



IMPACTO AMBIENTAL DO USO DA INTELIGÊNCIA ARTIFICIAL NA SAÚDE

 <https://doi.org/10.56238/isevmjv4n1-007>

Recebimento dos originais: 14/12/2024

Aceitação para publicação: 14/01/2025

Rafael Dias Ribeiro

E-mail: rafaeldiaribeiro@gmail.com

ORCID: <https://orcid.org/0009-0007-6105-8117>

Amanda Gomes

E-mail: amandagomes0@gmail.com

ORCID: <https://orcid.org/0000-0003-0174-4856>

Daniela Gomes

E-mail: gomesdaniela170@gmail.com

ORCID: <https://orcid.org/0009-0005-0884-5168>

Gabriela Gomes

E-mail: gabrielaaggomes@gmail.com

ORCID: <https://orcid.org/0000-0002-1008-1639>

Erick Vitor de Souza

E-mail: erickvitor72@hotmail.com

ORCID: <https://orcid.org/0009-0007-8405-3271>

Renata de Carvalho Vieira Sousa

E-mail: renatadecarvalho@gmail.com

ORCID: <https://orcid.org/0009-0007-0055-4213>

Valter Gomes

E-mail: valtervieira@ufv.br

ORCID: <https://orcid.org/0000-0002-8425-5355>

Lucia Helena Gomes

E-mail: lucia.gomes@ufv.br

RESUMO

A inteligência artificial (IA) emergiu como uma ferramenta de inovação na área da saúde, redefinindo o diagnóstico, o tratamento e a gestão hospitalar. Desde algoritmos que aprimoram análises de imagens médicas até sistemas de suporte à decisão clínica, a IA oferece benefícios significativos na eficiência e precisão dos serviços de saúde. Contudo, a crescente demanda por IA exige infraestrutura computacional, sustentada por data centers que consomem grandes quantidades de energia e recursos naturais. Esses centros, responsáveis por treinar e operar modelos como o GPT-3, geram emissões significativas de gases de efeito estufa e demandam grandes volumes de água para resfriamento. Além disso, a produção de hardwares especializados e o descarte de equipamentos intensificam os desafios ambientais. Paradoxalmente, a IA também oferece soluções para problemas climáticos, como a otimização de recursos energéticos e a previsão de desastres naturais. O objetivo deste manuscrito é explorar essa dualidade, analisando



os benefícios da IA na saúde e os desafios ambientais. Ademais, as práticas sustentáveis e tecnologias emergentes, buscam um equilíbrio entre o avanço tecnológico e a preservação ambiental.

Palavras-chave: Inteligência Artificial na Saúde. Impacto Ambiental. Tecnologia Sustentável.

1 INTRODUÇÃO

A inteligência artificial (IA) tem se consolidado como uma ferramenta essencial na área da saúde, aprimorando diagnósticos, tratamentos e processos gerenciais. Seu uso abrange desde algoritmos avançados para análise de imagens médicas até sistemas de suporte à decisão clínica, promovendo uma maior eficiência e precisão nos serviços de saúde (MARTINEAU, 2020). Contudo, apesar dos avanços tecnológicos, a aplicação da IA também levanta importantes questões ambientais.

A IA tem revolucionado o setor da saúde, possibilitando análises mais precisas de dados médicos e promovendo avanços em diagnósticos e tratamentos personalizados (MARTINEAU, 2020). Modelos como o GPT-3 têm sido usados para acelerar a análise de grandes volumes de dados, contribuindo para uma gestão hospitalar eficiente. Além disso, a IA tem demonstrado potencial para apoiar a telemedicina e prever epidemias, impactando positivamente o acesso à saúde em regiões remotas (ARBIX, 2024).

O treinamento e a operação de modelos de IA exigem infraestruturas computacionais robustas, frequentemente sustentadas por data centers que consomem grandes volumes de energia e recursos naturais. Esses centros, além de gerarem emissões significativas de gases de efeito estufa, também apresentam um impacto expressivo sobre os recursos hídricos, sendo estimado que o treinamento de grandes modelos, como o GPT-3, possa consumir milhões de litros de água limpa para resfriamento (LI et al., 2023). A localização e a fonte de energia utilizada por esses centros influenciam diretamente na pegada de carbono da IA evidenciando a necessidade de práticas mais sustentáveis (ARBIX, 2024).

Estudos revisados, como o de (Li et al., 2023), destacam que o treinamento de grandes modelos de IA exige um alto consumo energético e hídrico, devido à infraestrutura de data centers. Esses centros podem consumir milhões de litros de água e gerar emissões substanciais de carbono, especialmente em locais onde a energia é predominantemente não renovável. Relatórios do MIT (MARTINEAU, 2020) também ressaltam o papel dos materiais utilizados na fabricação de hardware, que intensificam o impacto ambiental e social, devido às cadeias produtivas de extração mineral.

Além disso, os impactos ambientais não se limitam ao consumo energético. A produção e o descarte de hardwares especializados aumentam a extração de materiais e geram resíduos que contribuem para a degradação ambiental e violações de direitos humanos em cadeias produtivas (ARBIX, 2024). Paradoxalmente, a IA também se apresenta como uma aliada no combate às

mudanças climáticas, sendo aplicada para otimizar sistemas de energia, prever desastres ambientais e implementar cadeias de suprimentos mais sustentáveis (ECYCLE, 2024).

A dualidade entre os benefícios e os impactos ambientais da IA é discutida em relatórios e artigos revisados neste estudo. Publicações da Universidade de Berkeley e da revista *Nature Climate Change* reforçam a necessidade de estratégias como a localização sustentável de data centers, a adoção de fontes de energia renováveis e a otimização de processos computacionais para reduzir a pegada ambiental (ECYCLE, 2024).

A inteligência artificial (IA) tem transformado significativamente a área da saúde, oferecendo soluções inovadoras para diagnósticos, tratamentos e gestão de sistemas médicos. Entretanto, o impacto ambiental associado ao seu desenvolvimento e aplicação tem gerado preocupações, motivando discussões sobre a necessidade de práticas sustentáveis. Este estudo fundamenta-se em uma revisão bibliográfica que considera tanto os benefícios quanto os desafios ambientais da IA, com base de dados segundo critérios de relevância e confiabilidade.

Diante desse cenário, o presente artigo analisa o uso e os benefícios da IA na área da saúde, com uma abordagem crítica sobre os desafios ambientais. A partir de uma revisão dos impactos e das soluções existentes, busca-se propor caminhos que conciliem o avanço tecnológico com a preservação ambiental, promovendo um futuro sustentável para o setor de saúde.

2 METODOLOGIA

Este estudo emprega uma abordagem exploratória e descritiva para investigar e avaliar os impactos da inteligência artificial (IA) na saúde, com ênfase nos seus benefícios e implicações ambientais. O levantamento bibliográfico foi conduzido em duas etapas principais.

Utilizou-se uma combinação de artigos em bases científicas, como *Nature*, *MIT News* e publicações acadêmicas em *arXiv*. A estratégia de busca foi baseada nas seguintes palavras-chave: (("Inteligência Artificial" AND "Saúde") OR ("Impacto Ambiental" AND "Tecnologia Sustentável")) OR ("Inteligência Artificial" AND "Impacto Ambiental") OR ("Inteligência Artificial" AND "Tecnologia Sustentável")). Foram estabelecidos critérios de inclusão: artigos em inglês, publicados entre 2018-2023. Critérios de exclusão: estudos duplicados, resumos, artigos de revisão e trabalhos sem acesso ao texto na íntegra.

Após a coleta de dados, a análise será estruturada em duas etapas. Na primeira os artigos foram organizados em categorias relacionadas aos benefícios da IA na saúde e aos desafios ambientais, incluindo consumo energético, pegada hídrica e impactos relacionados à produção de hardware. Na segunda foi realizada análise integrativa com base na literatura revisada, análise

crítica dos dados, discutindo a dualidade entre os benefícios tecnológicos da IA e seus impactos ambientais. Ademais, a revisão está limitada à literatura e à relevância das fontes utilizadas. A proposta do manuscrito é um diálogo com ênfase nas práticas sustentáveis no uso da IA na saúde.

3 RESULTADOS E DISCUSSÃO

A inteligência artificial (IA) tem se mostrado um recurso indispensável na área da saúde, promovendo avanços significativos em diagnósticos, tratamentos e gestão hospitalar. O impacto positivo da IA é evidente, mas é necessário discutir como esses avanços influenciam o meio ambiente, considerando a pegada ecológica associada ao seu desenvolvimento e uso.

3.1 CONTRIBUIÇÕES DA IA NA SAÚDE

A análise dos dados coletados demonstra que a IA desempenha um papel central na transformação da prática médica, especialmente no apoio ao diagnóstico e na personalização dos tratamentos. O uso predominante de aprendizado de máquina (72%) e *deep learning* (28%) entre os artigos analisados indica que essas metodologias têm sido altamente eficazes na extração de padrões complexos a partir de grandes volumes de dados médicos, como os prontuários eletrônicos e exames de imagem. Isso reforça a ideia de que a IA pode melhorar significativamente a precisão diagnóstica, como destacado por (Carrasco-Ribelles et al., 2023), que utilizaram modelos preditivos para antecipar a evolução de doenças crônicas, e por (Ladyzynski et al., 2022), que aplicaram redes bayesianas dinâmicas para prever a resposta ao tratamento em pacientes com leucemia linfocítica crônica.

3.2 TIPOS DE INTELIGÊNCIAS ARTIFICIAIS

Machine Learning (ML) é um subconjunto da IA que permite que os sistemas aprendam e melhorem a partir de dados sem serem explicitamente programados para realizar tarefas específicas. Ele funciona através de algoritmos que encontram padrões nos dados e fazem previsões baseadas nesses padrões. O ML é amplamente utilizado em diagnósticos médicos, previsão de desfechos clínicos e personalização de tratamentos, como apresentado nos artigos (Mendo et al., 2021), (Maurovich-Horvat, 2021), (Zhu et al., 2022), (Ren et al., 2022), (Strauss et al., 2023), (Rodriguez-Diaz et al., 2022), (Kenner et al., 2021), (Mendo et al., 2021), (Montanaro et al., 2021), (Rostam Niakan Kalhori et al., 2021), (Yun et al., 2021), (Basit et al., 2021), (Kulkarni & Singh, 2023), (Mohsen et al., 2022), (Letterie, 2021), (Morey et al., 2021), (Ho et al., 2022), (Wu et al., 2022), (Reeves et al., 2021), (Kashyap et al., 2021),

A Deep Learning (DL) é uma subcategoria do *Machine Learning*, caracterizada pelo uso de redes neurais profundas (DNNs) com múltiplas camadas para processar grandes volumes de dados complexos. Esse tipo de IA é particularmente eficaz no reconhecimento de padrões complexos, como imagens médicas e fala. Ele tem sido amplamente utilizado em diagnósticos por imagem, como na detecção de câncer e doenças oftalmológicas e presente nos artigos de (Rostam Niakan Kalhori et al., 2021), (Samaras et al., 2023), (Mohsen et al., 2022), (Adler-Milstein et al., 2021)

O *Natural Language Processing* (NLP - Processamento de Linguagem Natural) é uma subcategoria da IA que foca na interação entre computadores e linguagem humana, permitindo que os sistemas compreendam, interpretem e respondam a textos e falas humanas. No setor de saúde, o NLP tem sido utilizado para a análise de registros médicos, identificação de sintomas em pacientes e apoio ao preenchimento de prontuários médicos e em muitas outras aplicações como as apresentadas em (Sagheb et al., 2022), (Mattay et al., 2023), (Riskin et al., 2023), (Shevchenko et al., 2022), (Morin et al., 2021), (Samaras et al., 2023), (Tashman, 2022), (Yao et al., 2021), (Li et al., 2021)

Generative Adversarial Networks (GANs), ou Redes Gerativas Adversariais são um tipo de IA que envolve dois modelos de rede neural que competem entre si: um gerador, que cria dados falsos, e um discriminador, que tenta distinguir os dados gerados dos dados reais. Esse tipo de IA tem sido utilizado para melhorar a robustez dos sistemas de IA em diagnósticos médicos, simulando cenários adversos e prevenindo ataques a sistemas de diagnóstico (Zhou et al., 2021),

Redes Bayesianas são modelos gráficos probabilísticos que representam um conjunto de variáveis e suas relações condicionais. No setor de saúde, são usadas para prever o progresso de doenças e os efeitos do tratamento em condições crônicas, como a leucemia linfocítica crônica (Ladyzynski et al., 2022).

As Redes Neurais Recorrentes (RNNs) são um tipo especial de rede neural projetada para lidar com dados sequenciais ou temporais. A principal característica das RNNs é a sua capacidade de manter uma "memória" ao longo do tempo, o que permite que informações de entradas anteriores influenciem as saídas futuras. Isso é particularmente útil em aplicações de saúde, onde dados temporais, como sinais vitais ou séries temporais de sintomas, são analisados (Carrasco-Ribelles et al., 2023).

A IA Explicável (XAI) é um ramo da IA que se concentra em tornar os modelos de IA mais compreensíveis para humanos, fornecendo explicações sobre como as decisões ou previsões foram

feitas. No setor de saúde, isso é crucial para aumentar a confiança dos médicos nas predições feitas pelos algoritmos (Sariyar & Holm, 2022).

Em (Clement & Maldonado, 2021), o estudo apresenta o uso de IA para auxiliar nas decisões clínicas em transplantes de órgãos sólidos. A IA é utilizada para analisar grandes volumes de dados clínicos, incluindo biomarcadores e históricos de pacientes, fornecendo previsões personalizadas para regimes de imunossupressão. Um dos principais benefícios mencionados é a capacidade da IA de identificar padrões e fazer previsões que podem não ser facilmente detectáveis por humanos. O estudo destaca a importância de superar desafios relacionados à transparência e à explicabilidade dos algoritmos de IA, além de sugerir a criação de equipes dedicadas à integração de IA nos centros de transplante, promovendo o uso ético e eficaz dessas ferramentas na prática clínica.

No entanto, desafios relacionados à confiança nos sistemas de IA, particularmente no que se refere aos modelos de "caixa preta", permanecem significativos. Sariyar e Holm (2022) argumentam que a falta de explicabilidade dos algoritmos de IA, um fenômeno comum em modelos avançados como redes neurais profundas, limita a confiança dos profissionais de saúde nesses sistemas, especialmente em cenários clínicos onde decisões críticas precisam ser tomadas rapidamente. A análise sugere que a implementação de IA explicável (XAI) pode mitigar essas preocupações ao tornar as decisões mais transparentes e interpretáveis.

3.3 MODELOS PREDITIVOS E SUPORTE À DECISÃO CLÍNICA

Os modelos preditivos têm desempenhado um papel crucial na personalização do tratamento e na previsão de resultados em pacientes com condições graves, como o câncer e doenças cardíacas. De acordo com (Ladyzynski et al., 2022), o uso de redes bayesianas dinâmicas em pacientes com leucemia linfocítica crônica permitiu prever a resposta ao tratamento e o prognóstico com base em fatores clínicos, contribuindo para decisões terapêuticas mais informadas. Esse uso de modelos preditivos ilustra o potencial da IA em lidar com dados médicos complexos e personalizar os cuidados de saúde. No entanto, é importante destacar que esses modelos não estão isentos de limitações. Segundo (Jain et al., 2021), a IA aplicada à dermatologia em práticas de telemedicina demonstrou aumentos na precisão diagnóstica, mas ainda enfrenta barreiras, como a variabilidade nas avaliações humanas. A confiança excessiva nos sistemas de IA, sem a devida validação por especialistas humanos, pode levar a erros diagnósticos, ressaltando a necessidade de supervisão contínua dos modelos.

Em (Khoury et al., 2022) é enfatizado que é necessário um marco para avaliar, aprovar e monitorar o impacto dessas tecnologias. Eles destacam a importância da participação ativa dos especialistas no desenvolvimento, validação e implementação de sistemas de IA na área de alergia e imunologia, além de discutirem os desafios relacionados à governança da IA, educação e questões éticas, incluindo a equidade no uso dessas tecnologias. O artigo sugere que os dados multidimensionais, tanto de registros eletrônicos de saúde quanto de conjuntos de dados imunológicos, podem ser significativamente reduzidos e analisados para proporcionar suporte à decisão clínica. No entanto, para garantir a aplicação adequada dessas tecnologias, é essencial que os profissionais da área estejam envolvidos em todo o processo.

3.4 DESAFIOS E LIMITAÇÕES DO ESTUDO

Embora a IA apresente inúmeros benefícios, a sua implementação na medicina também traz desafios significativos. Um dos principais desafios é garantir a qualidade dos dados de entrada, uma vez que os algoritmos dependem fortemente da quantidade e da qualidade dos dados para fornecer previsões precisas (Akay et al., 2023) e (Bajgain et al., 2023) complementam a necessidade de revisão foca em como os sistemas baseados em IA podem ser desenvolvidos para melhorar o suporte à decisão clínica, correlacionando as características dos pacientes com os desfechos, ajudando assim os clínicos a tomar decisões informadas. Embora haja potencial significativo, existem ameaças à validade e desafios de tradução clínica.

A heterogeneidade nos métodos de coleta de dados e práticas de relato são apontados como obstáculos importantes a serem superados para uma implementação eficaz. Além disso, há preocupações éticas e regulatórias quanto ao uso de IA em ambientes clínicos, como destacado em (Maurud et al., 2023), particularmente no que diz respeito à privacidade dos pacientes e à responsabilidade por decisões automatizadas.

Em (Gellert, 2023), o artigo explora como o uso crescente de assistentes de registros médicos pode estar impactando a evolução da IA nos registros eletrônicos de saúde (*electronic health records* – EHRs). A IA discutida no artigo está relacionada principalmente à automação e à capacidade dos EHRs de integrar novas evidências clínicas e facilitar a prática médica de forma eficiente.

O artigo argumenta que os assistentes de registros médicos, embora aumentem a produtividade e a eficiência do fluxo de trabalho dos médicos, podem estar desacelerando o progresso da IA nos EHRs ao desconectar os médicos do processo de evolução dos sistemas. Ele sugere que o uso de assistentes de registros médicos pode isolar os profissionais de saúde do

aprendizado contínuo que ocorre com a IA integrada nos registros eletrônicos, o que poderia prejudicar o avanço da IA na área de saúde.

De acordo com (Sariyar & Holm, 2022), a confiança nos sistemas de IA é outro ponto crítico. Os profissionais de saúde muitas vezes hesitam em adotar essas tecnologias devido à falta de transparência nos processos de tomada de decisão dos algoritmos. Para superar esses desafios, os desenvolvedores de IA devem priorizar a criação de sistemas que não apenas apresentem alta precisão, mas também ofereçam explicações claras para suas previsões, a fim de aumentar a confiança e a aceitação entre os médicos.

Em (Lim et al., 2022), explora as opiniões de 603 pacientes sobre o uso da inteligência artificial (IA) no diagnóstico de câncer de pele. A pesquisa revelou que 47% dos participantes não se opunham ao uso da IA para auxiliar os especialistas em pele no diagnóstico. No entanto, 81% consideravam importante que um dermatologista confirmasse o diagnóstico e discutisse os resultados com eles. O estudo conclui que, embora os pacientes aceitem o uso da IA como uma ferramenta de apoio, a interação com o médico continua sendo valorizada, ressaltando a importância da presença do dermatologista durante o processo de diagnóstico.

Contudo ainda existe resistência na adoção de novas tecnologias, como em (Samaran et al., 2021) que examinou as dificuldades enfrentadas por médicos generalistas franceses no diagnóstico de câncer de pele não-melanoma e avaliou seu interesse no uso de ferramentas de inteligência artificial para ajudar nesse processo. A pesquisa, que incluiu 147 médicos, revelou que 98% enfrentam dificuldades nesses diagnósticos, e 86% acreditam que uma ferramenta de IA seria útil no consultório. No entanto, 68% não estariam dispostos a pagar por esse tipo de software, destacando que o interesse na IA é alto, mas o custo e a acessibilidade são barreiras importantes para sua adoção.

No artigo (Dobson et al., 2023), os autores examinam as percepções dos pacientes sobre o uso secundário de suas informações de saúde, além do cuidado imediato. A pesquisa utilizou entrevistas semiestruturadas com usuários de serviços de saúde na Nova Zelândia. As entrevistas exploraram cenários sobre o uso de informações de saúde, incluindo práticas atuais, inteligência artificial, aprendizado de máquina, calculadoras clínicas, pesquisas, registros e vigilância em saúde pública.

Os resultados revelaram quatro temas principais: ajudar os outros, compartilhamento de dados como algo importante, confiança e respeito. Os participantes apoiaram o uso de suas informações de saúde para ajudar outros e avançar a ciência, mas colocaram condições,

especialmente relacionadas à confiança nas instituições de saúde para proteger seus dados e garantir que não sejam usados de maneira prejudicial.

Em (Xu et al., 2023) e (Jeong & Kamaleswaran, 2022), defendem que a interpretabilidade é crucial para a aceitação dos sistemas de suporte à decisão clínica no ambiente clínico, uma vez que os profissionais de saúde precisam confiar nos resultados gerados por esses sistemas. Além disso, são discutidos desafios relacionados à complexidade dos dados e ao uso de modelos "caixa-preta", como redes neurais profundas, que dificultam a transparência.

Embora os benefícios sejam claros, o impacto ambiental do uso de IA merece destaque. A necessidade de treinamento e operação de grandes modelos, como GPT-3 e GPT-4, demanda uma infraestrutura computacional significativa, sustentada por data centers altamente intensivos em energia e recursos. Estima-se que o treinamento do GPT-3 consuma até 700.000 litros de água limpa e uma quantidade substancial de energia elétrica, cuja pegada de carbono varia conforme a matriz energética do local (LI et al., 2023).

Os data centers utilizados pelas principais empresas de tecnologia, como Google, Microsoft e Amazon, podem aumentar drasticamente as emissões de CO₂ dependendo de suas localizações e fontes de energia. Em regiões que dependem de combustíveis fósseis, essas emissões tornam-se ainda mais preocupantes. Relatórios indicam que a pegada de carbono da IA já equivale a cerca de 2% das emissões globais, com tendência de crescimento devido ao aumento da demanda por computação intensiva (ARBIX, 2024; ECYCLE, 2024).

Além disso, o impacto ambiental também está associado à produção de hardwares especializados. A extração de minerais raros e a fabricação de componentes requerem altos investimentos energéticos, frequentemente associados à degradação ambiental e questões de direitos humanos. Esses desafios colocam a sustentabilidade como um tema central no debate sobre o uso de IA na saúde.

Há estratégias promissoras para reduzir os impactos ambientais da IA sem comprometer seus benefícios no setor de saúde. A adoção de fontes de energia renováveis para alimentar data centers é uma solução viável e amplamente discutida na literatura (MARTINEAU, 2020). Além disso, a localização desses centros em regiões de clima frio pode reduzir a necessidade de resfriamento intensivo e, conseqüentemente, o consumo de energia e água (LI et al., 2023).

A melhoria da eficiência energética de hardwares e o desenvolvimento de modelos de IA menos dependentes de recursos computacionais também são estratégias importantes. Além disso, a transparência no monitoramento e divulgação de dados ambientais, como pegada de carbono e hídrica, pode impulsionar políticas públicas e investimentos em tecnologias mais limpas.

Embora a IA ofereça oportunidades únicas para otimizar os sistemas de saúde, é essencial considerar seus custos ambientais. A implementação de práticas sustentáveis e tecnologias verdes na área da saúde, como o uso de IA para prever e mitigar impactos ambientais, pode equilibrar essa dualidade. Assim, a saúde e a sustentabilidade podem caminhar juntas, promovendo um futuro onde a inovação tecnológica não comprometa o meio ambiente, mas, ao contrário, contribua para sua preservação.

4 CONSIDERAÇÕES FINAIS

A inteligência artificial (IA) tem se consolidado como uma ferramenta na área da saúde, trazendo avanços significativos em diagnósticos, tratamentos e gestão hospitalar. A análise de dados com precisão e rapidez tem transformado a prática médica e a qualidade do atendimento. Contudo, à medida que essas tecnologias ganham protagonismo, emergem preocupações sobre seus impactos ambientais.

A análise realizada neste estudo revelou uma dualidade inerente à aplicação da IA na saúde. De um lado, os benefícios diretos, como a otimização de recursos médicos e a personalização de tratamentos, contribuem para um sistema de saúde mais eficiente e acessível. De outro, o alto consumo de energia e água para o treinamento e operação de modelos de IA, além dos impactos ambientais associados à produção de hardware, apresentam desafios consideráveis.

É essencial adotar estratégias sustentáveis que equilibrem os benefícios tecnológicos com a preservação ambiental. A localização estratégica de data centers em regiões de clima frio e com fontes de energia renováveis é uma das soluções mais promissoras. Além disso, o desenvolvimento de tecnologias computacionais mais eficientes, como hardwares de baixo consumo energético e modelos de IA menos intensivos em recursos, pode reduzir significativamente a pegada de carbono e hídrica.

REFERÊNCIAS

- Adler-Milstein, J., Chen, J. H., & Dhaliwal, G. (2021). Next-Generation Artificial Intelligence for Diagnosis: From Predicting Diagnostic Labels to “Wayfinding”. *JAMA*, 326(24), 2467–2468. <https://doi.org/10.1001/jama.2021.22396>
- Akay, E. M. Z., Hilbert, A., Carlisle, B. G., Madai, V. I., Mutke, M. A., & Frey, D. (2023). Artificial Intelligence for Clinical Decision Support in Acute Ischemic Stroke: A Systematic Review. *Stroke*, 54(6), 1505–1516. <https://doi.org/10.1161/STROKEAHA.122.041442>
- Arbix, G. Como a rápida explosão de ferramentas de IA afeta o clima? Rádio USP, 2024. Disponível em: <https://jornal.usp.br/?p=802425>. Acesso em: 16 de novembro de 2024.
- Bajgain, B., Lorenzetti, D., Lee, J., & Sauro, K. (2023). Determinants of implementing artificial intelligence-based clinical decision support tools in healthcare: a scoping review protocol. *BMJ Open*, 13(2), e068373–e068373. <https://doi.org/10.1136/bmjopen-2022-068373>
- Basit, M. A., Lehmann, C. U., & Medford, R. J. (2021). Managing Pandemics with Health Informatics: Successes and Challenges. *Yearb Med Inform*, 30(1), 17–25. <https://doi.org/10.1055/s-0041-1726478>
- Carrasco-Ribelles, L. A., Llanes-Jurado, J., Gallego-Moll, C., Cabrera-Bean, M., Monteagudo-Zaragoza, M., Violán, C., & Zabaleta-Del-Olmo, E. (2023). Prediction models using artificial intelligence and longitudinal data from electronic health records: a systematic methodological review. *J Am Med Inform Assoc*, 30(12), 2072–2082. <https://doi.org/10.1093/jamia/ocad168>
- Clement, J., & Maldonado, A. Q. (2021). Augmenting the Transplant Team With Artificial Intelligence: Toward Meaningful AI Use in Solid Organ Transplant. *Front Immunol*, 12, 694222. <https://doi.org/10.3389/fimmu.2021.694222>
- Dobson, R., Wihongi, H., & Whittaker, R. (2023). Exploring patient perspectives on the secondary use of their personal health information: an interview study. *BMC Med Inform Decis Mak*, 23(1), 66. <https://doi.org/10.1186/s12911-023-02143-1>
- Ecycle. Pegada de carbono da inteligência artificial. eCycle, 2024. Disponível em: <https://www.ecycle.com.br/pegada-de-carbono-da-inteligencia-artificial/>. Acesso em: 16 de novembro de 2024.
- Gellert, G. A. (2023). Medical Scribes: Symptom or Cause of Impeded Evolution of a Transformative Artificial Intelligence in the Electronic Health Record? *Perspect Health Inf Manag*, 20(1), 1d–1d. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC9860472>
- Jain, A., Way, D., Gupta, V., Gao, Y., de Oliveira Marinho, G., Hartford, J., Sayres, R., Kanada, K., Eng, C., Nagpal, K., DeSalvo, K. B., Corrado, G. S., Peng, L., Webster, D. R., Dunn, R. C., Coz, D., Huang, S. J., Liu, Y., Bui, P., & Liu, Y. (2021). Development and Assessment of an Artificial Intelligence-Based Tool for Skin Condition Diagnosis by Primary Care Physicians and Nurse Practitioners in Teledermatology Practices. *JAMA Netw Open*, 4(4), e217249–e217249. <https://doi.org/10.1001/jamanetworkopen.2021.7249>

Jeong, H., & Kamaleswaran, R. (2022). Pivotal challenges in artificial intelligence and machine learning applications for neonatal care. *Semin Fetal Neonatal Med*, 27(5), 101393. <https://doi.org/10.1016/j.siny.2022.101393>

Kashyap, S., Morse, K. E., Patel, B., & Shah, N. H. (2021). A survey of extant organizational and computational setups for deploying predictive models in health systems. *J Am Med Inform Assoc*, 28(11), 2445–2450. <https://doi.org/10.1093/jamia/ocab154>

Kenner, B. J., Abrams, N. D., Chari, S. T., Field, B. F., Goldberg, A. E., Hoos, W. A., Klimstra, D. S., Rothschild, L. J., Srivastava, S., Young, M. R., & Go, V. L. W. (2021). Early Detection of Pancreatic Cancer: Applying Artificial Intelligence to Electronic Health Records. *Pancreas*, 50(7), 916–922. <https://doi.org/10.1097/MPA.0000000000001882>

Khoury, P., Srinivasan, R., Kakumanu, S., Ochoa, S., Keswani, A., Sparks, R., & Rider, N. L. (2022). A Framework for Augmented Intelligence in Allergy and Immunology Practice and Research-A Work Group Report of the AAAAI Health Informatics, Technology, and Education Committee. *J Allergy Clin Immunol Pract*, 10(5), 1178–1188. <https://doi.org/10.1016/j.jaip.2022.01.047>

Kulkarni, P. A., & Singh, H. (2023). Artificial Intelligence in Clinical Diagnosis: Opportunities, Challenges, and Hype. *JAMA*, 330(4), 317–318. <https://doi.org/10.1001/jama.2023.11440>

Ladyzynski, P., Molik, M., & Foltynski, P. (2022). Dynamic Bayesian networks for prediction of health status and treatment effect in patients with chronic lymphocytic leukemia. *Sci Rep*, 12(1), 1811. <https://doi.org/10.1038/s41598-022-05813-8>

Letterie, G. (2021). Three ways of knowing: the integration of clinical expertise, evidence-based medicine, and artificial intelligence in assisted reproductive technologies. *J Assist Reprod Genet*, 38(7), 1617–1625. <https://doi.org/10.1007/s10815-021-02159-4>

Li, P., Yang, J., Islam, M. A., & Ren, S. Tornando a IA menos 'sedenta': Descobrindo e abordando a pegada hídrica secreta dos modelos de IA. 2023. Disponível em: <https://arxiv.org/abs/2304.03271>. Acesso em: 16 de novembro de 2024.

Martineau, K. Reduzindo a pegada de carbono do aprendizado profundo. MIT News, 7 ago. 2020. Disponível em: <https://news.mit.edu/2020/shrinking-deep-learning-carbon-footprint-0807>. Acesso em: 16 de novembro de 2024.

Mattay, G. S., Griffey, R. T., Narra, V., Poirier, R. F., & Bierhals, A. (2023). Impact of Predictive Text Clinical Decision Support on Imaging Order Entry in the Emergency Department. *J Am Coll Radiol*, 20(12), 1250–1257. <https://doi.org/10.1016/j.jacr.2023.05.023>

Maurovich-Horvat, P. (2021). Current trends in the use of machine learning for diagnostics and/or risk stratification in cardiovascular disease. *Cardiovasc Res*, 117(5), e67–e69. <https://doi.org/10.1093/cvr/cvab059>

Maurud, S., Henni, S. H., & Moen, A. (2023). Health Equity in Clinical Research Informatics. *Yearb Med Inform*, 32(1), 138–145. <https://doi.org/10.1055/s-0043-1768720>

Mendo, I. R., Marques, G., de la Torre Díez, I., López-Coronado, M., & Martín-Rodríguez, F. (2021). Machine Learning in Medical Emergencies: a Systematic Review and Analysis. *J Med Syst*, 45(10), 88. <https://doi.org/10.1007/s10916-021-01762-3>

Mohsen, F., Ali, H., El Hajj, N., & Shah, Z. (2022). Artificial intelligence-based methods for fusion of electronic health records and imaging data. *Sci Rep*, 12(1), 17981. <https://doi.org/10.1038/s41598-022-22514-4>

Montanaro, V. V. A., Hora, T. F., Guerra, A. A., Silva, G. S., Bezerra, R. de P., Oliveira-Filho, J., Santos, L. S. B., de Melo, E. S., Alves de Andrade, L. P., Junior, W. A. de O., de Meira, F. C. A., Nunes, M. do C. P., Oliveira, E. M. de J., & de Freitas, G. R. (2021). Artificial Intelligence-Based Decision for the Prediction of Cardioembolism in Patients with Chagas Disease and Ischemic Stroke. *J Stroke Cerebrovasc Dis*, 30(10), 106034. <https://doi.org/10.1016/j.jstrokecerebrovasdis.2021.106034>

Morey, J. R., Zhang, X., Yaeger, K. A., Fiano, E., Marayati, N. F., Kellner, C. P., De Leacy, R. A., Doshi, A., Tuhim, S., & Fifi, J. T. (2021). Real-World Experience with Artificial Intelligence-Based Triage in Transferred Large Vessel Occlusion Stroke Patients. *Cerebrovasc Dis*, 50(4), 450–455. <https://doi.org/10.1159/000515320>

Morin, O., Vallières, M., Braunstein, S., Ginart, J. B., Upadhaya, T., Woodruff, H. C., Zwanenburg, A., Chatterjee, A., Villanueva-Meyer, J. E., Valdes, G., Chen, W., Hong, J. C., Yom, S. S., Solberg, T. D., Löck, S., Seuntjens, J., Park, C., & Lambin, P. (2021). An artificial intelligence framework integrating longitudinal electronic health records with real-world data enables continuous pan-cancer prognostication. *Nat Cancer*, 2(7), 709–722. <https://doi.org/10.1038/s43018-021-00236-2>

Reeves, J. J., Pageler, N. M., Wick, E. C., Melton, G. B., Tan, Y.-H. G., Clay, B. J., & Longhurst, C. A. (2021). The Clinical Information Systems Response to the COVID-19 Pandemic. *Yearb Med Inform*, 30(1), 105–125. <https://doi.org/10.1055/s-0041-1726513>

Ren, Y., Loftus, T. J., Datta, S., Ruppert, M. M., Guan, Z., Miao, S., Shickel, B., Feng, Z., Giordano, C., Upchurch, G. R., Rashidi, P., Ozrazgat-Baslanti, T., & Bihorac, A. (2022). Performance of a Machine Learning Algorithm Using Electronic Health Record Data to Predict Postoperative Complications and Report on a Mobile Platform. *JAMA Netw Open*, 5(5), e2211973–e2211973. <https://doi.org/10.1001/jamanetworkopen.2022.11973>

Riskin, D., Cady, R., Shroff, A., Hindiyeh, N. A., Smith, T., & Kymes, S. (2023). Using artificial intelligence to identify patients with migraine and associated symptoms and conditions within electronic health records. *BMC Med Inform Decis Mak*, 23(1), 121. <https://doi.org/10.1186/s12911-023-02190-8>

Rodriguez-Diaz, E., Jepeal, L. I., Baffy, G., Lo, W.-K., MashimoMD, H., A'amar, O., Bigio, I. J., & Singh, S. K. (2022). Artificial Intelligence-Based Assessment of Colorectal Polyp Histology by Elastic-Scattering Spectroscopy. *Dig Dis Sci*, 67(2), 613–621. <https://doi.org/10.1007/s10620-021-06901-x>

Rostam Niakan Kalhori, S., Tanhapour, M., & Gholamzadeh, M. (2021). Enhanced childhood diseases treatment using computational models: Systematic review of intelligent experiments

heading to precision medicine. *J Biomed Inform*, 115, 103687. <https://doi.org/10.1016/j.jbi.2021.103687>

Sagheb, E., Wi, C.-I., Yoon, J., Seol, H. Y., Shrestha, P., Ryu, E., Park, M., Yawn, B., Liu, H., Homme, J., Juhn, Y., & Sohn, S. (2022). Artificial Intelligence Assesses Clinicians' Adherence to Asthma Guidelines Using Electronic Health Records. *J Allergy Clin Immunol Pract*, 10(4), 1047-1056.e1. <https://doi.org/10.1016/j.jaip.2021.11.004>

Samaran, R., L'Orphelin, J.-M., Dreno, B., Rat, C., & Domp Martin, A. (2021). Interest in artificial intelligence for the diagnosis of non-melanoma skin cancer: a survey among French general practitioners. *Eur J Dermatol*, 31(4), 457–462. <https://doi.org/10.1684/ejd.2021.4090>

Samaras, A., Bekiaridou, A., Papazoglou, A. S., Moysidis, D. V, Tsoumakas, G., Bamidis, P., Tsigkas, G., Lazaros, G., Kassimis, G., Fragakis, N., Vassilikos, V., Zarifis, I., Tziakas, D. N., Tsioufis, K., Davlourous, P., & Giannakoulas, G. (2023). Artificial intelligence-based mining of electronic health record data to accelerate the digital transformation of the national cardiovascular ecosystem: design protocol of the CardioMining study. *BMJ Open*, 13(4), e068698–e068698. <https://doi.org/10.1136/bmjopen-2022-068698>

Sariyar, M., & Holm, J. (2022). Medical Informatics in a Tension Between Black-Box AI and Trust. *Stud Health Technol Inform*, 289, 41–44. <https://doi.org/10.3233/SHTI210854>

Shevchenko, E. V, Danilov, G. V, Usachev, D. Y., Lukshin, V. A., Kotik, K. V, & Ishankulov, T. A. (2022). [Artificial intelligence guided predicting the length of hospital-stay in a neurosurgical hospital based on the text data of electronic medical records]. *Zh Vopr Neirokhir Im N N Burdenko*, 86(6), 43–51. <https://doi.org/10.17116/neiro20228606143>

Strauss, A. T., Sidoti, C. N., Sung, H. C., Jain, V. S., Lehmann, H., Purnell, T. S., Jackson, J. W., Malinsky, D., Hamilton, J. P., Garonzik-Wang, J., Gray, S. H., Levan, M. L., Hinson, J. S., Gurses, A. P., Gurakar, A., Segev, D. L., & Levin, S. (2023). Artificial intelligence-based clinical decision support for liver transplant evaluation and considerations about fairness: A qualitative study. *Hepatol Commun*, 7(10). <https://doi.org/10.1097/HC9.0000000000000239>

Tashman, A. P. (2022). Practical Implementation and Challenges of Artificial Intelligence-Driven Electronic Health Record Evaluation: Protected Health Information. *Adv Chronic Kidney Dis*, 29(5), 427–430. <https://doi.org/10.1053/j.ackd.2022.05.003>

Wu, D. T. Y., Vithala, T. M., Vu, H., Xin, C., Li, L., Roberto, A., Alexander, A., Sohal, D. P., Herzog, T. J., & Lee, J. J. (2022). Development of a Clinical Decision Support System to Predict Unplanned Cancer Readmissions. *AMIA Annu Symp Proc*, 2022, 1173–1180. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC10148334>

Xu, Q., Xie, W., Liao, B., Hu, C., Qin, L., Yang, Z., Xiong, H., Lyu, Y., Zhou, Y., & Luo, A. (2023). Interpretability of Clinical Decision Support Systems Based on Artificial Intelligence from Technological and Medical Perspective: A Systematic Review. *J Healthc Eng*, 2023, 9919269. <https://doi.org/10.1155/2023/9919269>

Yao, X., Attia, Z. I., Behnken, E. M., Walvatne, K., Giblon, R. E., Liu, S., Siontis, K. C., Gersh, B. J., Graff-Radford, J., Rabinstein, A. A., Friedman, P. A., & Noseworthy, P. A. (2021). Batch enrollment for an artificial intelligence-guided intervention to lower neurologic events in patients



with undiagnosed atrial fibrillation: rationale and design of a digital clinical trial. *Am Heart J*, 239, 73–79. <https://doi.org/10.1016/j.ahj.2021.05.006>

Yun, H. J., Kim, H. J., Kim, S. Y., Lee, Y. S., Lim, C. Y., Chang, H.-S., & Park, C. S. (2021). Adequacy and Effectiveness of Watson For Oncology in the Treatment of Thyroid Carcinoma. *Front Endocrinol (Lausanne)*, 12, 585364. <https://doi.org/10.3389/fendo.2021.585364>

Zhou, Q., Zuley, M., Guo, Y., Yang, L., Nair, B., Vargo, A., Ghannam, S., Arefan, D., & Wu, S. (2021). A machine and human reader study on AI diagnosis model safety under attacks of adversarial images. *Nat Commun*, 12(1), 7281. <https://doi.org/10.1038/s41467-021-27577-x>

Zhu, Y., Song, T., Zhang, Z., Deng, C., Alkhalaf, M., Li, W., Yin, M., Chang, H. C. R., & Yu, P. (2022). Agitation Prevalence in People With Dementia in Australian Residential Aged Care Facilities: Findings From Machine Learning of Electronic Health Records. *J Gerontol Nurs*, 48(4), 57–64. <https://doi.org/10.3928/00989134-20220309-01>