

fluxos de trabalho desatualizados e lacunas de interoperabilidade.⁴ Acrescem preocupações quanto à substituição parcial de funções, erosão de competências clínicas e instabilidade das carreiras, reforçando a necessidade de planejar a força de trabalho e investir em programas consistentes de desenvolvimento profissional, de modo a assegurar que a IA complementa, e não compromete, a prática médica.⁴

Questões éticas e regulatórias são igualmente centrais. A transparência da decisão algorítmica, a segurança do doente, a proteção de dados e a mitigação do enviesamento constituem fatores determinantes para a aceitação por profissionais e utentes.^{5,6} No espaço europeu, o Regulamento (UE) 2024/1689 (*AI Act*) estabelece regras harmonizadas para sistemas de alto risco, exigindo documentação detalhada, gestão contínua do risco e supervisão humana obrigatória.⁷

Assim, o objetivo desta revisão narrativa é analisar de que forma a IA está a redefinir papéis e competências, identificar riscos emergentes para a organização do trabalho e propor princípios para uma integração sustentável e centrada no doente.

MÉTODOS

Foi realizada uma revisão da literatura, metodologia considerada adequada à análise de questões complexas de natureza sociotécnica, nas quais se pretendeu integrar múltiplas perspetivas e não apenas medir um efeito quantitativo. A pesquisa bibliográfica decorreu em agosto de 2025, sem restrição temporal, abrangendo as bases de dados PubMed, Scopus e Web of Science Core Collection. Utilizaram-se combinações de termos relativos a inteligência artificial, força de trabalho em saúde, sistemas de apoio à decisão clínica e governação.

Foram incluídos estudos originais e de revisão publicados em revistas com revisão por pares, bem como documentos normativos e institucionais relevantes. Foram consultadas bases de dados biomédicas e repositórios institucionais, combinando os termos “inteligência artificial”, “aprendizagem automática”, “modelos de linguagem”, “força de trabalho em saúde”, “papéis clínicos”, “organização do trabalho” e “educação médica”. Excluíram-se trabalhos técnicos ou algorítmicos sem aplicação clínica ou organizacional. A seleção e a síntese seguiram uma abordagem temática, com leitura integral dos textos, avaliação crítica da qualidade e ênfase nas implicações para a prática clínica, educação médica e organização do trabalho em saúde.

Por se tratar de uma revisão narrativa e não de uma revisão sistemática, o registo em PROSPERO não se aplica.

Evolução e conceitos fundamentais

A aplicação da IA em saúde evoluiu de sistemas basea-

dos em regras para modelos de aprendizagem profunda e, mais recentemente, para arquiteturas de transformadores capazes de integrar dados multimodais.^{8,9} Em tarefas específicas, como a deteção de retinopatia diabética, modelos validados demonstraram desempenho comparável ao de especialistas humanos.¹⁰ Apesar destes avanços, a confiança clínica permanece condicionada pela opacidade de muitos algoritmos. A IA explicável (XAI), através de técnicas como Grad-CAM, LIME ou SHAP, procura tornar inteligíveis as previsões; contudo, a utilidade clínica da explicabilidade deve ser avaliada em contexto e equilibrada com desempenho e usabilidade.¹¹

A adoção sustentável da IA depende da integração nos fluxos de trabalho, da interoperabilidade entre sistemas e da monitorização pós-implementação, necessária para detetar fenómenos como o desvio de dados (*data drift*), a degradação de desempenho, enviesamentos emergentes e problemas de robustez ou incerteza dos modelos.¹² A crescente pressão assistencial – associada ao envelhecimento populacional, multimorbilidade e exigências documentais – abre espaço para automatização de tarefas, sem que isso dispense o juízo clínico humano. Sem desenho organizacional adequado, a tecnologia pode, contudo, contribuir para sobrecarga cognitiva e novos riscos.^{13,14}

Aplicações clínicas

Em áreas como Imagiologia e Patologia Digital (leitura de lâminas digitalizadas com triagem/apoio por IA), redes neuronais profundas e modelos baseados em transformadores demonstraram desempenho semelhante ao de especialistas em tarefas de triagem e deteção de achados relevantes.¹³ Revisões recentes sublinham que, embora os algoritmos alcancem um desempenho comparável em tarefas de triagem, a integração clínica requer demonstração de impacto real em fluxos de trabalho e desfechos, com resultados ainda heterogéneos entre áreas como Radiologia, Gastrenterologia/Hepatologia ou Cuidados Intensivos.¹⁵⁻¹⁷

Na estratificação de risco, modelos preditivos têm sido utilizados para apoiar a priorização de cuidados e a vigilância clínica, com estudos multicêntricos a avaliar impacto em alertas, listas de trabalho e tempos de resposta.^{16,18,19} No contexto das unidades de Cuidados Intensivos (UCI), uma *scoping review* de modelos de predição de mortalidade evidenciou uma grande diversidade de abordagens, poucos estudos com validação externa robusta e limitada avaliação de impacto na segurança do doente.^{16,20,21}

O processamento de linguagem natural (NLP) tem sido aplicado à sumarização de notas clínicas, extração estruturada de informação em registos eletrónicos e codificação, com ganhos de consistência e eficiência.²² Em paralelo, as revisões centradas na interação entre clínicos e doentes, e em modelos de risco mostram que fatores, como a forma

de apresentação da informação, a explicabilidade percebida e a integração no fluxo de trabalho condicionam fortemente a utilização efetiva dos sistemas, mais do que as métricas algorítmicas isoladas.^{23,24} Estudos sobre apoio à decisão em serviços de urgência e contextos de cuidados de doença aguda mostram igualmente a importância de normas metodológicas consistentes para garantir segurança e reprodutibilidade.^{19,25}

Uma revisão sistemática sobre decisão clínica baseada em dados destaca que a maioria dos sistemas continua focada na predição de eventos, com menor evidência sobre o impacto em decisões partilhadas, a reorganização de processos assistenciais e os resultados centrados no doente, o que reforça a necessidade de avaliações prospetivas em cenários do mundo real.²⁶

Para que estes resultados se traduzam em valor assistencial, são determinantes a recalibração periódica, os níveis de explicabilidade proporcionais ao risco de uso, a presença de supervisão humana em decisões com implicação clínica, o desenho centrado no utilizador e a governação orientada, para evitar a fadiga de alarmes.^{13,23,24} No doente crítico, revisões recentes sobre modelos de predição de mortalidade e sobre a utilização de IA na decisão terapêutica em infeções graves sugerem a existência de potencial para melhorar a estratificação de risco e a personalização terapêutica, mas sublinham o risco de limitações de generalização, transparência e avaliação do seu impacto na segurança do doente.²⁷⁻²⁹

Aplicações administrativas e operacionais

Na esfera administrativa, a IA tem sido utilizada para prever procura assistencial, otimizar escalas de trabalho e apoiar a gestão de camas.³⁰ Em registos eletrónicos, contribui para a organização, recuperação de informação e auditorias.³¹ No ciclo de faturação e codificação, o NLP permite acelerar o mapeamento diagnóstico-procedimental, embora a validação humana permaneça necessária por razões do foro legal e financeiro.²²

Implementações que não considerem a usabilidade e o contexto organizacional podem, porém, agravar a fragmentação do trabalho ou a sobrecarga cognitiva. Abordagens centradas no utilizador, testadas em todo o percurso (*end-to-end*), demonstram maior adesão e segurança.^{14,23} Para além do desempenho algorítmico em validações retrospectivas, a evidência disponível descreve falhas e efeitos indesejados quando a implementação ignora o contexto sociotécnico.^{32,33}

Impacto em papéis e competências profissionais

A introdução da IA tem deslocado o foco da prática profissional para tarefas de maior complexidade, incluindo a supervisão crítica de sistemas, a integração de múltiplas

fontes de dados e a tomada de decisão em cenários de incerteza.²⁰ Torna-se necessária uma competência em literacia digital aplicada à prática clínica, com capacidade de leitura crítica de métricas de desempenho (discriminação, calibração, *drift*) e interpretação de explicações algorítmicas, sem perda de responsabilidade clínica.³⁴⁻³⁷ A substituição da prática ativa pela validação passiva poderá promover a erosão de competências (*deskilling*), sobretudo em áreas de grande volume de triagens automatizadas. Estratégias tais como a rotação de funções, a prática deliberada e a formação contínua são propostas como medidas mitigadoras.³⁸ Estudos recentes sobre o papel da IA nas áreas de enfermagem de cuidados intensivos, saúde mental e equipas que utilizam sistemas de apoio à decisão salientam que a confiança, a perceção de utilidade, a clarificação de responsabilidades e o redesenho dos processos de trabalho são determinantes para que estes novos sistemas redistribuam tarefas de forma equilibrada, em vez de apenas acrescentarem nova carga de monitorização.^{39,40} O perfil híbrido de profissionais capazes de interpretar e supervisionar estes sistemas ganha relevância, desde que detenham capacitação formal e possam dispor de tempo protegido para garantir a sua segurança, respeito pela deontologia e adequação individual.²⁰

Riscos de *deskilling*, substituição de funções e precarização

Na ausência de planeamento institucional, a adoção de IA pode induzir uma substituição parcial de funções, erosão de competências e formas de instabilidade laboral. Modelos de externalização de serviços ou automatização de tarefas têm sido associados a riscos de fragmentação e à perda de coesão das equipas.^{14,20} A evidência emergente sobre a aceitação profissional e os desafios institucionais reforça que estes riscos são amplificados quando a implementação de IA ocorre sem enquadramento estratégico da força de trabalho e sem mecanismos de participação dos profissionais na conceção e seleção dos novos sistemas.^{40,41} Medidas de antecipação, incluindo a reconversão profissional, a proteção laboral e a valorização da supervisão humana, são apontadas como necessárias para assegurar que a tecnologia complementa a prática clínica, em vez de a substituir.

Considerações éticas, regulatórias e de privacidade

A interpretabilidade e prestação de contas permanecem questões centrais para a conformidade regulatória, auditoria e a rastreabilidade de decisões. A opacidade algorítmica pode dificultar a confiança e a responsabilização clínica, mesmo quando o desempenho é elevado, colocando tensão entre modelos *black box* e exigências de transparência.^{5,42,43} Equidade e viés requerem dados representativos

e monitorização contínua, sob pena de perpetuar desigualdades, incluindo na estratificação de risco em áreas como a sépsis em cuidados intensivos.^{6,44}

O *AI Act* estabelece obrigações de documentação, gestão de risco e supervisão humana para sistemas de alto risco,⁷ articulando-se com o Regulamento Geral de Proteção de Dados (RGPD), que exige licitude, minimização e pseudonimização no tratamento de dados de saúde.²¹ Em paralelo, propostas recentes para governação local e *oversight* de sistemas algorítmicos em contexto hospitalar sublinham a importância da criação de comissões clínico-digitais, monitorização de desempenho em produção, definição de critérios para atualização de modelos e processos claros de aprovação institucional.⁴⁵

A adoção segura de IA em saúde exige articulação entre reguladores de dispositivos e tecnologias, autoridades de proteção de dados, estruturas internas de qualidade e segurança, e ordens/sociedades profissionais. Estas instituições devem definir padrões de prática, requisitos de formação e enquadramentos de responsabilidade.

Quadros de referência éticos, como a iniciativa *AI4People*, propõem princípios de transparência, responsabilidade e beneficência para orientar as sociedades digitais.²⁷ Relatórios internacionais reforçam a necessidade de governação ética e colaboração global.⁴⁶ A definição clara de responsabilidades em eventos adversos mediados por IA exige políticas institucionais consistentes, auditorias independentes e alinhamento com os regulamentos que enquadram a utilização dos dispositivos médicos de decisão clínica.^{43,45,47}

Educação médica e colaboração interdisciplinar

A literacia digital é hoje considerada uma competência essencial na educação médica. Diversos relatórios internacionais recomendam a integração curricular de ciência de dados, ética digital e governação algorítmica, bem como programas de *upskilling* contínuo para profissionais no ativo.^{48,49} Em paralelo, têm sido propostos modelos de integração ao longo do *continuum* formativo (pré-graduado, pós-graduado e desenvolvimento profissional contínuo) que adaptem a profundidade do ensino e o grau de responsabilidade (por exemplo, perfis consumidor/tradutor/desenvolvedor, ou níveis básico/proficiente/perito) aos diversos níveis de competência.^{50,51} Revisões recentes sobre a utilização de grandes modelos de linguagem (LLM) em saúde e sobre aplicações de sistemas como o ChatGPT sublinham, adicionalmente, a necessidade de competências específicas em formulação de perguntas, validação crítica das respostas e compreensão dos limites destes sistemas.^{17,52}

A colaboração interdisciplinar entre clínicos, engenheiros, cientistas de dados, juristas e gestores é apontada

como condição para que a inovação mantenha relevância clínica e conformidade regulatória.^{53,54} A comunicação transparente com o doente sobre o papel da IA é igualmente sublinhada como parte integrante da prática responsável.⁵⁵

DISCUSSÃO

A presente revisão narrativa sintetizou evidência sobre a integração da IA em saúde e os seus efeitos na prática clínica, na organização do trabalho e na educação médica. Foram identificados benefícios consistentes em áreas de maturidade tecnológica, como a Imagiologia, a Patologia Digital e os sistemas de apoio à decisão clínica,^{1,18} bem como em funções administrativas, incluindo codificação e gestão de recursos (Tabela 1).^{26,31} Estes ganhos associam-se a maior precisão diagnóstica, maior eficiência na documentação e potencial de redução da carga burocrática.^{22,56}

Para reforçar a dimensão operacional, propomos que a avaliação de impacto de soluções de IA vá além de métricas de discriminação e inclua indicadores de processo e de trabalho: carga de alertas, tempo efetivo em tempo no registo clínico eletrónico (RCE), taxa de *overrides* (alertas ignorados ou não seguidos), erros introduzidos/evitados, efeitos na coordenação de equipa e impacto na segurança do doente.^{33,57}

Um exemplo do risco no mundo real é a validação externa do *Epic Systems Sepsis Model*, que demonstrou fraca discriminação e calibração para prever sepsis. A adoção generalizada deste instrumento, apesar da sua modesta performance, ilustra como modelos 'prontos a usar' podem gerar alertas/decisões com impacto operacional e clínico se não forem validados localmente.⁵⁸ Outro exemplo concreto é a utilização de um algoritmo comercial para a seleção de doentes a incluir em programas de gestão de cuidados que subestimou o risco em doentes negros. Os autores mostraram que para corrigir este viés seria necessário aumentar substancialmente a proporção de doentes negros, evidenciando um risco real de inequidade e a necessidade de auditoria ao sistema.⁵

A dimensão económica e laboral pode ser tornada mais explícita ao enquadrar a adoção em termos de custo total de propriedade (*total cost of ownership* - isto é, o conjunto de custos ao longo do ciclo de vida que vai para além da aquisição), mas também implementação, integração, infraestrutura, formação, operação, manutenção/atualizações, monitorização e conformidade. Em muitos cenários, a IA não elimina trabalho: desloca-o para revisão, validação e gestão de exceções, podendo criar funções e novos riscos de precarização se a governação for orientada apenas para a produtividade.^{59,60}

Outros contextos clínicos terão implicações na implementação dos sistemas de IA.⁶¹ Por exemplo, as áreas de

Tabela 1 – Matriz das aplicações da inteligência artificial no trabalho médico e métricas

Dimensão	Aplicações	Impacto na força de trabalho	Riscos identificados	Estratégias de mitigação	Métricas/ indicadores sugeridos
Clínica	Imagiologia; Patologia; Triagem.	Apoio ao diagnóstico; Libertação de tempo para doentes complexos.	Perda de competências (<i>deskilling</i>); Viés de automação; Fadiga de alarmes.	Supervisão humana (<i>human-in-the-loop</i>); Formação contínua.	Desempenho: sensibilidade/especificidade; valor preditivo positivo (VPP)/valor preditivo negativo (VPN); calibração; análise por subgrupos. Processo: n.º de alertas/doente-dia; taxa de anulação; tempo de leitura/releto; tempo no registo clínico eletrónico (RCE). Segurança: falsos negativos críticos; incidentes/eventos adversos relacionados com IA.
Administrativa	Resumo de notas; Escalas; Codificação/faturação.	Redução de carga burocrática e de exaustão ocupacional (<i>burnout</i>).	Erros de codificação; Dependência tecnológica.	Auditorias periódicas; Desenho centrado no utilizador.	Eficiência: tempo de documentação (min/turno) e tempo no RCE; n.º de cliques/nota. Qualidade: completude e legibilidade; taxa de erros de codificação/faturação; retrabalho. Impacto humano: satisfação; <i>burnout</i> ; variação entre equipas/serviços.
Operacional	Gestão de camas; Fluxo da urgência.	Otimização de recursos; Melhoria do fluxo de trabalho.	Fragmentação do trabalho; Precarização laboral.	Governança institucional robusta; Participação dos profissionais no desenho.	Fluxo: tempo de permanência na urgência; tempo de espera por cama após decisão de internamento; tempo até atribuição de cama; taxa de ocupação. Decisão: taxa de aceitação/anulação; tempos de resposta e de escalamento. Segurança/equidade: incidentes; atrasos críticos; desempenho por turnos e subgrupos.

Imagiologia e Patologia (Clínica ou Anatomia Patológica) (que têm um elevado volume de produção e tarefas relativamente padronizadas) diferem da Medicina Intensiva (caracterizada pela tomada de decisão em tempo real, dados ruidosos e com elevada variabilidade), que por sua vez diferem também dos Cuidados de Saúde Primários (que gerem a incerteza diagnóstica e a continuidade longitudinal dos cuidados aos doentes).⁶²⁻⁶⁴ Isto limita a generalização de resultados e exige cautela. A validação local e a adaptação aos fluxos laborais locais devem ser consideradas requisitos e não apenas etapas opcionais.³³

Em paralelo, a literatura mais recente tem sublinhado a emergência de novos riscos e desafios. A opacidade algorítmica continua a limitar a confiança clínica, apesar dos progressos em XAI e dos esforços para avaliar a sua robustez e incerteza em contexto médico.^{11,12,42} Os modelos de predição e triagem, quando mal integrados, podem induzir fadiga de alarmes, erosão de competências (*deskilling*) ou novos padrões de sobrecarga cognitiva.^{23,38} As revisões centradas na utilização de IA em contexto de cuidados intensivos, emergência e segurança do doente crítico reforçam que muitos sistemas permanecem em fase exploratória, com validação limitada e impacto clínico ainda pouco caracterizado.^{19,21,25} Outros estudos alertam para a possibi-

lidade de instabilidade laboral e fragmentação do trabalho quando a adoção tecnológica não é acompanhada de planeamento institucional robusto e de estratégias explícitas de gestão da força de trabalho.^{40,41}

Os nossos resultados são consistentes com relatórios internacionais, incluindo os da Organização Mundial da Saúde e da Organização para a Cooperação e Desenvolvimento Económico, que destacam a necessidade de governação ética, supervisão humana e monitorização contínua.^{46,65} A articulação com o *AI Act* europeu é particularmente relevante: a imposição de documentação, gestão de risco e de mecanismos de transparência criaram um enquadramento regulatório que condicionará a implementação da IA em Portugal e noutros países da União Europeia.^{43,45} A evidência emergente sobre vieses em modelos de risco e sobre o papel de determinantes sociodemográficos na predição automatizada sublinha ainda a importância da equidade no desenho e monitorização dos novos sistemas.⁴⁵

As implicações práticas da adoção crescente da IA incluem a necessidade de investir em literacia digital clínica,^{42,48,49} formação interdisciplinar,^{53,54} reconversão profissional^{20,38} e mecanismos de participação dos profissionais no desenho, implementação e avaliação dos

sistemas.^{23,24,35,36} A adoção segura da IA implica não apenas avaliação algorítmica em condições controladas, mas também a sua validação em cenários do mundo real, com métricas de resultado clinicamente significativas e avaliação formal da interação humano-máquina.^{15,34} A proteção da autonomia profissional e a clareza das responsabilidades institucionais são essenciais para preservar a confiança dos doentes e dos profissionais.^{47,66}

Como limitação desta revisão reconhece-se a possibilidade de viés de seleção em resultado da metodologia narrativa não seguir um protocolo sistemático.¹⁴ Por outro lado, a exclusão de literatura não publicada e de relatórios técnicos pode ter limitado a abrangência deste trabalho, apesar da pesquisa em múltiplas bases de dados.³¹

Estudos multicêntricos prospetivos que avaliem o impacto clínico e organizacional da IA para além da acurácia algorítmica deverão ser realizados^{13,16} para explorar as métricas de segurança a definir, o tempo de resposta e os resultados em saúde, bem como a interação entre a IA e as equipas de trabalho.^{23,24} É igualmente prioritário desenvolver investigações sobre modelos de formação e estratégias de mitigação do *deskilling*,^{48,49} bem como avaliar com independência a eficácia dos mecanismos regulatórios introduzidos pelo *AI Act* e a governação local dos sistemas de apoio à decisão.^{43,45}

CONCLUSÃO

A integração da IA em saúde apresenta um potencial transformador, mas requer uma abordagem sociotécnica que equilibre a inovação tecnológica com a preservação das competências humanas, a proteção dos valores éticos e a estabilidade da força de trabalho. Em particular, a implementação sustentável da inteligência artificial dependerá da articulação entre evidência científica, governação ins-

tucional e enquadramento regulatório europeu, bem como da capacidade de envolver os profissionais e os doentes no desenho e na avaliação dos novos sistemas de apoio à decisão clínica.

ACKNOWLEDGMENTS

Foi utilizado o ChatGPT com o objetivo de revisão semântica e ortográfica de um rascunho inicial do texto. Após a utilização desta ferramenta, o conteúdo foi revisto e editado pelos autores, que assumem total responsabilidade pelo conteúdo.

CONTRIBUTO DOS AUTORES

JF: Conceção do estudo, pesquisa da literatura, escrita e revisão crítica do manuscrito.

AP, ARM: Conceção do estudo, pesquisa da literatura, revisão crítica do manuscrito.

MP, BDN: Revisão crítica do manuscrito.

HD: Pesquisa da literatura, revisão crítica do manuscrito.

AVC: Conceção do estudo, revisão crítica do manuscrito.

Todos os autores aprovaram a versão final a ser publicada.

CONFLITOS DE INTERESSE

Os autores declaram não ter conflitos de interesse relacionados com o presente trabalho.

FONTES DE FINANCIAMENTO

Este trabalho não recebeu qualquer tipo de suporte financeiro de nenhuma entidade no domínio público ou privado.

REFERÊNCIAS

1. Topol EJ. High-performance medicine: the convergence of human and artificial intelligence. *Nat Med*. 2019;25:44-56.
2. Esteva A, Robicquet A, Ramsundar B, Kuleshov V, DePristo M, Chou K, et al. A guide to deep learning in healthcare. *Nat Med*. 2019;25:24-9.
3. Rajpurkar P, Chen E, Banerjee O, Topol EJ. AI in health and medicine. *Nat Med*. 2022;28:31-8.
4. Johnson AE, Ghassemi MM, Nemati S, Niehaus KE, Clifton DA, Clifford GD. Machine learning and decision support in critical care. *Proc IEEE*. 2016;104:444-66.
5. London AJ. Artificial intelligence and black-box medical decisions: accuracy versus explainability. *Hastings Cent Rep*. 2019;49:15-21.
6. Obermeyer Z, Powers B, Vogeli C, Mullainathan S. Dissecting racial bias in an algorithm used to manage the health of populations. *Science*. 2019;366:447-53.
7. European Union. Regulation (EU) 2024/1689 of the European Parliament and of the Council of 13 June 2024 laying down harmonised rules on artificial intelligence (AI Act). *Off J Eur Union*. 2024. [consultado 2025 ago 19]. Disponível em: <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX%3A32024R1689>.
8. LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature*. 2015;521:436-44.
9. Vaswani A, Shazeer N, Parmar N, Uszkoreit J, Jones L, Gomez AN, et al. Attention is all you need. *Adv Neural Inf Process Syst*. 2017;30:5998-6008.
10. Gulshan V, Peng L, Coram M, Stumpe MC, Wu D, Narayanaswamy A, et al. Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs. *JAMA*. 2016;316:2402-10.
11. Lundberg SM, Lee SI. A unified approach to interpreting model predictions. *Adv Neural Inf Process Syst*. 2017;30:4765-74.
12. Marconi L, Cabrita F. Show and tell: a critical review on robustness and uncertainty for a more responsible medical AI. *Int J Med Inform*. 2025;202:105970.
13. Sendak M, Elish MC, Gao M, Futoma J, Ratliff W, Nichols M, et al. "The human body is a black box": supporting clinical decision-making with deep learning. *Proc ACM CHI Conf Hum Factors Comput Syst*. 2020;2020:1-12.
14. Greenhalgh T, Thorne S, Malterud K. Time to challenge the spurious hierarchy of systematic over narrative reviews? *Eur J Clin Invest*. 2018;48:e12931.
15. Futoma J, Morris J, Lucas J. A comparison of models for predicting early hospital readmissions. *J Biomed Inform*. 2015;56:229-38.
16. Olang O, Mohseni S, Shahabinezhad A, Hamidiashirazi Y, Goli A, Abolghasemian M, et al. Artificial intelligence-based models for prediction of mortality in ICU patients: a scoping review. *J Intensive Care*

- Med. 2025;40:1240-6.
17. Wiest IC, Bhat M, Clusmann J, Schneider CV, Jiang X, Kather JN. Large language models for clinical decision support in gastroenterology and hepatology. *Nat Rev Gastroenterol Hepatol.* 2025;22:773-87.
 18. Rumshisky A, Ghassemi M, Naumann T, Szolovits P, Castro VM, McCoy TH, et al. Predicting early psychiatric readmission with natural language processing of narrative discharge summaries. *Transl Psychiatry.* 2016;6:e921.
 19. Kareemi H, Yadav K, Price C, Bobrovitz N, Meehan A, Li H, et al. Artificial intelligence-based clinical decision support in the emergency department: a scoping review. *Acad Emerg Med.* 2025;32:386-95.
 20. Salluh JI, Churpek MM, Alvim RC, Kashyap R, Meyer A, Soares M, et al. Artificial intelligence, big data, and precision medicine in critical care. *Crit Care.* 2020;24:462.
 21. European Union. Regulation (EU) 2016/679 of the European Parliament and of the Council of 27 April 2016 on the protection of natural persons with regard to the processing of personal data and on the free movement of such data (General Data Protection Regulation – GDPR). *Off J Eur Union.* 2016. [consultado 2025 ago 19]. Disponível em: <https://eur-lex.europa.eu/eli/reg/2016/679/oj>.
 22. Rajkomar A, Oren E, Chen K, Dai AM, Hajaj N, Hardt M, et al. Scalable and accurate deep learning with electronic health records. *NPJ Digit Med.* 2018;1:18.
 23. Giddings R, Joseph A, Callender T, Janes SM, van der Schaar M, Sheringham J, et al. Factors influencing clinician and patient interaction with machine learning-based risk prediction models: a systematic review. *Lancet Digit Health.* 2024;6:e131-44.
 24. Noselli M, Van Der Vegt A, Cordeil M, Campbell V, Wang AP, Shetty A, et al. Presenting artificial intelligence predictions based on electronic medical records to clinicians in hospitals: a systematic review. *IEEE J Biomed Health Inform.* 2025;29:7619-32.
 25. Kareemi H, Li H, Rajaram A, Holodinsky JK, Hall JN, Grant L, et al. Establishing methodological standards for the development of artificial intelligence-based clinical decision support in emergency medicine. *CJEM.* 2025;27:87-95.
 26. Lyu G. Data-driven decision making in patient management: a systematic review. *BMC Med Inform Decis Mak.* 2025;25:239.
 27. Floridi L, Cowlis J, Beltrametti M, Chatila R, Chazerand P, Dignum V, et al. AI4People—an ethical framework for a good AI society: opportunities, risks, principles, and recommendations. *Minds Mach.* 2018;28:689-707.
 28. Barea Mendoza JA, Valiente Fernández M, Pardo Fernández A, Gómez Álvarez J. Current perspectives on the use of artificial intelligence in critical patient safety. *Med Intensiva.* 2025;49:154-64.
 29. Giacobbe DR, Vena A, Bassetti M. Role of artificial intelligence in ICU therapeutic decision-making for severe infections. *Curr Opin Crit Care.* 2025;31:547-53.
 30. Miotto R, Li L, Kidd BA, Dudley JT. Deep patient: an unsupervised representation to predict the future of patients from the electronic health records. *Sci Rep.* 2016;6:26094.
 31. Chen JH, Asch SM. Machine learning and prediction in medicine—beyond the peak of inflated expectations. *N Engl J Med.* 2017;376:2507-9.
 32. Magrabi E, McNair JB, De Keizer NF, Hyppönen H, Nykänen P, Rigby M, et al. Artificial intelligence in clinical decision support: challenges for evaluating AI and practical implications. *Yearb Med Inform.* 2019;28:128-34.
 33. Harrison MI, Koppel R, Bar-Lev S. Unintended consequences of information technologies in health care—an interactive sociotechnical analysis. *J Am Med Inform Assoc.* 2007;14:542-9.
 34. Sisk BA, Frankel RM, Kodish E, DuBois JM. Ethical and epistemic issues in the use of AI in health care. *Hastings Cent Rep.* 2020;50:35-42.
 35. Tun HM, Rahman HA, Naing L, Malik OA. Trust in artificial intelligence-based clinical decision support systems among health care workers: systematic review. *J Med Internet Res.* 2025;27:e69678.
 36. Park Y, Chang SJ, Kim E. Artificial intelligence in critical care nursing: a scoping review. *Aust Crit Care.* 2025;38:101225.
 37. Ito Y, Kajiwara K, Kako J, Kobayashi M, Tsubaki M, Sakuramoto H, et al. Artificial intelligence in nursing support for patients: a rapid review. *Int J Med Inform.* 2025;204:106087.
 38. Davenport T, Kalakota R. The potential for artificial intelligence in healthcare. *Future Healthc J.* 2019;6:94-8.
 39. Auf H, Svedberg P, Nygren J, Nair M, Lundgren LE. The use of AI in mental health services to support decision-making: scoping review. *J Med Internet Res.* 2025;27:e63548.
 40. Higgins O, Wilson RL. Integrating artificial intelligence (AI) with workforce solutions for sustainable care: a follow up to artificial intelligence and machine learning (ML) based decision support systems in mental health. *Int J Ment Health Nurs.* 2025;34:e70019.
 41. Nesa L, Rony MK, Chowdhury S, Naznin MB, Halder K, Ara MH, et al. Artificial intelligence in healthcare: a scoping review of medical professionals' acceptance and institutional challenges in implementation. *J Eval Clin Pract.* 2025;31:e70170.
 42. Amann J, Blasimme A, Vayena E, Frey D, Madai VI. Explainability for artificial intelligence in healthcare: a multidisciplinary perspective. *BMC Med Inform Decis Mak.* 2020;20:310.
 43. Weissman GE. Evaluation and regulation of artificial intelligence medical devices for clinical decision support. *Annu Rev Biomed Data Sci.* 2025;8:81-99.
 44. Hauschildt KE, Pan A, Bernstein T, Admon AJ, Mukherjee B, Iwashyna TJ, et al. Consideration of sociodemographics in machine learning-driven sepsis risk prediction. *Crit Care Med.* 2025;53:e1815-24.
 45. Lin AL, Parrish AB, Cary M, Silcox C, Balu S, Jelovsek JE, et al. Algorithm-based clinical decision support: evolving regulatory landscape and best practices for local oversight. *Annu Rev Biomed Data Sci.* 2025;8:491-507.
 46. World Health Organization. Ethics and governance of artificial intelligence for health: WHO guidance. Geneva: WHO; 2021.
 47. Shortliffe EH, Sepúlveda MJ. Clinical decision support in the era of artificial intelligence. *JAMA.* 2018;320:2199-200.
 48. Price WN, Gerke S, Cohen IG. Potential liability for physicians using artificial intelligence. *JAMA.* 2019;322:1765-6.
 49. Hwang TJ, Kesselheim AS, Vokinger KN. Lifecycle regulation of artificial intelligence- and machine learning-based software devices in medicine. *JAMA.* 2019;322:2285-6.
 50. Schubert T, Oosterlinck T, Stevens RD, Maxwell PH, van der Schaar M. AI education for clinicians. *EClinicalMedicine.* 2025;79:102506.
 51. Mendes JM. Reimagining healthcare education through nurturing AI-driven innovation. *BMC Med Educ.* 2025;25:1644.
 52. Jagatheesaperumal SK, Pandiyarajan A, Boopathy P, Deepa N, Barreto AG, de Albuquerque VH. A review on recent advancements of ChatGPT and datification in healthcare applications. *Comput Biol Med.* 2025;197:110885.
 53. Kolachalama VB, Garg PS. Machine learning and medical education. *NPJ Digit Med.* 2018;1:54.
 54. Beede E, Baylor E, Hersch F, Iurchenko A, Wilcox L, Ruamviboonsuk P, et al. A human-centered evaluation of a deep learning system deployed in clinics for the detection of diabetic retinopathy. *Proc ACM CHI Conf Hum Factors Comput Syst.* 2020;2020:1-12.
 55. Masters K. Artificial intelligence in medical education. *Med Teach.* 2019;41:976-80.
 56. Shanafelt TD, Dyrbye LN, Sinsky C, Hasan O, Satele D, Sloan J, et al. Relationship between clerical burden and characteristics of the electronic environment with physician burnout and professional satisfaction. *Mayo Clin Proc.* 2016;91:836-48.
 57. Adler-Milstein J, Adelman JS, Tai-Seale M, Patel VL, Dymek C. EHR audit logs: a new goldmine for health services research? *J Biomed Inform.* 2020;101:103343.
 58. Wong A, Ottes E, Donnelly JP, Krumm A, McCullough J, DeTroyer-Cooley O, et al. External validation of a widely implemented proprietary sepsis prediction model in hospitalized patients. *JAMA Intern Med.* 2021;181:1065-70.
 59. Rule A, Chiang MF, Hribar MR. Using electronic health record audit logs to study clinical activity: a systematic review of aims, measures, and methods. *J Am Med Inform Assoc.* 2020;27:480-90.
 60. Chaparro JM, Dziorny AC, Hagedorn PA, Hernandez S, Kandaswamy S, Kirkendall ES, et al. Clinical decision support stewardship: best practices and techniques to monitor and improve interruptive alerts. *Appl Clin Inform.* 2022;13:560-8.
 61. Guo LL, Pfohl SR, Currie G, Jeanselme V, Shah N, Potosnak A, et

- al. Evaluation of domain generalization and adaptation on improving model robustness to temporal dataset shift in clinical medicine. *Sci Rep.* 2022;12:2726.
62. Laranjo L, Coiera E. Artificial intelligence in primary care: innovation at a crossroads. *Lancet Prim Care.* 2025;1:100078.
63. Wong A, Vangala S, Seger DL, Bates DW, Awdish R. Facilitators and barriers to interacting with clinical decision support in the icu: a mixed-methods approach. *Crit Care Explor.* 2023;5:e0854.
64. Nensa F. The future of radiology: the path towards multimodal AI and superdiagnostics. *Eur J Radiol Artif Intell.* 2025;2:100014.
65. Organisation for Economic Co-operation and Development. Artificial intelligence in health: findings and recommendations. Paris: OECD; 2023.
66. Weissman GE, Zwaan L, Bell SK. Diagnostic scope: the AI can't see what the mind doesn't know. *Diagnosis.* 2024;12:189-96.