

Thales Pardini Fagundes^a <https://orcid.org/0000-0002-3302-9913>Roberta Moreira Wichmann^b <https://orcid.org/0000-0002-4951-9327>Maria Eduarda de Lima e Silva^b <https://orcid.org/0000-0003-3100-8817>Tiago Almeida de Oliveira^c <https://orcid.org/0000-0003-4147-7721>

^a Universidade de São Paulo, Faculdade de Medicina de Ribeirão Preto, Hospital das Clínicas. Ribeirão Preto, SP, Brasil.

^b Instituto Brasileiro de Ensino, Desenvolvimento e Pesquisa, Programa de Pós-graduação em Economia. Brasília, DF, Brasil.

^c Universidade Estadual da Paraíba, Departamento de Estatística, Programa de Pós-graduação em Desenvolvimento Regional. Campina Grande, PB, Brasil.

Contato:

Thales Pardini Fagundes

E-mail:

tpfagundes@hcrp.usp.br

Como Citar (Vancouver):

Fagundes TP, Wichmann RM, Silva MEL, Oliveira TA. *Big data em Saúde do Trabalhador: o quão distantes estamos?* Rev. Bras. Saúde Ocup. [Internet]. 2024;49:edcinq11. Disponível em: <https://doi.org/10.1590/2317-6369/40522pt2024v49edcinq11>

Big data em Saúde do Trabalhador: o quão distantes estamos?

Big data in Occupational Health: how far are we?

Resumo

Objetivo: identificar estratégias e desafios no uso de *big data* e inteligência artificial (IA) em saúde ocupacional, assim como práticas e obstáculos na sua implementação.

Métodos: revisão de escopo utilizando termos relacionados à saúde ocupacional, *big data* e IA em quatro bases de dados (Medline, Embase, BVS e SciELO), considerando artigos em português, espanhol e inglês publicados até 2022. Foram incluídos estudos com uso de grandes bases de dados e IA para análises relacionadas à saúde ocupacional. A seleção dos artigos foi feita independentemente por dois pesquisadores, com conflitos resolvidos por consenso. **Resultados:** de 505 artigos identificados, 16 foram selecionados. O baixo número pode estar associado à escassez de dados que tratam da saúde do trabalhador de maneira sistêmica, considerando fatores demográficos, tecnológicos, socioeconômicos e ambientais. Os estudos selecionados mostraram que o *big data* e a IA têm bom potencial para subsidiar a saúde ocupacional ao identificar indicadores de saúde e possibilitar previsões precisas. A implementação enfrenta desafios, como armazenamento de dados e questões éticas.

Conclusão: *big data* e IA podem ser ferramentas úteis para analisar interações complexas de variáveis visando aprimorar a identificação de determinantes de saúde e dados de registros sobre ambientes de trabalho e indivíduos a eles expostos.

Palavras-chave: *Big Data*; Doenças Ocupacionais; Inteligência Artificial; Aprendizado de Máquina; Algoritmos; Saúde do Trabalhador.

Abstract

Objective: to identify strategies and challenges in the use of big data and Artificial Intelligence (AI) in occupational health, as well as practices and obstacles to their implementation. **Methods:** scoping review using terms related to occupational health, big data, and AI in four databases (MEDLINE, EMBASE, BVS, and SciELO) considering articles in Portuguese, Spanish, and English published up to 2022. Studies using large databases and AI for occupational health-related analyses were included. Article selection was performed independently by two researchers, and the conflicts were resolved by consensus. **Results:** of the 505 articles identified, 16 were selected. The low number may be associated with the scarcity of data that address worker's health systemically, considering demographic, technological, socioeconomic, and environmental factors. The selected studies showed that big data and AI have a good potential to support occupational health by identifying health indicators and enabling accurate predictions. Implementation faces challenges such as data storage and ethical issues. **Conclusion:** big data and AI can be useful tools for analyzing the complex interactions of variables to improve the identification of health determinants and record data on work environments and individuals exposed to them.

Keywords: Big Data; Occupational Diseases; Artificial Intelligence; Machine Learning; Algorithms; Occupational Health.



Introdução

Indivíduos economicamente ativos estão expostos a uma variedade de estímulos físicos, químicos, biológicos e sociais durante suas atividades ocupacionais¹. Existe um reconhecimento crescente da interação entre esses agentes e o surgimento de doenças, causando perdas individuais, sociais e econômicas². Mudanças na organização do trabalho já foram associadas a efeitos adversos na saúde dos trabalhadores e podem estar relacionadas a demissões, terceirização, clareza de função e previsibilidade³.

Diante dessas mudanças, uma variedade de exposições ocupacionais pode estar contribuindo para o surgimento e agravamento do sofrimento dos trabalhadores. O conhecimento sobre a associação entre essas exposições e as doenças relacionadas ao trabalho pode beneficiar desde a tomada de decisões por governos até os médicos que atendem trabalhadores diariamente em sua prática. No Brasil, em 2007, uma iniciativa foi implementada para utilizar critérios epidemiológicos para estabelecer associações entre exposição ocupacional e doenças, o Nexo Técnico Epidemiológico Previdenciário (NTEP), durante a avaliação da elegibilidade para benefícios relacionados a doenças^{4,5}. Os dados que suportam tais associações no país são encontrados em um banco de dados chamado Sistema Único de Benefícios (SUB), que contém registros de benefícios fornecidos pelo sistema de previdência social brasileiro⁵.

Modelos de aprendizado de máquina (ML) são usados em uma ampla gama de áreas do conhecimento humano e têm impactado fortemente as ciências da saúde, principalmente em oncologia, radiologia, medicina nuclear, alvos terapêuticos, medicina de emergência, nefrologia e oftalmologia⁶. Através dos modelos de ML, é possível prever o risco de acidentes biológicos em profissionais de saúde que fornecem cuidados primários e de emergência⁷. Uma das definições de ML é que se trata de uma subdivisão da inteligência artificial (IA) que dota o sistema da capacidade de aprender e melhorar automaticamente a partir de experiências⁷. Algoritmos de ML são capazes de aprender por tentativa e erro e melhorar seu desempenho ao longo do tempo⁸.

Diferentes métodos de aprendizado variam de acordo com o tipo de dados de entrada e de saída e do problema a ser analisado⁹. Inicialmente, eles podem ser categorizados como algoritmos de aprendizado supervisionado, não supervisionado, semisupervisionado e de reforço⁷. O supervisionado é usado quando a função de aprendizado mapeia entradas para saídas definidas. Uma das tarefas mais comuns é a classificação por rótulos. O aprendizado não supervisionado é aplicado quando os dados não são rotulados. Nessa situação, o algoritmo busca identificar padrões subjacentes nos dados e agrupá-los de acordo com suas características. Um exemplo é o algoritmo de *clustering*. O aprendizado semisupervisionado é uma combinação dos métodos anteriores e combina dados rotulados e não rotulados. Inicialmente, os dados não rotulados são classificados pelo modelo de *clustering*, e os dados rotulados são usados para classificar os dados não rotulados. O algoritmo de reforço envolve um sistema de recompensas e penalidades, onde o resultado das ações é inferido a partir das interações com o ambiente¹⁰.

Alguns autores caracterizam cinco componentes do *big data*, frequentemente referidos como os “cinco V”: volume, variedade, velocidade, veracidade e valor^{11,12}. Outros parâmetros para definir *big data* consideram uma diversidade de recursos e provedores, como mídias sociais, dispositivos móveis, bancos de dados e registros de diferentes fontes. Isso requer métodos contemporâneos de análise e armazenamento para lidar com o crescimento exponencial dos dados, considerando a heterogeneidade e as diferenças na arquitetura dos dados, com dados não estruturados ou semiestruturados¹³. Uma análise de *big data* permite novas fontes e a criação de hipóteses que de outra forma não seriam possíveis a partir da combinação de dados de fontes diversas e não tradicionais, a geração de *links* entre diferentes tipos de informações, que contribuem para a elaboração de políticas públicas de saúde e segurança mais eficientes, detectando causas de doenças, otimizando a oferta de serviços de saúde, custos e melhorando a qualidade do atendimento à saúde^{11,13}.

No entanto, deve-se notar que, como a análise de *big data* depende de dados contidos em registros eletrônicos e dispositivos móveis de diferentes naturezas, grupos socialmente vulneráveis podem ser excluídos ou sub-representados nesses conjuntos de dados devido a barreiras de acesso a esses dados, associadas a idade, gênero, raça e acesso aos serviços de saúde⁸. Nesse ponto, a aplicação da técnica pode reforçar desigualdades e torná-los propensos a não cobertura de ações e políticas orientadas à proteção por fatores ambientais e estratégias de segurança no local de trabalho. Diante dessas ressalvas, Stieb⁸ destaca que o *big data* tem sido reconhecido como uma ferramenta poderosa para explorar determinantes de saúde ocupacional e ambiental. A combinação de uma ampla variedade de dados integra fatores ocupacionais, genéticos, comportamentais, tecnológicos, políticos e econômicos relacionados ao trabalho, que interagem entre si ao longo da vida do indivíduo e podem afetar a saúde ocupacional.

Incluir fatores diversos e intrincados nos modelos de análise pode aproximar os dados da verdadeira distribuição do problema¹⁴.

O objetivo deste estudo é identificar estratégias e desafios no uso de *big data* e IA em saúde ocupacional, assim como as práticas e os obstáculos na implementação de grandes bancos de dados e ferramentas de ML para melhorar a análise e a prevenção de doenças ocupacionais.

Métodos

Estratégia de busca: Uma revisão de escopo foi realizada utilizando termos relacionados à saúde ocupacional, *big data* e IA para encontrar estudos sobre o uso de *big data* para melhorar as informações sobre doenças relacionadas ao trabalho. Os termos de busca foram aplicados em quatro bases de dados: *Medical Literature Analysis and Retrieval System On-line* – Medline (via PubMed), Embase, Biblioteca Virtual em Saúde – BVS e *Scientific Electronic Library On-line* – SciELO, cobrindo todos os anos disponíveis até dezembro de 2022. A estratégia de busca completa está descrita no **Quadro 1**. Adicionalmente, buscas manuais foram conduzidas nas referências citadas pelos artigos retornados para obter fontes adicionais de informação.

Quadro 1 Estratégia de busca

MEDLINE	(“Occupational Health”[MeSH] OR “Health, Occupational”[MeSH] OR “Hygiene, Industrial”[MeSH] OR “Employee Health”[MeSH] OR “Occupational Medicine”[MeSH] OR “Occupational Health Services”[MeSH]) AND (“Artificial Intelligence”[MeSH] OR “Machine Intelligence”[MeSH] OR “Machine Learning”[MeSH] OR “Deep Learning”[MeSH] OR “Big Data”[MeSH] OR “Information Systems”[MeSH] OR “Databases, Factual”[MeSH] OR “Health Information Systems”[MeSH]) Total de artigos: 75 Artigos Seleccionados: 15
EMBASE	PARTE 1 (‘occupational health’/exp OR ‘occupational health’) AND (‘artificial intelligence’/exp OR ‘artificial intelligence’ OR ‘machine learning’/exp OR ‘machine learning’ OR ‘big data’/exp OR ‘big data’) AND ‘data base’ Total: 45 Artigos Seleccionados: 6 PARTE 2 (‘occupational health’/exp OR ‘occupational health’) AND (‘artificial intelligence’/exp OR ‘artificial intelligence’ OR ‘machine learning’/exp OR ‘machine learning’ OR ‘big data’/exp OR ‘big data’ OR ‘data base’/exp OR ‘data base’) AND (2010:py OR 2011:py OR 2012:py OR 2013:py OR 2014:py OR 2015:py OR 2016:py OR 2017:py OR 2018:py OR 2019:py OR 2020:py OR 2021:py OR 2022:py) AND (‘cohort analysis’/de OR ‘human experiment’/de OR ‘longitudinal study’/de OR ‘observational study’/de) AND ‘article’/it Total de artigos: 409 Artigos Seleccionados: 15
BVS	(mh: (“Inteligência Artificial”)) AND (mh: (“Saúde Ocupacional”)) Total de artigos: 32 Artigos seleccionados: 20
SciELO	(“saúde ocupacional” OR “saúde do trabalhador”) AND (“inteligência artificial” OR “aprendizado de máquina” OR “machine learning” OR “big data”) AND (“base de dados” OR “banco de dados” OR “database”) Total de artigos : 20 Artigos seleccionados: 1

Crerios de incluso: Foram includos os estudos que descrevem experincias com grandes bases de dados contendo informaes sobre sade de trabalhadores; os que relatam experincias na obteno de informaes sobre sade ocupacional e fatores relacionados, em sistemas de informao disponveis e aqueles que utilizam algoritmos de IA para melhorar o processo de recuperao e anlise de dados de sade ocupacional.

Seleo de artigos: A seleo dos artigos foi realizada em duas etapas, por dois pesquisadores, de forma independente. Inicialmente, os artigos foram triados com base no ttulo e resumo. Subsequentemente, os artigos selecionados foram lidos na integra para incluso final. Conflitos na seleo foram resolvidos por consenso entre os pesquisadores.

Restries de idioma e tipos de estudos: Apenas artigos escritos em portugus, espanhol e ingls foram selecionados. Artigos originais, revises e *preprints* que atendiam aos critrios de incluso foram includos.

Ferramentas e softwares utilizados: O gerenciamento das referncias foi realizado utilizando o *software* EndNote.

Registro do protocolo: No houve registro de protocolo para esta reviso.

Extrao e sntese de dados: Foi utilizada uma planilha de extrao de dados criada no *Google Sheets*, preenchida de forma independente por dois pesquisadores. Os mtodos empregados na sntese dos resultados incluram anlise qualitativa e categorizao dos dados extraids de acordo com os principais temas identificados.

Resultados

Um total de 505 artigos foram identificados atravs de buscas nas bases de dados: 75 do Medline, 409 do Embase, 20 da BVS e um da SciELO. Apas a triagem de ttulos e resumos, 43 estudos foram selecionados para leitura completa. Destes, 26 foram excluids devido a indisponibilidade para leitura completa ou por no atenderem aos critrios de incluso descritos na seo anterior. Isso resultou em 17 artigos de texto completo avaliados para elegibilidade. Apas a leitura dos textos completos, um artigo foi excluio, restando os 16 estudos includos na reviso (**Figura 1**). Os artigos selecionados foram publicados entre 2003 e 2022 (**Figura 2**). Observou-se um aumento no nmero de publicaes nos ltimos anos. Entre 2003 e 2014 foram publicados seis artigos. J no perodo de 2015 a 2022, foram 10, indicando um crescente interesse na aplicao de *big data* e ML na pesquisa em sade ocupacional.




Figura 1 Fluxograma PRISMA da busca na literatura




Figura 2 Número de estudos selecionados segundo o ano de publicação

Fonte: Artigos selecionados por este estudo nas bases Medline, Embase, BVS e SciELO.

O **Quadro 2** lista e descreve os objetivos dos artigos selecionados pelo estudo que utilizam técnicas de *big data* e ML aplicadas à saúde ocupacional.

Quadro 2 Artigos selecionados

Título	Identificação	País	Tipo de Estudo	É Big Data?	Resumo da contribuição do estudo para a área de saúde ocupacional
REDECA: A Novel Framework to Review Artificial Intelligence and Its Applications in Occupational Safety and Health	Pishgar et al. 2021 ⁶	EUA	Revisão	Não	A metodologia REDECA é usada para revisar artigos que aplicam inteligência artificial para avaliar e prevenir riscos de acidentes no ambiente de trabalho em empresas de cinco setores (petróleo e gás, mineração, transporte, construção e agricultura). À medida que as aplicações de IA em todas as indústrias continuam a aumentar, é necessária uma exploração adicional dos benefícios e desafios das aplicações de IA em segurança e saúde ocupacional para proteger de forma ideal a saúde, segurança e bem-estar dos trabalhadores.
Predictors of working beyond retirement in older workers with and without a chronic disease - results from data linkage of Dutch questionnaire and registry data	Wind et al. 2018 ¹³	Holanda	Original	Não	Visa a identificar os fatores relevantes que explicam a oferta de trabalho entre indivíduos após a aposentadoria. Estes foram divididos em dois grupos, aqueles com doenças crônicas e aqueles sem doenças crônicas. Fatores relacionados à saúde (melhor percepção de saúde física e altura) e trabalho (nível de qualificação do trabalho e carga de trabalho) são significativos para explicar a oferta de trabalho além da aposentadoria para ambos os grupos. A maior dificuldade de previsão entre trabalhadores com doenças crônicas pode estar associada ao maior grau de heterogeneidade do grupo em comparação com seus pares sem doenças crônicas.

Continua

Quadro 2 Artigos selecionados. Continuação

Determinants of metabolic syndrome in obese workers: gender differences in perceived job-related stress and in psychological characteristics identified using artificial neural networks	Vigna et al. 2019 ¹⁴	Itália	Original	Não	O estudo investigou as associações entre gênero, variáveis psicossociais, estresse relacionado ao trabalho e a presença de síndrome metabólica (SM) em uma coorte de trabalhadores obesos caucasianos. As análises de dados foram realizadas com um algoritmo de rede neural artificial chamado Auto Semantic Connectivity Map (AutoCM), usando todas as variáveis disponíveis, idade, IMC, circunferência da cintura, glicose em jejum, pressão arterial, triglicerídeos e colesterol HDL foram coletados para definir SM. Além disso, foram avaliados comportamentos alimentares, sintomas depressivos e estresse relacionado ao trabalho. Foi encontrada uma associação complexa relacionada ao gênero entre SM, fatores de risco psicossocial e determinantes ocupacionais.
Prediction of pneumoconiosis by serum and urinary biomarkers in workers exposed to asbestos-contaminated minerals	Yang 2019 ¹⁶	Taiwan	Original	Não	O objetivo deste estudo foi avaliar a precisão diagnóstica de biomarcadores séricos e urinários para pneumoconiose em trabalhadores expostos a minerais contaminados com amianto. O estudo usou algoritmos de aprendizado de máquina para identificar marcadores relevantes para o diagnóstico de pneumoconiose, uma doença pulmonar.
A comparison of confounder selection and adjustment methods for estimating causal effects using large healthcare databases	Benasseur et al. 2018 ¹⁷	Canadá	Original	Não	Estudo usando simulações para comparar o desempenho de diferentes métodos de aprendizado de máquina para reduzir viés por variáveis não medidas e medidas em grandes bases de dados de saúde. Foram comparados o ajuste bayesiano para confundimento (BAC), estimativa causal bayesiana generalizada (GBCEE), Group Lasso e estimativa duplamente robusta, escore de propensão de alta dimensão (hdPS) e algoritmos de máxima verossimilhança direcionada colaborativa escalável. A técnica ajuda a reduzir o viés em LHDs, mas os resultados ainda são inconclusivos.
Differential occupational risks to healthcare workers from SARS-CoV-2 observed during a prospective observational study	Eyre et al. 2020 ¹⁸	Reino Unido	Original	Não	O estudo avaliou diferenciais de risco para SARS-CoV-2 entre funcionários sintomáticos e assintomáticos de um hospital de ensino. Os resultados indicaram uma taxa maior de resultados positivos entre profissionais que trabalham em área com contato direto com pacientes, que tinham maior probabilidade de serem contaminados. A menor taxa foi observada entre funcionários da unidade de terapia intensiva. Resultados positivos eram mais prováveis em funcionários negros e asiáticos, independentemente da função ou local de trabalho, e em carregadores e faxineiros.

Continua

Quadro 2 Artigos selecionados. Continuação

Availability and accuracy of occupation in cancer registry data among Florida firefighters	McClure et al. 2019 ¹⁹	EUA	Original	Não	O objetivo deste estudo é determinar a frequência e os preditores de dados ocupacionais ausentes e imprecisos para uma coorte de bombeiros de carreira em um registro estadual de câncer. Entre os registros de pacientes com câncer, os resultados do modelo de regressão logística apresentam uma maior probabilidade de atribuição da ocupação de bombeiros entre homens, com diagnóstico mais recente e entre os mais jovens.
Empirical estimation of the grades of hearing impairment among industrial workers based on new artificial neural networks and classical regression methods	Farhadian et al. 2015 ²⁰	Irã	Original	Não	Este estudo teve como objetivo analisar o potencial das técnicas de redes neurais artificiais e regressão logística para a estimativa de deficiência auditiva entre trabalhadores industriais. Cinco características, incluindo a idade dos trabalhadores, experiência de trabalho, nível de exposição ao ruído, status de tabagismo e uso de EPI auditivo, foram determinadas como as variáveis finais para desenvolver o modelo de previsão. O resultado confirmou que as redes neurais podem ser uma ferramenta adequada para análise de um fenômeno como a perda auditiva, em que os dados necessários para diferentes variáveis estão sendo coletados, enquanto os mecanismos de efeitos de interação são complexos e não totalmente compreendidos.
Non-cancer morbidity among Estonian Chernobyl cleanup workers: A register-based cohort study	Rahu et al. 2014 ²¹	Estônia	Original	Não	Examinar a morbidade não oncológica na coorte de trabalhadores de limpeza de Chernobyl da Estônia em comparação com a amostra populacional, com atenção especial às doenças relacionadas à radiação e transtornos de saúde mental. Foi encontrada morbidade elevada na coorte exposta para doenças do sistema nervoso, sistema digestivo, sistema musculoesquelético, doença cardíaca isquêmica e para causas externas. O excesso de risco mais saliente foi observado para doenças da tireoide, autolesão intencional e diagnósticos selecionados relacionados ao álcool. Nenhuma morbidade excessiva óbvia consistente com os efeitos biológicos da radiação foi observada na coorte exposta, exceto para doenças benignas da tireoide.

Continua

Quadro 2 Artigos selecionados. Continuação

Solbase: a databank of solutions for occupational hazards and risks	Swuste et al. 2003 ²²	Espanha, Itália, Irlanda, Alemanha, Reino Unido e Holanda	Original	Sim	Solbase é um banco de dados que reúne informações do ambiente de trabalho de diferentes empresas e processos em diferentes setores para mapear soluções para riscos de acidentes ocupacionais. É uma base construída conjuntamente entre diferentes países europeus. Conclui-se que a base é uma boa ferramenta de busca para soluções de ambiente de trabalho, de modo que as informações extraídas possam ser transferidas entre países, empresas e ramos, atribuindo escalabilidade às soluções encontradas.
Research on workplace health promotion in the Nordic countries: a literature review, 1986-2008	Torp et al. 2011 ²³	Países nórdicos: Noruega, Suécia, Dinamarca, Finlândia e Islândia	Revisão	Não	Esta revisão de literatura teve como objetivo identificar estudos sobre promoção da saúde no local de trabalho nos países nórdicos, descrever quando, onde e como os estudos foram realizados e analisar ainda mais o uso de abordagens de configurações e processos de empoderamento. Os resultados identificam três níveis de intervenção: 1) individual focado em evitar o estresse com estratégias de relaxamento e meditação; 2) definição de papéis e apoio entre pares, e 3) intervenções voltadas para aspectos físicos, sociais e organizacionais, potenciais fontes de estresse.
Intelligent Robotics Incorporating Machine Learning Algorithms for Improving Functional Capacity Evaluation and Occupational Rehabilitation	Fong et al. 2020 ²⁷	Canadá	Revisão	Não	Este artigo revisa os esforços para desenvolver soluções robóticas de avaliação de capacidade funcional (FCE) que incorporam algoritmos de aprendizado de máquina. O Sistema de Reabilitação funciona simulando manobras mais habilidosas e tarefas funcionais. As abordagens baseadas em aprendizado de máquina combinam os benefícios dos sistemas robóticos com a expertise e experiência de terapeutas humanos.
Identification and classification of high-risk groups for Coal Workers' Pneumoconiosis using an artificial neural network based on occupational histories: a retrospective cohort study	Liu et al. 2009 ²⁸	China	Original	Não	O estudo foi realizado usando dados retrospectivos longitudinais com rede neural artificial para prever a probabilidade de pneumoconiose de trabalhadores do carvão (CWP) e categorizar os níveis de risco. A duração da exposição à poeira e a categoria ocupacional foram os dois fatores mais importantes para CWP. Mineiros de carvão em diferentes níveis de risco para CWP poderiam ser classificados pela análise de rede neural de três camadas com base no histórico ocupacional.

Continua

Quadro 2 Artigos selecionados. Continuação

Ethical Considerations of Using Machine Learning for Decision Support in Occupational Health: An Example Involving Periodic Workers' Health Assessments	Dijkstra et al. 2020 ³⁰	Holanda	Revisão	Sim	O objetivo deste estudo foi explorar considerações éticas e potenciais consequências do uso de ferramentas de suporte à decisão (DSTs) baseadas em ML no contexto da saúde ocupacional. Foram deliberados os princípios éticos biomédicos: respeito à autonomia, beneficência, não maleficência e justiça. Para minimizar efeitos adversos indesejáveis, deve-se observar a qualidade dos dados (completude e confiabilidade, incluindo informações de diferentes atores) para reduzir possíveis vieses nos resultados, aderir à responsabilidade social ao projetar os modelos e observar questões epidemiológicas em torno de seus pontos fortes e fracos.
From worker health to citizen health: moving upstream	Sepulveda 2013 ³¹	EUA	Revisão	Sim	O estudo discute o uso de dados longitudinais relacionados à saúde ocupacional para analisar e identificar oportunidades de apoiar estratégias de prevenção, aumentando o retorno sobre investimentos em saúde e segurança. O valor do big data está na generalização de resultados, atribuindo escalabilidade às intervenções. As intervenções podem alcançar melhores resultados a partir dos dados de múltiplas fontes.
Qualidade dos dados do sistema de informação sobre acidentes de trabalho com exposição a material biológico no Brasil, 2010 a 2015	Gomes & Caldas 2017 ³²	Brasil	Original	Sim	O estudo tem como objetivo analisar a acessibilidade, oportunidade e completude como critérios de qualidade das informações fornecidas pelo Sistema de Informação de Agravos de Notificação (SINAN) sobre Acidentes de Trabalho com Exposição a Material Biológico (ATEMB) de 2010 a 2015. As informações são acessíveis e oportunas. Apesar da acessibilidade da base de dados e da relevância de suas variáveis, o SINAN-ATEMB apresenta problemas em sua qualidade que indicam uma necessidade indiscutível de melhorar a completude das informações.

Fonte: Artigos selecionados por este estudo nas bases Medline, Embase, BVS e SciELO.

Big Data e Saúde Ocupacional

Apenas um artigo¹³ relatou experiência com *big data* para gerar informações sobre saúde ocupacional. Este estudo investigou se fatores demográficos, socioeconômicos, características do trabalho e fatores sociais e de saúde podem ser utilizados para prever a possibilidade de trabalhar após aposentadoria em trabalhadores com e sem doença

crônica. Eles identificaram que se sentir cheio de vida, ser fisicamente ativo, ter maior estatura e experimentar menor carga física no trabalho em que se encontravam no momento do estudo previam com precisão trabalhar após aposentadoria. O estudo foi desenvolvido com uma população de 1.125 trabalhadores selecionados, a partir de critérios de inclusão e exclusão de um grande conjunto de dados holandês chamado STREAM¹⁵, contendo informações de 15.118 trabalhadores. A regressão logística multivariada foi aplicada para investigar o desfecho¹³.

Inteligência Artificial e Saúde Ocupacional

Dois artigos usaram técnicas de ML e/ou aprendizado profundo para prever doenças em trabalhadores. Um desses estudos empregou um algoritmo chamado *Auto Semantic Connectivity Map* (AutoCM) para prever a síndrome metabólica em 210 trabalhadores obesos usando características demográficas e antropométricas como idade, índice de massa corporal (IMC), circunferência da cintura, glicose em jejum, bem como variáveis relacionadas ao trabalho, por exemplo, estresse relacionado ao trabalho¹⁴. Informações sobre as métricas usadas para avaliar o desempenho do algoritmo de ML não estavam disponíveis no artigo. O outro estudo investigou a precisão diagnóstica de biomarcadores séricos e urinários para pneumoconiose em trabalhadores expostos ao amianto¹⁶. Neste estudo caso-controle, algoritmos de ML foram usados para vincular variáveis clínicas a biomarcadores, séricos e urinários, e gerar modelos mais precisos para o diagnóstico de pneumoconiose. A área sob a curva da característica de operação do receptor (Auroc) desses algoritmos variou de 0,7 a 1,0¹⁶.

Algoritmos de Aprendizado de Máquina

Identificamos um total de sete algoritmos de IA utilizados em dois estudos^{14,16}, a saber: árvore de decisão, *boosting* de gradiente extremo, florestas aleatórias, máquinas de vetores de suporte, modelos lineares generalizados, redes neurais artificiais e AutoCM.

Data

Outros estudos contribuíram de forma importante para nossa compreensão da saúde ocupacional e a aplicação de *big data* e IA. Um estudo do Canadá utilizou simulações para comparar o desempenho de diferentes métodos de ML para reduzir o viés por variáveis não medidas e medidas em grandes bancos de dados de saúde¹⁷. Esse estudo comparou ajuste bayesiano para confusão, estimativa de efeito causal bayesiana generalizada, Group Lasso e estimativa duplamente robusta, escore de propensão de alta dimensão e algoritmos de máxima verossimilhança colaborativa escalável. A técnica ajuda a reduzir o viés em grandes bancos de dados de saúde, mas os resultados ainda são inconclusivos¹⁷.

Um estudo realizado no Reino Unido avaliou os riscos ocupacionais de infecção por SARS-CoV-2 entre funcionários de um hospital universitário. Os pesquisadores compararam as taxas de teste positivo para covid-19 entre diferentes grupos de trabalhadores. Os resultados indicaram que profissionais que trabalham em áreas com contato direto com pacientes apresentavam maior probabilidade de testar positivo para o vírus. A equipe da unidade de terapia intensiva mostrou a menor taxa de testes positivos. O estudo também revelou que funcionários negros e asiáticos, bem como carregadores e pessoal de limpeza, tinham maior probabilidade de testar positivo, independentemente de sua função ou local de trabalho¹⁸.

Um estudo dos Estados Unidos focou na precisão e disponibilidade de dados ocupacionais entre bombeiros em um registro de câncer da Flórida, Estados Unidos. Ele determinou a frequência e os preditores de dados ocupacionais ausentes e imprecisos em uma coorte de bombeiros profissionais¹⁹.

No Irã, um estudo teve como objetivo analisar o potencial de redes neurais artificiais e técnicas de regressão logística para a estimativa de perda auditiva entre trabalhadores industriais. O estudo confirmou que as redes neurais podem ser uma ferramenta adequada para analisar interações complexas de variáveis relacionadas à perda auditiva²⁰.

Na Estônia, um estudo de coorte baseado em registros examinou a morbidade não cancerosa entre trabalhadores da limpeza de Chernobyl em comparação com a população geral. O estudo encontrou morbidade elevada para doenças do sistema nervoso, sistema digestivo, sistema musculoesquelético e doença cardíaca isquêmica²¹.

Um estudo conduzido em vários países europeus desenvolveu uma base de dados chamada Solbase, que reúne informações de vários ambientes de trabalho para mapear soluções para riscos de acidentes ocupacionais. Esta base de dados é uma ferramenta valiosa para compartilhar e dimensionar soluções em diferentes setores²².

Uma revisão de literatura dos países nórdicos identificou estudos sobre promoção da saúde no local de trabalho, descrevendo intervenções focadas na redução do estresse individual, definição de papéis, apoio dos colegas e aspectos físicos, sociais e organizacionais²³.

Discussão

Em nossas buscas na literatura, não encontramos outras revisões que exploraram diretamente o uso de *big data* e ML em doenças ocupacionais. Como um tema com evidências limitadas, a revisão de escopo foi adotada como uma estratégia para descrever o estado atual do conhecimento sobre a saúde dos trabalhadores, baseada em modelos de previsão mais precisos através da aplicação de *big data* e IA⁶. Esta abordagem serve como uma base válida para formular estratégias de estudo que visem identificar determinantes de saúde e orientar possíveis melhorias no conjunto de dados de registros sobre as características do ambiente de trabalho e dos indivíduos. A falta de padronização e a incompletude dos dados estão entre as principais barreiras para a aplicação de *big data* na saúde ocupacional^{10,24}.

Anteriormente, algumas revisões descreveram o uso da IA para prever acidentes ocupacionais^{25,26}. Pishgar et al.⁶ conduziram uma revisão narrativa explorando como o *big data* poderia abordar e prever riscos no local de trabalho, concluindo que essa tecnologia poderia ser útil para descobrir novas relações entre doenças e exposições, revelar como as pessoas reagem a perigos potenciais e investigar como as práticas e leis no local de trabalho impactam a saúde dos trabalhadores. No entanto, a revisão deles focou especificamente na aplicação da IA na segurança e saúde ocupacional em cinco indústrias, enquanto nossa revisão de escopo visa fornecer uma visão mais ampla do uso de *big data* e ML no contexto das doenças ocupacionais.

Nossa revisão de escopo evidencia exemplos de como a IA pode aprimorar a investigação de situações ocupacionais, que geralmente envolvem interações complexas entre variáveis ambientais, mentais e genéticas. Através de nossa pesquisa na literatura, identificamos os estudos de Fong et al.²⁷ e Liu et al.²⁸ que utilizaram *big data* e ML para prever desfechos em saúde ocupacional. Especificamente, Yang¹⁶ usou algoritmos de ML para identificar biomarcadores relevantes para o diagnóstico de pneumoconiose, enquanto Farhadian et al.²⁰ analisaram o potencial de redes neurais artificiais e técnicas de regressão logística para a estimativa de perda auditiva entre trabalhadores industriais. McClure et al.¹⁹ investigaram a disponibilidade e precisão de dados ocupacionais em registros de câncer, destacando a importância de dados confiáveis para estudos de saúde ocupacional.

A análise de *big data* permite uma distribuição de dados que reflete mais de perto a realidade do fenômeno investigado ao incluir múltiplos potenciais preditores das características dos trabalhadores, saúde, fatores socioeconômicos e sociais²², facilitando a identificação de relações complexas e diferenças não lineares subjacentes entre a variável resposta e os preditores. Devido às características da técnica, Wind et al.¹³ usam *big data* para mitigar as dificuldades de prever o trabalho após a aposentadoria, especialmente entre indivíduos com doenças crônicas. A maior dificuldade está associada à influência de questões subjetivas, como suporte social e autonomia associada ao trabalho, e à maior heterogeneidade entre indivíduos com doenças crônicas em comparação ao grupo sem doenças crônicas. As características dos fatores de decisão e dos indivíduos tornam a relação entre os determinantes da oferta de trabalho ainda mais intrincada.

Vigna et al.¹⁴ aplicaram técnicas de ML para fazer uma abordagem sistêmica para avaliar os determinantes da síndrome metabólica, considerando fatores relacionados ao trabalho e variáveis psicopatológicas, como compulsão alimentar e sintomas depressivos. A estratégia empírica adotada visa superar as limitações dos modelos estatísticos tradicionais, com propriedades lineares, que surgem na presença de relações complexas e não lineares, características dos sistemas biológicos. O método usado, AutoCM, permite encontrar tendências e associações

entre variáveis e reconstruir canais parciais de transmissão em um conjunto de dados complexo. Yang¹⁶ empregou diferentes algoritmos de ML, árvores de decisão e redes neurais, para construir o modelo de previsão que visa avaliar a precisão do diagnóstico de pneumoconiose em trabalhadores de mineração expostos ao amianto. O modelo incluiu variáveis demográficas como idade e sexo, e biomarcadores séricos e urinários. Os resultados indicam que os dados extraídos dos modelos de ML geram modelos preditivos com alta precisão.

A inclusão nesta revisão de apenas alguns artigos que utilizam *big data* em saúde ocupacional pode estar associada à escassez de dados que tratam da saúde do trabalhador de maneira sistêmica, considerando fatores demográficos, tecnológicos, socioeconômicos e ambientais. A multiplicidade de variáveis resulta da diversidade e da natureza dos eventos adversos e dos fatores de risco para a saúde dos trabalhadores. O estado de saúde dos trabalhadores pode ser afetado por problemas ergonômicos, intoxicação química e contaminação biológica, exposição ao ruído, acidentes de trabalho, relações interpessoais e organizacionais, dentre outros fatores e agentes de exposição relacionados às condições e ambiente de trabalho. Nesse ponto, a falta de registros de agravos à saúde relacionados ao trabalho é o maior problema. Facchini et al.²⁹ atribuem a escassez de informações ao conflito de interesses existente, uma vez que, na maioria dos países, incluindo o Brasil, os registros desses dados são realizados pela própria empresa, que pode optar por subnotificar ou não registrar para evitar sanções por parte das instituições de supervisão e controle. Santana e Nobre²⁴ ainda enfatizam que a falta de qualidade nos sistemas de informação de saúde ocupacional dificulta o desenvolvimento de estratégias eficazes de prevenção.

Facchini et al.²⁹ argumentam que a limitação de disponibilidade de dados pode resultar da inadequação na coleta e na não padronização das variáveis, o que leva à inconsistência, falta de harmonização e pouca articulação entre diferentes sistemas de informação. Além disso, existem problemas como o sub-registro de informações e a baixa confiabilidade de variáveis importantes²⁹. A falta de dados também pode estar associada à ausência de orientação dos profissionais responsáveis pelos registros, que podem não entender o significado dos dados para suas atividades diárias, levando a erros na inserção dos dados²⁹. Por outro lado, a escassez de estudos com *big data* em saúde ocupacional pode estar ligada ao conhecimento limitado sobre os dados disponíveis, que, às vezes, estão dispersos em diferentes repositórios de dados²⁹.

A aplicação de *big data* à ciência da saúde pode enfrentar barreiras técnicas e éticas quando lida com a descentralização e compartilhamento de dados em diferentes repositórios. Dijkstra et al.³⁰ discutem as considerações éticas e as potenciais consequências do uso de ferramentas de suporte à decisão baseadas em ML na saúde ocupacional, enfatizando a importância da qualidade dos dados, da adesão à responsabilidade social ao projetar modelos e da observância das questões epidemiológicas. Outro problema é que a partição dos registros pode reduzir o volume de informações, resultando em dados insuficientes para a construção de *big data*. As questões relacionadas à ausência de cronogramas periódicos e sistemáticos de coleta e à má qualidade dos registros sobre a saúde dos trabalhadores dificultam a construção e manutenção de grandes conjuntos de dados, limitando a aplicação de modelos preditivos com ML²³.

Sepulveda³¹ enfatiza a importância do uso de dados longitudinais relacionados à saúde ocupacional para analisar e identificar oportunidades para apoiar estratégias de prevenção, aumentando o retorno sobre os investimentos em saúde e segurança. O valor do *big data* reside na generalização dos resultados, atribuindo escalabilidade às intervenções e permitindo que elas alcancem melhores resultados a partir de dados de múltiplas fontes. Gomes e Caldas³² investigaram a qualidade dos dados no sistema de informação brasileiro para acidentes de trabalho envolvendo exposição a materiais biológicos. Apesar da acessibilidade do banco de dados e da relevância de suas variáveis, eles descobriram que o sistema apresenta problemas na qualidade dos dados, indicando uma clara necessidade de melhorar a completude das informações. O estudo destaca a importância de garantir a qualidade dos dados nos sistemas de informação de saúde ocupacional para permitir análises e tomadas de decisão eficazes.

Esses desafios na qualidade e disponibilidade dos dados podem explicar a escassez de estudos que aplicam ML à análise de dados de saúde ocupacional. Além disso, muitos dos estudos existentes apresentam limitações em sua estrutura de dados. Por exemplo, a análise da síndrome metabólica realizada por Vigna et al.¹⁴, que não é necessariamente uma doença relacionada ao trabalho, utiliza dados transversais. Já o estudo de Yang¹⁶ sobre asbestose,

uma doença relacionada ao trabalho, é de natureza retrospectiva. Essas abordagens, embora valiosas, limitam a capacidade de estabelecer relações causais e acompanhar mudanças ao longo do tempo. Variáveis sociodemográficas, clínicas e laboratoriais também foram incluídas no modelo para a previsão de doença no estudo conduzido por Yang et al.¹⁶. Essa abordagem está alinhada com uma proposição de avaliação sistêmica, baseada em fatores internos e externos que interagem como determinantes da saúde dos trabalhadores.

Conclusão

Embora a aplicação de *big data* e ML na saúde ocupacional mostre potencial para melhorar nossa compreensão das complexas interações entre fatores relacionados ao trabalho e desfechos de saúde, há desafios importantes a serem enfrentados. Estes incluem a falta de padronização e de qualidade dos dados de saúde ocupacional, considerações éticas no uso de informações sensíveis de saúde e a necessidade de conjuntos de dados mais abrangentes e longitudinais. Pesquisas futuras devem se concentrar no desenvolvimento de estratégias para superar essas barreiras e aproveitar o potencial do *big data* e da IA para avançar na saúde e segurança ocupacional. Esforços colaborativos entre pesquisadores, indústria e formuladores de políticas serão essenciais para garantir o uso responsável e eficaz dessas tecnologias em benefício dos trabalhadores em todo o mundo.

Referências

1. World Health Organization. Risks in ambient work environment. Geneve: World Health Organization; 2024 [citado 3 jun 2024]. Disponível em: <https://www.who.int/tools/occupational-hazards-in-health-sector/risks-in-ambient-work-environment>
2. Rushton L. The global burden of occupational disease. *Curr Environ Health Rep*. 2017;4(3):340-8. <https://doi.org/10.1007/s40572-017-0151-2>
3. Fløvik L, Knardahl S, Christensen JO. The effect of organizational changes on the psychosocial work environment: changes in psychological and social working conditions following organizational changes. *Front Psychol*. 2019;10:2845. <https://doi.org/10.3389/fpsyg.2019.02845>
4. Brasil. Câmara dos Deputados. Decreto nº 3.048, de 6 de maio de 1999. Aprova o Regulamento da Previdência Social, e dá outras providências. *Diário Oficial União*, 12 maio 1999.
5. Groto AD, Perlin CM, Andrade SM, Salamanca MAB. Uso da inteligência artificial para predição de acidentes de trabalho com materiais biológicos em profissionais da saúde. *Res Soc Dev*. 2021;10(12):e93101219743-e. <https://doi.org/10.33448/rsd-v10i12.19743>
6. Pishgar M, Issa SF, Sietsema M, Pratap P, Darabi H. REDECA: a novel framework to review artificial intelligence and its applications in occupational safety and health. *Int J Environ Res Public Health*. 2021 Jun;18(13):6705. <https://doi.org/10.3390/ijerph18136705>
7. Taiwo Oladipupo A. Types of machine learning algorithms. In: Yagang Z, editor. *New advances in machine learning*. Rijeka: IntechOpen; 2010. p. 19-48.
8. Stieb DM, Boot CR, Turner MC. Promise and pitfalls in the application of big data to occupational and environmental health. *BMC Public Health*. 2017;372. <https://doi.org/10.1186/s12889-017-4286-8>
9. Brisimi TS, Chen R, Mela T, Olshevsky A, Paschalidis IC, Shi W. Federated learning of predictive models from federated electronic health records. *Int J Med Inform*. 2018 Apr;112:59-67. <https://doi.org/10.1016/j.ijmedinf.2018.01.007>
10. Nguyen TL. A framework for five big v's of big data and organizational culture in firms. 2018 IEEE International Conference on Big Data (Big Data); 2018 Dec 10-13; Seattle, USA. IEEE; 2018. p. 5411-3.
11. Mehta N, Pandit A. Concurrence of big data analytics and healthcare: a systematic review. *Int J Med Inform*. 2018 Jun;114:57-65. <https://doi.org/10.1016/j.ijmedinf.2018.03.013>
12. Rieke N, Hancox J, Li W, Milletari F, Roth HR, Albarqouni S, et al. The future of digital health with federated learning. *NPJ Digital Med*. 2020;3(1):1-7. <https://doi.org/10.1038/s41746-020-00323-1>
13. Wind A, Scharn M, Geuskens GA, Beek AJ, Boot CR. Predictors of working beyond retirement in older workers with and without a chronic disease-results from data linkage of Dutch questionnaire and registry data. *BMC Public Health*. 2018 Feb;18:265. <https://doi.org/10.1186/s12889-018-5151-0>

14. Vigna L, Brunani A, Brugnera A, Grossi E, Compare A, Tirelli AS, et al. Determinants of metabolic syndrome in obese workers: gender differences in perceived job-related stress and in psychological characteristics identified using artificial neural networks. *Eat Weight Disord*. 2019 Feb;24(1):73-81. <https://doi.org/10.1007/s40519-018-0536-8>
15. Ybema JF, Geuskens G, Van den Heuvel S, Wind A. Study on transitions in employment, ability and motivation (STREAM): the design of a four-year longitudinal cohort study among 15,118 persons aged 45 to 64 years. Hoofddorp: TNO; 2011.
16. Yang H-Y. Prediction of pneumoconiosis by serum and urinary biomarkers in workers exposed to asbestos-contaminated minerals. *PLoS One*. 2019;14(4):e0214808. <https://doi.org/10.1371/journal.pone.0214808>
17. Benasseur I, Talbot D, Durand M, Holbrook A, Matteau A, Potter BJ, et al. A comparison of confounder selection and adjustment methods for estimating causal effects using large healthcare databases. *Pharmacoepidemiol Drug Saf*. 2022 Apr;31(4):424-33. <https://doi.org/10.1002/pds.5403>
18. Eyre DW, Lumley SE, O'Donnell D, Campbell M, Sims E, Lawson E, et al. Differential occupational risks to healthcare workers from SARS-CoV-2 observed during a prospective observational study. *Elife*. 2020 Aug;9:e60675. <https://doi.org/10.7554/eLife.60675>.
19. McClure LA, Koru-Sengul T, Hernandez MN, Mackinnon JA, Schaefer Solle N, Caban-Martinez AJ, et al. Availability and accuracy of occupation in cancer registry data among Florida firefighters. *PloS One*. 2019;14(4):e0215867. <https://doi.org/10.1371/journal.pone.0215867>
20. Farhadian M, Aliabadi M, Darvishi E. Empirical estimation of the grades of hearing impairment among industrial workers based on new artificial neural networks and classical regression methods. *Indian J Occup Environ Med*. 2015 May-Aug;19(2):84-9. <https://doi.org/10.4103/0019-5278.165337>
21. Rahu K, Bromet EJ, Hakulinen T, Auvinen A, Uusküla A, Rahu M. Non-cancer morbidity among Estonian Chernobyl cleanup workers: a register-based cohort study. *BMJ open*. 2014;4(5):e004516. <https://doi.org/10.1136/bmjopen-2013-004516>
22. Swuste P, Hale A, Pantry S. Solbase: a databank of solutions for occupational hazards and risks. *Ann Occup Hyg*. 2003 Oct;47(7):541-7. <https://doi.org/10.1093/annhyg/meg056>
23. Torp S, Eklund L, Thorpenberg S. Research on workplace health promotion in the Nordic countries: a literature review, 1986–2008. *Glob Health Promot* 2011;18(3):15-22. <https://doi.org/10.1177/1757975911412401>
24. Santana VS, Nobre L, editors. Sistemas de informação em saúde do trabalhador; 3a Conferência Nacional de Saúde do Trabalhador; 2005. Brasília, DF: Ministério da Saúde, Ministério do Trabalho e Emprego, Ministério da Previdência e Assistência Social; 2005. (Série D. Reuniões e Conferências).
25. Khairuddin MZF, Hasikin K, Abd Razak NA, Lai KW, Osman MZ, Aslan MF, et al. Predicting occupational injury causal factors using text-based analytics: a systematic review. *Front Public Health*. 2022;10:984099. <https://doi.org/10.3389/fpubh.2022.984099>
26. Barker TT. Finding pluto: an analytics-based approach to safety data ecosystems. *Saf Health Work*. 2021;12(1):1-9. <https://doi.org/10.1016/j.shaw.2020.09.010>
27. Fong J, Ocampo R, Gross DP, Tavakoli M. Intelligent robotics incorporating machine learning algorithms for improving functional capacity evaluation and occupational rehabilitation. *J Occup Rehabil*. 2020 Sep;30(3):362-70. <https://doi.org/10.1007/s10926-020-09888-w>
28. Liu H, Tang Z, Yang Y, Weng D, Sun G, Duan Z, et al. Identification and classification of high risk groups for Coal Workers' Pneumoconiosis using an artificial neural network based on occupational histories: a retrospective cohort study. *BMC Public Health*. 2009;9:366. <https://doi.org/10.1186/1471-2458-9-366>
29. Facchini LA, daCosta Nobre LC, Faria NM, Fassa AG, Thumé E, Tomasi E, et al. Occupational Health Information System: challenges and perspectives in the Brazilian Unified Health System (SUS). *Cienc Saude Coletiva*. 2005 Dec;10(4):857-67. <https://doi.org/10.1590/S1413-81232005000400010>
30. Six Dijkstra MW, Siebrand E, Dorrestijn S, Salomons EL, Reneman MF, Oosterveld FG, et al. Ethical considerations of using machine learning for decision support in occupational health: an example involving periodic workers' health assessments. *J Occup Rehabil*. 2020;30(4):343-53. <https://doi.org/10.1007/s10926-020-09895-x>
31. Sepulveda M-J. From worker health to citizen health: moving upstream. *J Occup Environ Med*. 2013;55(12 suppl):S52-7. <https://doi.org/10.1097/JOM.0000000000000033>
32. Gomes SCS, Caldas AdJM. Qualidade dos dados do sistema de informação sobre acidentes de trabalho com exposição a material biológico no Brasil, 2010 a 2015. *Rev Bras Med Trab*. 2017;15(3):200-28. <https://doi.org/10.5327/Z1679443520170036>

Contribuições de autoria: Fagundes TP, Wichmann RM, Silva MEL, Oliveira TA contribuíram igualmente na concepção, na elaboração e na aprovação final da versão publicada e assumem total responsabilidade por todos os aspectos do trabalho.

Disponibilidade de dados: Todo o conjunto de dados que dá suporte aos resultados deste estudo foi disponibilizado no repositório SciELO Data, disponível em: <https://doi.org/10.48331/scielodata.7FNOXU>.

Financiamento: Os autores declaram que o trabalho não foi subvencionado.

Conflito de interesses: Os autores declaram que não há conflitos de interesses.

Apresentação do estudo em evento científico: Os autores informam que este estudo não foi apresentado em evento científico.

Recebido: 08/11/2022

Revisado: 01/02/2023

Aprovado: 28/04/2023

Editor-Chefe:

José Marçal Jackson Filho