



PBPC
ISSN 2674-9432



Qualis A3
CAPES 2021-2024



DOI - Crossref

Latindex

Indexado no
Google Acadêmico

SAÚDE OCUPACIONAL ORIENTADA POR DADOS: MÉTODOS ANALÍTICOS PARA GESTÃO DE RISCOS

Denyse do Amaral Krawczyk¹, Julio César Oliveira Santos², Fábio Barbosa Rodrigues³, Rafael Viana de Carvalho⁴, Rogério José de Almeida⁵



<https://doi.org/10.36557/2674-9432.2026v5n1p2447-2465>

Artigo recebido em 10 de Janeiro e publicado em 10 de Março de 2026

REVISÃO SISTEMÁTICA

RESUMO

Esta revisão sistemática tem por objetivo analisar como a aplicação de métodos de análise de dados, especialmente algoritmos de inteligência artificial, contribuem para identificar padrões relacionados aos agravos à saúde dos trabalhadores e apoiar decisões estratégicas na gestão de pessoas. A busca foi conduzida nas bases BVS e PubMed, com publicações entre 2020 e 2025, seguindo as diretrizes PRISMA 2020, resultando em 12 estudos incluídos na amostra final. Os achados evidenciam que o aprendizado de máquina constitui o eixo metodológico central dos estudos analisados, confirmando sua relevância no campo da saúde ocupacional. Os estudos primários demonstraram que técnicas como redes neurais, lógica fuzzy e algoritmos evolutivos permitem antecipar riscos ocupacionais e diagnosticar doenças relacionadas ao trabalho, somando-se ao uso de tecnologias de coleta, como sensores vestíveis e sensores fixos, empregados para monitorar padrões posturais, biomecânicos e de movimento em tempo real, o que amplia a qualidade e a diversidade dos dados analisados pelos modelos. As análises também evidenciaram avanços metodológicos, com ênfase em modelos preditivos e arquiteturas híbridas, além de apontarem lacunas relacionadas à padronização dos modelos, validação multicêntrica e integração aos sistemas organizacionais. A aplicação de inteligência artificial amplia a capacidade preditiva, fortalece a gestão de pessoas e subsidia políticas preventivas, promovendo ambientes laborais mais seguros e sustentáveis. Contudo, a consolidação dessa abordagem exige interoperabilidade entre sistemas, integração organizacional e formação de gestores com competências em análise de dados e ética digital, a fim de assegurar reprodutibilidade, transparência e aplicabilidade prática dos modelos no contexto ocupacional.

Palavras-chave: Saúde ocupacional; Gestão de pessoas; Inteligência artificial; Big data; Aprendizado de máquina.

ABSTRACT

This systematic review aims to examine how the application of data analysis methods, particularly artificial intelligence algorithms, contributes to identifying patterns related to occupational health disorders and supporting strategic decision making in people management. The search was conducted in the BVS and PubMed databases, covering publications from 2020 to 2025, following the PRISMA 2020 guidelines, and resulting in 12 studies included in the final sample. The findings show that machine learning forms the core methodological framework of the analyzed studies, reinforcing its relevance in the field of occupational health. The primary studies demonstrated that techniques such as neural networks, fuzzy logic, and evolutionary algorithms make it possible to anticipate occupational risks and diagnose work-related diseases. These approaches are complemented by data-collection technologies, including wearable and fixed sensors used to monitor postural, biomechanical, and movement patterns in real time, which enhances the quality and diversity of data feeding the models. The analysis also identified methodological advances, with emphasis on predictive models and hybrid architectures, while highlighting gaps related to model standardization, multicenter validation, and integration into organizational systems. The use of artificial intelligence strengthens predictive capacity, supports people management, and informs preventive policies, promoting safer and more sustainable work environments. However, the consolidation of this approach requires system interoperability, organizational integration, and the training of managers in data analysis and digital ethics to ensure reproducibility, transparency, and practical applicability of these models in occupational settings.

Keywords: Occupational Health; Human Resource Management; Artificial Intelligence; Big Data; Machine Learning.

Instituição afiliada –

^{1,5} Pontifícia Universidade Católica de Goiás (PUC Goiás) – Goiânia, GO

^{2,3,4} Universidade Estadual de Goiás (UEG Goiás) – Trindade, GO

Autor correspondente: M^a Denyse do Amaral Krawczyk – denyse.krawczyk@gmail.com

This work is licensed under a [Creative Commons Attribution 4.0 International License](https://creativecommons.org/licenses/by/4.0/).



Agência de Fomento: Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES)



1 INTRODUÇÃO

A saúde ocupacional configura-se como dimensão estratégica da gestão organizacional, sobretudo em ambientes laborais de alta complexidade como os serviços de saúde, onde a diversidade e intensidade dos riscos ocupacionais demandam abordagens específicas de gestão (Yeşilgöz; Arga, 2025). A capacidade de antecipar e gerenciar esses riscos representa um indicador de maturidade em gestão de riscos e um imperativo para sistemas sustentáveis de saúde ocupacional, integrando proteção à saúde e segurança dos trabalhadores (Ferrari *et al.*, 2025; Yeşilgöz; Arga, 2025). Nesse contexto, profissionais desse setor enfrentam riscos físicos, emocionais e organizacionais que contribuem para agravos como estresse, fadiga, síndrome de burnout e adoecimento mental (Yeşilgöz; Arga, 2025).

Evidências provenientes de revisão sistemática com metanálise estimam que cerca de 39% da força de trabalho global em saúde pública apresenta sinais de síndrome de burnout (Nagarajan *et al.*, 2024). Essa condição de natureza predominantemente psicossocial exige ferramentas capazes de identificar variáveis preditoras comportamentais e cognitivas para além dos relatórios retrospectivos. Além dos prejuízos individuais, os agravos à saúde ocupacional geram perdas organizacionais significativas. Segundo o Ministério do Trabalho e Emprego, os acidentes de trabalho podem gerar perdas equivalentes a 4% do Produto Interno Bruto nacional (Brasil, 2025). Dados da Pesquisa Nacional de Saúde 2019, conduzida pelo Instituto Brasileiro de Geografia e Estatística, indicam que 38,5% dos indivíduos em condição de ocupação relataram absenteísmo por motivos de saúde, associado à carga de doenças crônicas não transmissíveis (Fernandes *et al.*, 2024).

Diante desse cenário, cresce o interesse por abordagens analíticas avançadas que ofereçam maior capacidade preditiva e apoio a decisões estratégicas. Técnicas como inteligência artificial, aprendizado de máquina e mineração de dados vêm sendo exploradas como ferramentas promissoras na saúde ocupacional, capazes de detectar padrões ocultos, antecipar riscos e subsidiar intervenções mais eficazes (Ahmad; Edaris; Jamaludin, 2023; Molina-Castaño *et al.*, 2024). A aplicação da IA em ambientes ocupacionais ainda é incipiente, marcada por lacunas metodológicas. Sua integração enfrenta desafios éticos, técnicos e organizacionais que ainda limitam a adoção ampla e

sustentável, especialmente em pequenas e médias empresas (Fiegler-Rudol *et al.*, 2025; Jetha *et al.*, 2024). Em particular, a governança algorítmica, a transparência e a responsabilidade no uso de IA são questões cruciais para a consolidação de uma saúde e segurança ocupacional orientada por dados (Six Dijkstra *et al.*, 2020).

Embora o uso de dados e algoritmos de inteligência artificial esteja em expansão nas organizações, ainda não há evidência consolidada sobre como essas ferramentas contribuem para identificar padrões de risco à saúde ocupacional e apoiar decisões estratégicas na gestão de pessoas. Essa lacuna metodológica e prática limita o desenvolvimento de abordagens integradas e fundamentadas, justificando a necessidade de uma revisão sistemática que sintetize o estado atual do conhecimento.

Esta revisão sistemática tem como objetivo analisar como a aplicação de métodos de análise de dados, especialmente algoritmos de inteligência artificial, contribuem para identificar padrões relacionados aos agravos à saúde dos trabalhadores e apoiar decisões estratégicas na gestão de pessoas.

2 METODOLOGIA

Trata-se de uma Revisão Sistemática conduzida segundo as diretrizes do PRISMA 2020 (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*) para garantir a máxima transparência do processo. O processo metodológico foi executado com rigor desde a definição dos critérios de elegibilidade até a análise final dos estudos incluídos, utilizando os *checklists* de avaliação crítica do *Joanna Briggs Institute* (JBI) para análise da qualidade metodológica e risco de viés dos estudos selecionados.

As buscas bibliográficas foram realizadas de forma independente nas bases de dados Biblioteca Virtual em Saúde (BVS), pela sua relevância na área da saúde e cobertura da produção científica latino-americana, e PubMed, pela sua ampla cobertura internacional na área da saúde.

As estratégias de busca foram formuladas com o uso de descritores DeCS (Descritores em Ciências da Saúde) na BVS e descritores MeSH (*Medical Subject Headings*) na PubMed. A combinação dos termos foi realizada por meio dos operadores booleanos AND e OR, visando maximizar a sensibilidade da busca e garantir alinhamento

com o escopo da revisão. Não foi realizada busca manual em referências (*snowballing*), sendo considerados exclusivamente os registros identificados nas bases consultadas cujo processo detalhado e sintaxe de busca está apresentado na Quadro 1.

Quadro 1. Estratégia de busca e sintaxe utilizada nas bases de dados (BVS e PubMed).

Eixo Temático	BVS (DeCS)	PubMed (MeSH)
Aplicação de tecnologias analíticas para identificar padrões de agravos à saúde dos trabalhadores e apoiar decisões em gestão de pessoas	("Saúde Ocupacional" OR "Exposição Ocupacional" OR "Doenças Ocupacionais" OR "Ambiente de Trabalho") AND ("Inteligência Artificial" OR "Aprendizado de Máquina" OR "Grandes Dados")	("Occupational Health"[MeSH] OR "Occupational Exposure"[MeSH] OR "Occupational Diseases"[MeSH] OR "Workplace"[MeSH]) AND ("Artificial Intelligence"[MeSH] OR "Machine Learning"[MeSH] OR "Big Data"[MeSH])

Fonte: Elaborado pelos autores.

A revisão buscou-se responder ao seguinte problema de pesquisa: Como a aplicação de métodos de análise de dados, especialmente algoritmos de inteligência artificial, contribui para identificar padrões de risco à saúde ocupacional e apoiar decisões estratégicas na gestão de pessoas?

Conforme quadro 2, foram incluídos estudos publicados entre janeiro de 2020 e a data da última busca, 21 de setembro de 2025, nos idiomas português, inglês ou espanhol, com texto completo disponível. Esse recorte temporal foi escolhido para capturar os avanços mais recentes no uso de inteligência artificial aplicada à saúde ocupacional. Foram considerados elegíveis estudos primários que abordassem o uso de métodos de análise de dados, especialmente algoritmos de inteligência artificial, com evidências empíricas de aplicabilidade organizacional.

Foram excluídos artigos duplicados, estudos com foco exclusivo em intervenção clínica individual, artigos de natureza exclusivamente conceitual que não apresentassem metodologia de pesquisa ou análise de dados, além de publicações que não apresentavam conexão com os objetivos da revisão, mesmo após leitura na íntegra. A exclusão de trabalhos opinativos e conceituais visou garantir a análise de evidências empíricas aplicáveis, assegurando maior robustez e relevância prática dos resultados.

Quadro 2. Critérios de elegibilidade para a seleção dos estudos

Componente	Critério de Inclusão	Critério de Exclusão
-------------------	-----------------------------	-----------------------------

População (P)	Estudos focados na saúde do trabalhador em qualquer setor ou ocupação.	Estudos com foco exclusivo em intervenção clínica individual (não relacionada ao contexto ocupacional).
Intervenção	Uso de métodos de análise de dados, especificamente algoritmos de Inteligência Artificial (IA), Machine Learning (ML), ou Big Data.	Trabalhos que não utilizam métodos de análise de dados ou IA.
Desfecho	Evidência de aplicabilidade na identificação de padrões de risco à saúde ocupacional ou suporte à decisão na gestão de pessoas.	Estudos com foco em intervenção clínica individual ou resultados puramente teóricos.
Delineamento	Artigos primários (quantitativos e mistos) com metodologia explícita.	Artigos duplicados, trabalhos opinativos sem base empírica ou de natureza exclusivamente conceitual. E artigos secundários (revisões, opiniões de especialista)
Tempo	Publicado entre Janeiro de 2020 e Setembro de 2025.	Publicado fora do recorte temporal.
Idioma	Português, Inglês ou Espanhol.	Idioma não listado.

Fonte: Elaborado pelos autores.

A triagem e extração dos dados foram apoiadas pela ferramenta Zotero e seguiram as quatro etapas recomendadas pelo PRISMA: (1) identificação dos registros nas bases, (2) remoção de duplicatas, (3) triagem por título e resumo e (4) leitura completa dos textos potencialmente elegíveis.

Os estudos elegíveis foram submetidos à avaliação da qualidade metodológica e risco de viés, utilizando os instrumentos de Avaliação Crítica do *Joanna Briggs Institute* (JBI).

Para os 12 Estudos Primários, foram aplicados os checklists JBI específicos para o delineamento de cada artigo. Foram utilizados os seguintes checklist: JBI *Critical Appraisal Checklist for Analytical Cross-Sectional Studies*; JBI *Critical Appraisal Checklist for Cohort Studies* e JBI *Critical Appraisal Checklist for Diagnostic Test Accuracy Studies*.

Os resultados da classificação final do Risco de Viés (Baixo, Moderado ou Alto) foram utilizados para a síntese analítica no Quadro 3. A análise dos dados extraídos foi conduzida por categorização temática, estruturada a partir dos eixos definidos previamente, com foco na caracterização metodológica, aplicação tecnológica, contexto organizacional e implicações para a saúde ocupacional

3 RESULTADOS e DISCUSSÃO

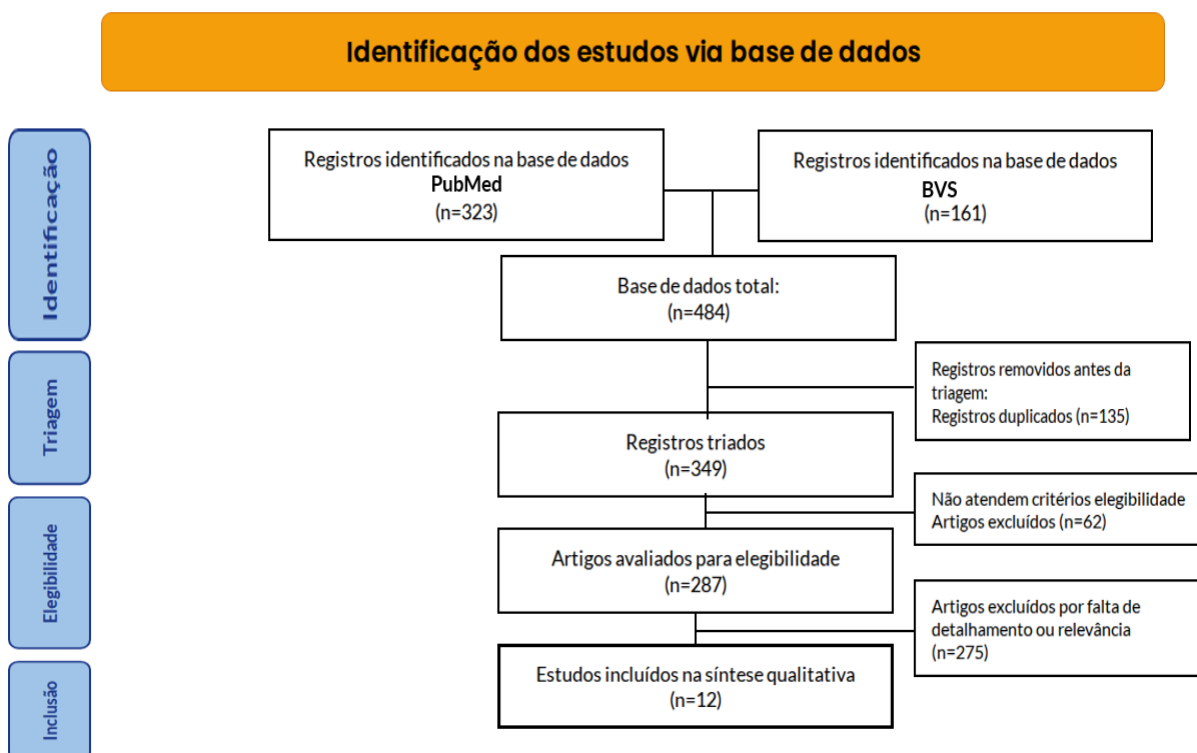
A busca sistemática nas bases de dados BVS e PubMed identificou 484 registros

(161 provenientes da BVS e 323 da PubMed). Após a remoção de 135 registros duplicados, restaram 349 artigos únicos para a etapa de triagem. Na fase de triagem (análise de títulos e resumos), 62 estudos foram excluídos por não atenderem aos critérios de elegibilidade predefinidos. Dessa forma, 287 artigos foram selecionados para a leitura na íntegra.

Na etapa de leitura na íntegra, verificou-se que a maioria dos estudos, embora tematicamente relevante, não fornecia o detalhe metodológico e os dados extraíveis necessários para a síntese qualitativa e a caracterização completa dos campos de interesse da pesquisa. Assim, para garantir a consistência e a profundidade interpretativa, 12 estudos forneceram profundidade metodológica e aderência temática suficientes para integrar a síntese analítica desta revisão.

O processo completo de seleção está representado no fluxograma PRISMA (Figura 1), que detalha as etapas de identificação, triagem, elegibilidade e inclusão.

Figura 1. O fluxograma apresenta o número de registros identificados, triados, avaliados e incluídos na síntese qualitativa, conforme as diretrizes PRISMA 2020.



Fonte: Elaborado pelos autores.

Os 12 estudos incluídos concentram as evidências mais relevantes para a

compreensão do papel dos métodos de análise de dados e dos algoritmos de inteligência artificial aplicados à saúde ocupacional.

O Quadro 3 apresenta a síntese metodológica, delineamento, tecnologia principal e o resultado da Avaliação da Qualidade e Risco de Viés (JBI) para cada artigo, servindo como a base fundamental para a síntese dos resultados. Com base nessa caracterização metodológica, foi possível realizar a síntese analítica dos achados agrupando os estudos de acordo com o foco tecnológico e a contribuição estratégica, conforme apresentado no Quadro 4. Esta estrutura analítica dos resultados guiará a discussão subsequente.

Quadro 3. Caracterização dos estudos primários incluídos na amostra final.

Artigo (Autor/Ano)	Delineamento	Agravo à Saúde (Desfecho)	Tecnologia Principal	População/Setor	Qualidade Final JBI (Risco de Viés)
Achouri <i>et al.</i> (2025)	Estudo Preditivo	Risco Ocupacional Genérico (Prevenção)	Algoritmo Híbrido ANFIS-PSO/GA	Não Especificado	Moderado
Adapa <i>et al.</i> (2022)	Estudo Preditivo	Síndrome de Burnout	Machine Learning Explicável (XAI)	Profissionais de Saúde	Moderado
Adeleke <i>et al.</i> (2024)	Estudo Coorte / Preditivo	Hipertensão (Rastreamento)	Machine Learning (k-means Clustering)	Trabalhadores de Universidade	Moderado
Bozorgmehr; Thielmann; Weltermann, (2021)	Estudo Analítico	Estresse Crônico	Machine Learning (4 Classificadores)	Assistentes de Prática Clínica	Baixo
Conforti <i>et al.</i> (2020)	Quase-Experimental	Risco Musculoesquelético (Levantamento)	Machine Learning + <i>Wearables</i> (IMUs)	Amostra Saudável	Baixo
Donisi <i>et al.</i> (2021)	Estudo Preditivo	Risco de Lesão (NIOSH Lifting Equation)	Machine Learning + Sensor Inercial	Indústria/Manuseio de Carga	Baixo
Dzeng <i>et al.</i> (2024)	Estudo Preditivo de Detecção	Acidentes Comuns (Detecção de Quedas)	Modelo GRU (Rede Neural Recorrente)	Trabalhadores da Construção	Moderado
Effati <i>et al.</i> (2024)	Estudo Preditivo (Web App)	Doença Cardiovascular / Hipertensão	Machine Learning (<i>Random Forest</i>)	Trabalhadores de Mina	Moderado
Luo <i>et al.</i> (2024)	Estudo Preditivo (ML Framework)	Distúrbios Musculoesqueléticos	Machine Learning Explicável (XAI)	Profissionais de Saúde	Moderado
Sánchez-Guillén <i>et al.</i> (2024)	Estudo Transversal	Lesões Musculoesqueléticas	Algoritmo/Calculadora de Risco de ML	Cirurgiões	Moderado

Sun <i>et al.</i> (2025)	Caso-Controle Retrospectivo	Silicose	Machine Learning (Modelo Preditivo Integrado)	Trabalhadores com Risco de Silicose	Moderado
Wang <i>et al.</i> (2024)	Acurácia Diagnóstica	Pneumoconiose (Diagnóstico e Estadiamento)	Deep Learning (MLANet)	Trabalhadores /Radiologistas	Baixo

Fonte: Elaborado pelos autores.

Quadro 4. Síntese analítica do 12 artigos incluídos na amostra final.

Autores/ Ano	Título do artigo	Objetivo	Agravo à Saúde/Foco Temático	Contribuição para gestão de pessoas e saúde ocupacional
Achouri <i>et al.</i> , 2025	Adaptive hybrid Adaptive Neuro-Fuzzy Inference System with Particle Swarm Optimization and Genetic Algorithm for occupational risk prediction	Prever riscos ocupacionais	Risco Ocupacional Genérico (Prevenção)	Modelo híbrido eficaz para decisões preventivas baseadas em dados permitindo intervenções proativas e localizadas
Adapa <i>et al.</i> , 2022	Using Explainable Supervised Machine Learning to Predict Burnout in Healthcare Professionals	Prever Síndrome de Burnout	Síndrome de Burnout	Utiliza Machine Learning Explicável, identificando fatores-chave Síndrome de Burnout (ex: carga de trabalho, staffing), crucial para auditoria e confiança gerencial.
Adeleke <i>et al.</i> , 2024	Machine learning evaluation of a hypertension screening program in a university workforce over five years	Avaliar o programa de rastreamento de hipertensão em uma força de trabalho universitária usando ML	Hipertensão (Rastreamento)	Demonstra uma estratégia sustentável para diagnóstico e controle de hipertensão, otimizando o rastreamento em grandes populações de trabalhadores.
Bozorgmehr; Thielmann; Weltermann, (2021)	Chronic stress in practice assistants: An analytic approach comparing four machine learning classifiers with a standard logistic	Comparar classificadores de aprendizado de máquina com o modelo padrão de regressão logística na previsão de estresse crônico	Estresse Crônico	Aprendizado de máquina demonstrou melhor desempenho, identificando fatores organizacionais críticos para a gestão intervir na estrutura do trabalho e mitigar o

	regression model			estresse
Conforti <i>et al.</i> , 2020	Measuring Biomechanical Risk in Lifting Load Tasks Through Wearable System and Machine-Learning Approach	Propor uma solução para o reconhecimento de padrões posturais (corretos e incorretos) durante tarefas de levantamento de carga	Risco Musculoesquelético (Levantamento)	Prevenção de distúrbios musculoesqueléticos com sensores vestíveis, oferecendo feedback em tempo real para o trabalhador e insights para a gestão ergonômica
Donisi <i>et al.</i> , 2021	Work-Related Risk Assessment According to the Revised NIOSH Lifting Equation	Avaliar o risco de trabalho de acordo com a Equação de Levantamento NIOSH Revisada (Revised NIOSH Lifting Equation).	Risco de Lesão (NIOSH <i>Lifting Equation</i>)	Oferece uma avaliação preliminar de risco de lesão utilizando sensor inercial vestível e ML, permitindo uma análise mais rápida e fácil em comparação com métodos tradicionais.
Dzeng <i>et al.</i> , 2024	A GRU-Based Model for Detecting Common Accidents of Construction Workers	Detectar acidentes comuns (como quedas) de trabalhadores da construção civil usando um modelo baseado em GRU	Acidentes Comuns (Detecção de Quedas)	Proposta de um sistema de detecção de acidentes em tempo real para a construção civil, elevando a segurança através da identificação e alerta imediato de quedas
Effati <i>et al.</i> , 2024	Web application using machine learning to predict cardiovascular disease and hypertension in mine workers	Apresentar uma aplicação web usando ML para prever doença cardiovascular (DCV) e hipertensão (HTN) em trabalhadores de minas	Doença Cardiovascular / Hipertensão	Fornece avaliações de risco personalizadas, permitindo intervenções direcionadas (modificações no local de trabalho) para mitigar riscos crônicos de saúde ocupacional
Luo <i>et al.</i> , 2024	Explainable machine learning framework to predict the risk of work-related neck and	Prever o risco de distúrbios musculoesqueléticos (DMEs) no pescoço e ombro, utilizando um framework de ML	Distúrbios Musculoesqueléticos	Desenvolve um framework de ML explicável (XAI) para DMEs, permitindo que gestores e ergonomistas identifiquem os

	shoulder musculoskeletal disorders among healthcare professionals	explicável.		fatores de risco mais influentes de forma transparente.
Sánchez-Guillén <i>et al.</i> , 2024	A calculator for predicting musculoskeletal injuries in surgeons: a machine learning approach	Calcular o risco de lesões musculoesqueléticas em cirurgiões após a prática cirúrgica usando um algoritmo de ML.	Lesões Musculoesqueléticas	Cria uma calculadora de risco online baseada em ML para cirurgiões, oferecendo uma ferramenta preditiva e personalizada para a gestão da saúde ocupacional e prevenção de lesões.
Sun <i>et al.</i> , 2025	Development of a multi-laboratory integrated predictive model for silicosis utilizing machine learning: a retrospective case-control study	Desenvolver um modelo preditivo integrado para silicose utilizando aprendizado de máquina.	Silicose	Oferece um modelo preditivo robusto e multi-laboratorial para rastreamento precoce de silicose, permitindo intervenções de controle de exposição mais rápidas e direcionadas em ambientes de risco.
Wang <i>et al.</i> , 2024	Deep learning for pneumoconiosis diagnosis	Propor um modelo de Deep Learning (MLANet) para diagnóstico e estadiamento de Pneumoconiose, comparando a acurácia com radiologistas.	Pneumoconiose (Diagnóstico e Estadiamento)	Demonstra que o ML pode aumentar a eficiência e consistência no diagnóstico da Pneumoconiose, auxiliando radiologistas e permitindo o estadiamento precoce para intervenção médica.

Fonte: Elaborado pelos autores.

Os resultados da busca nas bases BVS e PubMed evidenciam crescimento significativo nas publicações entre 2024 e 2025, que correspondem a 56% dos registros identificados (n = 161), indicando intensificação recente do interesse pelo uso de métodos baseados em dados na saúde ocupacional. Para além do crescimento quantitativo, os achados evidenciam evolução metodológica consistente, com adoção de algoritmos de inteligência artificial capazes de modelar relações complexas e identificar padrões associados a agravos à saúde dos trabalhadores. Estudos primários

recentes ilustram esse movimento, como Achouri *et al.* (2025), que empregaram sistemas neuro-fuzzy híbridos para predição de risco ocupacional, e Sun *et al.* (2025), que desenvolveram modelo preditivo multicêntrico para silicoses com validação externa e independente. Em conjunto, esses resultados apontam para a adoção de arquiteturas preditivas avançadas, como modelos neuro-fuzzy otimizados por meta-heurísticas (ANFIS-PSO e ANFIS-GA) e modelos multibiomarcadores integrados, capazes de aprimorar a acurácia na previsão de riscos ocupacionais e de sustentar decisões estratégicas em gestão de pessoas e vigilância em saúde do trabalhador.

O incremento na adoção de arquiteturas preditivas não lineares e de modelos híbridos de aprendizado supervisionado na gestão da saúde ocupacional está associado ao aprimoramento da capacidade preditiva dos modelos contemporâneos, especialmente em contextos caracterizados por múltiplas interações e estruturas não lineares. Diferentemente das abordagens estatísticas tradicionais baseadas em pressupostos lineares, os modelos de aprendizado de máquina têm demonstrado maior capacidade de relações multivariadas complexas, o que amplia sua aplicabilidade no suporte à gestão organizacional (Achouri *et al.*, 2025; Bozorgmehr; Thielmann; Weltermann (2021); Effati *et al.*, 2024).

Os estudos se destacam pelo aumento da sofisticação metodológica, com ênfase em arquiteturas híbridas que combinam redes neuro-fuzzy otimizadas por algoritmos evolutivos, modelos supervisionados multivariados e, mais recentemente, estruturas de deep learning baseadas em *Convolutional Neural Networks* (CNNs). Achouri *et al.* (2025) demonstram o emprego de modelos híbridos ANFIS-PSO e ANFIS-GA, enquanto Sun *et al.* (2025) utilizam técnicas supervisionadas clássicas, como *Random Forest*, SVM e ANN, aplicadas à identificação de riscos ocupacionais e biomarcadores laboratoriais. Essa evolução metodológica é reforçada por Wang *et al.* (2024), que aplicaram uma CNN especializada, o modelo MLANet, ao diagnóstico e estadiamento da pneumoconiose, com validação interna, externa e prospectiva, obtendo desempenho comparável ao de radiologistas experientes.

Entre os estudos incluídos, observa-se a predominância de técnicas de Inteligência Artificial baseadas em aprendizado supervisionado, especialmente modelos como *Random Forest*, *Support Vector Machines* (SVM), *K-Nearest Neighbors* (KNN) e *Artificial Neural Networks* (ANN) de baixa profundidade. Esses modelos são

frequentemente combinados a métodos de seleção de atributos, como *chi-square*, *mutual information* e *recursive feature elimination* (RFE), conforme demonstrado por Adapa et al. (2022) na predição da Síndrome de Burnout em profissionais de saúde, com desempenho elevado (AUC = 0.81). A literatura também evidencia aplicações em ergonomia por meio de dados de sensores, com modelos supervisionados capazes de extrair padrões biomecânicos relevantes (Donisi et al., 2021), além do uso de *Random Forest* na predição de distúrbios musculoesqueléticos em profissionais de saúde, como apresentado por Luo et al. (2024). Em conjunto, esses estudos mostram que tais algoritmos não apenas identificam padrões de risco com boa performance, mas também oferecem potencial para apoiar decisões organizacionais em prevenção de agravos, redução do absenteísmo e formulação de políticas preventivas. Entretanto, permanece necessária a validação multicêntrica e a padronização metodológica para ampliar a reprodutibilidade e a aplicabilidade dos modelos em distintos contextos ocupacionais.

De forma complementar, Achouri et al. (2025) demonstraram que o modelo híbrido de Sistema de Inferência Neuro-Fuzzy Adaptativo otimizado por Otimização por Enxame de Partículas (ANFIS-PSO) apresentou um desempenho superior às Redes Neurais Artificiais (ANN) e às Máquinas de Vetores de Suporte (SVM). Mesmo quando estas últimas foram aprimoradas por algoritmos evolutivos, como o próprio PSO ou o Algoritmo Genético (GA), alcançando menores valores de erro na predição de riscos ocupacionais. O ANFIS combina redes neurais artificiais com lógica difusa, permitindo modelar relações complexas e não lineares típicas do ambiente industrial. Os resultados indicam que essa abordagem contribui para o aprimoramento da estimativa de risco, com implicações para o fortalecimento de estratégias preventivas baseadas em dados. Esses achados reforçam o potencial da inteligência artificial como suporte à gestão e aos sistemas de vigilância em saúde do trabalhador.

A revisão também identificou o avanço de estudos que aplicam mineração de dados e algoritmos de agrupamento, no acompanhamento longitudinal de programas de saúde ocupacional. O estudo de Adeleke et al. (2024) com n=1.723, utilizou o algoritmo *k-means clustering* para avaliar um programa periódico de triagem de hipertensão em trabalhadores universitários ao longo de cinco anos, demonstrando que essa estratégia é eficaz, viável e sustentável para o monitoramento e controle da hipertensão na população laboral. Embora o estudo evidencie o potencial das técnicas



avançadas de análise de dados para aprimorar avaliações de saúde no ambiente de trabalho, os autores destacam a necessidade de pesquisas futuras sobre custo-efetividade e desafios práticos de implementação desses programas.

Uma outra estratégia em crescimento para a gestão da saúde ocupacional é o uso de tecnologias vestíveis associadas à análise de dados. Os dispositivos inteligentes, como sensores corporais e palmilhas conectadas, têm sido empregados para monitorar padrões posturais, biomecânicos e de movimento em tempo real. O estudo de Conforti *et al.* (2020) demonstrou a eficácia de sensores inerciais combinados com classificadores supervisionados para identificar posturas inadequadas durante tarefas de levantamento de carga. Esses achados reforçam o potencial das tecnologias vestíveis na prevenção de distúrbios musculoesqueléticos e na promoção de ambientes laborais mais seguros.

Os estudos evidenciam o fortalecimento de uma abordagem analítica na saúde ocupacional, sustentada pela incorporação de dados captados por sensores e analisados por modelos de aprendizado de máquina. As aplicações revisadas demonstram que o uso de aprendizado de máquina, especialmente por meio de modelos supervisionados como redes neurais recorrentes e algoritmos de classificação, tem possibilitado a identificação de padrões de risco e a detecção de eventos críticos relacionados à segurança ocupacional em diferentes contextos laborais (Dzeng *et al.*, 2024), como na calculadora de risco desenvolvida por Sánchez-Guillén *et al.* (2024) para prever lesões musculoesqueléticas em cirurgiões. Esses achados reforçam a transição para uma saúde ocupacional orientada por dados, na qual a inteligência artificial aprimora a capacidade preditiva e o suporte às decisões preventivas nos ambientes laborais.

Em conjunto, os achados desta revisão sugerem um movimento consistente de transição na saúde ocupacional, com deslocamento de abordagens predominantemente reativas, centradas na detecção de agravos, para modelos preditivos e preventivos baseados em dados. Estudos como os de Achouri *et al.* (2025) e Sun *et al.* (2025) demonstram a viabilidade de modelos robustos e validados, enquanto aplicações como as descritas por Adapa *et al.* (2022) e Wang *et al.* (2024) evidenciam o potencial de integração dessas ferramentas aos processos decisórios e à prática clínica. Esse movimento aponta para o potencial de transformação dos sistemas de vigilância em saúde do trabalhador, com incorporação progressiva de recursos analíticos capazes de antecipar riscos e subsidiar intervenções organizacionais.

Contudo, a análise dos estudos incluídos evidencia lacunas metodológicas e operacionais que limitam a consolidação da evidência empírica no campo. Muitos trabalhos ainda apresentam validações restritas a amostras únicas ou ambientes controlados, como observado em estudos com pequeno número de participantes (Conforti *et al.*, 2020; Donisi *et al.*, 2021), o que limita a generalização dos resultados. Observa-se também heterogeneidade nas métricas de desempenho e avaliação preditiva, além da escassez de indicadores organizacionais que relacionem os modelos analíticos à performance institucional.

Essas fragilidades são ilustradas em estudos primários como o de Bozorgmehr; Thielmann; Weltermann (2021) que ao comparar diferentes algoritmos de ML para prever estresse crônico em assistentes de consultório, demonstrou ganhos de acurácia mas com limitações de generalização por se tratar de uma população específica. Esses achados reforçam a necessidade de maior padronização metodológica, validação multicêntrica e ampliação das amostras, a fim de fortalecer a reprodutibilidade e a aplicabilidade prática dos modelos.

4 CONCLUSÃO

Esta revisão sistemática evidenciou o avanço das abordagens analíticas aplicadas à saúde ocupacional, com destaque para o uso de algoritmos de inteligência artificial, aprendizado de máquina e técnicas estatísticas na identificação de padrões de risco, monitoramento de trabalhadores e apoio à tomada de decisão. Os estudos analisados demonstram sofisticação metodológica crescente, com aplicação prática especialmente em setores de alta complexidade, como saúde, indústria e construção civil, confirmando a tendência de consolidação de uma saúde ocupacional orientada por dados.

Apesar dos progressos, persistem desafios metodológicos e operacionais, entre eles a falta de padronização dos modelos, a limitação das validações multicêntricas e a dificuldade de integração dos dados aos sistemas organizacionais. Superar essas barreiras requer o desenvolvimento de soluções interoperáveis, a qualificação técnica de profissionais de diferentes áreas e o fortalecimento da governança e da ética em dados, e a modernização dos sistemas de vigilância em saúde do trabalhador, elementos essenciais para garantir transparência, confiabilidade e aplicabilidade dos resultados.

Em perspectiva, a consolidação de uma saúde ocupacional baseada em dados e inteligência artificial representa uma mudança de paradigma na gestão de pessoas, ao permitir decisões mais assertivas, ambientes de trabalho mais seguros, sustentáveis e preventivos, e promover uma cultura organizacional centrada na saúde, no desempenho humano e na sustentabilidade.

5 REFERÊNCIAS

ACHOURI, N. *et al.* Adaptive hybrid ANFIS-PSO and ANFIS-GA approach for occupational risk prediction. **International journal of occupational safety and ergonomics: JOSE**, v. 31, n. 2, p. 1–16, jan. 2025. Disponível em: <https://www.tandfonline.com/doi/full/10.1080/10803548.2024.2444807> . Acesso em 21 set 2025.

ADAPA, K. *et al.* Using Explainable Supervised Machine Learning to Predict Burnout in Healthcare Professionals. **Studies in health technology and informatics**, Amsterdam, v. 294, p. 58–62, 25 maio 2022. Disponível em: [IOS Press Ebooks - Using Explainable Supervised Machine Learning to Predict Burnout in Healthcare Professionals](https://iospress.com/using-explainable-supervised-machine-learning-to-predict-burnout-in-healthcare-professionals). Acesso em 21 set 2025.

ADELEKE, O. *et al.* Machine learning evaluation of a hypertension screening program in a university workforce over five years. **Sci Rep**, v. 14, n. 1, p. 30255–30255, dez. 2024. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/39632838/> . Acesso em 18 ago 2025.

AHMAD, S.; EDARIS, Z. L.; JAMALUDIN, N. I. S. Artificial Intelligence and Machine Learning in Occupational Safety and Health: A Review of Present Status, Opportunities and Challenges. **Borneo Engineering & Advanced Multidisciplinary International Journal**, v. 2, n. Special Issue (TECHON 2023), p. 17–22, 29 set. 2023. Disponível em: <https://beam.pmu.edu.my/index.php/beam/article/view/81> Acesso em 12 jul 2025.

BOZORGMEHR, A.; THIELMANN, A.; WELTERMANN, B. Chronic stress in practice assistants: An analytic approach comparing four machine learning classifiers with a standard logistic regression model. **PloS One**, v. 16, n. 5, p. e0250842–e0250842, maio 2021. Disponível em: <https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0250842>. Acesso em 21 set 2025.

BRASIL. **Prevenção é essencial para um ambiente de trabalho seguro, destaca Luiz Marinho na Canpat 2025**. Ministério do Trabalho e Emprego. Brasília, 2025. Disponível em: <https://www.gov.br/trabalho-e-emprego/pt-br/noticias-e-conteudo/2025/abril/prevencao-e-essencial-para-um-ambiente-de-trabalho-seguro-destaca-ministro-luiz-marinho-na-canpat-2025> . Acesso em: 12 set 2025.

CONFORTI, I. *et al.* Measuring Biomechanical Risk in Lifting Load Tasks Through Wearable System and Machine-Learning Approach. **Sensors (Basel)**, v. 20, n. 6, mar.



2020. Disponível em: <https://www.mdpi.com/1424-8220/20/6/1557> Acesso em: 18 set 2025.

DONISI, L. *et al.* A deep learning approach for ergonomic risk assessment in manual lifting operations using a single wearable device. *Sensors*, v. 21, n. 10, p. 3415, maio 2021. Disponível em: <https://pmc.ncbi.nlm.nih.gov/articles/PMC8068056/> Acesso em: 18 ago 2025.

DZENG, R-J *et al.* A GRU-Based Model for Detecting Common Accidents of Construction Workers. *Sensors (Basel, Switzerland)*, v. 24, n. 2, 21 jan. 2024. Disponível em: <https://www.mdpi.com/1424-8220/24/2/672> acesso em 21 set 2025.

EFFATI, S. *et al.* Web application using machine learning to predict cardiovascular disease and hypertension in mine workers. *Sci Rep*, v. 14, n. 1, p. 31662–31662, dez. 2024. Disponível em: <https://pmc.ncbi.nlm.nih.gov/articles/PMC11686148/> . Acesso em 18 ago 2025.

FERNANDES, B. S. A. *et al.* Doenças crônicas não transmissíveis e absenteísmo no trabalho: Pesquisa Nacional de Saúde 2019. *Revista Brasileira de Epidemiologia*, v. 27, p. e240061, 16 dez. 2024. Disponível em: https://www.scielosp.org/article/rbepid/2024.v27/e240061/pt/?utm_source=chatgpt.com . Acesso em 12 jul 2025.

FERRARI, G. N. *et al.* Investigation of the usage of machine learning to explore the impacts of climate change on occupational health: a systematic review and research agenda. *Front Public Health*, v. 13, p. 1578558–1578558, jul. 2025. Disponível em: <https://pmc.ncbi.nlm.nih.gov/articles/PMC12206760/> . Acesso em: 21 set 2025.

FIEGLER-RUDOL, J. *et al.* Exploring Human-AI Dynamics in Enhancing Workplace Health and Safety: A Narrative Review. *International Journal of Environmental Research and Public Health*, v. 22, n. 2, p. 199, 30 jan. 2025. Disponível em: <https://www.mdpi.com/1660-4601/22/2/199>. Acesso em 12 jul 2025.

JETHA, A. *et al.* Do Occupational Health and Safety Tools that Utilize Artificial Intelligence Have a Measurable Impact on Worker Injury or Illness? Findings from a Systematic Review. Rochester, *NYSocial Science Research Network*, Jul. 2025. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/40646643/> . Acesso em: 18 ago 2025.

JOANNA BRIGGS INSTITUTE. **Critical appraisal tools for use in JBI systematic reviews.** Adelaide: Joanna Briggs Institute, 2020. Disponível em: <https://jbi.global/critical-appraisal-tools> . Acesso em 05 dez 2025.

LUO, N. *et al.* Explainable machine learning framework to predict the risk of work-related neck and shoulder musculoskeletal disorders among healthcare professionals. *Front Public Health*, v. 12, p. 1414209–1414209, set. 2024. Disponível em: <https://www.frontiersin.org/journals/public-health/articles/10.3389/fpubh.2024.1414209/full>. Acesso em: 21 set 2025.

MOLINA-CASTAÑO, C. F. *et al.* Aplicaciones de la Inteligencia Artificial en salud y seguridad en el trabajo: una revisión sistemática. **Revista de la Asociación Española de Especialistas en Medicina del Trabajo**, v. 33, n. 4, p. 485–502, 2024. Disponível em: https://scielo.isciii.es/scielo.php?script=sci_arttext&pid=S3020-11602024000400010 . Acesso em 12 jul 2025.

NAGARAJAN, R. *et al.* Global estimate of burnout among the public health workforce: a systematic review and meta-analysis. **Human Resources for Health**, v. 22, n. 1, p. 30, 21 maio 2024. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/38773482/> . Acesso em: 12 jul 2025.

PAGE, M. J. *et al.* The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. **BMJ**, v. 372, n. 71, 2021. Disponível em: <https://www.prisma-statement.org> . Acesso em: 6 jul. 2025.

SÁNCHEZ-GUILLÉN, L. *et al.* A calculator for musculoskeletal injuries prediction in surgeons: a machine learning approach. **Surg Endosc**, v. 38, n. 11, p. 6577–6585, set. 2024. Disponível em <https://pubmed.ncbi.nlm.nih.gov/39285040/> . Acesso em: 18 ago 2025.

SIX DIJKSTRA, M. W. M. C. *et al.* Ethical Considerations of Using Machine Learning for Decision Support in Occupational Health: An Example Involving Periodic Workers' Health Assessments. **J Occup Rehabil**, v. 30, n. 3, p. 343–353, jun. 2020. Disponível em: https://www.researchgate.net/publication/341919573_Ethical_Considerations_of_Using_Machine_Learning_for_Decision_Support_in_Occupational_Health_An_Example_Involving_Periodic_Workers'_Health_Assessments Acesso em: 18 ago 2025.

SUN, G.-K. *et al.* Development of a multi-laboratory integrated predictive model for silicosis utilizing machine learning: a retrospective case-control study. **Frontiers in public health**, v. 12, p. 1450439, 2025. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/39882130/> . Acesso em: 21 set 2025.

WANG, Y. *et al.* Deep Learning Models of Multi-Scale Lesion Perception Attention Networks for Diagnosis and Staging of Pneumoconiosis: A Comparative Study with Radiologists. **Journal of imaging informatics in medicine**, v. 37, n. 6, p. 3025–3033, dez. 2024. Disponível em: <https://pmc.ncbi.nlm.nih.gov/articles/PMC11612096/> Acesso em: 21 set 2025.

YEŞİLGÖZ, P.; ARGAN, K. Y. A health-sector-specific occupational health and safety management system model. **Healthcare**, Basel, v. 13, n. 3, p. 271, 2025. DOI: 10.3390/healthcare13030271. Disponível em: <https://www.mdpi.com/2227-9032/13/3/271> . Acesso em 22 jan 2026.