

Revisão Sistemática

Machine Learning na Gestão de Recursos Humanos em Saúde: Uma Revisão Sistemática

Machine Learning in Healthcare Human Resources Management: A Systematic Review

Vilas Boas A¹, Alves C³, Sendim F², Costa F¹, Rocha V¹

¹ Serviço de Urgência, ULS Barcelos Esposende, Barcelos, Portugal

² Serviço de Medicina Intensiva, ULS Braga, Braga, Portugal

³ ISAVE - Instituto Superior de Saúde, Amares, Portugal

Autor correspondente: António Carlos Sousa Vilas Boas, vilasboas16@mail.com, ULS Barcelos/Esposende, Barcelos, Portugal.

ORCID dos autores

António Carlos Vilas Boas: <https://orcid.org/0000-0002-0779-8807>

Filipa Sendim: <https://orcid.org/0009-0000-5710-1396>

Francisco Costa: <https://orcid.org/0000-0002-7724-6434>

Vítor Rocha: <https://orcid.org/0009-0002-1502-3988>

Catarina Alves: <https://orcid.org/0000-0002-6306-6889>

Resumo

Introdução: A gestão de recursos humanos em saúde enfrenta desafios crescentes associados à escassez de profissionais, elevada rotatividade e complexidade organizacional.

Objetivos: Analisar criticamente a evidência científica disponível sobre a aplicação de técnicas de *machine learning* na gestão de recursos humanos em saúde, com foco na previsão de necessidades de pessoal e de turnover.

Material e Métodos: Realizou-se uma revisão sistemática da literatura com síntese narrativa, reportada segundo as diretrizes PRISMA. A pesquisa, orientada pelo

modelo PECO, incluiu estudos publicados entre 2019 e 2025 nas bases de dados PubMed e Scopus.

Resultados: Foram incluídos quatro estudos primários que recorreram a algoritmos como Random Forest, LASSO, Support Vector Machines e Boosted Trees, aplicados ao planeamento preditivo de pessoal, adequação de modelos de cuidados e previsão da intenção de saída. Os modelos de machine learning apresentaram, de forma geral, desempenho preditivo superior aos métodos estatísticos tradicionais.

Conclusões: O *machine learning* apresenta potencial para apoiar a tomada de decisão na gestão de recursos humanos em saúde, embora a evidência disponível seja limitada e marcada por desafios metodológicos e éticos, exigindo investigação futura mais robusta.

Palavras-chave: Inteligência Artificial, Aprendizagem Automática, Recursos Humanos no Setor da Saúde, Pessoal e Programação, Turnover.

Abstract

Introduction: Human resource management in healthcare faces increasing challenges related to workforce shortages, high turnover and organisational complexity.

Objectives: To critically analyse the available scientific evidence on the application of machine learning techniques in healthcare human resource management, with a focus on predicting staffing needs and turnover.

Material and Methods: A systematic literature review with narrative synthesis was conducted and reported according to PRISMA guidelines. The search was guided by the PECO framework and included studies published between 2019 and 2025 in the PubMed and Scopus databases.

Results: Four primary studies were included, using algorithms such as Random Forest, LASSO, Support Vector Machines and Boosted Trees, applied to predictive workforce planning, care model adequacy and turnover intention prediction. Overall, machine learning models showed better predictive performance than traditional statistical approaches.

Conclusions: Machine learning shows promise as a decision-support tool in healthcare human resource management; however, its application should be context-sensitive, ethically grounded and supported by more methodologically robust research.

Keywords: Artificial Intelligence, Machine Learning, Human Resources in the Health Sector, Staffing and Scheduling, Turnover.

Introdução

A gestão de recursos humanos em saúde constitui um determinante central da qualidade assistencial, segurança do doente e sustentabilidade das organizações de saúde. A escassez global de profissionais, o envelhecimento da força de trabalho, a intensificação da carga assistencial e a crescente complexidade clínica têm exposto limitações estruturais nos modelos tradicionais de planeamento e organização do trabalho, particularmente em contexto hospitalar (World Health Organization, 2020; Buchan et al., 2022). Estes desafios refletem-se em

fenômenos persistentes como elevado turnover, burnout, absentismo e dificuldades na adequação da dotação de pessoal às necessidades reais dos serviços, com impacto direto nos resultados clínicos e organizacionais (Yakusheva et al., 2021).

Historicamente, a gestão de recursos humanos em saúde tem assentado em abordagens predominantemente reativas, baseadas em indicadores retrospectivos, regras normativas e experiência empírica dos gestores. Embora estes modelos tenham desempenhado um papel relevante, revelam limitações significativas num contexto caracterizado por elevada variabilidade assistencial, imprevisibilidade da procura e necessidade de respostas rápidas e ajustadas (Biron et al., 2021). A incapacidade de antecipar flutuações na carga de trabalho, riscos de subdimensionamento ou intenção de saída dos profissionais contribui para decisões tardias, frequentemente associadas a custos elevados e impacto negativo no bem-estar das equipas (Suh & Lee, 2022).

Neste contexto, a inteligência artificial (IA), em particular o *machine learning* (ML), tem emergido como uma tecnologia com potencial transformador no setor da saúde. O ML, enquanto subcampo da IA, baseia-se no desenvolvimento de algoritmos capazes de aprender a partir de grandes volumes de dados, identificar padrões complexos e realizar previsões com base em relações não lineares entre múltiplas variáveis (Rajkomar et al., 2019; Topol, 2019). Estas características tornam o ML particularmente atrativo para lidar com sistemas complexos e dinâmicos, como os que caracterizam a gestão de recursos humanos em ambientes hospitalares.

A aplicação do ML tem sido amplamente explorada em domínios clínicos, incluindo diagnóstico, prognóstico, imagiologia e apoio à decisão terapêutica, com resultados consistentes e promissores (Rajkomar et al., 2019; Esteva et al., 2021). Mais recentemente, estas técnicas começaram a ser transpostas para o domínio da gestão em saúde, incluindo áreas como planeamento de pessoal, análise da carga de trabalho, previsão de absentismo, adequação dos modelos de cuidados e antecipação do risco de turnover (Denecke et al., 2021; Chen et al., 2022).

Ao contrário dos métodos estatísticos tradicionais, os algoritmos de ML permitem captar interações complexas entre variáveis organizacionais, clínicas e psicossociais, oferecendo novas possibilidades para uma gestão mais preditiva e baseada em dados. Estudos recentes sugerem que modelos como Random Forest, regressões penalizadas e algoritmos de *boosting* apresentam desempenho superior na previsão de necessidades de pessoal e comportamentos organizacionais, quando comparados com abordagens lineares convencionais (Tawfik et al., 2019; Yakusheva et al., 2021; Park & Kim, 2025).

Apesar do interesse crescente, a evidência científica sobre a aplicação do ML na gestão de recursos humanos em saúde permanece dispersa, heterogénea e limitada em número. Os estudos existentes variam amplamente quanto aos contextos institucionais, tipos de dados utilizados, algoritmos aplicados e objetivos analíticos, dificultando a sistematização do conhecimento e a extrapolação dos resultados para a prática organizacional (Denecke et al., 2021; Li et al., 2023). Adicionalmente, a utilização de algoritmos preditivos em contextos de gestão de pessoas levanta questões éticas relevantes, relacionadas com a transparência algorítmica, proteção de dados, risco de enviesamentos e necessidade de supervisão humana (Obermeyer et al., 2019; Choudhury et al., 2023).

Face a este enquadramento, torna-se pertinente realizar uma síntese crítica da evidência disponível, clarificando de que forma as técnicas de ML têm sido aplicadas na gestão de recursos humanos em saúde, quais os seus potenciais contributos e quais as principais limitações e desafios associados à sua implementação.

Assim, a presente revisão sistemática tem como objetivo analisar a evidência científica disponível sobre a utilização de técnicas de ML na gestão de recursos humanos em saúde, com foco na previsão de necessidades de pessoal, organização do trabalho e antecipação do risco de turnover em contexto hospitalar.

Materiais e métodos

Foi realizada uma revisão sistemática da literatura com síntese narrativa, conduzida e reportada de acordo com as diretrizes *Preferred Reporting Items for Systematic Reviews and Meta-Analyses* (PRISMA), com o objetivo de garantir transparência, reprodutibilidade e rigor metodológico (Page et al., 2021). A opção por uma síntese narrativa deveu-se à heterogeneidade esperada entre os estudos, nomeadamente ao nível dos contextos institucionais, populações, variáveis preditoras, algoritmos utilizados e *outcomes* analisados, inviabilizando a realização de meta-análise.

A pergunta de investigação foi estruturada segundo o modelo PECO, adequado à análise de intervenções organizacionais e de gestão. A população incluiu profissionais de saúde, com particular enfoque em equipas de enfermagem, em contexto hospitalar. A exposição correspondeu à aplicação de técnicas de ML na gestão de recursos humanos. O contexto abrangeu organizações de saúde, nomeadamente hospitais, unidades de internamento e serviços especializados. Os resultados considerados incluíram a previsão de necessidades de pessoal, análise da carga de trabalho, adequação dos modelos de cuidados e previsão do risco ou intenção de turnover.

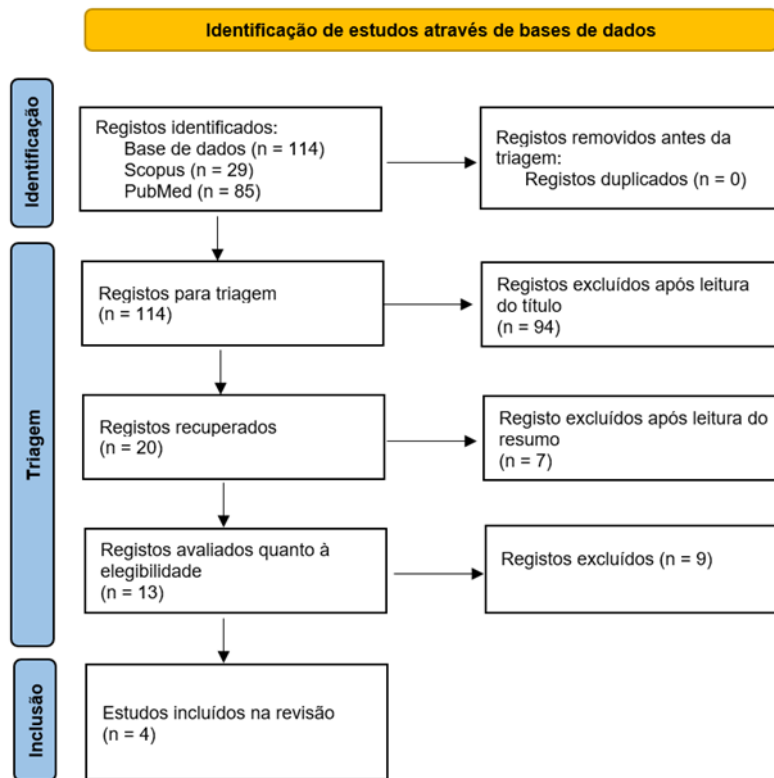
A pesquisa bibliográfica foi realizada nas bases de dados PubMed e Scopus, por integrarem literatura relevante nas áreas da saúde, gestão e aplicações práticas de ML (Denecke et al., 2021). Foram incluídos estudos publicados entre janeiro de 2019 e maio de 2025, nos idiomas português, inglês e espanhol, com acesso ao texto completo. A limitação ao acesso gratuito foi imposta por constrangimentos institucionais, reconhecendo-se o potencial viés de seleção associado a este critério.

A estratégia de pesquisa combinou termos MeSH e palavras-chave livres, utilizando operadores booleanos, de modo a maximizar a sensibilidade da pesquisa. A expressão de pesquisa incluiu combinações dos termos “machine learning”, “artificial intelligence”, “human resources”, “workforce planning”, “staffing”, “turnover”, “healthcare” e “hospital”.

Foram incluídos estudos primários que aplicassem técnicas de *machine learning* à gestão de recursos humanos em saúde, com aplicação prática no planeamento de pessoal, alocação de equipas, organização do trabalho ou previsão de turnover. Foram excluídos estudos focados exclusivamente em aplicações clínicas, revisões da literatura, editoriais, artigos de opinião e estudos teóricos sem aplicação empírica. Foram igualmente excluídos estudos que recorressem apenas a métodos estatísticos tradicionais, sem utilização de algoritmos de ML.

A seleção dos estudos foi realizada por quatro revisores independentes, com recurso ao software *Rayyan*, permitindo a triagem cega de títulos e resumos (Ouzzani et al., 2016). As divergências foram resolvidas por consenso após leitura integral dos textos. O processo de identificação, triagem, elegibilidade e inclusão dos estudos seguiu as etapas recomendadas pelo PRISMA e encontra-se representado no fluxograma apresentado na FIGURA 1.

FIGURA 1 - Fluxograma PRISMA do processo de identificação, triagem, elegibilidade e inclusão dos estudos incluídos na revisão sistemática



A extração de dados foi realizada com base numa matriz estruturada, previamente definida, incluindo informações relativas aos autores, ano e país de publicação, objetivo do estudo, delineamento metodológico, tipo de algoritmo de ML utilizado, área de aplicação na gestão de recursos humanos, principais resultados, limitações reportadas e implicações organizacionais.

A avaliação da qualidade metodológica dos estudos incluídos foi realizada através das ferramentas do *Joanna Briggs Institute* (JBI) e do *Mixed Methods Appraisal Tool* (MMAT), de acordo com o delineamento de cada estudo, permitindo contextualizar criticamente os resultados e identificar limitações metodológicas relevantes (Hong et al., 2018).

Resultados e discussão

A aplicação da estratégia de pesquisa resultou na identificação inicial de 114 artigos potencialmente relevantes. Após a remoção de duplicados e aplicação dos critérios de inclusão e exclusão definidos, foram incluídos quatro estudos primários na síntese final. As principais características metodológicas, contextuais e analíticas dos estudos incluídos encontram-se sintetizadas na Tabela 1.

TABELA 1 – Avaliação da qualidade metodológica dos estudos incluídos

Estudo	Desenho	Instrumento	Principais critérios avaliados	Qualidade global
Tawfik et al., 2019	Observacional longitudinal	JBI	Amostra adequada; controlo de confundidores; análise estatística apropriada	Alta
Yakusheva et al., 2021	Observacional transversal	JBI	Medição válida de exposição e <i>outcomes</i> ; análise multivariada	Alta
Park & Kim, 2025	Observacional transversal	JBI	Instrumentos validados; limitações de amostra	Moderada–Alta
Aslan & Toros, 2025	Estudo preditivo aplicado	MMAT	Clareza do objetivo; adequação do modelo; integração dos dados	Moderada–Alta

Abreviaturas: JBI – Joanna Briggs Institute; MMAT – Mixed Methods Appraisal Tool

Embora o número de estudos seja reduzido, estes apresentam diversidade quanto aos contextos institucionais, objetivos analíticos, tipos de dados utilizados e algoritmos de ML aplicados, permitindo uma análise exploratória e crítica do potencial destas técnicas na gestão de recursos humanos em saúde.

Os estudos incluídos recorreram a diferentes algoritmos de ML, nomeadamente Random Forest, regressão LASSO, Support Vector Machines (SVM), *boosted trees* e *k*-Nearest Neighbors, aplicados sobretudo ao planeamento preditivo de pessoal, análise da carga de trabalho de enfermagem, previsão da intenção de turnover e adequação dos modelos de cuidados. De forma consistente, os estudos demonstraram que os modelos baseados em ML apresentaram desempenho preditivo superior aos métodos estatísticos tradicionais, particularmente na identificação de relações não lineares entre variáveis organizacionais, clínicas e psicossociais (Tawfik et al., 2019; Yakusheva et al., 2021; Park & Kim, 2025; Aslan & Toros, 2025).

Planeamento preditivo de pessoal e carga de trabalho de enfermagem

No domínio do planeamento de pessoal, os estudos analisados evidenciam que os modelos de ML permitem estimar de forma mais precisa as necessidades de enfermagem, ajustando a dotação de profissionais às características clínicas e organizacionais dos serviços. O estudo de Tawfik et al. (2019), conduzido em unidades de cuidados intensivos neonatais, demonstrou que a utilização de regressão LASSO permitiu explicar uma proporção significativa da variação na dotação de pessoal, associando desvios positivos face ao número estimado de enfermeiros a uma redução substancial das taxas de infeção hospitalar. Este resultado sugere que a utilização

de modelos preditivos pode contribuir para decisões de alocação de recursos mais alinhadas com a segurança do doente e a qualidade dos cuidados.

De forma complementar, Yakusheva et al. (2021) analisaram a relação entre horas de enfermagem por doente/dia e taxas de readmissão hospitalar, utilizando algoritmos Random Forest. Os autores identificaram uma relação não linear em forma de U, demonstrando que tanto a escassez como o excesso de pessoal estavam associados a piores resultados clínicos. A identificação de um ponto ótimo de dotação reforça a ideia de que decisões baseadas em regras fixas ou médias globais podem ser inadequadas em contextos assistenciais complexos. Este tipo de análise, difícil de alcançar com modelos estatísticos lineares, ilustra uma das principais vantagens do ML na gestão de recursos humanos: a capacidade de captar padrões complexos e contextuais (Denecke et al., 2021; Chen et al., 2022).

Os resultados destes estudos convergem com a literatura mais ampla sobre gestão de enfermagem, que tem vindo a demonstrar que o subdimensionamento está associado a aumento do risco clínico, burnout e insatisfação profissional, enquanto o sobredimensionamento representa ineficiência e desperdício de recursos (Buchan et al., 2022; Li et al., 2023). Assim, o ML surge como uma ferramenta com potencial para apoiar decisões mais equilibradas e sustentáveis no planeamento da força de trabalho.

Previsão da intenção de turnover

A previsão do *turnover* constitui outra área de aplicação relevante do ML identificada nesta revisão. O estudo de Park e Kim (2025) analisou a intenção de saída de enfermeiros hospitalares, comparando modelos lineares tradicionais com algoritmos de ML, nomeadamente *bootstrap forest* e *boosted trees*. Os resultados demonstraram que os modelos de ML explicaram mais de 50% da variância na intenção de *turnover*, um desempenho substancialmente superior ao observado nos modelos lineares. As variáveis mais preditivas incluíram *burnout*, satisfação profissional e equilíbrio trabalho-vida pessoal.

Estes achados corroboram estudos prévios que apontam o *burnout* e a insatisfação profissional como determinantes centrais do turnover na enfermagem, mas acrescentam valor ao demonstrar que os algoritmos de ML são particularmente eficazes na modelação de fenómenos organizacionais complexos e multifatoriais (Suh & Lee, 2022; Hasson et al., 2023). A capacidade de antecipar o risco de saída dos profissionais pode permitir aos gestores implementar estratégias preventivas mais direcionadas, reduzindo custos associados à rotatividade e mitigando impactos negativos na continuidade e qualidade dos cuidados.

No entanto, importa salientar que os estudos focados na previsão do *turnover* recorrem predominantemente a dados psicossociais autorreportados, o que pode introduzir viés de resposta e limitar a estabilidade dos modelos quando aplicados a outros contextos institucionais (Nguyen et al., 2022; van de Wiel et al., 2021). Esta limitação reforça a necessidade de validação externa e de integração de múltiplas fontes de dados, incluindo indicadores administrativos e organizacionais.

Adequação dos modelos de cuidados e organização do trabalho

O estudo de Aslan e Toros (2025) alarga o campo de aplicação do ML ao explorar a sua utilização na avaliação da adequação dos modelos de cuidados de enfermagem face à gravidade clínica e dependência dos doentes. Utilizando algoritmos como *Random Forest* e SVM, os autores demonstraram que apenas uma proporção reduzida dos modelos de cuidados em uso estava alinhada com as necessidades reais dos doentes. O desempenho superior do *Random Forest*

na previsão da adequação das equipas de enfermagem sugere que o ML pode apoiar decisões mais informadas sobre a organização do trabalho e a escolha de modelos assistenciais.

Este resultado é particularmente relevante num contexto em que a inadequação dos modelos de cuidados pode contribuir para sobrecarga das equipas, ineficiência organizacional e riscos para a segurança do doente. A utilização de modelos preditivos pode, assim, apoiar uma gestão mais adaptativa e centrada nas necessidades reais dos serviços, reforçando o papel do ML como ferramenta estratégica na gestão hospitalar (Li et al., 2023).

Síntese crítica e implicações organizacionais

Considerados de forma integrada, os estudos incluídos nesta revisão sugerem que o ML apresenta potencial consistente para apoiar a gestão de recursos humanos em saúde, sobretudo em domínios caracterizados por elevada complexidade e variabilidade. De forma transversal, os algoritmos de ML demonstraram maior capacidade para captar relações não lineares e interações complexas entre variáveis, quando comparados com modelos estatísticos tradicionais (Tawfik et al., 2019; Yakusheva et al., 2021; Park & Kim, 2025).

No entanto, persistem limitações relevantes na evidência disponível. A maioria dos estudos apresenta desenho observacional, amostras limitadas e contextos institucionais específicos, o que compromete a generalização dos resultados. A ausência de validação externa sistemática e de avaliação do impacto organizacional da implementação real dos modelos constitui uma lacuna importante na literatura (Denecke et al., 2021; Nguyen et al., 2022).

Para além das limitações metodológicas, emergem desafios éticos e operacionais associados à utilização do ML na gestão de pessoas. A opacidade algorítmica, o risco de enviesamentos associados a dados históricos e a utilização de informação sensível dos profissionais exigem mecanismos robustos de governação, transparência e supervisão humana (Obermeyer et al., 2019; Choudhury et al., 2023). A aceitação organizacional destas ferramentas depende, em grande medida, da literacia digital dos gestores e da confiança dos profissionais nos sistemas utilizados.

Importa ainda sublinhar que os modelos de *machine learning* devem ser encarados como instrumentos de apoio à decisão e não como substitutos do julgamento humano. A sua integração eficaz requer articulação com o conhecimento contextual dos gestores, consideração dos valores organizacionais e respeito pelos princípios éticos fundamentais, evitando decisões automatizadas descontextualizadas ou potencialmente injustas (Topaz & Pruinelli, 2021).

Conclusão

Os resultados desta revisão sistemática indicam que a aplicação de técnicas de ML na gestão de recursos humanos em saúde constitui uma área emergente, ainda pouco explorada, mas com potencial relevante para apoiar a resposta aos desafios organizacionais atuais. A evidência analisada sugere que os modelos preditivos baseados em ML podem contribuir para decisões mais informadas e ajustadas no planeamento de pessoal, na organização do trabalho de enfermagem e na antecipação do risco de turnover, superando, em vários contextos, o desempenho dos métodos estatísticos tradicionais (Tawfik et al., 2019; Yakusheva et al., 2021; Park & Kim, 2025).

Os estudos incluídos demonstram que algoritmos como *Random Forest*, *LASSO*, *boosted trees* e *SVM* apresentam capacidade para identificar padrões complexos e relações não lineares entre

variáveis organizacionais, clínicas e psicossociais, oferecendo suporte a uma gestão mais preditiva e baseada em dados. Em particular, a utilização de ML revelou-se promissora na identificação de dotações ótimas de pessoal, na análise da carga de trabalho de enfermagem e na previsão da intenção de saída dos profissionais, áreas críticas para a sustentabilidade das organizações de saúde (Buchan et al., 2022; Li et al., 2023).

Contudo, a evidência disponível apresenta limitações significativas que devem ser consideradas na interpretação dos resultados. O número reduzido de estudos incluídos, a predominância de desenhos observacionais, a heterogeneidade metodológica e a ausência de validação externa consistente limitam a generalização dos achados e impedem o estabelecimento de relações causais robustas (Denecke et al., 2021; Nguyen et al., 2022). Adicionalmente, a dependência de dados autorreportados em alguns estudos aumenta o risco de viés e compromete a estabilidade dos modelos quando aplicados a diferentes contextos institucionais.

Para além das limitações metodológicas, a integração de modelos de ML na gestão de recursos humanos em saúde levanta desafios éticos e organizacionais relevantes. Questões relacionadas com a transparência algorítmica, proteção de dados, risco de enviesamentos e necessidade de supervisão humana contínua devem ser cuidadosamente consideradas, de modo a garantir que a adoção destas tecnologias não compromete princípios fundamentais de equidade, justiça e confiança organizacional (Obermeyer et al., 2019; Choudhury et al., 2023).

Em síntese, o ML deve ser encarado como uma ferramenta de apoio à decisão, complementando — e não substituindo — o julgamento humano e o conhecimento contextual dos gestores. A sua implementação eficaz exige enquadramento ético rigoroso, literacia digital adequada e integração com as práticas organizacionais existentes (Topaz & Pruinelli, 2021).

Futuras investigações deverão privilegiar estudos longitudinais e multicêntricos, com validação externa dos modelos e avaliação do impacto organizacional e psicossocial da implementação real de sistemas baseados em ML. Apenas com uma base empírica mais robusta será possível sustentar a integração responsável, eficaz e eticamente fundamentada destas tecnologias na gestão de recursos humanos em saúde.

Conflito de Interesses

Os autores declaram que não há conflito de interesses.

Financiamento

O presente estudo não recebeu qualquer financiamento de entidades públicas, privadas ou do setor empresarial.

Contribuições autorais

Conceptualização, A.C.V.B., F.S., F.C., V.R. e C.A.; metodologia, A.C.V.B., F.S., F.C., V.R. e C.A.; investigação, A.C.V.B., F.S., F.C., V.R. e C.A.; análise formal, A.C.V.B., F.S., F.C., V.R. e C.A.; curadoria de dados, A.C.V.B., F.S., F.C., V.R. e C.A.; redação – preparação do *draft* original, A.C.V.B., F.S., F.C., V.R. e C.A.; redação – revisão e edição, A.C.V.B., F.S., F.C., V.R. e C.A.; visualização, A.C.V.B., F.S., F.C., V.R. e C.A.; supervisão, A.C.V.B., F.S., F.C., V.R. e C.A.; coordenação do projeto, A.C.V.B., F.S., F.C., V.R. e C.A. Todos os autores contribuíram de forma igual para o presente trabalho e leram e concordaram com a versão publicada do manuscrito.

Responsabilidades éticas

Os autores declaram que este estudo respeitou os princípios éticos definidos na Declaração de Helsínquia e as recomendações do Comité Internacional dos Editores das Revistas Médicas (ICMJE). Por se tratar de uma revisão sistemática da literatura, não envolveu a recolha de dados primários, nem a participação direta de seres humanos ou animais, não sendo, por isso, necessária aprovação por comissão de ética.

Referências bibliográficas

Aslan, M., & Toros, E. (2025). Machine learning in optimising nursing care delivery models: An empirical analysis of hospital wards. *Journal of Evaluation in Clinical Practice*, 31(1), e70001. <https://doi.org/10.1111/jep.70001>

Biron, A., Loisel, C. G., & Lavoie-Tremblay, M. (2021). Artificial intelligence in nursing: Priorities, risks, and responsibilities. *Nursing Outlook*, 69(5), 742–750. <https://doi.org/10.1016/j.outlook.2021.04.005>

Buchan, J., Dhillon, I., & Campbell, J. (2022). Health workforce in the COVID-19 context: Strategies to improve resilience and sustainability. *Human Resources for Health*, 20(1), 12. <https://doi.org/10.1186/s12960-021-00651-3>

Chen, C., Lin, Z., & Ma, J. (2022). Predictive analytics in human resource management: Applications and challenges. *Journal of Organizational Computing and Electronic Commerce*, 32(1), 1–19. <https://doi.org/10.1080/10919392.2021.2009745>

Choudhury, M. D., De, S., & Eisenstein, J. (2023). Ethics in AI for human resources: Emerging risks and governance gaps. *AI & Society*, 38, 1105–1120. <https://doi.org/10.1007/s00146-022-01385-9>

Conselho Nacional de Saúde. (2022). *Relatório sobre sustentabilidade e saúde no contexto português*. <https://www.cns.pt/sustentabilidade-saude-relatorio>

Denecke, K., Gabarron, E., Grainger, R., Konstantinidis, S. T., & Hansen, M. (2021). Artificial intelligence for human resources in healthcare: A scoping review. *Journal of Medical Internet Research*, 23(3), e24283. <https://doi.org/10.2196/24283>

Esteva, A., Chou, K., Yeung, S., Naik, N., Madani, A., Mottaghi, A., ... Dean, J. (2021). Deep learning-enabled healthcare: A review of the challenges and opportunities. *Nature Biomedical Engineering*, 5(6), 498–510. <https://doi.org/10.1038/s41551-021-00707-9>

Hasson, H., Lindqvist, R., & Andersson, J. (2023). Algorithmic bias and fairness in predictive workforce analytics: Ethical implications for human resource management. *Journal of Business Ethics*, 184(2), 433–450. <https://doi.org/10.1007/s10551-022-05246-7>

Hong, Q. N., Pluye, P., Fàbregues, S., Bartlett, G., Boardman, F., Cargo, M., ... Vedel, I. (2018). Mixed Methods Appraisal Tool (MMAT), version 2018. *Education for Information*, 34(4), 285–291. <https://doi.org/10.3233/EFI-180221>

Li, Y., Shi, Z., Zhang, Q., & Huang, J. (2023). Machine learning in nurse staffing optimization: A systematic review. *Journal of Nursing Management*, 31(2), 225–234. <https://doi.org/10.1111/jonm.13795>

Nguyen, M., Ziebart, B., & Ghosh, A. (2022). Predicting healthcare worker burnout using machine learning: A multi-site study. *Journal of Medical Systems*, 46(2), 22. <https://doi.org/10.1007/s10916-021-01799-1>

Obermeyer, Z., Powers, B., Vogeli, C., & Mullainathan, S. (2019). Dissecting racial bias in an algorithm used to manage the health of populations. *Science*, 366(6464), 447–453. <https://doi.org/10.1126/science.aax2342>

Uzzani, M., Hammady, H., Fedorowicz, Z., & Elmagarmid, A. (2016). Rayyan—A web and mobile app for systematic reviews. *Systematic Reviews*, 5, 210. <https://doi.org/10.1186/s13643-016-0384-4>

Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., ... Moher, D. (2021). The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. *BMJ*, 372, n71. <https://doi.org/10.1136/bmj.n71>

Park, Y., & Kim, J. (2025). Impact of professional quality of life on turnover intention among general hospital nurses: A comparative study using linear and nonlinear analysis methods. *Journal of Korean Academy of Nursing Administration*, 31(1), 132–141. <https://doi.org/10.11111/jkana.2025.31.1.132>

Rajkumar, A., Dean, J., & Kohane, I. (2019). Machine learning in medicine. *New England Journal of Medicine*, 380(14), 1347–1359. <https://doi.org/10.1056/NEJMra1814259>

Suh, S. M., & Lee, H. S. (2022). Predicting nurse turnover intention using gradient boosting algorithms: A longitudinal approach. *International Journal of Medical Informatics*, 158, 104655. <https://doi.org/10.1016/j.ijmedinf.2021.104655>

Tawfik, D. S., Profit, J., Liu, V. X., Schoenherr, L. A., Tadlock, M. D., Fuller, T. E., ... Sharek, P. J. (2019). Using machine learning to develop a staffing metric predictive of neonatal ICU outcomes. *Health Services Research*, 54(6), 1314–1325. <https://doi.org/10.1111/1475-6773.13249>

Topaz, M., & Pruinelli, L. (2021). Big data and nursing: How artificial intelligence and data science are transforming the profession. *Nursing Outlook*, 69(3), 419–421. <https://doi.org/10.1016/j.outlook.2021.01.001>

Topol, E. (2019). *Deep medicine: How artificial intelligence can make healthcare human again*. Basic Books.

Van de Wiel, M. A., Ledderhof, T., & van der Putten, W. (2021). Generalizability of nurse absenteeism prediction models: A multi-hospital comparison. *International Journal of Medical Informatics*, 151, 104474. <https://doi.org/10.1016/j.ijmedinf.2021.104474>

World Health Organization. (2020). *State of the world's nursing 2020: Investing in education, jobs and leadership*. <https://www.who.int/publications/i/item/9789240003279>

Yakusheva, O., Costa, D. K., Weiss, M., & Poghosyan, L. (2021). Nonlinear association of nurse staffing and readmissions uncovered in machine learning analysis. *Health Services Research*, 56(1), 75–83. <https://doi.org/10.1111/1475-6773.13695>