, o emprego pleno e produtivo e o trabalho digno para todos (Nações Unidas Brasil, 2025).

No contexto dos trabalhadores de saúde, a exposição a riscos ocupacionais varia de acordo com o setor de atuação. Esses trabalhadores enfrentam riscos físicos, biológicos, psicológicos e químicos, que podem levar ao desenvolvimento de doenças musculoesqueléticas, infecciosas ou transtornos mentais.

A Norma Regulamentadora 32 (NR-32) estabelece diretrizes fundamentais para a implementação de medidas de proteção à segurança e à saúde dos trabalhadores da área da saúde. Seu foco principal está nos riscos biológicos, físicos e químicos, conforme descrito na NR-01. No entanto, é importante destacar a negligência em relação aos riscos psicológicos, que podem se manifestar por meio de sintomas como ansiedade, fadiga, irritabilidade e insônia, comprometendo tanto a qualidade de vida quanto o desempenho profissional (Jarruche; Mucci, 2021; Brasil, 2022; Dalmolin et al., 2022).

Os profissionais da saúde estão expostos a diversos agentes de risco em seu ambiente de trabalho. Dentre os riscos físicos e ergonômicos, destacam-se a exposição à radiação ionizante, sobrecarga de peso, trabalho repetitivo, ruído excessivo e variações de temperatura, fatores que podem comprometer a audição, a integridade celular e o bem-estar geral.

Os riscos biológicos, por sua vez, envolvem o contato com micro-organismos, fluidos corporais e materiais contaminados, aumentando a vulnerabilidade a doenças infecciosas. Os riscos psicológicos estão relacionados a altas demandas emocionais, sobrecarga de trabalho e a necessidade de tomadas de decisão críticas contribuem para o desenvolvimento de

transtornos como estresse, ansiedade, depressão e Síndrome de *Burnout*, afetando diretamente a saúde mental dos profissionais e a qualidade da assistência prestada por eles no trabalho (Santos, et al., 2021; Jarruche; Mucci, 2021; Faustino et al., 2025).

Os riscos químicos abrangem a exposição a substâncias potencialmente nocivas, como quimioterápicos, gases anestésicos, medicamentos aerossolizados, agentes de desinfecção, xileno, tolueno, formaldeído e fumaça cirúrgica, que podem desencadear intoxicações, alergias e comprometimentos à saúde respiratória e sistêmica (Taskingul; Kiran; Emerce, 2024; Brasil, 2022; Fernandes et al., 2021).

## **2.2 Exposição Ocupacional à Fumaça Cirúrgica**

Entre os ambientes mais críticos de um hospital, destaca-se o bloco cirúrgico. Devido à sua complexidade e à constante exposição dos profissionais a diversos riscos ocupacionais, esse setor requer cuidados contínuos para garantir a segurança e o bem-estar da equipe de saúde. Entre os principais riscos presentes nesse ambiente estão os riscos psicológicos, ergonômicos e a exposição a agentes químicos, físicos e biológicos (Teixeira et al., 2022; Santos; Silva; Matos, 2025; Faustino et al., 2025; Alpi et al., 2021).

O risco ocupacional relacionado à exposição a agentes químicos refere-se à possibilidade de prejuízos à saúde dos trabalhadores decorrentes do contato direto ou indireto com substâncias químicas presentes no ambiente de trabalho. No contexto hospitalar, esses agentes incluem quimioterápicos, gases anestésicos, medicamentos aerossolizados, desinfetantes, xileno, tolueno, formaldeído e a fumaça cirúrgica (Rocha et al., 2021; Zhou et al., 2023; Charlie et al., 2021).

Entre esses riscos, destaca-se a exposição à fumaça cirúrgica, comumente gerada pelo uso do eletrocautério durante os procedimentos operatórios (Asghar et al., 2020). O eletrocautério é um dispositivo que utiliza corrente elétrica de alta frequência para cortar tecidos e promover a coagulação, reduzindo o sangramento durante a cirurgia. Apesar de sua eficácia, o uso do eletrocautério produz uma fumaça densa proveniente da queima do tecido biológico, conhecida como fumaça cirúrgica (Massarweh; Cosgriff; Slakey, 2006).

Essa fumaça é composta por 95% de vapor de água e 5% de outros produtos, como, benzeno, formaldeído e outros compostos orgânicos voláteis, reconhecidos por seus potenciais efeitos adversos à saúde humana, como irritações respiratórias, efeitos neurotóxicos e até propriedades carcinogênicas. (Leachi et al., 2024; Zhou et al., 2023)

A exposição prolongada a essa fumaça pode causar diversos malefícios à saúde, como

problemas respiratórios, irritações oculares e até mesmo condições mais graves, como câncer, devido à natureza carcinogênica de alguns componentes presentes na fumaça cirúrgica (Benaim; Jaspers, 2024; Leachi, et al., 2024).

Além desses malefícios, a exposição contínua à fumaça cirúrgica pode resultar em sinais e sintomas relacionados à saúde nos diversos sistemas do organismo humano, como tosse, espirros, congestão nasal e falta de ar (respiratório); ardência, lacrimejamento e fotofobia (ocular); náuseas e dor abdominal (digestivo); fraqueza muscular (osteomuscular); coceira e irritações na pele (tegumentar); e cefaleia, tontura e desmaios (nervoso). Esses efeitos comprometem o desempenho profissional e a qualidade de vida dos trabalhadores da saúde, quando expostos a longo prazo (Bieniek; Leachi; Ribeiro, 2022; Saito et al., 2019).

Diante da gravidade dos riscos associados à exposição à fumaça cirúrgica, a proteção dos trabalhadores tem se destacado como prioridade nas políticas de saúde ocupacional. Diversas intervenções têm sido implementadas, como o uso de sistemas de ventilação adequados, máscaras protetoras e uso de Equipamentos de Proteção Individual (EPI). A máscara N95, por exemplo, apresenta alta capacidade de filtração e boa vedação, mas não é eficaz contra compostos químicos, como gases e vapores presentes na fumaça cirúrgica, devido à ausência de filtros específicos para adsorção desses componentes. Nesse contexto, torna-se necessária a incorporação de novas tecnologias e abordagens que garantam uma proteção mais eficaz aos profissionais de saúde expostos (Leachi; Ribeiro, 2023; Mahdood et al., 2024).

Nesse sentido, o uso de técnicas de *Machine Learning* (ML) na predição de doenças ocupacionais surge como uma medida promissora. Algoritmos como redes neurais, *random forest*, *support vector machine* e *naive bayes* têm demonstrado alto desempenho na identificação de fatores associados ao surgimento de doenças ocupacionais. Essa capacidade de antecipação permite a implementação de estratégias preventivas mais eficazes, promovendo ambientes de trabalho mais seguros e protegendo a saúde dos profissionais antes que os agravos se manifestem (Fagundes et al., 2024).

### **2.3 Machine Learning**

O aprendizado de máquina ou ML é um campo da Inteligência Artificial (IA) que se baseia em algoritmos e modelos estatísticos permitindo que sistemas aprendam a partir de dados, ou seja, eles são capazes de identificar padrões e tomar decisões sem necessidade de programação explícita (Géron, 2021).

O aprendizado de máquina tem evoluído ao longo dos anos e se consolidado como uma ferramenta poderosa, especialmente na análise de grandes volumes de dados, como os encontrados em registros médicos e dados ocupacionais. Esse crescimento tornou o ML uma ferramenta promissora para a identificação precoce de doenças, predição de riscos à saúde e otimização de processos em saúde ocupacional (Deo, 2015; Laudemir, 2021).

O aprendizado de máquina pode ser dividido em aprendizado supervisionado, aprendizado não supervisionado e aprendizado por reforço (Géron, 2021). Cada um desses tipos tem suas características, algoritmos e aplicações específicas, porém neste estudo científico iremos nos aprofundar no aprendizado supervisionado, mais especificamente no algoritmo de Redes Neurais Artificiais (RNA).

No aprendizado supervisionado, o modelo é treinado a partir de um conjunto de dados rotulado, ou seja, os dados de entrada já possuem resultados conhecidos que permitem que o modelo aprenda e faça previsões ou classificações sobre novos dados. Este tipo de aprendizado é amplamente utilizado em sistemas de diagnóstico e predição de doenças, sendo que algoritmos de aprendizado supervisionado se adaptam bem a dois tipos de problemas: problemas de classificação e problemas de regressão (Uddin et al., 2019).

Entre os algoritmos mais utilizados no aprendizado supervisionado aplicados à análise de dados estruturados, destacam-se o *Random Forest*, o *Gradient Boosting* e o *Tabular Prior-Data Fitted Network (TabPFN)*.

*Random Forest* é um método de *ensemble learning* baseado na construção de múltiplas árvores de decisão independentes. Cada árvore é treinada a partir de subconjuntos aleatórios das amostras e de subconjuntos aleatórios das variáveis, uma estratégia que aumenta a diversidade do conjunto e reduz a variância do modelo. Ao final, as previsões individuais das árvores são combinadas, por votação, no caso de classificação, ou por média, em regressão, o que proporciona maior robustez e melhor capacidade de generalização. Essa abordagem é particularmente eficaz para dados tabulares, lida bem com variáveis ruidosas e mantém bom desempenho mesmo quando há correlação entre preditores (Liu; Wang; Zhang, 2012; Salman; Kalakech; Steiti, 2024).

O *Gradient Boosting*, por sua vez, segue a filosofia dos métodos de *boosting*, construindo o modelo de forma sequencial. Ele gera um conjunto de modelos fracos, geralmente árvores de decisão rasas, onde cada novo modelo tenta corrigir os erros residuais do modelo anterior. Diferentemente do *Random Forest*, que funciona de maneira paralela e com árvores independentes, o *Gradient Boosting* cria dependência entre as etapas do

aprendizado, permitindo otimizar diretamente uma função de perda diferenciável e controlar finamente o processo de ajuste (Zhang et al., 2019; Boldini et al., 2023).

Um componente central desse algoritmo é a taxa de aprendizagem (*learning rate*), um fator multiplicativo que define o quanto cada árvore contribuirá para o modelo final. Taxas menores reduzem a influência individual de cada árvore, levando a um aprendizado mais lento porém mais estável e menos propenso a *overfitting*, desde que combinadas a um número adequado de iterações (Zhang et al., 2019; Boldini et al., 2023).

Já o *TabPFN* representa uma abordagem mais recente e inovadora. Trata-se de um modelo baseado em redes neurais profundas capaz de atuar como um prior aprendido para tarefas supervisionadas em dados tabulares. Ele é intensivamente pré-treinado em milhões de tarefas sintéticas de classificação, de modo que, quando recebe um novo conjunto de dados, não requer ajustes adicionais: o modelo produz previsões imediatamente, funcionando quase como um “classificador de uso instantâneo”. Essa característica o torna particularmente vantajoso em cenários com poucos dados ou quando há necessidade de previsão rápida sem etapas extensas de treinamento (Rundel et al., 2024; Tran; Byeon, 2024).

Outros algoritmos de aprendizado de máquina supervisionado podem ser utilizados, mas algumas vezes não desempenham uma boa performance a depender do tipo de dados que serão analisados, como por exemplos as RNA.

As redes RNA são algoritmos de aprendizado de máquina inspirados no funcionamento do cérebro humano, compostos por camadas de neurônios artificiais interconectados. Elas são projetadas para resolver problemas complexos como reconhecimento de padrões, classificação e previsão (Kriegeskorte; Golan, 2019; Uddin et al., 2019; Géron, 2021).

Uma RNA típica é composta por três camadas principais: a camada de entrada, a camada oculta e a camada de saída. A camada de entrada recebe os dados, como por exemplo, características dos trabalhadores de saúde (idade, sexo e doenças prévias). Esses dados são processados nas camadas ocultas, onde os neurônios aplicam funções matemáticas para identificar padrões complexos e relações não lineares entre as variáveis. Por fim, a camada de saída gera a previsão ou a classificação final, como a identificação de sinais ou sintomas ou a probabilidade do desenvolvimento de uma doença (Kriegeskorte; Golan, 2019; Uddin et al., 2019; Géron, 2021).

O processo de treinamento da RNA envolve duas etapas fundamentais: a propagação para frente (*forward propagation*) e a retropropagação (*backpropagation*). Na propagação

para frente, os dados de entrada são passados através das camadas da rede, onde cada neurônio aplica uma função de ativação para transformar os valores de entrada em uma saída. Essa saída é comparada com o valor esperado e a diferença entre a previsão e o valor real, é calculada. Na retropropagação, esse erro é propagado de volta pela rede para ajustar os pesos das conexões entre os neurônios, de modo que a rede aprenda a melhorar suas previsões ao longo do tempo. Esse processo de ajustes contínuos permite que a rede neural se adapte aos dados e se torne mais precisa conforme o treinamento avança (Kriegeskorte; Golan, 2019; Uddin et al., 2019; Géron, 2021).

Há muitos estudos na literatura que abordam a utilização de RNA em diversas áreas da saúde com resultados promissores, como por exemplo, em intervenções de otorrinolaringologista, interpretações de Eletrocardiograma (ECG) na síndrome coronariana aguda, no suporte a decisões em pacientes com câncer e entre outros estudos (Lisboa; Taktak, 2006; Ellahham, 2020; Bispo et al., 2024; Taciuc et al., 2024).

Para avaliar os algoritmos citados, é fundamental utilizar métricas de performance adequadas, capazes de capturar diferentes dimensões do desempenho preditivo. Entre essas métricas, destaca-se a área sob a curva ROC (AUC-ROC), que mensura a capacidade global do modelo de discriminar corretamente entre as classes, independentemente do ponto de corte adotado. Valores mais próximos de 1 indicam melhor separação entre positivos e negativos (Géron, 2021).

Adicionalmente, métricas derivadas da matriz de confusão são essenciais para uma interpretação mais contextualizada do desempenho. A sensibilidade (ou *recall*) mede a proporção de verdadeiros positivos corretamente identificados pelo modelo, sendo especialmente importante em cenários nos quais falhar em detectar a classe positiva é mais custoso. A especificidade, por sua vez, indica a proporção de verdadeiros negativos corretamente previstos, sendo crucial quando é indesejável classificar falsamente indivíduos como positivos (Géron, 2021).

O valor preditivo positivo (VPP) expressa a probabilidade de que uma observação classificada como positiva seja realmente positiva, refletindo a precisão das previsões positivas. Já o valor preditivo negativo (VPN) representa a probabilidade de que um caso classificado como negativo seja realmente negativo. Diferentemente da sensibilidade e especificidade, o VPP e o VPN dependem diretamente da prevalência da classe positiva no conjunto de dados, o que reforça sua importância em situações de desbalanceamento (Géron, 2021).

Além das métricas mencionadas, o processo de avaliação também envolve o ajuste de hiperparâmetros, etapa essencial para otimizar o desempenho e evitar tanto o sobreajuste. Esse ajuste é realizado comumente por meio de validação cruzada (*cross-validation*) no conjunto de treino, permitindo testar sistematicamente múltiplas combinações de hiperparâmetros e selecionar aquela que produz o melhor desempenho médio ao longo das diferentes partições dos dados (Géron, 2021).

O uso da IA especificamente a área de aprendizado de máquina, estão revolucionando a maneira como as organizações abordam a saúde e a segurança, oferecendo *insights* preditivos, monitoramento em tempo real e estratégias de mitigação de riscos que não apenas minimizam acidentes e perigos, mas também abrem caminho para uma abordagem mais proativa e responsiva para proteger os trabalhadores de saúde (Xá; Mishra, 2024).

### 3 OBJETIVOS

#### 3.1 Objetivo Geral

Analisar um algoritmo *Machine Learning* na predição de sinais e sintomas relacionados à exposição ocupacional de trabalhadores da saúde à fumaça cirúrgica.

##### 3.1.1 Objetivos Específicos

Desenvolver um algoritmo de *Machine Learning* capaz de prever sinais e sintomas relacionados à exposição ocupacional à fumaça cirúrgica em trabalhadores da saúde.

Avaliar os modelos preditivos existentes aplicados à predição de doenças em trabalhadores da saúde por meio de uma revisão sistemática da literatura.

Discutir, com base na literatura científica, as implicações dos modelos preditivos aplicados à exposição ocupacional à fumaça cirúrgica.

Portanto esta dissertação será apresentada no formato de artigos científicos:

1. SINAIS E SINTOMAS EM TRABALHADORES EXPOSTOS À FUMAÇA CIRÚRGICA: UMA ABORDAGEM *MACHINE LEARNING*
2. PREDIÇÃO DE DOENÇAS EM TRABALHADORES DA SAÚDE COM O USO DE *MACHINE LEARNING*: REVISÃO SISTEMÁTICA

## 4 RESULTADOS

### 4.1 ESTUDO 1

#### 4.1.1 SINAIS E SINTOMAS EM TRABALHADORES EXPOSTOS À FUMAÇA CIRÚRGICA: UMA ABORDAGEM *MACHINE LEARNING*

*ARTIGO ACEITO PARA PUBLICAÇÃO NA REVISTA TEXTO E CONTEXTO – ENFERMAGEM*

#### 4.1.2 RESUMO

**Objetivo:** avaliar a capacidade preditiva de um modelo baseado em *Machine Learning* na identificação de sinais e sintomas de trabalhadores com exposição ocupacional à fumaça cirúrgica. **Método:** estudo transversal com abordagem preditiva, conduzido com base em dados coletados no período de 2021 e 2023 em três instituições de saúde, situadas no norte do Paraná e no centro do Rio Grande do Sul. A amostra foi composta por 364 trabalhadores da saúde e foram coletadas informações sociodemográficas, ocupacionais e intensidade dos sinais e sintomas. Para a construção do modelo preditivo foi escolhido a Rede Neural Artificial, sendo que o desempenho do modelo foi avaliado por métricas como acurácia, especificidade, sensibilidade, curva de perda, percentual de acertos e matriz de confusão. As ferramentas *MATLAB*® e *Python*® foram utilizadas para o pré-processamento dos dados, testes e implementação final do modelo. **Resultados:** no sistema respiratório, a acurácia média foi de 86,59% no treinamento e 76,50% em operação, com especificidade média de 96,36% e sensibilidade de 71,29%. Já no sistema ocular, a acurácia média foi de 77,87% no treinamento e 69,44% em operação, com especificidade média de 84,06% e sensibilidade de 67,21%. O percentual de acertos seguiu uma linha parecida com a curva da evolução da função de perda, mostrando assim a melhoria das redes neurais ao longo das épocas. **Conclusão:** o modelo alcançou um desempenho satisfatório, demonstrando o potencial das redes neurais como ferramenta preditiva para a identificação precoce de sinais e sintomas associados à exposição ocupacional à fumaça cirúrgica.

**DESCRITORES:** Aprendizado de Máquina; Fumaça; Redes Neurais de Computação; Saúde Ocupacional; Sinais e Sintomas.

### 4.1.3 ABSTRACT

**Objective:** to evaluate the predictive capacity of a Machine Learning-based model in identifying signs and symptoms among workers with occupational exposure to surgical smoke. **Method:** a cross-sectional study with a predictive approach, conducted with data collected between 2021 and 2023 in three healthcare institutions located in northern Paraná and central Rio Grande do Sul, Brazil. The sample consisted of 364 healthcare workers, and sociodemographic, occupational, and symptom intensity data were collected. An Artificial Neural Network was chosen to build the predictive model, and its performance was assessed using metrics such as accuracy, specificity, sensitivity, loss curve, hit rate, and confusion matrix. MATLAB® and Python® tools were used for data preprocessing, testing, and final model implementation. **Results:** For the respiratory system, mean accuracy was 86.59% during training and 76.50% in operation, with a mean specificity of 96.36% and sensitivity of 71.29%. For the ocular system, mean accuracy was 77.87% during training and 69.44% in operation, with a mean specificity of 84.06% and sensitivity of 67.21%. The hit rate followed a pattern similar to the loss function evolution curve, indicating the improvement of the neural networks over the epochs. **Conclusion:** The model achieved satisfactory performance, demonstrating the potential of Artificial Neural Networks as a predictive tool for the early identification of signs and symptoms associated with occupational exposure to surgical smoke.

**KEYWORDS:** Machine Learning; Smoke; Neural Networks; Occupational Health; Signs and Symptoms.

#### 4.1.4 INTRODUÇÃO

A saúde ocupacional dos trabalhadores inseridos no ambiente cirúrgico é uma preocupação, especialmente considerando a complexidade do bloco cirúrgico, onde são realizados procedimentos delicados, com o uso de equipamentos sofisticados (Martins et al., 2021). Entre esses equipamentos está o uso do eletrocautério, utilizado para dissecação de tecidos e controle de sangramento por meio de corrente de radiofrequência, o que resulta na emissão da fumaça cirúrgica, composta por partículas de água, resíduos de tecidos e compostos químicos carcinogênicos, representando um sério risco à saúde dos trabalhadores expostos de forma ocupacional (Searle; Ali; Al-Niaimi, 2021; Leachi et al., 2024).

Essa exposição pode acometer vários sistemas do organismo humano, por meio dos seguintes sinais e sintomas apresentados por trabalhadores expostos à fumaça cirúrgica: tosse, ardência de faringe, espirros, rinite, lesão de nasofaringe, sensação de corpo estranho na garganta, congestão nasal, inflamação das vias aéreas, lacrimejamento dos olhos, náuseas, vômitos, dor abdominal, fraqueza, cãibra, dermatite, cefaleia, sonolência e tonturas (Bieniek et al., 2021; Bieniek; Leachi; Ribeiro, 2022).

Esse contexto de adoecimento, precedido pelos sinais e sintomas citados, necessita ser revertido antes que os sintomas evoluam para um quadro clínico mais grave, devido a complicações diversas e tratamentos inadequados. Dessa forma, tem-se observado a prática de predição na área da saúde ocupacional com crescente importância, sendo definida como a tradução da antecipação de acontecimentos, permitindo assim, intervenções mais eficazes (Chaudhry; Choudhury, 2024; Paixão et al., 2022).

Essa antecipação pode ser realizada com o uso de algoritmos *Machine Learning*, também conhecida como aprendizado de máquina, um ramo da Inteligência Artificial (IA), onde ferramentas são utilizadas para analisar grandes volumes de dados clínicos e identificar padrões e indicadores precoces de vários segmentos (Chaudhry; Choudhury, 2024; Paixão et al., 2022).

Dessa forma, a exposição à fumaça cirúrgica é uma preocupação significativa em ambientes hospitalares e clínicos, representando um desafio para a saúde ocupacional, alinhado aos Objetivos de Desenvolvimento Sustentável da Organização das Nações Unidas (Organização das Nações Unidas, 2015). Portanto, o poder preditivo das doenças relacionadas à exposição de trabalhadores à fumaça cirúrgica, por meio de algoritmos *Machine Learning*, representa uma abordagem inovadora, que pode oferecer resultados valiosos para a prevenção de doenças ocupacionais.

Para tanto, se faz necessário responder à pergunta de pesquisa: um modelo *Machine Learning* é capaz de prever sinais e sintomas de trabalhadores com exposição ocupacional à fumaça cirúrgica? Logo, o presente estudo tem como objetivo avaliar a capacidade preditiva de um modelo baseado em *Machine Learning* na identificação de sinais e sintomas de trabalhadores com exposição ocupacional à fumaça cirúrgica.

#### 4.1.5 MATERIAL E MÉTODO

Trata-se de um estudo transversal com abordagem preditiva, norteado pelas orientações de descrição de modelos preditivos multivariados para diagnóstico ou prognóstico (*Transparent Reporting of a Multivariable Prediction Model for Individual Prognosis or Diagnosis – TRIPOD*) (Moons et al., 2019).

O presente estudo foi realizado a partir de um banco de dados originado de pesquisas conduzidas pelo Grupo de Estudos em Gestão do Cuidado, Editoração Científica e Saúde do Trabalhador (GeeST), com parecer favorável pelo Comitê de Ética das instituições envolvidas. Os dados foram coletados no período de 2021 na Instituição I e II e no período de 2023 na Instituição III. A instituição I e II são referências de saúde para a região noroeste do norte do Paraná, sendo que a a instituição I é um serviço filantrópico especializado em oncologia, com seis salas operatórias, funcionando de segunda a sábado, a instituição II é um hospital universitário com sete salas operatórias em funcionamento 24 horas e a instituição III é referência em saúde para a região centro do Rio Grande do Sul com sete salas no Centro Cirúrgico e duas salas do Centro Obstétrico com funcionamento de 24 horas por dia.

A amostra foi composta por 364 trabalhadores da saúde (técnicos de enfermagem, enfermeiros e médicos cirurgiões) expostos à fumaça cirúrgica. O banco de dados incluiu informações sociodemográficas e ocupacionais, como: idade, sexo, doença crônica pré-existente, tabagismo, profissão, escolaridade, área de atuação e uso de Equipamentos de Proteção Individual (EPIs) contra a fumaça cirúrgica (máscara cirúrgica, máscara N95, óculos e aspirador de fumaça).

Os sinais e sintomas associados à exposição foram avaliados com o uso da Escala para Avaliação da intensidade dos Sinais e Sintomas relacionados à Exposição à Fumaça Cirúrgica (EASE), composta de 33 itens, subdivididos em seis domínios: sistema respiratório (10 itens), ocular (9 itens), digestório (3 itens), osteomuscular (2 itens), tegumentar (4 itens) e nervoso (5 itens). A escala é medida de forma numérica, que varia de 0 a 3, sendo 0 (sem sinais e sintomas), 1 (baixa intensidade), 2 (moderada intensidade) e 3 (alta intensidade),

correspondente aos sinais e sintomas avaliados. Ao final da autoavaliação, a escala dará por um score geral, ou seja, quanto maior a pontuação nos domínios, maior é a intensidade e a exposição à fumaça cirúrgica (Bieniek; Leachi; Ribeiro, 2022).

A construção do modelo de predição ocorreu baseado em três etapas, sendo elas: pré-processamento dos dados; construção do algoritmo *Machine Learning* e treinamento e validação do modelo.

Na fase inicial de pré-processamento, os dados foram tabulados em planilha eletrônica através do *Microsoft Excel*®, com dupla digitação para garantir maior acurácia e por um processo de limpeza para eliminar inconsistências e imputar valores ausentes (*missing*) (Géron, 2021).

A construção do algoritmo iniciou-se no primeiro semestre de 2024, onde uma série de algoritmos de aprendizado de máquina foi avaliada para prever sinais e sintomas associados à exposição à fumaça cirúrgica. Como este estudo trabalha com dados diversificados e com relações não lineares, foi escolhida a Rede Neural Artificial (RNA), do tipo *Perceptron* de Múltiplas Camadas (arquitetura *feedforward*) com treinamento supervisionado baseado no algoritmo de retropropagação do erro (*backpropagation*) (Géron, 2021).

Os dados de entrada foram codificados em números para facilitar o processamento pela rede neural, garantindo sua interpretação correta pelo modelo. Foram utilizados os seguintes atributos: idade, sexo (1 para feminino e 2 para masculino), presença de doença crônica pré-existente (1 para não e 2 para sim), hábito de tabagismo (1 para não e 2 para sim), profissão (1 para enfermeiro, 2 para médico, 3 para técnico em enfermagem, 4 para residente em enfermagem e 5 para residente médico), ano de conclusão do curso, nível de escolaridade (1 para ensino médio completo, 2 para graduação, 3 para especialização/residência, 4 para mestrado, 5 para doutorado e 6 para técnico), área de atuação (variando de 1 a 20), tempo de experiência no setor, turno de trabalho (1 para matutino, 2 para vespertino, 3 para noturno e 4 para integral) e uso de EPIs, sendo eles, máscara cirúrgica (1 para não e 2 para sim), máscara N95 (1 para não e 2 para sim), óculos de proteção ocular (1 para não e 2 para sim), aspirador de fumaça (1 para não e 2 para sim), totalizando 15 variáveis de entrada. Após o tratamento e a transformação dos dados em valores numéricos, diversas configurações foram testadas, variando a quantidade de camadas ocultas e o número de neurônios em cada camada, conforme descrito na Tabela 1, com o objetivo de prever sintomas respiratórios e oculares. Por fim, a rede neural gera a predição da intensidade dos sinais e sintomas dos sistemas

respiratório e ocular, conforme os domínios da escala EASE, utilizando as informações fornecidas.

Não foram identificados padrões significativos nos sintomas dos sistemas digestório, osteomuscular, tegumentar e nervoso, indicando que esses domínios podem não ser preditos com base nos dados disponíveis. Por essa razão, os dados referentes a esses sistemas não foram abordados neste estudo.

**Tabela 1** – Configuração da Rede Neural Artificial para o sistema respiratório e ocular. Londrina - PR, Brasil, 2024.

		Redes								
		1	2	3	4	5	6	7	8	9
Sistema Respiratório	1ª Camada (Neurônios)	16	20	20	10	10	5	5	5	6
	2ª Camada (Neurônios)	8	5	7	5	6	2	2	5	3
	3ª Camada (Neurônios)	-	-	-	-	-	-	-	5	-
	4ª Camada (Neurônios)	-	-	-	-	-	-	-	5	-
	5ª Camada (Neurônios)	-	-	-	-	-	-	-	5	-
Sistema Ocular	1ª Camada (Neurônios)	170	5	10	7	8	8	5	5	10
	2ª Camada (Neurônios)	20	1	4	7	7	8	1	2	7

Fonte: própria autora.

Os dados utilizados na rede neural foram divididos em dois conjuntos distintos: 70% das informações foram empregadas para composição da base de treino, 15% foram utilizados para teste e 15% para validação.

Para a avaliação do desempenho da rede neural foram utilizadas métricas de desempenho, essenciais para uma análise completa e detalhada dos resultados obtidos. Dentre as principais métricas, destacam-se a acurácia, a especificidade, a sensibilidade, a evolução da curva de perda (LOSS), a evolução do percentual de acertos e a matriz de confusão.

A acurácia mede a proporção de previsões corretas feitas pela rede em relação ao total de amostras e é calculada pela fórmula:  $\frac{TP+TN}{TP+TN+FP+FN}$  onde TP são os verdadeiros positivos, TN são os verdadeiros negativos, FP são os falsos positivos e FN são os falsos negativos (Géron, 2021).

A especificidade avalia a capacidade da rede neural de identificar corretamente os casos negativos, evitando falsos positivos. Sua fórmula é dada por  $\frac{TN}{TN+FP}$ , enquanto a sensibilidade mede a capacidade do modelo de identificar corretamente os casos positivos, evitando falsos negativos, sendo calculada por  $\frac{TP}{TP+FN}$  (Géron, 2021).

A curva de perda é usada para monitorar a evolução do erro do modelo durante o treinamento, observando como ele diminui ao longo das épocas. O percentual de acertos acompanha a taxa de acertos do modelo ao longo das previsões e é calculado pela fórmula:  $\frac{n^{\circ} \text{ acertos}}{n^{\circ} \text{ total de aceros}} \times 100$  (Géron, 2021).

Por fim, a matriz de confusão é uma tabela que compara as previsões do modelo com as classes reais, ajudando a identificar erros específicos, como falsos positivos e falsos negativos (Géron, 2021).

Para as etapas de pré-processamento e testes preliminares do modelo foram realizadas no *MATLAB*®, devido à sua interface interativa e ferramentas especializadas para modelagem. Posteriormente, os dados foram migrados para o *Python*®, onde foi conduzida a implementação final do modelo utilizando a biblioteca *Keras*, executada sobre a *API TensorFlow* (Géron, 2021; Chollet et al., 2015). Além disso, todas as análises estatísticas, construção de gráficos e validações do modelo foram realizadas nesse ambiente de programação, garantindo maior flexibilidade e integração das ferramentas.

#### 4.1.6 RESULTADOS

A amostra foi constituída por 364 trabalhadores da área da saúde, sendo que 64 (17,58%) eram médicos, 43 (11,81%) residentes de medicina, 11 (3,02%) enfermeiros, 59 (16,21%) técnicos de enfermagem e 2 (0,55%) foram classificados como outros. A média de idade dos participantes foi de 37 anos (DP  $\pm$ 11,46), e a média de tempo de trabalho no centro cirúrgico foi de sete anos.

Em relação ao turno de trabalho, a maioria dos trabalhadores, 218 (63,55%), tinha turnos de trabalho integral, enquanto 62 (18,07%) trabalhavam no período matutino, 51 (14,86%) no período vespertino e 16 (3,52%) no período noturno.

Os trabalhadores fizeram uso de EPI contra a fumaça cirúrgica, sendo que 342 (93,96%) profissionais usavam máscara cirúrgica, 137 (37,64%) máscara N95, 178 (48,90%) fizeram o uso óculos para proteção ocular e 3 (0,82%) utilizaram o aspirador de fumaça.

No que se refere a intensidade dos sinais e sintomas relacionados ao sistema respiratório 166 (45,60%) trabalhadores não apresentaram sinais ou sintomas, 186 (51,10%) trabalhadores relacionaram os sintomas a baixa intensidade, 10 (2,75%) apresentaram moderada intensidade e apenas 1 (0,27%) alta intensidade. No sistema ocular, 199 (54,67%) trabalhadores não apresentaram sinais ou sintomas, 151 (41,48%) apresentaram baixa intensidade, 12 (3,30%) moderada intensidade e 1 (0,27%) alta intensidade.

No sistema respiratório (Tabela 2) a RNA alcançou altos valores de acurácia em treinamento, variando de 85,42% a 88,33% e uma acurácia em operação entre 75,0% e 80,77%. Isso demonstra uma boa capacidade de generalização para novos dados. A especificidade, que mede a capacidade da rede de identificar corretamente os casos negativos (ausência de sintomas), apresentou valores elevados com destaque para as Redes 2, 3, 4, e 9 que atingiram 100%.

No entanto, a sensibilidade, que reflete a capacidade de identificar corretamente os casos positivos (presença de sintomas), variou de 68,57% a 75,0%, indicando que há margem para melhorar a identificação de sintomas em indivíduos sintomáticos. Para garantir que a RNA realizou previsões corretas, foi realizada uma análise com uma amostra de dados cuja veracidade é garantida pelo banco de dados. Por exemplo, um caso específico com ausência de sintomas respiratórios foi corretamente classificado pela Rede 2 (que apresentou 100% de especificidade), confirmando sua capacidade de identificar os casos negativos. Da mesma forma, um exemplo de caso positivo (presença de sintomas) foi corretamente identificado pela Rede 5, que apresentou sensibilidade de 73,68%. Esses exemplos reforçam a confiabilidade das previsões realizadas pela RNA, embora ainda exista espaço para aprimorar a sensibilidade.

No sistema ocular (Tabela 2), a RNA apresentou uma acurácia em treinamento entre 74,17% e 93,75%, mas a acurácia em operação variou de 63,46% a 76,92%, indicando um desempenho inferior ao observado no sistema respiratório. A Rede 1, apresentou alta acurácia

em treinamento (93,75%), mas o desempenho em operação foi consideravelmente menor (76,92%), sugerindo um possível sobreajuste (*overfitting*) aos dados de treinamento.

**Tabela 2** – Configuração da Rede Neural Artificial para os sistemas respiratório e ocular. Londrina - PR, Brasil, 2024.

	Redes	Acurácia em treinamento	Acurácia em operação	Especificidade	Sensibilidade
<b>Sistema Respiratório</b>	Rede 1	85,83 %	76,92 %	89,47%	74,19 %
	Rede 2	88,33 %	75,00 %	100 %	70,59 %
	Rede 3	87,92 %	75,00 %	100 %	70,59 %
	Rede 4	87,92 %	75,00 %	100 %	70,59 %
	Rede 5	86,25 %	78,85 %	94,44 %	72,72 %
	Rede 6	85,42 %	80,77 %	94,44 %	69,69 %
	Rede 7	86,25 %	75,00 %	94,11 %	69,69 %
	Rede 8	85,42 %	76,92 %	94,74 %	75,00 %
	Rede 9	85,83 %	75,00 %	100 %	68,57 %
<b>Sistema Ocular</b>	Rede 1	93,75 %	76,92 %	79,31 %	63,63 %
	Rede 2	75,42 %	69,23 %	86,36 %	65,52 %
	Rede 3	75,42 %	63,46 %	80,00 %	65,38 %
	Rede 4	76,25 %	71,15 %	82,61 %	64,29 %
	Rede 5	77,08 %	67,31 %	90,00 %	64,52 %
	Rede 6	76,25 %	63,46 %	90,00 %	64,52 %
	Rede 7	74,17 %	73,08 %	82,14 %	73,91 %
	Rede 8	75,00 %	67,31 %	82,14 %	73,91 %
	Rede 9	77,50 %	73,08 %	84,00 %	69,23 %

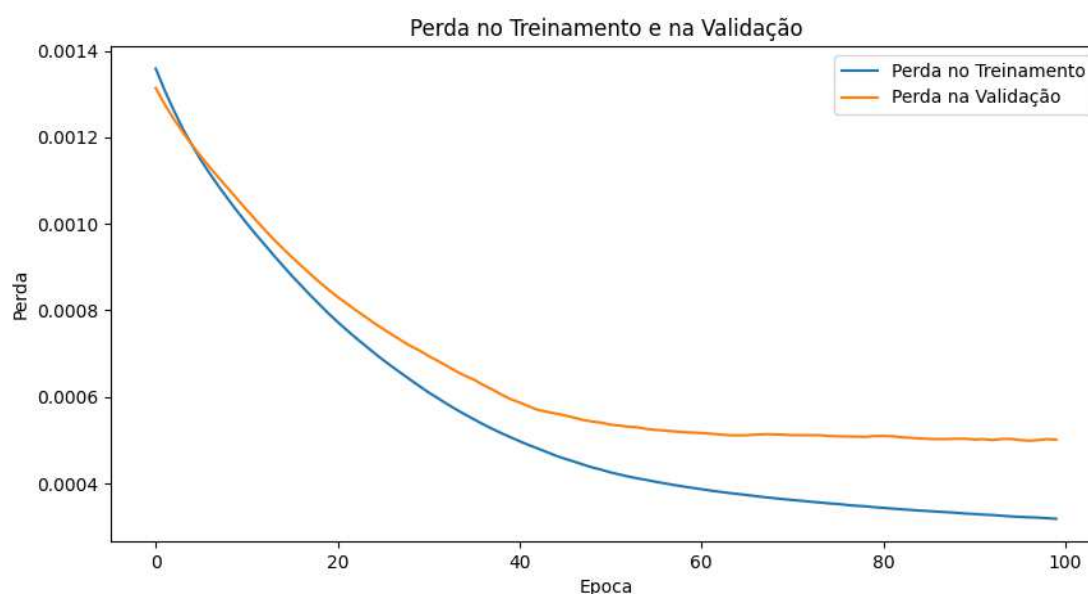
Fonte: própria autora.

A especificidade para o sistema ocular variou entre 79,31% e 90%, enquanto a sensibilidade teve um intervalo de 63,63% a 73,91%. Para ilustrar o comportamento da RNA, analisamos um caso com sintomas oculares moderados, previamente categorizado no banco de dados como positivo. A Rede 3 classificou corretamente este caso, refletindo sua sensibilidade de 70,83%. Por outro lado, um caso negativo (ausência de sintomas) foi corretamente identificado pela Rede 4, que apresentou especificidade de 85,71%. Apesar

disso, os valores gerais sugerem uma dificuldade da RNA em lidar com os padrões sintomáticos mais complexos desse sistema.

A curva de perda (Figura 1) apresentou uma redução consistente ao longo das épocas, indicando que o treinamento foi eficaz em minimizar os erros do modelo. Ou seja, a perda de treinamento reduz-se rapidamente, estabilizando abaixo de 0,0005 após 50 épocas e a perda de validação segue uma tendência similar, embora permaneça ligeiramente superior à de treinamento ao longo de todo o processo.

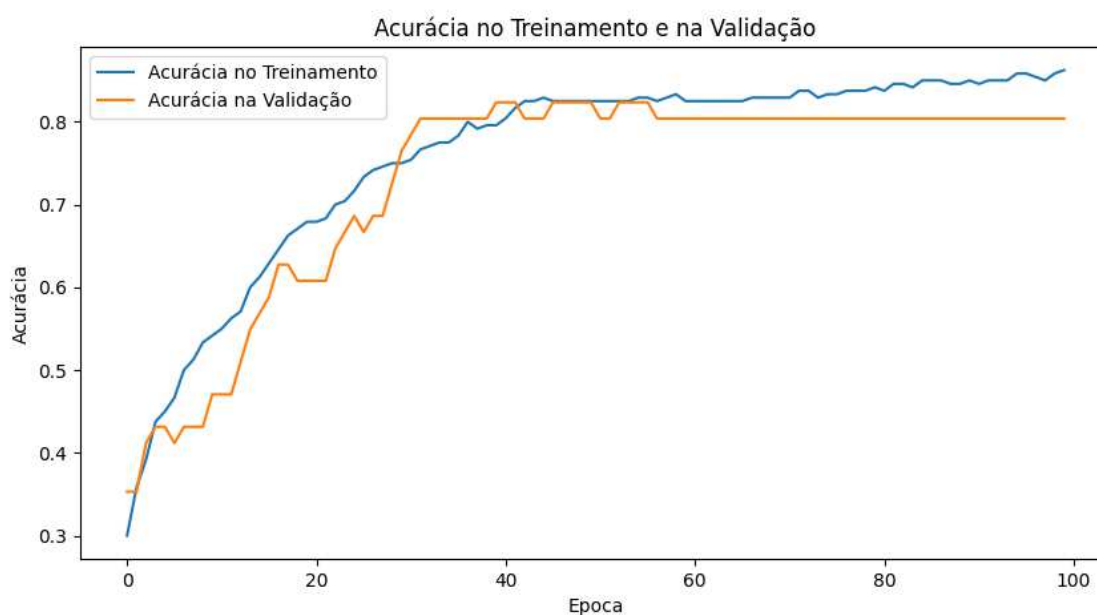
**Figura 1** - Evolução da curva da função de perda do treinamento e da validação. Londrina – PR, Brasil, 2024.



Fonte: própria autora, elaborado via *Python*<sup>®</sup>.

No que se refere ao percentual de acertos, segue-se uma linha parecida com a curva da evolução da função de perda, mostrando assim a melhoria da RNA ao longo das épocas. É possível observar que a acurácia de treinamento aumenta rapidamente e estabiliza acima de 0,85 após aproximadamente 50 épocas. A acurácia de validação segue uma tendência semelhante, estabilizando-se em torno de 0,75 com um gap evidente em relação ao treinamento.

**Figura 2** - Evolução do percentual de acertos ao longo das épocas do treinamento e validação. Londrina – PR, Brasil, 2024.




Fonte: própria autora, elaborado via *Python*<sup>®</sup>.

A matriz de confusão (Figura 3) demonstrou onde a RNA estavam com maior dificuldade de encontrar a resposta correta, sendo assim a classe 0 foi prevista corretamente 17 vezes, com 8 classificações errôneas na classe 1 e nenhuma na classe 2. A classe 1 teve um bom desempenho, com 23 previsões corretas e 1 erro em cada uma das outras classes. A classe 2 apresentou resultados mais desafiadores, com 1 previsão correta e 2 classificações equivocadas (1 em cada classe). Esses resultados indicam que o modelo tem maior dificuldade em prever a classe 2.

A análise geral indica que a RNA apresentou desempenho robusto nos dois sistemas, mas com variações notáveis. No sistema respiratório, a acurácia média foi de 86,59% no treinamento e 76,50% em operação, com especificidade média de 96,36% e sensibilidade de 71,29%. Já no sistema ocular, a acurácia média foi de 77,87% no treinamento e 69,44% em operação, com especificidade média de 84,06% e sensibilidade de 67,21%.

**Figura 3** - Matriz de confusão utilizada no treinamento da Rede Neural Artificial. Londrina – PR, Brasil, 2024.



Fonte: própria autora, elaborado via *Python*<sup>®</sup>.

#### 4.1.7 DISCUSSÃO

A RNA alcançou um desempenho satisfatório na predição da intensidade dos sinais e sintomas do sistema respiratório e ocular dos trabalhadores de saúde expostos à fumaça cirúrgica. Este estudo representa um passo importante para a saúde ocupacional, considerando que, atualmente, estratégias voltadas para a intervenção no cenário de adoecimento dos trabalhadores da saúde tornaram-se imprescindíveis (Chaudhry; Choudhury, 2024; Abadi et al., 2020).

As RNA destacam-se como uma ferramenta promissora e inovadora, podendo atuar como grandes aliadas na análise de dados da epidemiologia ocupacional. Isso é particularmente relevante no setor da saúde, um dos maiores polos empregadores, onde os

trabalhadores frequentemente enfrentam diversos riscos ocupacionais que podem levar ao adoecimento (Chaudhry; Choudhury, 2024; Abadi et al., 2020). Ao trazer para a prática a aplicação das RNAs, o presente estudo apresenta resultados que se somam a outros estudos que demonstraram o potencial dessa tecnologia na predição de sinais, sintomas e doenças em diferentes áreas da saúde, como no diagnóstico precoce de câncer de mama e previsão de surtos futuros de COVID-19 (Srinivasu et al., 2024; Khan et al., 2022).

Os resultados deste estudo sugerem que as RNAs são mais eficazes na identificação de indivíduos assintomáticos (alta especificidade), mas enfrentam dificuldades moderadas na identificação de casos sintomáticos (menor sensibilidade). Essa disparidade pode ser explicada pela quantidade limitada ou pela menor variabilidade dos dados relacionados aos casos sintomáticos. Este aspecto reflete um desafio amplamente discutido na literatura, já que as RNAs dependem de grandes volumes de dados para otimizar seu desempenho. Sua arquitetura é projetada para aprender padrões complexos, mas isso exige uma quantidade de informações suficiente para evitar problemas como o *overfitting* (Yelmen et al., 2023; Gygi; Kleinstein; Guan, 2023).

O *overfitting* ocorre quando o modelo se ajusta de forma excessiva aos dados de treinamento, prejudicando sua capacidade de generalizar para novos dados. Estratégias como os critérios de *Akaike* (AIC) e *Bayesiano* (BIC), além da validação cruzada, podem ser aplicadas para minimizar esse problema. Enquanto o AIC e o BIC ajudam a selecionar modelos mais simples ao penalizar a complexidade excessiva, a validação cruzada oferece uma estimativa robusta do erro de predição esperado, garantindo modelos mais equilibrados e eficazes (Yelmen et al., 2023; Gygi; Kleinstein; Guan, 2023).

Com uma maior quantidade de dados, as RNA conseguem capturar melhor a variabilidade e a diversidade das informações, reduzindo o impacto de ruídos estatísticos e aumentando sua capacidade de generalização. Essa capacidade foi evidenciada por estudos que empregaram grandes volumes de dados, resultando em modelos altamente preditivos (Kumari; Goyal; Morr, 2024; Zhang et al., 2022).

No entanto, é importante destacar que abordagens iniciadas com pequenas amostras de dados também são promissoras, especialmente para análises exploratórias ou diagnósticos iniciais. Estudos com amostras reduzidas confirmam que modelos podem fornecer predições eficientes, abrindo possibilidades para novas abordagens em populações maiores e mais representativas (Popescu et al., 2022; Portugal et al., 2022).

No presente estudo, o desempenho mais fraco observado para o sistema ocular pode ser atribuído à quantidade limitada de dados sintomáticos disponíveis. A baixa variabilidade nos padrões apresentados por esses dados provavelmente confundiu as RNAs durante o treinamento, reduzindo sua capacidade de generalizar adequadamente para novos casos. Uma solução promissora para enfrentar esse desafio é o uso do *Synthetic Minority Oversampling Technique* (SMOTE), uma técnica de sobreamostragem amplamente aplicada em situações de desequilíbrio de classes (Nguyen et al., 2023; Patel et al., 2022). O SMOTE gera exemplos sintéticos para as classes minoritárias, aumentando sua representatividade sem introduzir redundância, e demonstrou eficácia em diversos contextos. Estudos que aplicaram o SMOTE mostraram melhorias no desempenho de modelos preditivos em áreas como a predição de malária, identificação de genes relacionados ao autismo e predição de câncer cervical (Lee; Choi; Shin, 2021; Ismail; Gad; Hashem, 2023; Karamti et al., 2023).

Outro ponto relevante é que, no cenário da saúde ocupacional, não foram encontrados modelos preditivos baseados em ML que abordem diretamente a exposição de trabalhadores à fumaça cirúrgica. Este estudo é pioneiro nesse campo, ampliando o uso dessas tecnologias para novos contextos e abrindo caminho para futuras investigações. Enquanto estudos prévios exploraram a previsão de Burnout, resiliência e absenteísmo em trabalhadores de saúde, o foco deste trabalho em sintomas específicos relacionados à exposição ocupacional traz uma abordagem inédita (Lieslehto et al., 2022; Adapa et al., 2022; Gupta et al., 2021).

Este estudo trouxe avanços significativos para a saúde ocupacional ao demonstrar que a aplicação de RNA pode contribuir para a identificação precoce de sinais e sintomas associados à exposição à fumaça cirúrgica. O uso de um modelo baseado em ML, alimentado por dados coletados com a Escala EASE, destaca como tecnologias inovadoras podem ser aliadas na promoção da saúde dos trabalhadores. A RNA mostrou-se eficaz para prever sintomas respiratórios e oculares, permitindo um monitoramento mais preciso e eficiente. Essa abordagem oferece um método inovador que pode ser integrado às rotinas de avaliação de riscos ocupacionais, auxiliando na identificação precoce de condições que poderiam passar despercebidas por métodos tradicionais.

No entanto, o estudo apresenta como limitação a quantidade restrita de dados relacionados à exposição à fumaça cirúrgica e o predomínio de registros de trabalhadores assintomáticos em relação aos sintomáticos. Essa limitação destaca a necessidade de investigações futuras, com amostras maiores e mais diversificadas, abrangendo diferentes regiões do Brasil. Isso permitirá maior eficácia e generalização dos modelos preditivos,

consolidando o papel das tecnologias de *Machine Learning* como aliadas indispensáveis na saúde ocupacional.

#### **4.1.8 CONCLUSÃO**

Foi possível avaliar a capacidade preditiva do modelo baseado em *Machine Learning*, na identificação precoce de sinais e sintomas relacionados à exposição ocupacional à fumaça cirúrgica, utilizando a EASE, demonstrando o potencial das RNA como ferramenta preditiva para a identificação precoce de sinais e sintomas associados à exposição ocupacional à fumaça cirúrgica, contribuindo para a proteção da saúde dos trabalhadores em ambientes hospitalares.

Os resultados demonstraram que as RNA alcançaram um desempenho satisfatório, especialmente na identificação de casos negativos (ausência de sintomas), como evidenciado pelos altos valores de especificidade, particularmente no sistema respiratório, onde algumas redes atingiram 100%.

#### 4.1.9 REFERÊNCIAS

ABADI, M. et al. TensorFlow: large-scale machine learning on heterogeneous systems. 2020. Disponível em: <https://www.tensorflow.org>. Acesso em: 14 ago. 2020.

ADAPA, K. et al. Using explainable supervised machine learning to predict burnout in healthcare professionals. *Studies in Health Technology and Informatics*, v. 294, p. 58-62, 2022. DOI: <https://doi.org/10.3233/SHTI220396>.

BIENIEK, A. A.; ARONI, P.; COSTA, R. G.; RIBEIRO, R. P. Sinais e sintomas relacionados à exposição à fumaça cirúrgica: revisão integrativa. *Revista SOBECC*, São Paulo, v. 26, n. 3, p. 189-196, 2021. DOI: <https://doi.org/10.5327/Z1414-4425202100030009>.

BIENIEK, A. A.; LEACHI, H. F. L.; RIBEIRO, R. P. Construção e validação de escala de intensidade de sinais e sintomas relacionados à fumaça cirúrgica. *Revista Brasileira de Desenvolvimento*, v. 5, p. 41375-41388, 2022. DOI: <https://doi.org/10.34117/bjdv8n5-567>.

BOLINHA, A. F.; BUENO, A. A.; EVANGELISTA, R. A.; MACHADO, V. B.; MARTINS, K. N.; MAZONI, S. R. Management process in surgicenters from the perspective of nurses. *Acta Paulista de Enfermagem*, São Paulo, v. 34, eAPE00753, 2021. DOI: <https://doi.org/10.37689/acta-ape/2021AO00753>.

CHAUDHRY, Z. S.; CHOUDHURY, A. Clinical applications of artificial intelligence in occupational health: a systematic literature review. *Journal of Occupational and Environmental Medicine*, 2024. DOI: <https://doi.org/10.1097/jom.0000000000003212>.

CHOLLET, F. et al. Keras. 2015. Disponível em: <https://keras.io>. Acesso em: 20 mar. 2020.

GÉRON, A. Mãos à obra: aprendizado de máquina com Scikit-Learn, Keras e TensorFlow: conceitos, ferramentas e técnicas para a construção de sistemas inteligentes. Rio de Janeiro: Alta Books, 2021. 640 p.

GUPTA, M. D. et al. COVID 19-related burnout among healthcare workers in India and ECG based predictive machine learning model: insights from the BRUCEE-Li study. *Indian Heart Journal*, v. 73, n. 6, p. 674-681, 2021. DOI: <https://doi.org/10.1016/j.ihj.2021.10.002>.

GYGI, J. P.; KLEINSTEIN, S. H.; GUAN, L. Predictive overfitting in immunological applications: pitfalls and solutions. *Human Vaccines & Immunotherapeutics*, v. 19, n. 2, p. 2251830, 2023. DOI: <https://doi.org/10.1080/21645515.2023.2251830>.

ISMAIL, E.; GAD, W.; HASHEM, M. A hybrid stacking-SMOTE model for optimizing the prediction of autistic genes. *BMC Bioinformatics*, v. 24, n. 1, p. 379, 2023. DOI: <https://doi.org/10.1186/s12859-023-05501-y>.

KARAMTI, H. et al. Improving prediction of cervical cancer using KNN imputed SMOTE features and multi-model ensemble learning approach. *Cancers*, v. 15, n. 17, p. 4412, 2023. DOI: <https://doi.org/10.3390/cancers15174412>.

KHAN, R. U. et al. Probabilistic approach to COVID-19 data analysis and forecasting future outbreaks using a multi-layer perceptron neural network. *Diagnostics*, v. 12, n. 10, p. 2539, 2022. DOI: <https://doi.org/10.3390/diagnostics12102539>.

KRIEBEL, D. Advancing global public health with occupational epidemiology. *Occupational and Environmental Medicine*, v. 80, n. 9, p. 485-488, 2023. DOI: <https://doi.org/10.1136/oemed-2023-108939>.

KUMARI, B.; GOYAL, N.; EL MORR, C. Predictive models for Canadian healthcare workers mental health during COVID-19. *Journal of Primary Care & Community Health*, v. 15, p. 21501319241241468, 2024. DOI: <https://doi.org/10.1177/21501319241241468>.

LIESLEHTO, J. et al. A machine learning approach to predict resilience and sickness absence in the healthcare workforce during the COVID-19 pandemic. *Scientific Reports*, v. 12, n. 1, p. 8055, 2022. DOI: <https://doi.org/10.1038/s41598-022-12107-6>.

LEACHI, H. F. L.; ROCHA, A. F.; PEIXE, T. S.; LOPES, L. P.; SOUZA, V. D. B.; RIBEIRO, R. P. 1-Hidroxipireno na urina de trabalhadores expostos ao fumo cirúrgico: relação com os sinais e sintomas. *Revista de Enfermagem Referência*, v. 6, n. 3, p. 1-7, 2024. DOI: <https://doi.org/10.12707/RVI23.139.33708>.

LEE, Y. W.; CHOI, J. W.; SHIN, E. H. Machine learning model for predicting malaria using clinical information. *Computers in Biology and Medicine*, v. 129, 104151, 2021. DOI: <https://doi.org/10.1016/j.compbiomed.2020.104151>.

MOONS, K. G. M. et al. PROBAST: a tool to assess risk of bias and applicability of prediction model studies: explanation and elaboration. *Annals of Internal Medicine*, v. 170, n. 1, p. 1-33, 2019. DOI: <https://doi.org/10.7326/m18-1377>.

NGUYEN, T. et al. SMOTE-CD: SMOTE for compositional data. *PLoS One*, v. 18, n. 6, e0287705, 2023. DOI: <https://doi.org/10.1371/journal.pone.0287705>.

ORGANIZAÇÃO DAS NAÇÕES UNIDAS. Transformando nosso mundo: a Agenda 2030 para o desenvolvimento sustentável. 2015. Disponível em: <https://sdgs.un.org/2030agenda>. Acesso em: 19 maio 2024.

PAIXÃO, G. M. M. et al. Machine Learning na Medicina: revisão e aplicabilidade. *Arquivos Brasileiros de Cardiologia*, v. 118, n. 1, p. 95-102, 2022. DOI: <https://doi.org/10.36660/abc.20200596>.

PATEL, J. et al. A machine learning-based water potability prediction model by using synthetic minority oversampling technique and explainable AI. *Computational Intelligence and Neuroscience*, 2022. DOI: <https://doi.org/10.1155/2022/9283293>.

POPESCU, L. et al. A two-stage SEM-artificial neural network analysis of the engagement impact on employees' well-being. *International Journal of Environmental Research and Public Health*, v. 19, n. 12, p. 7326, 2022. DOI: <https://doi.org/10.3390/ijerph19127326>.

PORTUGAL, L. C. L. et al. Vulnerability and protective factors for PTSD and depression symptoms among healthcare workers during COVID-19: a machine learning approach. *Frontiers in Psychiatry*, v. 12, p. 752870, 2022. DOI: <https://doi.org/10.3389/fpsy.2021.752870>.

SEARLE, T.; ALI, F. R.; AL-NIAIMI, F. Surgical smoke generated by electrocautery. *Lasers in Medical Science*, v. 36, n. 7, p. 1555-1556, 2021. DOI: <https://doi.org/10.1007/s10103-020-03209-6>.

SRINIVASU, P. N. et al. XAI-driven CatBoost multi-layer perceptron neural network for analyzing breast cancer. *Scientific Reports*, v. 14, n. 1, p. 28674, 2024. DOI: <https://doi.org/10.1038/s41598-024-79620-8>.

YELMEN, B. et al. Deep convolutional and conditional neural networks for large-scale genomic data generation. *PLoS Computational Biology*, v. 19, n. 10, e1011584, 2023. DOI: <https://doi.org/10.1371/journal.pcbi.1011584>.

ZHANG, L. et al. Prediction of prognosis in elderly patients with sepsis based on machine learning (random survival forest). *BMC Emergency Medicine*, v. 22, n. 1, p. 26, 2022. DOI: <https://doi.org/10.1186/s12873-022-00582-z>.

## 4.2 ESTUDO 2

### 4.2.1 PREDIÇÃO DE DOENÇAS EM TRABALHADORES DA SAÚDE COM O USO DE *MACHINE LEARNING*: REVISÃO SISTEMÁTICA

#### 4.2.2 RESUMO

**Objetivo:** identificar na literatura científica modelos de Machine Learning utilizados na predição de doenças em trabalhadores da saúde. **Método:** revisão sistemática, realizada nas bases de dados Medline, Lilacs, Embase, Cinahl, Scopus e Web of Science, em setembro de 2024, sem recorte temporal. Foram incluídos estudos originais que aplicaram modelos de ML para predição de doenças em trabalhadores da saúde. O risco de viés foi avaliado pelo instrumento *Prediction model Risk Of Bias Assessment Tool*. **Resultados:** foram identificados 2.013 artigos, dos quais 14 atenderam aos critérios de inclusão. Todos os estudos utilizaram modelos supervisionados, com destaque para algoritmos baseados em árvores (*Random Forest, XGBoost, CatBoost*), Máquinas de Vetores de Suporte e Regressão Logística. As doenças mais preditas foram transtornos psicossociais (50%), respiratórios (42,86%) e neurológicos (7,14%). O desempenho variou conforme o algoritmo e a condição estudada, com métricas robustas para *Random Forest* (AUC-ROC até 0,90), Máquinas de Vetores de Suporte (AUC-ROC até 0,94) e *CatBoost* (acurácia de até 0,86). A análise de risco de viés revelou limitações metodológicas em parte dos estudos, especialmente no domínio da análise estatística. **Conclusão:** os algoritmos de aprendizado de máquina, especialmente *random forest*, máquinas de vetores de suporte e *CatBoost*, mostraram bom potencial na predição de doenças em trabalhadores da saúde, principalmente nas áreas mental e respiratória. Contudo, a falta de padronização e a escassez de estudos em países latino-americanos indicam a necessidade de mais pesquisas e validações em diferentes contextos ocupacionais.

**DESCRITORES:** Aprendizado de Máquina; Saúde Ocupacional; Revisão Sistemática.

### 4.2.3 ABSTRACT

**Objective:** to identify in the scientific literature machine learning models used for disease prediction in healthcare workers. **Method:** systematic review carried out in the databases Medline, Lilacs, Embase, Cinahl, Scopus, and Web of Science, in September 2024, with no time restrictions. Original studies that applied machine learning models to predict diseases in healthcare workers were included. The risk of bias was assessed using the Prediction Model Risk of Bias Assessment Tool. **Results:** a total of 2,013 articles were identified, of which 14 met the inclusion criteria. All studies used supervised models, with emphasis on tree-based algorithms (Random Forest, XGBoost, CatBoost), Support Vector Machines, and Logistic Regression. The most predicted diseases were psychosocial disorders (50%), respiratory conditions (42.86%), and neurological disorders (7.14%). Performance varied according to the algorithm and condition studied, with strong metrics for Random Forest (area under the ROC curve up to 0.90), Support Vector Machines (area under the ROC curve up to 0.94), and CatBoost (accuracy up to 0.86). The risk of bias analysis revealed methodological limitations in some studies, especially in the statistical analysis domain. **Conclusion:** machine learning algorithms, particularly Random Forest, Support Vector Machines, and CatBoost, showed strong potential for predicting diseases in healthcare workers, especially those related to mental health and respiratory conditions. However, the lack of standardization and the scarcity of studies in Latin American contexts highlight the need for further research and validation across different occupational settings.

**KEYWORDS:** Machine Learning; Occupational Health; Systematic Review.

#### 4.2.4 INTRODUÇÃO

A saúde do trabalhador pode ser compreendida como o processo saúde-doença relacionado às atividades laborais desempenhadas pelos indivíduos (Mendes; Dias, 1991). No contexto dos trabalhadores da saúde, com atuação em hospitais, clínicas, ambulatórios e outros, o cenário é complexo, pois existe a exposição a diversos riscos ocupacionais. Esses riscos incluem fatores ergonômicos, físicos, químicos, biológicos e psicossociais, que podem comprometer a saúde física e mental desses trabalhadores favorecendo o desenvolvimento de doenças ocupacionais (Alves, et al., 2021; Maltezou, et al., 2022).

A exposição prolongada ou sem os devidos cuidados relacionados a cada tipo de risco, pode resultar no desenvolvimento de doenças infectocontagiosas, osteomusculares, oculares, dermatológicas, psicológicas, entre outras, o que reforça a importância da identificação precoce dos riscos e do desenvolvimento de agravos na saúde de trabalhadores da saúde (Dias, et al., 2021; Brasil, 2023), com a implementação de cuidados necessários para evitar o adoecimento desses trabalhadores.

Para tanto, a predição de doenças, denominada como a capacidade de antecipar possíveis acometimentos antes que eles se manifestem, emerge como uma estratégia promissora para a proteção da saúde desses trabalhadores. Ao prever doenças, abre-se espaço para a implementação de intervenções preventivas mais eficazes para evitar a instalação das doenças, mitigando os impactos negativos no bem-estar dos trabalhadores e na eficiência das instituições de saúde (Hurtado et al., 2022; Paixão et al., 2022), pois os trabalhadores estarão mais protegidos e saudáveis e terão maior desempenho no cuidado prestado aos clientes.

As formas tradicionais de detecção e prevenção de doenças ocupacionais, como exames médicos periódicos, avaliações ergonômicas e programas de segurança no trabalho, são amplamente utilizadas no ambiente hospitalar e em outras instituições de saúde. Essas estratégias, embora importantes, apresentam limitações quanto à sua capacidade de prever doenças de forma antecipada e personalizada (Donato et al., 2021; Ferreira et al., 2024), cuidando dos trabalhadores antes da instalação de doenças, de forma preventiva.

Nesse contexto, a aplicação de algoritmos de *Machine Learning* (ML), ou também conhecidos como aprendizado de máquina, surge como uma alternativa inovadora. Essa tecnologia permite analisar grandes volumes de dados, identificar padrões complexos e realizar previsões precisas sobre a ocorrência de doenças, potencializando as estratégias de prevenção (Chaudhry; Choudhury, 2024; Paixão et al., 2022).

Apesar do potencial transformador do ML, ainda existem lacunas na literatura relacionadas à aplicação desses modelos na predição de doenças entre trabalhadores da saúde (Chaudhry; Choudhury, 2024). Estudos que compilem e analisem esses modelos utilizados são essenciais para preencher essas lacunas, além de proporcionar insights sobre como essas abordagens podem contribuir para melhorar as estratégias de prevenção e proteção da saúde no ambiente ocupacional.

Dessa forma, este estudo, tem como objetivo identificar na literatura científica modelos de *Machine Learning* utilizados na predição de doenças em trabalhadores da saúde.

#### 4.2.5 MATERIAL E MÉTODO

Trata-se de uma Revisão Sistemática (RS), método de pesquisa que reúne, avalia criticamente e sintetiza a literatura disponível sobre um determinado tema, com o objetivo de fornecer uma visão abrangente e confiável das evidências científicas relacionadas a uma estratégia de intervenção específica (Sampaio; Mancini, 2007).

Esta RS foi desenvolvida de acordo com o *Preferred Reporting Items for Systematic Reviews and Meta-Analyses* (PRISMA) (Page et al., 2020) e o *Transparent reporting of multivariable prediction models for individual prognosis or diagnosis: checklist for systematic reviews and meta-analyses* (TRIPOD-SRMA) (Snell et al., 2023). O protocolo desta RS foi previamente publicado na plataforma *International Prospective Register of Systematic Reviews* (PROSPERO), registrado sob o número CRD42024602629.

Utilizou-se como referência metodológico a *Cochrane Handbook for Systematic Reviews of Interventions*, garantindo transparência, reprodutibilidade e confiabilidade nos resultados, com as seguintes etapas: definição da pergunta de pesquisa, definição de descritores e estratégia de busca, seleção dos estudos, extração dos dados, avaliação do risco de viés, análise e síntese dos dados e discussão dos dados com a literatura (Higgins et al., 2024).

A pergunta de pesquisa foi elaborada a partir do anagrama PICO (População, Fenômeno de Interesse e Contexto) (Stern; Jordan; McArthur, 2014), onde definiu-se como sendo a População, modelos de ML; o Fenômeno de Interesse, os predição de doenças; o Contexto, os trabalhadores da saúde, resultando na seguinte questão norteadora: “Quais os modelos de Machine Learning são utilizados para predição de doenças em trabalhadores da saúde?”

A busca sistemática da literatura ocorreu nas bases de dados: Medline (*Medical Literature Analysis and Retrieval System Online*) via PubMed, Lilacs (Literatura Latino-Americana e do Caribe em Ciências da Saúde) via Biblioteca Virtual em Saúde (BVS), EMBASE (Excerpta Medica dataBase), Cinahl (*Cummulative Index to Nursing and Allied Health Literature*), Scopus e Web of Science. A busca ocorreu em 23 de setembro de 2024.

Foram incluídos na RS estudos que relatam modelos de predição de doenças em trabalhadores de saúde usando métodos de ML publicados em periódicos revisados por pares, sem recorte temporal. Foram excluídos artigos de revisões sistemáticas, resumos, capítulos de livro, dissertações, teses, relato de casos e os realizados com animais.

Para estratégia de busca (Figura 1) foram utilizados três vocabulários controlados em saúde: *Medical Subject Headings (MeSH)* para bases de dados *Medline*, *Scopus* e *Web of Science*; Descritores em Ciências da Saúde (DeCS) para Lilacs; thesaurus do Embase (EMTREE) para Embase e assuntos *Cinahl* para a base de dados *Cinahl*. Após definidos os termos de busca, eles foram associados aos operadores booleanos AND e OR.

Os resultados de cada base de dados foram importados eletronicamente para o software *Rayyan – Intelligent Systematic Review*® e procedeu-se a remoção dos artigos duplicados em mais de uma base de dados. Após, a leitura dos textos para compor a RS foi realizada em duas etapas: leitura dos títulos e resumos por dois revisores independentemente e leitura dos textos na íntegra pelos dois revisores. Nas duas etapas as divergências entre os revisores foram analisadas e decididas pelo terceiro revisor.

Para a extração dos dados dos estudos da amostra final da RS foi elaborada uma ficha com auxílio da ferramenta *Critical Appraisal and Data Extraction for Systematic Reviews of Prediction Modelling Studies* (CHARMS) (Moons et al., 2014). As informações extraídas dos estudos selecionados foram categorizadas em dois grupos: (1) Informações básicas: autor, ano de publicação, desenho da pesquisa, participantes, fonte de dados, tamanho da amostra e doença estudada; (2) Modelo de predição, tipo de aprendizado por máquina, métricas de desempenho e principais conclusões do desempenho do modelo.

**Figura 1** – Estratégia de busca dos artigos por bases de dados, utilizando os vocabulários controlados de cada base de dados. Brasil, 2025.

<b>Medline</b>	#1	<i>('Machine Learning') OR ('Supervised Machine Learning')</i>
	#2	<i>'Disease'</i>
	#3	<i>'Health Personnel'</i>
	#4	<i>((('Machine Learning') OR ('Supervised Machine Learning')) AND ('Disease')) AND ('Health Personnel')</i>
<b>Web of Science</b>	#1	<i>(ALL=('Machine Learning')) OR ALL=('Supervised Machine Learning')</i>
	#2	<i>ALL=('Disease')</i>
	#3	<i>ALL=('Health Personnel')</i>
	#4	<i>#1 AND #2 AND #3</i>
<b>Scopus</b>	#1	<i>(TITLE-ABS-KEY ('machine AND learning') OR TITLE-ABS-KEY ('supervised AND machine AND learning'))</i>
	#2	<i>TITLE-ABS-KEY ('disease')</i>
	#3	<i>TITLE-ABS-KEY ('health AND personnel')</i>
	#4	<i>((TITLE-ABS-KEY ('machine AND learning') OR TITLE-ABS-KEY ('supervised AND machine AND learning')) AND (TITLE-ABS-KEY ('disease'))) AND (TITLE-ABS-KEY ('health AND personnel'))</i>
<b>Embase</b>	#1	<i>'machine learning'</i>
	#2	<i>'supervised machine learning'</i>
	#3	<i>#1 OR #2</i>
	#4	<i>'diseases'</i>
	#5	<i>'health care personnel'</i>
	#6	<i>#3 AND #4 AND #5</i>
<b>Cinahl</b>	<i>machine learning AND pathology AND medical personnel</i>	
<b>Lilacs</b>	<i>(Aprendizado de Máquina) OR (Aprendizado de Máquina Supervisionado) AND (Doença) AND (Pessoal da Saúde)</i>	

Fonte: própria autora.

Para avaliar o risco de viés e aplicabilidade dos modelos de predição foi utilizado o *Prediction model Risk Of Bias Assessment Tool* (PROBAST), uma ferramenta que pode ser utilizada para a avaliação crítica de estudos envolvidos no desenvolvimento, validação ou atualização de modelos de previsão para previsões individualizadas, com 20 perguntas de sinalização categorizadas em quatro domínios: participantes, preditores, resultado e análise. Cada pergunta de sinalização pode ser respondida como "sim", "provavelmente sim", "não",

"provavelmente não" ou "nenhuma informação". Se pelo menos uma pergunta de sinalização em um domínio for respondida como "não" ou "provavelmente não", esse domínio deve ser considerado de alto risco de viés. Quando mais de uma pergunta de sinalização foi respondida com "nenhuma informação" o viés de risco do domínio será considerado pouco claro. Somente quando todos os domínios são julgados como baixo risco de viés, o viés geral pode ser considerado de baixo risco (Wolff et al., 2019).

#### 4.2.6 RESULTADOS

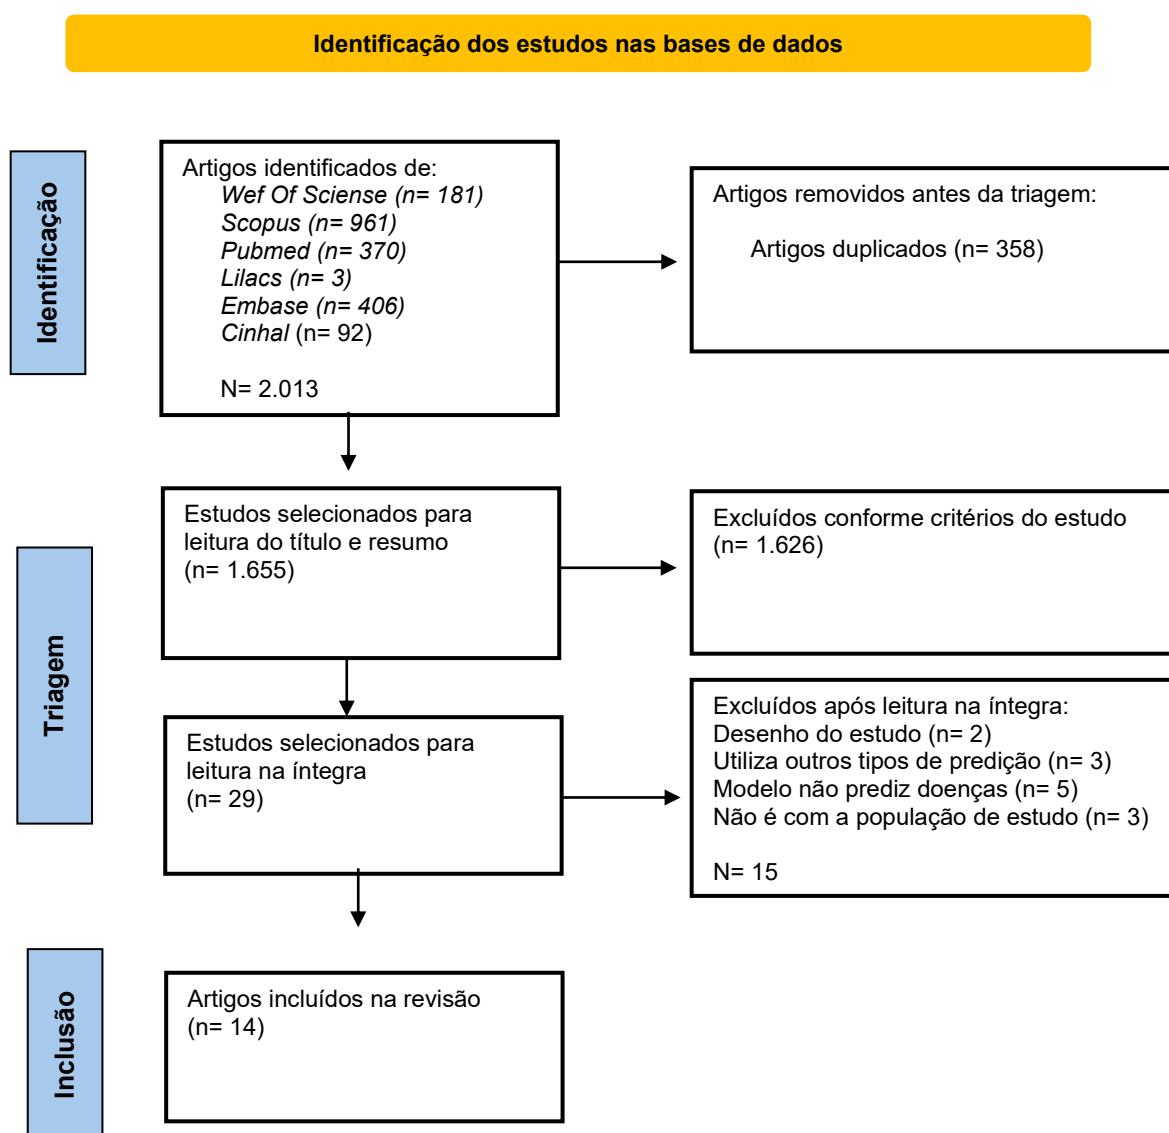
Foram identificados 2.013 artigos nas bases de dados, sendo excluídos 358 artigos duplicados e incluídos 1.655 para leitura do título e resumo. Posteriormente, 26 artigos foram selecionados para a leitura na íntegra, na qual 14 artigos foram incluídos nesta RS, como mostra a Figura 2.

Os estudos incluídos na RS abrangem um período de cinco anos (2020 a 2024), realizados em diversos países, com destaque para China e Estados Unidos. Quanto ao desenho dos estudos, sete (50%) utilizou o delineamento transversal, três (21,3%) coorte, um (7,4%) estudo multicêntrico observacional transversal e três (21,3%) não foram descritos o delineamento conforme Tabela 1.

Em relação às características dos modelos de ML (Tabela 2), observou-se que todos os estudos utilizaram aprendizado de máquina supervisionado. Entre os modelos supervisionados, foram utilizados algoritmos baseados em árvores (Random Forest, Árvore de Classificação e Regressão, Extra Trees, XGBoost, CatBoost, Árvore de Decisão e Máquinas de Aumento de Gradiente), modelos de regressão e regularização (Regressão Logística, Lasso, Rede Elástica e Mínimos Quadrados Parciais) e modelos baseados em Máquinas de Vetores de Suporte (Máquinas de Vetores de Suporte e Regressão Linear de Máquina de Vetor de Suporte Insensível a  $\epsilon$ ).

Em relação às características dos modelos de ML (Tabela 2), observou-se que todos os estudos utilizaram aprendizado de máquina supervisionado. Entre os modelos supervisionados, foram utilizados algoritmos baseados em árvores (*Random Forest*, Árvore de Classificação e Regressão, *Extra Trees*, *XGBoost*, *CatBoost*, Árvore de Decisão e Máquinas de Aumento de Gradiente), modelos de regressão e regularização (Regressão Logística, Lasso, Rede Elástica e Mínimos Quadrados Parciais) e modelos baseados em Máquinas de Vetores de Suporte (Máquinas de Vetores de Suporte e Regressão Linear de Máquina de Vetor de Suporte Insensível a  $\epsilon$ ).

**Figura 2** – Fluxograma da revisão sistemática acerca de modelos machine learning aplicados a predição de doenças em trabalhadores da saúde de acordo com *Preferred Reporting Items for Systematic Reviews and Meta-Analyses*. Brasil, 2025.



Fonte: própria autora.

**Tabela 1** – Características relacionadas a autor, ano, país, periódico científico, desenho e amostra dos estudos incluídos na revisão sistemática sobre modelos *Machine Learning* aplicados a previsão de doenças em trabalhadores da saúde. Brasil, 2025.

<b>Autor (ano)</b>	<b>País</b>	<b>Periódico Científico</b>	<b>Desenho do Estudo</b>	<b>Amostra</b>
Rios et al., (2020)	Espanha	Neural Computing and Application	Epidemiológico observacional transversal	139
Crowley et al., (2021)	Estados Unidos	Plos Computational Biology	Coorte	144
Gupta et al., (2021)	Índia	Indian Heart Journal	Observacional e transversal	1.615
Souza et al., (2021)	Brasil	Revista Brasileira de Epidemiologia	Multicêntrico observacional transversal	708
Leal-Neto et al., (2021)	Suíça	JMIR Public Health and Surveillance	Coorte prospectiva	1.004
Zhou et al., (2022)	China	Frontiers in Psychiatry	Transversal	2.574
Portugal et al., (2022)	Brasil	Frontiers in Psychiatry	Transversal	437
Nunzio et al., (2022)	Itália	Frontiers in Medicine	Transversal multicêntrico	405
Yao et al., (2022)	China	Medicine	Transversal	444
Yoshikawa (2022)	Japão	Journal of Infection and Chemotherapy	Não informado	169
Hirten, et al., (2022)	Estados Unidos	JAMIA Open	Observacional prospectivo multicêntrico	407
Geoffrion, et al., (2023)	Canadá	Journal of Medical Systems	Coorte prospectivo	816
Delgado-Gallegos, et al., (2023)	México	Brain Sciences	Não informado	106
Kumari, et al., (2024)	Canadá	Journal of Primary Care & Community Health	Não informado	18.139

**Fonte:** própria autora.

Em relação às características dos modelos de ML (Tabela 2), observou-se que todos os estudos utilizaram aprendizado de máquina supervisionado. Entre os modelos supervisionados, foram utilizados algoritmos baseados em árvores (*Random Forest*, Árvore de Classificação e Regressão, *Extra Trees*, *XGBoost*, *CatBoost*, Árvore de Decisão e Máquinas de Aumento de Gradiente), modelos de regressão e regularização (Regressão Logística, Lasso, Rede Elástica e Mínimos Quadrados Parciais) e modelos baseados em Máquinas de Vetores de Suporte (Máquinas de Vetores de Suporte e Regressão Linear de Máquina de Vetor de Suporte Insensível a  $\epsilon$ ).

As doenças previstas nos estudos foram classificadas em três grupos: transtornos psicossociais e psicológicos (n=7; 50%), doenças respiratórias e pulmonares (n=6; 42,86%) e

transtornos cognitivos e neurológicos (n=1; 7,14%) com ênfase no ambiente laboral. Os preditores utilizados nos estudos incluíram bancos de dados contendo informações sociodemográficas, ocupacionais e condições de saúde específicas de cada doença, além de questionários e instrumentos validados para diagnóstico das doenças.

**Tabela 2** – Modelos *Machine Learning* e métricas de desempenho dos estudos incluídos na Revisão Sistemática sobre modelos *Machine Learning* aplicados a previsão de doenças em trabalhadores da saúde. Brasil, 2025.

Autor (ano)	Doença predita	Tipo de Aprendizado de Máquina	Modelo	Métricas de desempenho e/ou estatísticas
Rios et al., (2020)	Síndrome da Visão Computacional	Supervisionado	Máquinas de Vetores de Suporte	Área sob a curva ROC
Crowley et al., (2021)	Lesão pulmonar WTC	Supervisionado	<i>Random Forest</i>	Área sob a curva ROC
Gupta et al., (2021)	Burnout	Supervisionado	<i>Random Forest</i> <i>CatBoost</i> <i>Extra-tree</i> <i>XG Boost</i> <i>KNN</i> <i>Gradient Boosting Classifier</i>	Área sob a curva ROC Precisão Pontuação F1 Sensibilidade
Souza et al., (2021)	Tuberculose	Supervisionado	Árvore de classificação e regressão	Curva ROC Área sob a curva ROC Precisão Sensibilidade Especificidade Valor preditivo negativo Valor preditivo positivo
Leal-Neto et al., (2021)	COVID-19	Supervisionado	<i>Random Forest</i>	Área sob a curva ROC Pontuação F1 Taxa de precisão Taxa de classificação incorreta
Zhou et al., (2022)	Depressão	Supervisionado	Árvore de decisão, LASSO <i>Random Forest</i> Árvores de aumento de gradiente	Área sob a curva ROC
Portugal et al., (2022)	Depressão e transtorno de estresse pós-traumático	Supervisionado	Regressão linear de máquina de vetor de suporte insensível a $\epsilon$	Coefficiente de correlação de Pearson Coefficiente de determinação Erro quadrático médio normalizado

Nunzio et al., (2022)	Apneia Obstrutiva do Sono	Supervisionado	<i>XGBoost</i>	Área sob a Curva ROC Fisher Score
Yao et al., (2022)	Depressão e Flexibilidade psicológica relacionada ao trabalho	Supervisionado	Algoritmo linear generalizado	Correlação de Pearson
Yoshikawa (2022)	COVID-19	Supervisionado	Classificador Bayes	Sensibilidade Especificidade Área sob a curva ROC Índice de <i>Youden</i>
Hirten, et al., (2022)	COVID-19	Supervisionado	Máquinas de aumento de gradiente Rede elástica	Área sob a curva ROC Precisão Sensibilidade
Geoffrion, et al., (2023)	Ansiedade, depressão e Transtorno de Estresse Pós-Traumático	Supervisionado	Regressão Logística Máquina de Vetores de Suporte	Precisão Sensibilidade Especificidade Valor preditivo positivo
Delgado-Gallegos, et al., (2023)	Estresse	Supervisionado	Árvore de decisão	Sensibilidade Especificidade Matriz de confusão
Kumari, et al., (2024)	Saúde mental percebida e estresse de vida percebido	Supervisionado	Regressão Logística <i>Random Forest</i> <i>Naive Bayes</i> <i>KNN</i> <i>Adaptive boost</i> <i>Multi-layer perceptron</i> <i>XGBoost</i> <i>LightBoost</i>	Área Sob a Curva ROC Precisão Acurácia Pontuação F1

**Fonte:** própria autora.

Observou-se que os algoritmos de aprendizado de máquina demonstraram variabilidade no desempenho, dependendo das métricas avaliadas e da doença predita. O algoritmo *Random Forest*, demonstrou um desempenho consistentemente forte, especialmente na predição de saúde mental percebida, onde a AUC-ROC foi de 0,81 e para lesão pulmonar, o valor de AUC-ROC foi de 0,902. Para a predição de Burnout, o *Random Forest* apresentou precisão de 0,79, acurácia de 0,77 e Pontuação F1 de 0,79. Na análise da apneia do sono, o algoritmo obteve acurácia de 0,86 e sensibilidade de 0,85, indicando uma alta capacidade de identificar corretamente casos positivos.

O algoritmo *CatBoost* também se destacou, apresentando métricas robustas. Na predição de Burnout, alcançou AUC-ROC de 0,80, precisão de 0,76 e acurácia de 0,73. Para a apneia do sono, acurácia de 0,86 e sensibilidade de 0,88, sugerindo um excelente poder de detecção para essa condição.

O algoritmo de Máquinas de Vetores de Suporte (SVM) exibiu um desempenho notável em diversas aplicações, atingindo o valor mais alto de AUC-ROC de 0,9433 na predição da síndrome da visão computacional. Para a fadiga, a AUC-ROC foi de 0,87, com sensibilidade de 0,84 e especificidade de 0,88. Na apneia do sono, a acurácia foi de 0,86, com sensibilidade de 0,88 e especificidade de 0,84. Por outro lado, para ansiedade e transtorno depressivo maior, as métricas foram mais moderadas, com AUC-ROC em torno de 0,73 e 0,72, respetivamente.

A Regressão Logística demonstrou um desempenho variável. Para saúde mental percebida, a AUC-ROC foi de 0,811 e para a apneia do sono, acurácia de 0,77, sensibilidade de 0,76. Para ansiedade e transtorno de estresse pós-traumático, a AUC-ROC foi de 0,743 e 0,726, respetivamente. Na predição de Burnout, a AUC-ROC foi de 0,72 e a precisão de 0,76.

Outros algoritmos, como o KNN, demonstraram desempenhos mais modestos, com AUC-ROC de 0,57 e Pontuação F1 de 0,61 na predição de Burnout, indicando um desempenho de classificação limitado. O *XGBoost*, demonstrou AUC-ROC de 0,75 para Burnout. O *Gradient Boosting Classifier* e o *Extra-tree* também foram aplicados para Burnout, com AUC-ROC de 0,76 e 0,84, respetivamente.

A Tabela 3 apresenta a avaliação do risco de viés e da aplicabilidade de diferentes estudos utilizando o instrumento PROBAST observa-se no domínio participantes, três (21,4%) estudos apresentaram baixo risco, enquanto nos domínios preditores e resultados, esse número foi de 12 (85,7%) estudos. O domínio análise apresentou a maior variabilidade, com cinco (35,7%) estudos classificados como de baixo risco, evidenciando uma área crítica na construção dos modelos. No quesito aplicabilidade, a preocupação foi menor: no domínio participantes, nove (64,2%) estudos apresentaram baixa preocupação, seguido pelos domínios preditores e resultados, onde 12 (85,7%) e 13 (92,8%) estudos, respetivamente, tiveram avaliações favoráveis. Entre os 14 estudos analisados, um (7,2%) apresentaram baixo risco de viés e baixa preocupação com aplicabilidade, enquanto sete (92,8%) demonstraram alguma limitação metodológica.

**Tabela 3** – Risco de viés e aplicabilidade dos estudos incluídos na Revisão Sistemática sobre modelos *Machine Learning* aplicados a previsão de doenças em trabalhadores da saúde de acordo com o *Prediction model Risk Of Bias Assessment Tool*. Brasil, 2025.

Autor (ano)	Risco de viés				Aplicabilidade			Risco Geral	
	Participantes	Preditores	Resultados	Análise	Participantes	Preditores	Resultados	Risco de Viés	Aplicabilidade
Rios et al., (2020)	-	-	?	-	+	+	?	-	?
Crowley et al., (2021)	+	+	+	-	-	-	+	-	-
Gupta et al., (2021)	-	+	+	-	+	+	+	-	+
Souza et al., (2021)	?	+	+	-	?	+	+	-	?
Leal-Neto et al., (2021)	+	+	+	-	+	-	+	-	-
Zhou et al., (2022)	-	+	-	+	+	+	+	-	+
Portugal et al., (2022)	-	+	+	-	+	+	+	-	+
Nunzio et al., (2022)	-	+	+	+	+	+	+	-	+
Yao et al., (2022)	-	+	+	?	+	+	+	-	+
Yoshikawa (2022)	?	+	+	-	?	+	+	-	?
Hirten, et al., (2022)	-	+	+	+	+	+	+	-	+
Geoffrion, et al., (2023)	+	+	+	+	+	+	+	+	+
Delgado-Gallegos, et al., (2023)	?	-	+	-	?	+	+	-	?
Kumari, et al., (2024)	?	+	+	+	?	+	+	?	?

Vermelho (-) Alto risco de viés ou alta preocupação com aplicabilidade; Verde (+) Baixo risco de viés ou baixa preocupação com aplicabilidade; Amarelo (?) Pouco Claro.

#### 4.2.7 DISCUSSÃO

Este estudo permitiu identificar e caracterizar os modelos de ML aplicados à predição de doenças em trabalhadores da saúde, população frequentemente exposta a riscos ocupacionais diversos e intensos. Esse contexto de vulnerabilidade tem sido intensificado por fatores como a pandemia da COVID-19, que ampliou o adoecimento físico e mental nesses profissionais (Benavides et al., 2024). Estimativas globais indicam que mais de 2,7 milhões de mortes por ano estão associadas a causas ocupacionais, ressaltando a importância de estratégias preventivas inovadoras (Hämäläinen; Takala; Kiat, 2017).

Nos estudos analisados, os principais desfechos preditos referem-se a transtornos mentais, doenças respiratórias e condições neurológicas. Essa distribuição está alinhada aos

riscos psicossociais, biológicos e organizacionais que permeiam os ambientes hospitalares. O predomínio dos transtornos mentais, como ansiedade, depressão e Burnout, sugere um cenário de sofrimento psíquico significativo entre esses profissionais, reforçando a necessidade de intervenções direcionadas à saúde mental no trabalho (Feng; Cui, 2024).

As doenças respiratórias, como tuberculose e COVID-19, também foram amplamente exploradas nos modelos, especialmente pela alta transmissibilidade desses agravos nos serviços de saúde. Já os transtornos neurológicos, como apneia obstrutiva do sono, embora menos frequentes, evidenciam relações com a privação de sono e sobrecarga laboral, especialmente em turnos noturnos (Nunzio et al., 2022).

Importante destacar que vários dos agravos abordados nos estudos estão incluídos na Lista de Doenças Relacionadas ao Trabalho (LDRT) do Ministério da Saúde, o que reforça sua relevância para ações de vigilância em saúde ocupacional (Brasil, 2023). Ferramentas de predição baseadas em ML, podem se tornar aliadas importantes da enfermagem do trabalho, ao apoiar estratégias de prevenção e gerenciamento de riscos, contudo ainda há desafios importantes a serem enfrentados nesse mercado (Fagundes et al., 2024).

Outro achado relevante foi a ampla adoção de instrumentos validados para identificação das doenças-alvo, como por exemplo o GAD-7 para ansiedade, conferindo maior consistência aos dados utilizados nos modelos preditivos. A presença de dados estruturados, obtidos por meio de escalas reconhecidas, favorece o desempenho dos algoritmos ao reduzir ambiguidades nas variáveis analisadas, entretanto deve-se enfatizar também na qualidade e na disponibilidade dos dados nos sistemas de informação de saúde ocupacional (Fagundes et al., 2024).

Do ponto de vista metodológico, observou-se que a maior parte dos estudos utilizou delineamento transversal, o que limita a inferência temporal entre exposição e desfecho. Modelos de coorte e estudos longitudinais são mais adequados para validar a eficácia preditiva dos algoritmos ao longo do tempo, uma vez que permitem acompanhar a evolução das condições de saúde dos trabalhadores e identificar, com maior precisão, oportunidades para intervenções preventivas que aumentem a efetividade e o retorno dos investimentos em saúde e segurança ocupacional (Sepulveda, 2013).

A variação no tamanho das amostras nos estudos selecionados, demonstram que a maioria dos algoritmos, possuem grande quantidade de dados, sendo necessário assumir outras abordagens, como big data. O uso de big data, surge no cenário como uma solução promissora para o aprimoramento dos algoritmos, permitindo a análise de grandes volumes de

informações que integram aspectos clínicos, ambientais e ocupacionais (Fagundes et al., 2024; Soriano-Valdez et al., 2020).

Dessa forma, deve se levar em consideração os seguintes componentes: o volume dos dados, calculado como o número de unidades de observação vezes o número de pontos de dados, a velocidade ou rapidez com que novas unidades de observações são adicionadas aos conjuntos de dados, a variedade de técnicas necessárias para adquirir os diferentes pontos de dados, a variabilidade dos dados, dada a possibilidade de diversas interpretações, diagnósticos e resultados estatísticos, os métodos necessários para alcançar uma visualização científica adequada dos resultados obtidos, a veracidade como uma medida de quão precisos são os dados obtidos e qual valor ou melhoria na saúde seria obtido a partir da abordagem para justificar a aquisição de um volume tão alto de dados (Soriano-Valdez et al., 2020).

A predominância do aprendizado supervisionado nos estudos analisados pode ser justificada pela sua maior maturidade tecnológica e pela disponibilidade de dados rotulados. Esse tipo de aprendizado utiliza exemplos com respostas conhecidas, o que permite treinar os algoritmos para reconhecer padrões que indicam risco para o desenvolvimento de doenças, ou seja, o objetivo do algoritmo é construir um classificador que possa determinar corretamente a classe de novos exemplos ainda não rotulados (Ludemir, 2021).

Os modelos de aprendizagem de máquina supervisionado geralmente distinguem dois tipos de tarefas, sendo elas de regressão e classificação, dentre os algoritmos utilizados podemos citar o *Random Forest*, o SVM, o *XGBoost* e Regressão Logística. Esses algoritmos apresentam desempenho satisfatório em contextos clínicos, sendo capazes de lidar com dados heterogêneos e com múltiplas variáveis (Valkenborg et al., 2023; Uddin et al., 2019)

A SVM demonstrou bons resultados em tarefas de classificação, especialmente na predição de transtornos mentais como depressão, ansiedade e síndrome da visão computacional, (Rios et al., 2020; Geoffrion et al., 2023; Portugal et al., 2022). Esses modelos executam tarefas de classificação, regressão e detecção de outliers. No entanto, seu desempenho pode ser comprometido em dados ruidosos ou com sobreposição entre categorias (Pruneski, et al., 2023).

O Random Forest destacou-se por combinar múltiplas árvores de decisão, oferecendo resultados estáveis e com menor risco de *overfitting*, utilizados para predizer lesão pulmonar, *Burnout*, COVID-19 (Crowley et al., 2021; Gupta et al., 2021; Leal-Neto et al., 2021). O *XGBoost*, apresentou elevada acurácia e desempenho computacional, sendo indicado para bases de dados maiores (Nunzio et al., 2022; Kumari et al., 2024). A Regressão Logística,

embora mais simples, foi frequentemente utilizada devido à sua facilidade de interpretação, especialmente em ambientes hospitalares (Geoffrion et al., 2023; Kumari et al., 2024).

A avaliação do desempenho de modelos preditivos é um pilar fundamental na pesquisa clínica, e a capacidade discriminativa surge como uma métrica essencial para determinar sua utilidade. A Área sob a Curva (AUC) é o parâmetro mais frequentemente empregado para quantificar essa capacidade, especialmente em desfechos binários, medindo a habilidade de um modelo em distinguir corretamente entre classes positivas e negativas, com valores próximos a 1,0 indicando um desempenho discriminativo superior (Hond et al., 2022). Pesquisas empíricas mostram que modelos com valores de AUC mais altos são mais frequentemente clinicamente úteis (Gulati et al., 2022).

A curva *Receiver Operating Characteristic* (ROC), da qual a AUC é derivada, fornece uma representação visual da relação entre a sensibilidade (verdadeiros positivos) e a especificidade (falsos positivos). Um modelo com alta capacidade discriminativa terá sua curva ROC posicionada mais próxima ao canto superior esquerdo do gráfico, onde a sensibilidade é alta e a taxa de falsos positivos é baixa (Nahm, 2022).

Por exemplo, o algoritmo MVS desenvolvido para predição da síndrome da visão computacional obteve o melhor desempenho (AUC de 0,94) indicando uma excelente capacidade de predição para o desfecho (Rios et al., 2020). Por outro lado, o algoritmo KNN para predição do estresse de vida percebido apresentou a AUC mais baixa (0,65) (Kumari et al., 2024). Embora este valor demonstre uma capacidade discriminativa moderada, foi significativamente inferior quando comparada aos modelos com melhor desempenho. As possíveis razões para essa diferença podem estar relacionadas ao tipo de variáveis utilizadas, ao tamanho da amostra ou à população do estudo, que pode ter características prognósticas distintas em comparação com os estudos que obtiveram AUC mais altas (Rios et al., 2020; Kumari et al., 2024).

Embora a AUC ofereça uma medida global do desempenho do modelo, a análise de métricas como a sensibilidade e a especificidade são importantes para compreender sua utilidade em um contexto clínico específico, onde a sensibilidade mede a capacidade do modelo de identificar corretamente os casos positivos (taxa de verdadeiros positivos), enquanto a especificidade mede sua capacidade de identificar corretamente os casos negativos (taxa de verdadeiros negativos) (Hond et al., 2022; Monaghan et al., 2021; Mandrekar et al., 2010).

Esta RS demonstrou uma variação considerável nessas métricas, refletindo diferentes perfis de desempenho entre os modelos. O modelo de árvore de decisão para predição de COVID-19, por exemplo, apresentou uma alta sensibilidade de 87,0%. Isso sugere que o modelo é excepcionalmente bom em detectar pacientes que desenvolverão o desfecho de COVID-19 positivo, minimizando o risco de falsos negativos. Essa característica seria particularmente valiosa em ambientes de triagem, onde a principal preocupação é garantir que nenhum paciente de alto risco seja erroneamente classificado como de baixo risco. No entanto, sua especificidade foi de 58%, indicando que o modelo pode gerar um número considerável de falsos positivos, o que pode sobrecarregar recursos ao levar a investigações desnecessárias em pacientes que, na realidade, não contraíram a doença (Yoshikawa et al., 2022; Mandrekar et al., 2010).

Em contraste, o modelo de árvore de decisão para predição de estresse demonstrou um perfil de desempenho focado em uma alta precisão para a classificação de pacientes sem o desfecho. Este modelo obteve uma sensibilidade de 91% e uma alta especificidade de 98% para a predição do estresse. A alta especificidade sugere que este modelo é muito eficaz em classificar corretamente os pacientes que não desenvolverão o desfecho grave, o que poderia ser útil para a alocação eficiente de recursos, pois minimiza a intervenção em indivíduos sem necessidade real (Delgado-Gallegos et al., 2023).

Esses exemplos ilustram o trade-off inerente entre sensibilidade e especificidade. Enquanto um modelo) prioriza a identificação de todos os casos positivos (alta sensibilidade (Yoshikawa, 2022), outra busca a máxima confiabilidade na identificação dos casos negativos (alta especificidade) (Delgado-Gallegos et al., 2023; Yoshikawa et al., 2022). A escolha do modelo mais adequado para aplicação clínica dependerá, portanto, da prioridade do contexto de saúde pública e das consequências associadas a falsos positivos e falsos negativos.

Os achados desta RS indicam que o uso de ML na predição de doenças em trabalhadores da saúde é uma ferramenta promissora. A incorporação desses modelos em sistemas hospitalares pode potencializar estratégias de triagem precoce, gestão de riscos e promoção da saúde ocupacional.

Entretanto, ainda são escassos os estudos desenvolvidos em contextos latino-americanos e com foco em profissionais de saúde. Nesse sentido, recomenda-se o desenvolvimento de modelos preditivos localmente validados e com representatividade de diferentes categorias profissionais. Também se destaca a necessidade de estudos

intervencionais que avaliem o impacto real do uso de ML sobre os indicadores de saúde dos trabalhadores.

#### 4.2.8 CONCLUSÃO

Esta revisão sistemática evidenciou o crescente uso de algoritmos de machine learning na predição de doenças entre trabalhadores da saúde, com destaque para modelos de aprendizado supervisionado. A análise sugere que algoritmos baseados em árvores de decisão, como *Random Forest* e *CatBoost* e o SVM, tendem a alcançar métricas de desempenho superiores em comparação com modelos mais simples como a Regressão Logística e o KNN, especialmente na Área sob a Curva ROC, que mede a capacidade de discriminação do modelo.

A predominância de modelos supervisionados se relaciona à maior disponibilidade de dados rotulados e à maturidade tecnológica dessas abordagens. Contudo, a heterogeneidade dos modelos e a ausência de padronização nas métricas de desempenho dificultam comparações diretas entre os estudos, o que limita a generalização dos resultados.

Ainda, destaca-se a relevância da incorporação de modelos preditivos baseados em *Machine Learning* aos sistemas de saúde como ferramenta complementar às estratégias tradicionais de vigilância e prevenção, contribuindo para ambientes de trabalho mais seguros e para a promoção da saúde dos profissionais.

#### 4.2.9 REFERÊNCIAS

BENAVIDES, F. G.; UTZET, M.; SERRA, C. et al. Salud y bienestar del personal sanitario: condiciones de empleo y de trabajo más allá de la pandemia. *Gaceta Sanitaria*, v. 38, supl. 1, p. 102378, 2024. DOI: <https://doi.org/10.1016/j.gaceta.2024.102378>.

BRASIL. Ministério da Saúde. Portaria GM/MS nº 1.999, de 27 de novembro de 2023. Atualiza a Lista de Doenças Relacionadas ao Trabalho (LDRT). *Diário Oficial da União*, Brasília, DF, seção 1, 27 nov. 2023. Disponível em: <https://www.in.gov.br/web/dou/-/portaria-gm/ms-n-1.999-de-27-de-novembro-de-2023-526629116>. Acesso em: 17 jan. 2025.

CHAUDHRY, Z. S.; CHOUDHURY, A. Clinical applications of artificial intelligence in occupational health: a systematic literature review. *Journal of Occupational and Environmental Medicine*, v. 66, n. 12, p. 943-955, 2024. DOI: <https://doi.org/10.1097/JOM.0000000000003212>.

CROWLEY, G.; KIM, J.; KWON, S.; LAM, R.; PREZANT, D. J.; LIU, M.; NOLAN, A. PEDF, a pleiotropic WTC-LI biomarker: Machine learning biomarker identification and validation. *PLoS Computational Biology*, v. 17, n. 7, e1009144, 2021. DOI: <https://doi.org/10.1371/journal.pcbi.1009144>.

DELGADO-GALLEGOS, J. L.; AVILÉS-RODRIGUEZ, G.; PADILLA-RIVAS, G. R.; DE LOS ÁNGELES COSÍO-LEÓN, M.; FRANCO-VILLAREAL, H.; NIETO-HIPÓLITO, J. I.; DE DIOS SÁNCHEZ LÓPEZ, J.; ZUÑIGA-VIOLANTE, E.; ISLAS, J. F.; ROMO-CARDENAS, G. S. Application of C5.0 algorithm for the assessment of perceived stress in healthcare professionals attending COVID-19. *Brain Sciences*, v. 13, n. 3, p. 513, 2023. DOI: <https://doi.org/10.3390/brainsci13030513>.

DIAS, E. C.; SILVA-JUNIOR, J. S.; BAETA, K. F.; BANDINI, M. Lista de doenças relacionadas ao trabalho – obrigação legal de base técnica se transforma em imbróglgio político-social: reflexões sobre possíveis saídas. *Saúde em Debate*, v. 45, n. 129, p. 435-440, 2021. DOI: <https://doi.org/10.1590/0103-1104202112914>.

DONATO, T. A. A.; SILVA, R. M. A.; ANDRADE, A. C. de S.; KOCHERGIN, C. N.; MEDEIROS, D. S. de; SOARES, D. A. et al. Exame ocupacional periódico: oportunidade de diagnóstico e monitoramento de doença crônica não transmissível em homens. *Cadernos de Saúde Pública*, v. 37, n. 11, e00298320, 2021. DOI: <https://doi.org/10.1590/0102-311X00298320>.

FAGUNDES, T. P.; WICHMANN, R. M.; SILVA, M. E. L.; OLIVEIRA, T. A. Big data em Saúde do Trabalhador: o quão distantes estamos? *Revista Brasileira de Saúde Ocupacional*, v. 49, edcinq11, 2024. DOI: <https://doi.org/10.1590/2317-6369/40522pt2024v49edcinq11>.

FENG, Y.; CUI, J. Emotional exhaustion and emotional contagion: navigating turnover intention of healthcare personnel. *Journal of Multidisciplinary Healthcare*, v. 17, p. 1731-1742, 2024. DOI: <https://doi.org/10.2147/jmdh.s460088>.

FERREIRA, B. E. et al. Prevenção de riscos e agravos à saúde dos trabalhadores hospitalares à luz da Teoria da Atividade Histórico-Cultural. *Ciência & Saúde Coletiva*, v. 29, n. 5, e12892022, 2024. DOI: <https://doi.org/10.1590/1413-81232024295.12892022>.

GEOFFRION, S.; MORSE, C.; DUFOUR, M. M.; BERGERON, N.; GUAY, S.; LANOVAZ, M. J. Screening for psychological distress in healthcare workers using machine learning: a proof of concept. *Journal of Medical Systems*, v. 47, n. 1, p. 120, 2023. DOI: <https://doi.org/10.1007/s10916-023-02011-5>.

GULATI, G.; UPSHAW, J.; WESSLER, B. S.; BRAZIL, R. J.; NELSON, J.; VAN KLAVEREN, D. et al. Generalizability of cardiovascular disease clinical prediction models: 158 independent external validations of 104 unique models. *Circulation: Cardiovascular Quality and Outcomes*, v. 15, n. 4, e008487, 2022. DOI: <https://doi.org/10.1161/CIRCOUTCOMES.121.008487>.

GUPTA, M. D.; JHA, M. K.; BANSAL, A.; YADAV, R.; RAMAKRISHANAN, S.; GIRISH, M. P. et al. COVID-19-related burnout among healthcare workers in India and ECG-based predictive machine learning model: insights from the BRUCEE-Li study. *Indian Heart Journal*, v. 73, n. 6, p. 674-681, 2021. DOI: <https://doi.org/10.1016/j.ihj.2021.10.002>.

HÄMÄLÄINEN, P.; TAKALA, J.; KIAT, T. B. Global estimates of occupational accidents and work-related illnesses 2017. Singapore: Workplace Safety and Health Institute, 2017.

HIGGINS, J. P. T.; THOMAS, J.; CHANDLER, J.; CUMPSTON, M.; LI, T.; PAGE, M. J.; WELCH, V. A. (Eds.). *Cochrane handbook for systematic reviews of interventions*. Version 6.5. Cochrane, 2024. Disponível em: <https://training.cochrane.org/handbook>.

HIRTEN, R. P.; TOMALIN, L.; DANIELETTO, M.; GOLDEN, E.; ZWEIG, M.; KAUR, S. et al. Evaluation of a machine learning approach utilizing wearable data for prediction of SARS-CoV-2 infection in healthcare workers. *JAMIA Open*, v. 5, n. 2, ooac041, 2022. DOI: <https://doi.org/10.1093/jamiaopen/ooac041>.

HOND, A. A. H.; STEYERBERG, E. W.; VAN CALSTER, B. Interpreting area under the receiver operating characteristic curve. *Lancet Digital Health*, v. 4, n. 12, p. e853-e855, 2022. DOI: [https://doi.org/10.1016/S2589-7500\(22\)00188-1](https://doi.org/10.1016/S2589-7500(22)00188-1).

KUMARI, B.; GOYAL, N.; EL MORR, C. Predictive models for Canadian healthcare workers mental health during COVID-19. *Journal of Primary Care & Community Health*, v. 15, 21501319241241468, 2024. DOI: <https://doi.org/10.1177/21501319241241468>.

LEAL-NETO, O.; EGGER, T.; SCHLEGEL, M.; FLURY, D.; SUMER, J.; ALBRICH, W. et al. Digital SARS-CoV-2 detection among hospital employees: participatory surveillance study. *JMIR Public Health and Surveillance*, v. 7, n. 11, e33576, 2021. DOI: <https://doi.org/10.2196/33576>.

LIMA DA CRUZ, E.; DOS REIS SILVA, A.; GONÇALVES DE SOUSA WILK, M. M.; RAMOS DE ANDRADE ANTUNES GOMES, J.; FERMON DAMASCENO RIBEIRO, L. et al. Transtornos mentais comuns entre profissionais da saúde. *Health Residencies Journal*, v. 3, n. 14, p. 1072-1090, 2022. DOI: <https://doi.org/10.51723/hrj.v3i14.321>.

LUDERMIR, T. B. Inteligência artificial e aprendizado de máquina: estado atual e tendências. *Estudos Avançados*, v. 35, n. 101, p. 85-94, 2021. DOI: <https://doi.org/10.1590/s0103-4014.2021.35101.007>.

MALTEZOU, H. C.; MARTÍNEZ-JARRETA, B.; RAPISARDA, V.; LEDDA, C. Editorial: occupational risks of healthcare personnel. *Frontiers in Public Health*, v. 10, 1022327, 2022. DOI: <https://doi.org/10.3389/fpubh.2022.1022327>.

MANDREKAR, J. N. Receiver operating characteristic curve in diagnostic test assessment. *Journal of Thoracic Oncology*, v. 5, n. 9, p. 1315-1316, 2010. DOI: <https://doi.org/10.1097/JTO.0b013e3181ec173d>.

MENDES, R.; DIAS, E. C. Da medicina do trabalho à saúde do trabalhador. *Revista de Saúde Pública*, v. 25, n. 5, p. 341-349, 1991. DOI: <https://doi.org/10.1590/S0034-89101991000500003>.

MONAGHAN, T. F.; RAHMAN, S. N.; AGUDELO, C. W.; WEIN, A. J.; LAZAR, J. M.; EVERAERT, K.; DMOCHOWSKI, R. R. Foundational statistical principles in medical research: sensitivity, specificity, positive predictive value, and negative predictive value. *Medicina (Kaunas)*, v. 57, n. 5, p. 503, 2021. DOI: <https://doi.org/10.3390/medicina57050503>.

MOONS, K. G. M.; ALTMAN, D. G.; REITSMA, J. B.; IOANNIDIS, J. P. A.; MACASKILL, P.; STEYERBERG, E. W. et al. Transparent reporting of a multivariable prediction model for individual prognosis or diagnosis (TRIPOD): explanation and elaboration. *Annals of Internal Medicine*, v. 162, n. 1, p. 1-73, 2015. DOI: <https://doi.org/10.7326/m14-0698>.

MOONS, K. G. M.; GROOT, J. A. H.; BOUWMEESTER, W.; VERGOUWE, Y.; MALLETT, S.; ALTMAN, D. G. et al. Critical appraisal and data extraction for systematic reviews of prediction modelling studies: the CHARMS checklist. *PLoS Medicine*, v. 11, n. 10, 2014. DOI: <https://doi.org/10.1371/journal.pmed.1001744>.

NAHM, F. S. Receiver operating characteristic curve: overview and practical use for clinicians. *Korean Journal of Anesthesiology*, v. 75, n. 1, p. 25-36, 2022. DOI: <https://doi.org/10.4097/kja.21209>.

NUNZIO, G.; CONTE, L.; LUPO, R.; VITALE, E.; CALABRÒ, A.; ERCOLANI, M.; CARVELLO, M.; ARIGLIANI, M.; TORALDO, D. M.; DE BENEDETTO, L. A new Berlin Questionnaire simplified by machine learning techniques in a population of Italian healthcare workers to highlight the suspicion of obstructive sleep apnea. *Frontiers in Medicine (Lausanne)*, v. 9, 866822, 2022. DOI: <https://doi.org/10.3389/fmed.2022.866822>.

PAIXÃO, G. M. de M.; SANTOS, B. C.; ARAUJO, R. M. de; RIBEIRO, M. H.; MORAES, J. L. de; RIBEIRO, A. L. Machine learning na medicina: revisão e aplicabilidade. *Arquivos Brasileiros de Cardiologia*, v. 118, n. 1, p. 95-102, 2022. DOI: <https://doi.org/10.36660/abc.20200596>.

PAGE, M. J.; MCKEZINE, J. E.; BOSSUYT, P. M.; BOUTRON, I.; HOFFMANN, T. C.; MULROW, C. D. et al. The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. *BMJ*, v. 372, n. 71, p. 1-9, 2021. DOI: <https://doi.org/10.1136/bmj.n71>.

PORTUGAL, L. C. L.; GAMA, C. M. F.; GONÇALVES, R. M.; MENDLOWICZ, M. V.; ERTHAL, F. S.; MOCAIBER, I. et al. Vulnerability and protective factors for PTSD and depression symptoms among healthcare workers during COVID-19: a machine learning

approach. *Frontiers in Psychiatry*, v. 12, 752870, 2022. DOI: <https://doi.org/10.3389/fpsy.2021.752870>.

PRUNESKI, J. A.; PAREEK, A.; KUNZE, K. N.; MARTIN, R. K.; KARLSSON, J.; OEDING, J. F. et al. Supervised machine learning and associated algorithms: applications in orthopedic surgery. *Knee Surgery, Sports Traumatology, Arthroscopy*, v. 31, n. 4, p. 1196-1202, 2023. DOI: <https://doi.org/10.1007/s00167-022-07181-2>.

RÍOS, E. A.; SUÁREZ SÁNCHEZ, A.; SÁNCHEZ LASHERAS, F. et al. Algoritmo genético baseado em máquinas de vetores de suporte para classificação da síndrome da visão computacional em profissionais de saúde. *Neural Computing and Applications*, v. 32, p. 1239–1248, 2020. DOI: <https://doi.org/10.1007/s00521-018-3581-3>.

SAMPAIO, R. F.; MANCINI, M. C. Estudos de revisão sistemática: um guia para síntese criteriosa da evidência científica. *Revista Brasileira de Fisioterapia*, v. 11, n. 1, p. 83-89, 2007. DOI: <https://doi.org/10.1590/S1413-35552007000100013>.

SEPÚLVEDA, Dr. Da saúde do trabalhador à saúde do cidadão: movendo-se rio acima. *Revista de Medicina Ocupacional e Ambiental*, v. 55, supl., p. S52-S57, 2013. DOI: <https://doi.org/10.1097/JOM.0000000000000033>.

SNELL, K. I. E.; LEVIS, B.; DAMEN, J. A. A.; DHIMAN, P.; DEBRAY, T. P. A.; HOOFT, L. et al. Transparent reporting of multivariable prediction models for individual prognosis or diagnosis: checklist for systematic reviews and meta-analyses (TRIPOD-SRMA). *BMJ*, v. 381, e073538, 2023. DOI: <https://doi.org/10.1136/bmj-2022-073538>.

SOUZA, F. M.; PRADO, T. N. D.; WERNECK, G. L.; LUIZ, R. R.; MACIEL, E. L. N.; FAERSTEIN, E.; TRAJMAN, A. Classification and regression trees for predicting the risk of a negative test result for tuberculosis infection in Brazilian healthcare workers: a cross-sectional study. *Revista Brasileira de Epidemiologia*, v. 24, e210035, 2021. DOI: <https://doi.org/10.1590/1980-549720210035>.

STERN, C.; JORDAN, Z.; MCARTHUR, A. Developing the review question and inclusion criteria. *American Journal of Nursing*, v. 114, n. 4, p. 53-56, 2014. DOI: <https://doi.org/10.1097/01.naj.0000445689.67800.86>.

WOLLF, R. F.; MOONS, K. G. M.; RILEY, R. D.; WHITING, P. F.; WESTWOOD, M.; COLLINS, G. S.; REITSMA, J. et al. PROBAST: a tool to assess the risk of bias and applicability of prediction model studies. *Annals of Internal Medicine*, v. 170, n. 1, p. 51-58, 2019. DOI: <https://doi.org/10.7326/m18-1376>.

YAO, Y.; JING, X.; LU, L. Interaction of job-related psychological flexibility, coping style and personality types in depression in Chinese physicians: a cross-section study. *Medicine (Baltimore)*, v. 101, n. 39, e30838, 2022. DOI: <https://doi.org/10.1097/MD.00000000000030838>.

YOSHIKAWA, H. Can naive Bayes classifier predict infection in a close contact of COVID-19? A comparative test for predictability of the predictive model and healthcare workers in Japan. *Journal of Infection and Chemotherapy*, v. 28, n. 6, p. 774-779, 2022. DOI: <https://doi.org/10.1016/j.jiac.2022.02.017>.

ZHOU, Z.; LUO, D.; YANG, B. X.; LIU, Z. Machine learning-based prediction models for depression symptoms among Chinese healthcare workers during the early COVID-19 outbreak in 2020: a cross-sectional study. *Frontiers in Psychiatry*, v. 13, 876995, 2022. DOI: <https://doi.org/10.3389/fpsy.2022.876995>.

## 5 CONCLUSÕES

A exposição à fumaça cirúrgica representa um risco ocupacional significativo e, muitas vezes, subestimado, para os profissionais de saúde. Este estudo buscou analisar a natureza e os impactos dessa exposição, destacando a relevância crescente da inteligência artificial como uma ferramenta inovadora para a mitigação de riscos e a promoção da saúde ocupacional.

A pesquisa evidenciou que, apesar das diretrizes de segurança existentes, a conscientização sobre os perigos da fumaça cirúrgica ainda precisa ser ampliada. A implementação de sistemas de extração de fumaça e o uso de equipamentos de proteção individual adequados são medidas essenciais, mas sua eficácia pode ser substancialmente aprimorada pela adoção de tecnologias avançadas. Nesse contexto, a inteligência artificial surge como uma solução promissora, capaz de integrar inovação tecnológica e prevenção em saúde.

Ao longo desta dissertação, foi possível observar como a inteligência artificial pode ser aplicada na detecção precoce de riscos e na prevenção de doenças ocupacionais em geral, ampliando sua aplicabilidade a diferentes contextos de exposição no ambiente hospitalar. Essa tecnologia mostra-se relevante na proteção dos trabalhadores contra a fumaça cirúrgica, atuando no monitoramento contínuo das condições do ar e na identificação de padrões que indiquem potenciais ameaças à saúde. Além disso, possibilita a personalização de protocolos de segurança, adaptando medidas preventivas às necessidades específicas de cada equipe e ambiente de trabalho.

Os avanços na saúde ocupacional impulsionados pela inteligência artificial favorecem a análise de grandes volumes de dados, permitindo identificar padrões de exposição, prever surtos de doenças relacionadas ao trabalho e otimizar a alocação de recursos de proteção.

Uma vez, que a fumaça cirúrgica, como um agente de risco complexo e dinâmico, exige abordagens igualmente sofisticadas para sua gestão. Ao adotar soluções baseadas em inteligência artificial, as instituições de saúde podem avançar de uma postura reativa para uma abordagem proativa, protegendo de maneira mais eficaz a saúde e o bem-estar dos profissionais.

Ressalta-se que este trabalho constitui um estudo piloto voltado à construção de um modelo de predição desenvolvido pelo grupo de pesquisa. Ao longo de sua elaboração, evidenciou-se a necessidade de atualizá-lo, incorporando técnicas de Machine Learning com melhor desempenho em dados estruturados, como *gradient boosting*, *random forests* e *TabPFN*. Identificou-se, ainda, a importância de revisar a estratégia de divisão dos dados entre treino e validação, bem como as métricas de avaliação empregadas, considerando que a acurácia tem sido progressivamente substituída por indicadores mais robustos, como a área sob a curva ROC. Essas atualizações visam aprimorar o desempenho e a precisão dos modelos propostos.

Por fim, em novas etapas de pesquisa, o trabalho terá continuidade, com o desenvolvimento de um novo algoritmo de machine learning e a criação de um banco de dados ampliado, contendo preditores adicionais, com o objetivo de fortalecer a capacidade preditiva e a aplicabilidade do modelo em contextos mais amplos. Esta dissertação, portanto, constitui um ponto de partida para futuras investigações e para a formulação de políticas que promovam um ambiente de trabalho mais seguro e saudável para todos os envolvidos no processo cirúrgico.

## REFERÊNCIAS

ALPI, T. E. R.; OLIVERA, P. P. de; COSTENARO, R. G. S.; RANGEL, R. F.; ILHA, S. Riscos ergonômicos no cotidiano dos profissionais de enfermagem em hospitais brasileiros. *Pesquisa, Sociedade e Desenvolvimento*, [S. l.], v. 10, n. 7, p. e27410716257, 2021. DOI: <https://doi.org/10.33448/rsd-v10i7.16257>.

ASGHAR, M. S.; ZAMAN, B. S.; SHABIR, M. U.; ANWAR, J.; SIDDIQUE, A. A. Surgical smoke; an occupational hazard. *J Pak Med Assoc.*, v. 70, n. 10, p. 1807-1810, 2020. DOI: <https://doi.org/10.5455/jpma.38614>.

BENAIM, E. H.; JASPERS, I. Surgical smoke and its components, effects, and mitigation: a contemporary review. *Toxicological Sciences*, v. 198, n. 2, p. 157–168, 2024. DOI: <https://doi.org/10.1093/toxsci/kfae005>.

BIENIEK, A. A.; LEACHI, H. F. L.; RIBEIRO, R. P. Construction and validation of an intensity scale of signs and symptoms related to surgical smoke. *Brazilian Journal of Development*, v. 8, n. 5, p. 41375-41388, 2022. DOI: <https://doi.org/10.34117/bjdv8n5-567>.

BISPO, A. J.; NEHME, Z.; NANAYAKKARA, S.; ANDERSON, D.; DION, T.; MEADLEY, B. N. Artificial neural networks for ECG interpretation in acute coronary syndrome: A scoping review. *Am J Emerg Med.*, v. 83, p. 1-8, 2024. DOI: <https://doi.org/10.1016/j.ajem.2024.06.026>.

BOLDINI, D.; GRISONI, F.; KUHN, D.; FRIEDRICH, L.; SIEBER, S. A. Practical guidelines for the use of gradient boosting for molecular property prediction. *Journal of Cheminformatics*, v. 15, n. 1, p. 73, 2023. DOI: <https://doi.org/10.1186/s13321-023-00743-7>.

BRASIL. Ministério da Saúde. Ministério da Saúde atualiza lista de doenças relacionadas ao trabalho após 24 anos. Portal Gov.br, Brasília, 27 nov. 2023. Disponível em: <https://www.gov.br/saude/pt-br/assuntos/noticias/2023/novembro/ministerio-da-saude-atualiza-lista-de-doencas-relacionadas-ao-trabalho-apos-24-anos>. Acesso em: 10 mai. 2025.

BRASIL. Ministério da Saúde. Portaria GM/MS nº 1.999, de 27 de novembro de 2023. Dispõe sobre Lista de Doenças Relacionadas ao Trabalho (LDRT). Diário Oficial da União: seção 1, Brasília, DF, n. 226, p. 99, 2023. Disponível em: <https://www.in.gov.br/web/dou/-/portaria-gm/ms-n-1.999-de-27-de-novembro-de-2023-526629116>. Acesso em: 10 mai. 2025.

BRASIL. Ministério do Trabalho e Emprego. Norma Regulamentadora NR-01: Disposições Gerais e Gerenciamento de Riscos Ocupacionais. Brasília, DF: MTE, 2024. Disponível em: <https://www.gov.br/trabalho-e-emprego/pt-br/aceso-a-informacao/participacao-social/conselhos-e-orgaos-colegiados/comissao-tripartite-partitaria-permanente/normas-regulamentadora/normas-regulamentadoras-vigentes/nr-1>. Acesso em: 17 fev. 2025.

CHARLIER, B.; COGLIANESE, A.; DE ROSA, F.; et al. Chemical risk in hospital settings: Overview on monitoring strategies and international regulatory aspects. *J Public Health Res.*, v. 10, n. 1, p. 1993, 2021. DOI: <https://doi.org/10.4081/jphr.2021.1993>.

DALMOLIN, G. L.; POSSEBON, M. R.; LANES, T. C.; SCHUTZ, T. C.; MUNHOZ, T. C.; ANDOLHE, R. Occupational stress and burnout syndrome among health workers. *Revista*

Recien - Revista Científica de Enfermagem, v. 12, n. 37, p. 67–77, 2022. DOI: <https://doi.org/10.24276/rrecien2022.12.37.67-77>.

DEO, R. C. Machine Learning in Medicine. *Circulation*, v. 132, n. 20, p. 1920–1930. DOI: <https://doi.org/10.1161/CIRCULATIONAHA.115.001593>.

ELLAHHAM, S. Artificial Intelligence: The Future for Diabetes Care. *Am J Med.*, v. 133, n. 8, p. 895-900, 2020. DOI: <https://doi.org/10.1016/j.amjmed.2020.03.033>.

FAGUNDES, T. P.; et al. Big data em Saúde do Trabalhador: o quão distantes estamos?. *Revista Brasileira de Saúde Ocupacional*, v. 49, p. edcinq11, 2024. DOI: <https://doi.org/10.1590/2317-6369000000319>.

FAUSTINO, A. J. S.; CONCEIÇÃO, A. L. P. da; SILVA, G. V. da; MARQUES, L. F.; SANTOS, W. A. P. dos; VILLAGRAN, C. A. Impactos do ambiente de trabalho na saúde mental da enfermagem: Distúrbios psicossomáticos e fatores desencadeantes. *Pesquisa, Sociedade e Desenvolvimento*, [S. l.], v. 4, p. e7514448691, 2025. DOI: <https://doi.org/10.33448/rsd-v14i4.48691>.

FERNANDES, M. A.; et al. Riscos ocupacionais e intervenções que promovem segurança para a equipe de enfermagem oncológica. *Revista Brasileira de Saúde Ocupacional*, v. 46, p. e15, 2021. DOI: <https://doi.org/10.1590/2317-6369000000319>.

GÉRON, A. Mãos à obra: aprendizado de máquina com Scikit-Learn, Keras e TensorFlow: conceitos, ferramentas e técnicas para a construção de sistemas inteligentes. Rio de Janeiro: Alta Books, 2021. 640 p.

HURTADO, S. L. B.; SIMONELLI, A. P.; MININEL, V. A.; ESTEVES, T. V.; VILELA, R. A. de G.; NASCIMENTO, A. Políticas de saúde do trabalhador no Brasil: contradições históricas e possibilidades de desenvolvimento. *Ciência & Saúde Coletiva*, Rio de Janeiro, v. 27, n. 8, p. 3091-3102, ago. 2022. DOI: <https://doi.org/10.1590/1413-81232022278.04942022>

JARRUCHE, L. T.; MUCCI, S. Burnout syndrome in healthcare professionals: an integrative review. *Revista Bioética*, v. 29, n. 1, p. 162–173, 2021. Disponível em: [https://revistabioetica.cfm.org.br/revista\\_bioetica/article/view/2368](https://revistabioetica.cfm.org.br/revista_bioetica/article/view/2368). Acesso em: 10 mai. 2025.

KRIEGESKORTE, N.; GOLAN, T. Neural network models and deep learning. *Current Biology*, v. 29, n. 7, p. 231-236, 2019. DOI: <https://doi.org/10.1016/j.cub.2019.02.034>.

LAUDEMIR, T. B. Inteligência Artificial e Aprendizado de Máquina: estado atual e tendências. *Estudos Avançados*, v. 35, n. 101, p. 85-94, 2021. DOI: <https://doi.org/10.1590/s0103-4014.2021.35101.007>.

LEACHI, H. F.; RIBEIRO, R. P. HeLP: Development of occupational protection mask against surgical smoke. *Rev. Bras. Enferm.*, v. 76 (Suppl 4), 2023. DOI: <https://doi.org/10.1590/0034-7167-2022-0647pt>.

LEACHI, H. F. L.; ROCHA, A. F.; PEIXE, T. S.; LOPES, L. P.; SOUZA, V. D. B.; RIBEIRO, R. P. 1-Hydroxypyrene in the urine of health professionals exposed to surgical

smoke: Correlation with signs and symptoms. *Revista de Enfermagem Referência*, v. 6, n. 3, e33708, p. 1-7, 2024. DOI: <https://doi.org/10.12707/RVI23.139.33708>.

LISBOA, P. J.; TAKTAK, A. F. G. The use of artificial neural networks in decision support in cancer: a systematic review. *Neural Newt*, v. 19, n. 4, p. 408-415, 2006. DOI: <https://doi.org/10.1016/j.neunet.2005.10.007>.

LIU, Y.; WANG, Y.; ZHANG, J. New Machine Learning Algorithm: Random Forest. In: LIU, B.; MA, M.; CHANG, J. (eds.). *Information Computing and Applications. ICICA 2012. Lecture Notes in Computer Science*, v. 7473. Berlin; Heidelberg: Springer, 2012. DOI: [https://doi.org/10.1007/978-3-642-34062-8\\_32](https://doi.org/10.1007/978-3-642-34062-8_32).

MAHDOOD, B.; MERAJIKHAH, A. M.; MIRZAIEE, M.; BASTAMI, M.; BANOUEIZADEH, S. Virus and viral components transmitted through surgical smoke; a silent danger in operating room: a systematic review. *BMC Surg.*, v. 24, n. 1, p. 1-10, 2024. DOI: <https://doi.org/10.1186/s12893-024-02514-z>.

MASSARWEH, N. N.; COSGRIFF, N.; SLAKEY, D. P. Electrosurgery: history, principles, and current and future uses. *J Am Coll Surg.*, v. 202, n. 3, p. 520-530, 2006. DOI: <https://doi.org/10.1016/j.jamcollsurg.2005.11.017>.

MENDES, R.; DIAS, E. C. From occupational medicine to workers' health. *Rev. Saúde Pública*, v. 25, n. 5, p. 341-349, 1991. DOI: <https://doi.org/10.1590/S0034-89101991000500003>.

NAÇÕES UNIDAS NO BRASIL. *Objetivos de Desenvolvimento Sustentável (ODS)*. [S. l.]: Nações Unidas, 2025. Disponível em: <https://brasil.un.org/pt-br/sdgs>. Acesso em: 10 mai. 2025.

QUEIROZ, G. No collar health: occupational health challenges with the advent of post-Fordism. *Revista Brasileira de Saúde Ocupacional*, v. 48, e10, p. 1-7, 2023. DOI: <https://doi.org/10.1590/2317-6369/18521pt2023v48e10>.

ROCHA, S. D.; GOMES, A. N. H.; ZEN, P. R. G.; BICA, C. G. Handling of antineoplastic drugs: a health concern among health care workers. *Rev Bras Med Trab.*, v. 18, n. 4, p. 407-414, 2021. DOI: <https://doi.org/10.47626/1679-4435-2020-527>.

RÜGAMER, D.; NAGLER, T.; FEURER, M.; VON CRAILSHEIM, C.; KOBIALKA, J.; RUNDEL, D. Interpretable Machine Learning for TabPFN. In: LONGO, L.; LAPUSCHKIN, S.; SEIFERT, C. (Eds.). *Explainable Artificial Intelligence. xAI 2024. Communications in Computer and Information Science*, v. 2154. Cham: Springer, 2024. DOI: [https://doi.org/10.1007/978-3-031-63797-1\\_23](https://doi.org/10.1007/978-3-031-63797-1_23)

SAITO, A. C.; MARGATHO, A. S.; BIENIEK, A. A.; STANGANELLI, N. C.; RIBEIRO, R. P. Signs and symptoms related to inhalation of surgical smoke in the nursing team. *Esc Anna Nery*, v. 23, n. 3, e20180292, p. 1-6, 2019. DOI: <https://doi.org/10.1590/2177-9465-EAN-2018-0292>.

SANTOS, H. E. C. dos; GARCIA, G. P. A.; FRACAROLLI, I. F. L.; MARZIALE, M. H. P. Burnout, inestabilidad en el trabajo, trastornos musculoesqueléticos y absentismo en

profesionales de la salud: revisión de alcance. *Ciencia & Enfermería, Concepción*, v. 27, e7061, 2021. DOI: <https://doi.org/10.29393/CE27-37BIHM40037>.

SANTOS, I.; SILVA, V. C.; MATOS, A. H. C. Riscos ocupacionais presentes na atuação do enfermeiro em centros cirúrgicos: uma revisão integrativa da literatura. *Revista Amazônica de Ciências Médicas e Saúde – RACMS*, v. 1, n. 1, p. 22-35, 2025. Disponível em: <https://jiparana.emnuvens.com.br/racms/article/view/1577>. Acesso em: 10 mai. 2025.

SALMAN, H. A.; KALAKECH, A.; STEITI, A. Visão geral do algoritmo Random Forest. Trad. H. A. Salman; A. Kalakech; A. Steiti. *Babylonian Journal of Machine Learning*, 2024, p. 69-79. DOI: <https://doi.org/10.58496/BJML/2024/007>.

TACIU, L. A.; DUMITRU, M.; VRINCEANU, D.; GHERGHE, M.; MANOLE, F.; MARINESCU, A.; SERBOIU, C.; NEAGOS, A.; COSTACHE, A. Applications and challenges of neural networks in otolaryngology (Review). *Biomed Rep.*, v. 20, n. 6, 2024. DOI: <https://doi.org/10.3892/br.2024.1781>.

TASKINGUL, A. B.; KIRAN, S.; EMERCE, E. Comparison of health complaints, occupational risks, and occupational health practices of healthcare workers according to professions and departments in the hospital. *Cureus.*, v. 16, n. 7, 2024. DOI: <https://doi.org/10.7759/cureus.65614>.

TEIXEIRA, A. P. S. S.; CHOMEN, P.; MUZEKA, A. L. P.; MOTTER, A. A. Occupational risks and the recognition at work in a surgical center. *Divers@ Revista Eletrônica Interdisciplinar*, v. 15, n. 1, p. 76-89, 2022. DOI: <http://dx.doi.org/10.5380/diver.v15i1.83113>.

TRAN, V. Q.; BYEON, H. Predicting dementia in Parkinson's disease on a small tabular dataset using hybrid LightGBM-TabPFN and SHAP. *Digital Health*, v. 10, 2024. DOI: <https://doi.org/10.1177/20552076241272585>.

UDDIN, S.; KHAN, A.; HOSSAIN, E.; MONI, M. A. Comparing different supervised machine learning algorithms for disease prediction. *BMC Medical Informatics and Decision Making*, v. 19, n. 281, p. 1-16, 2019. DOI: <https://doi.org/10.1186/s12911-019-1004-8>.

XÁ, I. A.; MISHRA, S. D. Artificial intelligence in advancing occupational health and safety: an encapsulation of developments. *J Occup Health*, v. 66, n. 1, 2024. DOI: <https://doi.org/10.1093/joccuh/uiad017>.

ZHANG, Z.; ZHAO, Y.; CANES, A.; STEINBERG, D.; LYASHEVSKA, O.; AME BIG-DATA CLINICAL TRIAL COLLABORATIVE GROUP (on behalf of). Predictive analytics with gradient boosting in clinical medicine. *Annals of Translational Medicine*, v. 7, n. 7, p. 152, 2019. DOI: <https://doi.org/10.21037/atm.2019.03.29>

ZHOU, Y. Z.; WANG, C. Q.; ZHOU, M. H.; LI, Z. Y.; CHEN, D.; LIAN, A. L.; MA, Y. Surgical smoke: a hidden killer in the operating room. *Asian J Surg.*, v. 46, n. 9, p. 3447-3454, 2023. DOI: <https://doi.org/10.1016/j.asjsur.2023.03.066>.

**ANEXOS**

## ANEXO A

### Aprovação do Comitê de Ética

UNIVERSIDADE ESTADUAL DE  
LONDRINA - UEL



#### PARECER CONSUBSTANCIADO DO CEP

##### DADOS DO PROJETO DE PESQUISA

**Título da Pesquisa:** PREDIÇÃO DA SAÚDE DE TRABALHADORES EXPOSTOS À FUMAÇA CIRÚRGICA:  
UMA ABORDAGEM AVANÇADA COM MACHINE LEARNING

**Pesquisador:** Renata Perfeito Ribeiro

**Área Temática:**

**Versão:** 3

**CAAE:** [REDACTED]

**Instituição Proponente:** Programa de Pós Graduação em Enfermagem Nivel Mestrado e

**Patrocinador Principal:** Financiamento Próprio

##### DADOS DO PARECER

**Número do Parecer:** [REDACTED]

##### Apresentação do Projeto:

As informações elencadas foram retiradas do arquivo Informações Básicas da Pesquisa

[REDACTED]

##### Desenho:

Trata-se de um estudo transversal com abordagem preditiva, norteado pelas orientações de descrição de modelos preditivos multivariados para diagnóstico ou prognóstico (Transparent Reporting of a Multivariable Prediction Model for Individual Prognosis or Diagnosis  $\zeta$  TRIPOD) (Moons et al., 2015).

##### Resumo:

**Introdução:** A exposição à fumaça cirúrgica, gerada pelo uso de eletrocautério, contém partículas nocivas que podem causar sintomas como tosse, irritação ocular e cefaleia em trabalhadores de saúde, expostos de forma ocupacional. Dessa forma, se faz necessário o uso de tecnologias que possam prever esses sinais e sintomas para realizar a prevenção de doenças relacionadas a esses riscos ocupacionais. **Objetivo:** Desenvolver e aplicar modelos preditivos de machine learning para prever e identificar riscos à saúde de trabalhadores expostos a fumaça cirúrgica. **Material e métodos:** estudo transversal com abordagem preditiva a partir da construção de um banco de dados constituído por informações sociodemográficas e

**Endereço:** LABESC - Sala 14

**Bairro:** Campus Universitário

**UF:** PR

**Telefone:** (43)3371-5455

**Município:** LONDRINA

**CEP:** 86.057-970

**E-mail:** cep268@uel.br

Continuação do Parecer: 7.239.908

ocupacionais, hábitos de vida, informações antropométricas, sinais vitais, dados relacionados ao procedimento cirúrgico ao qual o trabalhador da saúde estava designado, sinais e sintomas apresentados pelos trabalhadores relacionados a inalação da fumaça cirúrgica, biomarcadores do estresse oxidativo e nitrosativo e presença e concentração de 1-hidroxipereno em indivíduos expostos a fumaça do eletrocautério. Esses dados foram coletados em pesquisas anteriores realizadas por este grupo de pesquisa, devidamente aprovadas pelo Comitê de ética em Pesquisa e serão utilizados em um banco de dados para a construção de algoritmos. Os dados serão analisados com técnicas de Machine Learning, como regressão logística e Random Forest. O desempenho dos modelos será medido por acurácia, sensibilidade, especificidade e área sob a Curva Característica de Operação do Receptor. A análise será realizada com o software R. Resultados Esperados: Espera-se a criação de um modelo preditivo seja eficaz para prever o desenvolvimento de doenças ocupacionais, promovendo intervenções preventivas e melhorando a saúde ocupacional dos trabalhadores da saúde expostos à fumaça cirúrgica.

**Desfecho Primário:**

Os resultados esperados desta pesquisa incluem a criação e validação de modelos preditivos baseados em Machine Learning para identificar riscos à saúde de trabalhadores expostos à fumaça cirúrgica. Ao final da pesquisa, espera-se que os modelos preditivos ofereçam uma ferramenta eficaz para o monitoramento e a prevenção de doenças relacionadas à exposição à fumaça cirúrgica.

Os resultados dessa pesquisa permitirão uma melhor gestão dos riscos ocupacionais, ajudando instituições de saúde a implementar estratégias preventivas mais eficientes. Além disso, o estudo contribuirá para o desenvolvimento de políticas de saúde mais adequadas para proteger os profissionais expostos, com base em evidências claras sobre os efeitos da fumaça cirúrgica e a eficácia dos Equipamentos de Proteção Individual (EPI).

Tamanho da Amostra: 576.

**Objetivo da Pesquisa:**

As informações elencadas foram retiradas do arquivo Informações Básicas da Pesquisa

**Objetivo Primário:**

**Endereço:** LABESC - Sala 14  
**Bairro:** Campus Universitário **CEP:** 86.057-970  
**UF:** PR **Município:** LONDRINA  
**Telefone:** (43)3371-5455 **E-mail:** cep268@uel.br

UNIVERSIDADE ESTADUAL DE  
LONDRINA - UEL



Continuação do Parecer: 7.239.908

Desenvolver e aplicar modelos preditivos de Machine Learning para prever e identificar riscos à saúde de trabalhadores expostos a fumaça cirúrgica.

Objetivo Secundário:

- Construir um banco de dados para uso das informações em algoritmos Machine Learning;
- Desenvolver algoritmos Machine Learning para avaliação dos sinais e sintomas definidos pela Escala para Avaliação da Intensidade dos Sinais e Sintomas.
- Desenvolver algoritmos Machine Learning para predição de doenças ocupacionais a partir de informações de saúde relacionados a exposição de trabalhadores a fumaça cirúrgica.

**Avaliação dos Riscos e Benefícios:**

As informações elencadas foram retiradas do arquivo Informações Básicas da Pesquisa



Riscos:

Riscos à privacidade e à confidencialidade: Coleta de dados pessoais e sensíveis dos trabalhadores, como informações sociodemográficas, ocupacionais e biomarcadores de estresse oxidativo e nitrosativo, exige rigor na proteção desses dados para evitar qualquer violação de privacidade. A Lei Geral de Proteção de Dados Pessoais (LGPD) será observada, garantindo que todos os dados sejam tratados de forma anônima e segura.

Risco de viés no modelo preditivo: Existe o risco de que os algoritmos de Machine Learning utilizados não forneçam previsões totalmente precisas ou imparciais, o que pode gerar falhas na predição das doenças ocupacionais.

Benefícios:

revenção de doenças ocupacionais: O desenvolvimento de modelos preditivos permitirá a identificação precoce de riscos à saúde, possibilitando intervenções preventivas em trabalhadores expostos à fumaça cirúrgica, o que pode reduzir significativamente a incidência de doenças relacionadas à exposição ocupacional.

Melhora na qualidade de vida dos profissionais de saúde: Ao prever e minimizar os riscos de exposição à fumaça cirúrgica, os trabalhadores poderão atuar em um ambiente mais seguro, melhorando sua saúde física e mental.

Avanço nas políticas de saúde ocupacional: Os resultados da pesquisa contribuirão para o

**Endereço:** LABESC - Sala 14

**Bairro:** Campus Universitário

**UF:** PR

**Município:** LONDRINA

**CEP:** 86.057-970

**Telefone:** (43)3371-5455

**E-mail:** cep268@uel.br

UNIVERSIDADE ESTADUAL DE  
LONDRINA - UEL



Continuação do Parecer: 7.239.908

desenvolvimento de políticas e práticas preventivas mais eficazes, baseadas em evidências científicas, favorecendo a implementação de protocolos mais rigorosos para o uso de Equipamentos de Proteção Individual (EPI).

Inovação em saúde ocupacional: A integração de algoritmos de Machine Learning com dados de saúde ocupacional representa uma abordagem inovadora, que pode ser adaptada a outras áreas da saúde para prever e prevenir doenças profissionais em diversos contextos.

**Comentários e Considerações sobre a Pesquisa:**

Pesquisa relevante para a área.

**Considerações sobre os Termos de apresentação obrigatória:**

O protocolo apresentou os seguintes documentos e informações obrigatórias:

- Folha de rosto devidamente preenchida e assinada pela pesquisadora e pela coordenadora do Programa de Pós-Graduação em Enfermagem da UEL;
- Projeto detalhado no formato de projeto de pesquisa contendo todos os itens informados na Plataforma Brasil;
- 4 Termos de Confidencialidade e Sigilo assinados pelas pesquisadora principal e demais membros da equipe de pesquisa;
- Cronograma de execução apresentado no documento de informações básicas da Plataforma Brasil e em arquivo próprio de cronograma;
- Financiamento próprio, com orçamento financeiro de R\$6.000,00 apresentado na Plataforma Brasil.

**Recomendações:**

Sem recomendações.

**Conclusões ou Pendências e Lista de Inadequações:**

Prezada pesquisadora, após análise dessa versão do protocolo de pesquisa, verificamos que todas as pendências foram atendidas e o parecer é pela APROVAÇÃO.

**Considerações Finais a critério do CEP:**

Prezado(a) Pesquisador(a),

**Endereço:** LABESC - Sala 14

**Bairro:** Campus Universitário

**UF:** PR

**Município:** LONDRINA

**CEP:** 86.057-970

**Telefone:** (43)3371-5455

**E-mail:** cep268@uel.br

UNIVERSIDADE ESTADUAL DE  
LONDRINA - UEL



Continuação do Parecer: 7.239.908

Este é seu parecer final de aprovação, vinculado ao Comitê de Ética em Pesquisas Envolvendo Seres Humanos da Universidade Estadual de Londrina. É sua responsabilidade apresentá-lo aos órgãos e/ou instituições pertinentes.

Ressaltamos, para início da pesquisa, as seguintes atribuições do pesquisador, conforme Resolução CNS 466/2012 e 510/2016:

A responsabilidade do pesquisador é indelegável e indeclinável e compreende os aspectos éticos e legais, cabendo-lhe:

- conduzir o processo de Consentimento e de Assentimento Livre e Esclarecido;
- apresentar dados solicitados pelo sistema CEP/CONEP a qualquer momento;
- desenvolver o projeto conforme delineado, justificando, quando ocorridas, a sua mudança ou interrupção;
- elaborar e apresentar os relatórios parciais e final;
- manter os dados da pesquisa em arquivo, físico ou digital, sob sua guarda e responsabilidade, por um período mínimo de 5 (cinco) anos após o término da pesquisa;
- encaminhar os resultados da pesquisa para publicação, com os devidos créditos aos pesquisadores e pessoal técnico integrante do projeto;
- justificar fundamentadamente, perante o sistema CEP/CONEP, interrupção do projeto ou a não publicação dos resultados.

Coordenação CEP/UEL.

**Este parecer foi elaborado baseado nos documentos abaixo relacionados:**

Tipo Documento	Arquivo	Postagem	Autor	Situação
Informações Básicas do Projeto		18/11/2024 13:50:53		Aceito
Outros	Carta_resposta_2.docx	18/11/2024 13:50:06	Renata Perfeito Ribeiro	Aceito
Folha de Rosto	Folha_rosto_assinada.pdf	18/11/2024 13:49:53	Renata Perfeito Ribeiro	Aceito
Outros	Carta_resposta.docx	08/11/2024 09:30:51	Renata Perfeito Ribeiro	Aceito
Projeto Detalhado / Brochura Investigador	Projeto_completo.doc	03/10/2024 14:29:16	Renata Perfeito Ribeiro	Aceito

**Endereço:** LABESC - Sala 14

**Bairro:** Campus Universitário

**CEP:** 86.057-970

**UF:** PR

**Município:** LONDRINA

**Telefone:** (43)3371-5455

**E-mail:** cep268@uel.br

UNIVERSIDADE ESTADUAL DE  
LONDRINA - UEL



Continuação do Parecer: 7.239.908

Outros	TERMO_DE_CONFIDENCIALIDADE_E_SIGILO_Renata_assinado.pdf	03/10/2024 14:28:30	Renata Perfeito Ribeiro	Aceito
Outros	TERMO_DE_CONFIDENCIALIDADE_E_SIGILO_Larissa_assinado.pdf	03/10/2024 14:28:19	Renata Perfeito Ribeiro	Aceito
Outros	TERMO_DE_CONFIDENCIALIDADE_E_SIGILO_Helenize_assinado.pdf	03/10/2024 14:28:09	Renata Perfeito Ribeiro	Aceito
Outros	TERMO_DE_CONFIDENCIALIDADE_E_SIGILO_Aline_assinado.pdf	03/10/2024 14:27:49	Renata Perfeito Ribeiro	Aceito
Cronograma	CRONOGRAMA.docx	03/10/2024 14:26:12	Renata Perfeito Ribeiro	Aceito

**Situação do Parecer:**

Aprovado

**Necessita Apreciação da CONEP:**

Não

LONDRINA, 22 de Novembro de 2024

Assinado por:

**Alessandra Lourenço Cecchini Armani**  
(Coordenador(a))

**Endereço:** LABESC - Sala 14

**Bairro:** Campus Universitário

**CEP:** 86.057-970

**UF:** PR **Município:** LONDRINA

**Telefone:** (43)3371-5455

**E-mail:** cep268@uel.br

## ANEXO B

### Escala para Avaliação da Intensidade dos Sinais e Sintomas relacionados a Exposição à Fumaça Cirúrgica (EASE)

#### Escala para Avaliação da Intensidade dos Sinais e Sintomas relacionados a Exposição à Fumaça Cirúrgica (EASE)

A Escala tem como objetivo avaliar a intensidade dos sinais e sintomas relacionados à exposição a fumaça cirúrgica em trabalhadores da área da saúde.

Os itens que abordam sinais e sintomas estão distribuídos por sistemas:

- 1 a 10 - Sistema Respiratório
- 11 a 19 - Sistema Ocular
- 20 a 22 - Sistema Digestório
- 23 a 24 - Sistema Osteomuscular
- 25 a 28 - Sistema Tegumentar
- 29 a 33 - Sistema Nervoso

**Para cada item abaixo, escolha qual intensidade melhor representa os sinais e sintomas quando você está exposto (a) à fumaça cirúrgica, sendo 0 (sem sinais e sintoma), 1 (baixa intensidade) COM melhora dos sinais e sintomas sem intervenção\*, 2 (moderada intensidade) COM melhora dos sinais e sintomas após intervenção e 3 (alta intensidade) SEM melhora dos sinais e sintomas mesmo com intervenção.**

**\* Considera-se intervenção qualquer medida utilizada para diminuir ou sanar o sinal ou sintoma.**

#### SISTEMA RESPIRATÓRIO

1. Tosse	<input type="text" value="0"/>	<input type="text" value="1"/>	<input type="text" value="2"/>	<input type="text" value="3"/>
2. Ardência de faringe	<input type="text" value="0"/>	<input type="text" value="1"/>	<input type="text" value="2"/>	<input type="text" value="3"/>
3. Lesão de nasofaringe	<input type="text" value="0"/>	<input type="text" value="1"/>	<input type="text" value="2"/>	<input type="text" value="3"/>
4. Espirro	<input type="text" value="0"/>	<input type="text" value="1"/>	<input type="text" value="2"/>	<input type="text" value="3"/>
5. Rinorreia (Coriza)	<input type="text" value="0"/>	<input type="text" value="1"/>	<input type="text" value="2"/>	<input type="text" value="3"/>
6. Congestão nasal	<input type="text" value="0"/>	<input type="text" value="1"/>	<input type="text" value="2"/>	<input type="text" value="3"/>
7. Prurido nasal (Coceira no nariz)	<input type="text" value="0"/>	<input type="text" value="1"/>	<input type="text" value="2"/>	<input type="text" value="3"/>
8. Sibilos	<input type="text" value="0"/>	<input type="text" value="1"/>	<input type="text" value="2"/>	<input type="text" value="3"/>
9. Dispneia (Falta de ar)	<input type="text" value="0"/>	<input type="text" value="1"/>	<input type="text" value="2"/>	<input type="text" value="3"/>
10. Aperto no peito	<input type="text" value="0"/>	<input type="text" value="1"/>	<input type="text" value="2"/>	<input type="text" value="3"/>

<b>0</b> SEM SINAIS E SINTOMAS
<b>1</b> BAIXA INTENSIDADE
<b>2</b> MODERADA INTENSIDADE
<b>3</b> ALTA INTENSIDADE

**SISTEMA OCULAR**

11. Hiperemia ocular (Vermelhidão)	<input type="text" value="0"/>	<input type="text" value="1"/>	<input type="text" value="2"/>	<input type="text" value="3"/>
12. Lacrimejamento	<input type="text" value="0"/>	<input type="text" value="1"/>	<input type="text" value="2"/>	<input type="text" value="3"/>
13. Edema palpebral (Pálpebras inchadas)	<input type="text" value="0"/>	<input type="text" value="1"/>	<input type="text" value="2"/>	<input type="text" value="3"/>
14. Sensação de areia no olho	<input type="text" value="0"/>	<input type="text" value="1"/>	<input type="text" value="2"/>	<input type="text" value="3"/>
15. Secreção ocular	<input type="text" value="0"/>	<input type="text" value="1"/>	<input type="text" value="2"/>	<input type="text" value="3"/>
16. Prurido ocular (Coceira)	<input type="text" value="0"/>	<input type="text" value="1"/>	<input type="text" value="2"/>	<input type="text" value="3"/>
17. Fotofobia (Sensibilidade à luz)	<input type="text" value="0"/>	<input type="text" value="1"/>	<input type="text" value="2"/>	<input type="text" value="3"/>
18. Hemeralopia (Visão turva)	<input type="text" value="0"/>	<input type="text" value="1"/>	<input type="text" value="2"/>	<input type="text" value="3"/>
19. Ardência ocular	<input type="text" value="0"/>	<input type="text" value="1"/>	<input type="text" value="2"/>	<input type="text" value="3"/>

**SISTEMA DIGESTÓRIO**

20. Dor abdominal	<input type="text" value="0"/>	<input type="text" value="1"/>	<input type="text" value="2"/>	<input type="text" value="3"/>
21. Náusea	<input type="text" value="0"/>	<input type="text" value="1"/>	<input type="text" value="2"/>	<input type="text" value="3"/>
22. Vômito	<input type="text" value="0"/>	<input type="text" value="1"/>	<input type="text" value="2"/>	<input type="text" value="3"/>

**SISTEMA OSTEOMUSCULAR**

23. Fraqueza muscular	<input type="text" value="0"/>	<input type="text" value="1"/>	<input type="text" value="2"/>	<input type="text" value="3"/>
24. Câibra muscular	<input type="text" value="0"/>	<input type="text" value="1"/>	<input type="text" value="2"/>	<input type="text" value="3"/>

**SISTEMA TEGUMENTAR**

25. Prurido na pele (Coceira)	<input type="text" value="0"/>	<input type="text" value="1"/>	<input type="text" value="2"/>	<input type="text" value="3"/>
26. Queimação na pele	<input type="text" value="0"/>	<input type="text" value="1"/>	<input type="text" value="2"/>	<input type="text" value="3"/>
27. Xerose (pele ressecada)	<input type="text" value="0"/>	<input type="text" value="1"/>	<input type="text" value="2"/>	<input type="text" value="3"/>
28. Eritema na pele (vermelhidão)	<input type="text" value="0"/>	<input type="text" value="1"/>	<input type="text" value="2"/>	<input type="text" value="3"/>

<b>0</b> <b>SEM</b> <b>SINAIS E</b> <b>SINTOMAS</b>
<b>1</b> <b>BAIXA</b> <b>INTENSIDADE</b>
<b>2</b> <b>MODERADA</b> <b>INTENSIDADE</b>
<b>3</b> <b>ALTA</b> <b>INTENSIDADE</b>

**SISTEMA NERVOSO**

29. Cefaleia	<input type="text" value="0"/>	<input type="text" value="1"/>	<input type="text" value="2"/>	<input type="text" value="3"/>
30. Tontura	<input type="text" value="0"/>	<input type="text" value="1"/>	<input type="text" value="2"/>	<input type="text" value="3"/>
31. Irritabilidade	<input type="text" value="0"/>	<input type="text" value="1"/>	<input type="text" value="2"/>	<input type="text" value="3"/>
32. Dor na pele	<input type="text" value="0"/>	<input type="text" value="1"/>	<input type="text" value="2"/>	<input type="text" value="3"/>
33. Desmaio	<input type="text" value="0"/>	<input type="text" value="1"/>	<input type="text" value="2"/>	<input type="text" value="3"/>

<b>0</b> <b>SEM</b> <b>SINAIS E</b> <b>SINTOMAS</b>
<b>1</b> <b>BAIXA</b> <b>INTENSIDADE</b>
<b>2</b> <b>MODERADA</b> <b>INTENSIDADE</b>
<b>3</b> <b>ALTA</b> <b>INTENSIDADE</b>

**Escore de grau de intensidade por sistema da escala**

<b>SISTEMAS</b>	<b>Baixa intensidade</b>	<b>Moderada intensidade</b>	<b>Alta intensidade</b>
Respiratório	1 a 10 pontos	11 a 20 pontos	21 a 30 pontos
Ocular	1 a 9 pontos	10 a 18 pontos	19 a 27 pontos
Digestório	1 a 3 pontos	4 a 6 pontos	7 a 9 pontos
Osteomuscular	1 a 2 pontos	3 a 4 pontos	5 a 6 pontos
Tegumentar	1 a 4 pontos	5 a 8 pontos	9 a 12 pontos
Nervoso	1 a 5 pontos	6 a 10 pontos	11 a 15 pontos

## ANEXO C

Transparent Reporting of a Multivariable Prediction Model for Individual Prognosis or  
Diagnosis (TRIPOD)

## TRIPOD Checklist: Prediction Model Development

Section/Topic	Item	Checklist Item	Page
<b>Title and abstract</b>			
Title	1	Identify the study as developing and/or validating a multivariable prediction model, the target population, and the outcome to be predicted.	
Abstract	2	Provide a summary of objectives, study design, setting, participants, sample size, predictors, outcome, statistical analysis, results, and conclusions.	
<b>Introduction</b>			
Background and objectives	3a	Explain the medical context (including whether diagnostic or prognostic) and rationale for developing or validating the multivariable prediction model, including references to existing models.	
	3b	Specify the objectives, including whether the study describes the development or validation of the model or both.	
<b>Methods</b>			
Source of data	4a	Describe the study design or source of data (e.g., randomized trial, cohort, or registry data), separately for the development and validation data sets, if applicable.	
	4b	Specify the key study dates, including start of accrual; end of accrual; and, if applicable, end of follow-up.	
Participants	5a	Specify key elements of the study setting (e.g., primary care, secondary care, general population) including number and location of centres.	
	5b	Describe eligibility criteria for participants.	
	5c	Give details of treatments received, if relevant.	
Outcome	6a	Clearly define the outcome that is predicted by the prediction model, including how and when assessed.	
	6b	Report any actions to blind assessment of the outcome to be predicted.	
Predictors	7a	Clearly define all predictors used in developing or validating the multivariable prediction model, including how and when they were measured.	
	7b	Report any actions to blind assessment of predictors for the outcome and other predictors.	
Sample size	8	Explain how the study size was arrived at.	
Missing data	9	Describe how missing data were handled (e.g., complete-case analysis, single imputation, multiple imputation) with details of any imputation method.	
Statistical analysis methods	10a	Describe how predictors were handled in the analyses.	
	10b	Specify type of model, all model-building procedures (including any predictor selection), and method for internal validation.	
	10d	Specify all measures used to assess model performance and, if relevant, to compare multiple models.	
Risk groups	11	Provide details on how risk groups were created, if done.	
<b>Results</b>			
Participants	13a	Describe the flow of participants through the study, including the number of participants with and without the outcome and, if applicable, a summary of the follow-up time. A diagram may be helpful.	
	13b	Describe the characteristics of the participants (basic demographics, clinical features, available predictors), including the number of participants with missing data for predictors and outcome.	
Model development	14a	Specify the number of participants and outcome events in each analysis.	
	14b	If done, report the unadjusted association between each candidate predictor and outcome.	
Model specification	15a	Present the full prediction model to allow predictions for individuals (i.e., all regression coefficients, and model intercept or baseline survival at a given time point).	
	15b	Explain how to use the prediction model.	
Model performance	16	Report performance measures (with CIs) for the prediction model.	
<b>Discussion</b>			
Limitations	18	Discuss any limitations of the study (such as nonrepresentative sample, few events per predictor, missing data).	
Interpretation	19b	Give an overall interpretation of the results, considering objectives, limitations, and results from similar studies, and other relevant evidence.	
Implications	20	Discuss the potential clinical use of the model and implications for future research.	
<b>Other information</b>			
Supplementary information	21	Provide information about the availability of supplementary resources, such as study protocol, Web calculator, and data sets.	
Funding	22	Give the source of funding and the role of the funders for the present study.	

We recommend using the TRIPOD Checklist in conjunction with the TRIPOD Explanation and Elaboration document.

## ANEXO D

## Preferred Reporting Items for Systematic Reviews and Meta-Analyses (PRISMA)



## PRISMA 2020 Checklist

Section and Topic	Item #	Checklist item	Location where item is reported
<b>TITLE</b>			
Title	1	Identify the report as a systematic review.	
<b>ABSTRACT</b>			
Abstract	2	See the PRISMA 2020 for Abstracts checklist.	
<b>INTRODUCTION</b>			
Rationale	3	Describe the rationale for the review in the context of existing knowledge.	
Objectives	4	Provide an explicit statement of the objective(s) or question(s) the review addresses.	
<b>METHODS</b>			
Eligibility criteria	5	Specify the inclusion and exclusion criteria for the review and how studies were grouped for the syntheses.	
Information sources	6	Specify all databases, registers, websites, organisations, reference lists and other sources searched or consulted to identify studies. Specify the date when each source was last searched or consulted.	
Search strategy	7	Present the full search strategies for all databases, registers and websites, including any filters and limits used.	
Selection process	8	Specify the methods used to decide whether a study met the inclusion criteria of the review, including how many reviewers screened each record and each report retrieved, whether they worked independently, and if applicable, details of automation tools used in the process.	
Data collection process	9	Specify the methods used to collect data from reports, including how many reviewers collected data from each report, whether they worked independently, any processes for obtaining or confirming data from study investigators, and if applicable, details of automation tools used in the process.	
Data items	10a	List and define all outcomes for which data were sought. Specify whether all results that were compatible with each outcome domain in each study were sought (e.g. for all measures, time points, analyses), and if not, the methods used to decide which results to collect.	
	10b	List and define all other variables for which data were sought (e.g. participant and intervention characteristics, funding sources). Describe any assumptions made about any missing or unclear information.	
Study risk of bias assessment	11	Specify the methods used to assess risk of bias in the included studies, including details of the tool(s) used, how many reviewers assessed each study and whether they worked independently, and if applicable, details of automation tools used in the process.	
Effect measures	12	Specify for each outcome the effect measure(s) (e.g. risk ratio, mean difference) used in the synthesis or presentation of results.	
Synthesis methods	13a	Describe the processes used to decide which studies were eligible for each synthesis (e.g. tabulating the study intervention characteristics and comparing against the planned groups for each synthesis (item #5)).	
	13b	Describe any methods required to prepare the data for presentation or synthesis, such as handling of missing summary statistics, or data conversions.	
	13c	Describe any methods used to tabulate or visually display results of individual studies and syntheses.	
	13d	Describe any methods used to synthesize results and provide a rationale for the choice(s). If meta-analysis was performed, describe the model(s), method(s) to identify the presence and extent of statistical heterogeneity, and software package(s) used.	
	13e	Describe any methods used to explore possible causes of heterogeneity among study results (e.g. subgroup analysis, meta-regression).	
	13f	Describe any sensitivity analyses conducted to assess robustness of the synthesized results.	
Reporting bias assessment	14	Describe any methods used to assess risk of bias due to missing results in a synthesis (arising from reporting biases).	
Certainty assessment	15	Describe any methods used to assess certainty (or confidence) in the body of evidence for an outcome.	
<b>RESULTS</b>			
Study selection	16a	Describe the results of the search and selection process, from the number of records identified in the search to the number of studies included in the review, ideally using a flow diagram.	
	16b	Cite studies that might appear to meet the inclusion criteria, but which were excluded, and explain	



## PRISMA 2020 Checklist

Section and Topic	Item #	Checklist item	Location where item is reported
		why they were excluded.	
Study characteristics	17	Cite each included study and present its characteristics.	
Risk of bias in studies	18	Present assessments of risk of bias for each included study.	
Results of individual studies	19	For all outcomes, present, for each study: (a) summary statistics for each group (where appropriate) and (b) an effect estimate and its precision (e.g. confidence/credible interval), ideally using structured tables or plots.	
Results of syntheses	20a	For each synthesis, briefly summarise the characteristics and risk of bias among contributing studies.	
	20b	Present results of all statistical syntheses conducted. If meta-analysis was done, present for each the summary estimate and its precision (e.g. confidence/credible interval) and measures of statistical heterogeneity. If comparing groups, describe the direction of the effect.	
	20c	Present results of all investigations of possible causes of heterogeneity among study results.	
	20d	Present results of all sensitivity analyses conducted to assess the robustness of the synthesized results.	
Reporting biases	21	Present assessments of risk of bias due to missing results (arising from reporting biases) for each synthesis assessed.	
Certainty of evidence	22	Present assessments of certainty (or confidence) in the body of evidence for each outcome assessed.	
<b>DISCUSSION</b>			
Discussion	23a	Provide a general interpretation of the results in the context of other evidence.	
	23b	Discuss any limitations of the evidence included in the review.	
	23c	Discuss any limitations of the review processes used.	
	23d	Discuss implications of the results for practice, policy, and future research.	
<b>OTHER INFORMATION</b>			
Registration and protocol	24a	Provide registration information for the review, including register name and registration number, or state that the review was not registered.	
	24b	Indicate where the review protocol can be accessed, or state that a protocol was not prepared.	
	24c	Describe and explain any amendments to information provided at registration or in the protocol.	
Support	25	Describe sources of financial or non-financial support for the review, and the role of the funders or sponsors in the review.	
Competing interests	26	Declare any competing interests of review authors.	
Availability of data, code and other materials	27	Report which of the following are publicly available and where they can be found: template data collection forms; data extracted from included studies; data used for all analyses; analytic code; any other materials used in the review.	

From: Page MJ, McKenzie JE, Bossuyt PM, Boutron I, Hoffmann TC, Mulrow CD, et al. The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. *BMJ* 2021;372:n71. doi: 10.1136/bmj.n71. This work is licensed under CC BY 4.0. To view a copy of this license, visit <https://creativecommons.org/licenses/by/4.0/>

## ANEXO E

## Checklist for reporting systematic reviews of prediction model studies (TRIPOD-SRMA)

## TRIPOD-SRMA Checklist for reporting systematic reviews of prediction model studies

Section and topic	Item No	Checklist Item	Page
<b>Title</b>			
Title	1	Identify the report as a systematic review or meta-analysis (or both) of diagnostic or prognostic model studies. Specify the target population and outcome(s) predicted as relevant to the review question.	
<b>Abstract</b>			
Abstract	2	See the TRIPOD-SRMA Checklist for Abstracts	
<b>Introduction</b>			
Rationale	3	Describe the rationale for the review in the context of existing knowledge.	
Objectives	4	Provide an explicit statement of the objective(s) being addressed with reference to: target population, index and comparator models (as relevant), outcome(s), time (prediction horizon and intended moment of using the model), and setting.	
<b>Methods</b>			
Study eligibility criteria	5	Specify study characteristics used as eligibility criteria, including any prediction models of specific interest, and whether development or validation studies (or both) were eligible.	
Information sources	6	Specify all databases, registers, websites, organisations, reference lists and other sources searched or consulted to identify studies. Specify the date when each source was last searched or consulted.	
Search strategy	7	Present the full search strategies for all databases, registers and websites, including any filters and limits used.	
Study selection process	8	Specify the methods used to decide whether a study met the inclusion criteria of the review, including how many reviewers screened each record and each report retrieved, whether they worked independently, and if applicable, details of automation tools used in the process.	
Data collection process	9	Specify the methods used to collect data from study reports, including how many reviewers collected data from each report, whether they worked independently, any processes for obtaining or confirming data from study investigators, and if applicable, details of automation tools used in the process.	
Data Items	10a	List and define all items for which data were sought from each study.	
	10b	State the model performance measures that were sought (e.g., measures of calibration, discrimination, overall model fit, clinical utility).	
	10c	Describe how any desired but unreported data items (items 10a, 10b) were handled (e.g., contacted authors, calculated from other reported information).	
Risk of bias and applicability assessment	11	Specify the methods used to assess risk of bias in the included studies and their applicability to the review question. This should be done separately for each model development and validation. Include details of any tool(s) used, how many reviewers assessed each study and whether they worked independently.	
Synthesis methods	12a	Describe any methods for synthesising estimates of performance measures for each model. If meta-analysis was carried out, describe the methods used, including any transformations of data prior to pooling, how any heterogeneity in model performance was quantified and handled, and software package(s) used.	
	12b	Describe any methods used to explore possible causes of heterogeneity in model performance (e.g., subgroup analysis, meta-regression), including whether or not they were planned.	

Section and topic	Item No	Checklist Item	Page
	12c	Describe any sensitivity analyses conducted to assess robustness of the synthesised results.	
Certainty assessment	13	Describe any methods used to assess certainty (or confidence) in the body of evidence for a prediction model.	
<b>Results</b>			
Study selection	14	Describe the results of the search and selection process, from the number of records identified in the search to the number of studies and models included in the review, ideally using a flow diagram.	
Study and model characteristics	15	Present study characteristics and model details extracted (as per item 10a), and cite the study reports.	
Risk of bias and applicability	16	Present results of risk of bias and applicability assessment. This should be done separately for each model development and validation in each included study.	
Results of model performance in individual studies	17	Present performance estimates and confidence intervals for each model and all evaluations, including whether they relate to the internal or external validation performance. If internal, give details of the method.	
Results of syntheses	18a	Present the results of any synthesis of model performance, together with details of which study estimates contributed. If meta-analysis was carried out, then for each model and performance measure, present summary results, confidence/credible intervals and measures of heterogeneity. Forest plots may be useful.	
	18b	For each model, present results of all investigations of possible causes of heterogeneity in model performance.	
	18c	Present results of all sensitivity analyses conducted to assess the robustness of the synthesised results.	
Certainty of evidence	19	Present any assessments of certainty (or confidence) in the body of evidence for each prediction model of interest.	
<b>Discussion</b>			
Summary of evidence	20	Summarise the main findings including the strengths and limitations of the evidence.	
Limitations	21	Discuss the strengths and limitations of the review process.	
Implications	22	Discuss implications of the results in the context of other evidence and for practice, policy, and future research.	
<b>Other information</b>			
Registration and protocol	23a	Provide registration information for the review, including register name and registration number, or state that the review was not registered.	
	23b	Indicate where the review protocol can be accessed, or state that a protocol was not prepared.	
	23c	Describe and explain any amendments to information provided at registration or in the protocol.	
Support	24	Describe sources of financial or non-financial support for the review, and the role of the funders or sponsors in the review.	
Competing interests	25	Declare any competing interests of review authors.	

Section and topic	Item No	Checklist item	Page
Availability of data, code, and other materials	26	Report which of the following are publicly available and where they can be found: template data collection forms; data extracted from included studies; data used for all analyses; analytic code; any other materials used in the review.	

This checklist appears in appendix 2 of Snell KIE, Levis B, Damen JAA, et al. Transparent reporting of multivariable prediction models for individual prognosis or diagnosis: checklist for systematic reviews and meta-analyses (TRIPOD-SRMA). *BMJ* 2023;381:e073538. doi:10.1136/bmj-2022-073538.

## ANEXO F

## Critical Appraisal and Data Extraction for Systematic Reviews of Prediction Modelling Studies (CHARMS)

**Table 2.** Relevant items to extract from individual studies in a systematic review of prediction models for purposes of description or assessment of risk of bias or applicability.

Domain	Key items	General	Applicability	Risk of bias
<b>Source of data</b>	• Source of data (e.g., cohort, case-control, randomised trial participants, or registry data)		X	X
<b>Participants</b>	• Participant eligibility and recruitment method (e.g., consecutive participants, location, number of centres, setting, inclusion and exclusion criteria)	X	X	
	• Participant description	X	X	
	• Details of treatments received, if relevant		X	X
	• Study dates	X	X	
<b>Outcome(s) to be predicted</b>	• Definition and method for measurement of outcome		X	X
	• Was the same outcome definition (and method for measurement) used in all patients?			X
	• Type of outcome (e.g., single or combined endpoints)	X	X	
	• Was the outcome assessed without knowledge of the candidate predictors (i.e., blinded)?			X
	• Were candidate predictors part of the outcome (e.g., in panel or consensus diagnosis)?			X
	• Time of outcome occurrence or summary of duration of follow-up		X	
<b>Candidate predictors (or index tests)</b>	• Number and type of predictors (e.g., demographics, patient history, physical examination, additional testing, disease characteristics)	X		
	• Definition and method for measurement of candidate predictors		X	X
	• Timing of predictor measurement (e.g., at patient presentation, at diagnosis, at treatment initiation)		X	
	• Were predictors assessed blinded for outcome, and for each other (if relevant)?			X
	• Handling of predictors in the modelling (e.g., continuous, linear, non-linear transformations or categorised)			X
<b>Sample size</b>	• Number of participants and number of outcomes/events	X		
	• Number of outcomes/events in relation to the number of candidate predictors (Events Per Variable)			X
<b>Missing data</b>	• Number of participants with any missing value (include predictors and outcomes)	X		X
	• Number of participants with missing data for each predictor			X
	• Handling of missing data (e.g., complete-case analysis, imputation, or other methods)			X
<b>Model development</b>	• Modelling method (e.g., logistic, survival, neural networks, or machine learning techniques)	X		
	• Modelling assumptions satisfied			X
	• Method for selection of predictors for inclusion in multivariable modelling (e.g., all candidate predictors, pre-selection based on unadjusted association with the outcome)			X
	• Method for selection of predictors during multivariable modelling (e.g., full model approach, backward or forward selection) and criteria used (e.g., p-value, Akaike Information Criterion)			X
	• Shrinkage of predictor weights or regression coefficients (e.g., no shrinkage, uniform shrinkage, penalized estimation)		X	X
<b>Model performance</b>	• Calibration (calibration plot, calibration slope, Hosmer-Lemeshow test) and Discrimination (C-statistic, D-statistic, log-rank) measures with confidence intervals		X	
	• Classification measures (e.g., sensitivity, specificity, predictive values, net reclassification improvement) and whether a priori cut points were used			X
<b>Model evaluation</b>	• Method used for testing model performance: development dataset only (random split of data, resampling methods, e.g., bootstrap or cross-validation, none) or separate external validation (e.g., temporal, geographical, different setting, different investigators)			X

Table 2. Cont.

Domain	Key items	General	Applicability	Risk of bias
	<ul style="list-style-type: none"> <li>In case of poor validation, whether model was adjusted or updated (e.g., intercept recalibrated, predictor effects adjusted, or new predictors added)</li> </ul>		X	X
<b>Results</b>	<ul style="list-style-type: none"> <li>Final and other multivariable models (e.g., basic, extended, simplified) presented, including predictor weights or regression coefficients, intercept, baseline survival, model performance measures (with standard errors or confidence intervals)</li> </ul>	X	X	
	<ul style="list-style-type: none"> <li>Any alternative presentation of the final prediction models, e.g., sum score, nomogram, score chart, predictions for specific risk subgroups with performance</li> </ul>	X	X	
	<ul style="list-style-type: none"> <li>Comparison of the distribution of predictors (including missing data) for development and validation datasets</li> </ul>			X
<b>Interpretation and Discussion</b>	<ul style="list-style-type: none"> <li>Interpretation of presented models (confirmatory, i.e., model useful for practice versus exploratory, i.e., more research needed)</li> </ul>	X	X	
	<ul style="list-style-type: none"> <li>Comparison with other studies, discussion of generalizability, strengths and limitations</li> </ul>	X	X	

doi:10.1371/journal.pmed.1001744.t002

## ANEXO G

## Prediction model study Risk Of Bias Assessment Tool (PROBAST)

<b>DOMAIN 1: Participants</b>			
<b>A. Risk of Bias</b>			
<i>Describe the sources of data and criteria for participant selection:</i>			
		Dev	Val
1.1 Were appropriate data sources used, e.g. cohort, RCT or nested case-control study data?			
1.2 Were all inclusions and exclusions of participants appropriate?			
<b>Risk of bias introduced by selection of participants</b>	<b>RISK:</b> <i>(low/ high/ unclear)</i>		
<i>Rationale of bias rating:</i>			
<b>B. Applicability</b>			
<i>Describe included participants, setting and dates:</i>			
<b>Concern that the included participants and setting do not match the review question</b>	<b>CONCERN:</b> <i>(low/ high/ unclear)</i>		
<i>Rationale of applicability rating:</i>			

<b>DOMAIN 2: Predictors</b>			
<b>A. Risk of Bias</b>			
<i>List and describe predictors included in the final model, e.g. definition and timing of assessment:</i>			
		Dev	Val
2.1 Were predictors defined and assessed in a similar way for all participants?			
2.2 Were predictor assessments made without knowledge of outcome data?			
2.3 Are all predictors available at the time the model is intended to be used?			
<b>Risk of bias introduced by predictors or their assessment</b>	<b>RISK:</b> <i>(low/ high/ unclear)</i>		
<i>Rationale of bias rating:</i>			
<b>B. Applicability</b>			
<b>Concern that the definition, assessment or timing of predictors in the model do not match the review question</b>	<b>CONCERN:</b> <i>(low/ high/ unclear)</i>		
<i>Rationale of applicability rating:</i>			

<b>DOMAIN 3: Outcome</b>			
<b>A. Risk of Bias</b>			
<i>Describe the outcome, how it was defined and determined, and the time interval between predictor assessment and outcome determination:</i>			
		Dev	Val
3.1	Was the outcome determined appropriately?		
3.2	Was a pre-specified or standard outcome definition used?		
3.3	Were predictors excluded from the outcome definition?		
3.4	Was the outcome defined and determined in a similar way for all participants?		
3.5	Was the outcome determined without knowledge of predictor information?		
3.6	Was the time interval between predictor assessment and outcome determination appropriate?		
<b>Risk of bias introduced by the outcome or its determination</b>		<b>RISK:</b> <i>(low/ high/ unclear)</i>	
<i>Rationale of bias rating:</i>			
<b>B. Applicability</b>			
<i>At what time point was the outcome determined:</i>			
<i>If a composite outcome was used, describe the relative frequency/distribution of each contributing outcome:</i>			
<b>Concern that the outcome, its definition, timing or determination do not match the review question</b>		<b>CONCERN:</b> <i>(low/ high/ unclear)</i>	
<i>Rationale of applicability rating:</i>			

DOMAIN 4: Analysis			
Risk of Bias			
<i>Describe numbers of participants, number of candidate predictors, outcome events and events per candidate predictor:</i>			
<i>Describe how the model was developed (for example in regards to modelling technique (e.g. survival or logistic modelling), predictor selection, and risk group definition):</i>			
<i>Describe whether and how the model was validated, either internally (e.g. bootstrapping, cross validation, random split sample) or externally (e.g. temporal validation, geographical validation, different setting, different type of participants):</i>			
<i>Describe the performance measures of the model, e.g. (re)calibration, discrimination, (re)classification, net benefit, and whether they were adjusted for optimism:</i>			
<i>Describe any participants who were excluded from the analysis:</i>			
<i>Describe missing data on predictors and outcomes as well as methods used for missing data:</i>			
		Dev	Val
4.1	Were there a reasonable number of participants with the outcome?		
4.2	Were continuous and categorical predictors handled appropriately?		
4.3	Were all enrolled participants included in the analysis?		
4.4	Were participants with missing data handled appropriately?		
4.5	Was selection of predictors based on univariable analysis avoided?		
4.6	Were complexities in the data (e.g. censoring, competing risks, sampling of controls) accounted for appropriately?		
4.7	Were relevant model performance measures evaluated appropriately?		
4.8	Were model overfitting and optimism in model performance accounted for?		
4.9	Do predictors and their assigned weights in the final model correspond to the results from multivariable analysis?		
<b>Risk of bias introduced by the analysis</b>		<b>RISK:</b> (low/ high/ unclear)	
<i>Rationale of bias rating:</i>			

Overall judgement about risk of bias and applicability of the prediction model evaluation		
<b>Overall judgement of risk of bias</b>	<b>RISK:</b> (low/ high/ unclear)	
<i>Summary of sources of potential bias:</i>		
<b>Overall judgement of applicability</b>	<b>CONCERN:</b> (low/ high/ unclear)	
<i>Summary of applicability concerns:</i>		