

UNIVERSIDADE ESTADUAL DE MARINGÁ
CENTRO DE CIÊNCIAS SOCIAIS APLICADAS
DEPARTAMENTO DE CIÊNCIAS CONTÁBEIS
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS CONTÁBEIS
ÁREA DE CONCENTRAÇÃO: CONTROLADORIA

AZUCENA PERES RODRIGUES

**INTELIGÊNCIA ARTIFICIAL: DETERMINANTES DE ADOÇÃO POR
ESTABELECIMENTOS DE SAÚDE**

Maringá

2025

AZUCENA PERES RODRIGUES

**INTELIGÊNCIA ARTIFICIAL: DETERMINANTES DE ADOÇÃO POR
ESTABELECIMENTOS DE SAÚDE**

Dissertação apresentada ao Programa de Pós-Graduação em Ciências Contábeis, área de concentração Controladoria, da Universidade Estadual de Maringá como requisito parcial para obtenção do título de Mestre em Ciências Contábeis.

Orientadora: Prof^ª. Dr^ª. Katia Abbas

Agência Financiadora: CAPES

Maringá

2025

Dados Internacionais de Catalogação-na-Publicação (CIP)
(Biblioteca Central - UEM, Maringá - PR, Brasil)

R696i

Rodrigues, Azucena Peres

Inteligência artificial : determinantes de adoção por estabelecimentos de saúde /
Azucena Peres Rodrigues. -- Maringá, PR, 2025.
129 f. : il., figs., tabs.

Orientadora: Profa. Dra. Katia Abbas.

Coorientador: Prof. Dr. José Braz Hercos Júnior.

Dissertação (mestrado) - Universidade Estadual de Maringá, Centro de Ciências
Sociais Aplicadas, Departamento de Ciências Contábeis, Programa de Pós-Graduação em
Ciências Contábeis, 2025.

1. Inteligência Artificial . 2. Tecnologia da informação . 3. Instituições de Saúde. 4.
Profissionais da saúde. I. Abbas, Katia, orient. II. Hercos Júnior, José Braz, coorient. III.
Universidade Estadual de Maringá. Centro de Ciências Sociais Aplicadas. Departamento
de Ciências Contábeis. Programa de Pós-Graduação em Ciências Contábeis. IV. Título.

CDD 23.ed. 658.4038011

Vanessa de Souza Pianovski - CRB 9/1804

ATA DE DEFESA PÚBLICA

Aos trinta dias do mês de setembro do ano de dois mil e vinte e cinco, às 14h00min., no Bloco B-12 Sala 10, realizou-se, no *Campus* Sede da Universidade Estadual de Maringá, a Defesa Pública da Dissertação de Mestrado, sob o título: **“Inteligência Artificial: Determinantes de Adoção por Estabelecimentos de Saúde”**, de autoria de **Azucena Peres Rodrigues**, aluna do Programa de Pós-Graduação em Ciências Contábeis – Mestrado – Área de Concentração: Controladoria - Linha de pesquisa em Contabilidade Gerencial. A Banca Examinadora foi composta pelos professores:

Membros da Banca	Função	IES
Prof. ^a Dr. ^a Katia Abbas	Presidente	PCO/UEM
Prof. Dr. José Braz Hercos Junior	Coorientador	PCO/UEM
Prof. Dr. Valter da Silva Faia	Examinador	PCO/UEM
Prof. Dr. Carlos Alberto Grespan Bonacim	Examinador Convidado	FEA-RP/USP

Concluídos os trabalhos de apresentação e arguição, a aluna foi **APROVADA** pela Banca Examinadora. A validação da aprovação na Defesa Pública está condicionada à aluna apresentar a versão definitiva da Dissertação, no prazo de 30 (trinta) dias, de acordo com Art. 64 da Resolução nº 044/2023-CI/CSA, para a expedição do Diploma de Mestre. Para constar, a presente Ata foi lavrada e assinada pelo Coordenador do Programa e pelos membros da Banca Examinadora.

Documento assinado digitalmente
 KATIA ABBAS
Data: 13/01/2026 12:04:34-0300
Verifique em <https://validar.itu.gov.br>

Maringá Pr., 30 de setembro de 2025.

Prof.^a Dr.^a Katia Abbas
(Presidente)

Documento assinado digitalmente
 JOSE BRAZ HERCOS JUNIOR
Data: 22/12/2025 11:39:07-0300
Verifique em <https://validar.itu.gov.br>

Prof. Dr. José Braz Hercos Júnior
(Coorientador)

Documento assinado digitalmente
 VALTER DA SILVA FAIA
Data: 22/12/2025 10:39:38-0300
Verifique em <https://validar.itu.gov.br>

Prof. Dr. Valter da Silva Faia
(Examinador)



Prof. Dr. Carlos Alberto Grespan Bonacim
(Examinador Convidado – FEA-RP/USP)


PROF. DR. ROMILDO DE OLIVEIRA MORAES
COORDENADOR DO PCO/UEM

AGRADECIMENTOS

À Jeová Deus, minha fonte de coisas boas, pela dádiva da vida e por iluminar meu caminho, providenciar sempre a saída e me abençoar com oportunidades incomparáveis (Salmo 16:2; 119:165; 1 Coríntios 10:13).

À Jesus Cristo, pelo sacrifício do resgate, pelo exemplo em como tratar os demais, que me ajuda a lidar com os desafios e vislumbrar a esperança futura (Marcos 10:45; Romanos 5:8; Efésios 1:7; 1 Pedro 2:21).

A minha família imediata, pela motivação, incentivo e apoio de sempre. Meus pais e irmãs, que acompanharam cada passo dessa jornada, me dando afeto, ajuda prática, cuidado e amor (Salmo 127:3; Gálatas 5:22; 1 Coríntios 13:4-8). Meus tios e primos, que me acolheram e possibilitaram meu estudo em outra cidade (Ester 2:6,7).

Aos meus amigos próximos, que compreenderam minha ausência e torceram pelo meu sucesso, sempre com palavras de encorajamento (Provérbios 17:17; 18:24).

À professora Dra. Katia Abbas, que me orientou ao longo desses anos, não só neste mestrado, mas também na graduação e outros projetos, muito obrigada por toda a atenção, carinho, por persistir quando eu não me sentia pronta e por sempre acreditar no meu potencial (Provérbios 1:5).

Aos professores Dr. José Braz Hercos Junior, Dr. Valter da Silva Faia e Dr. Carlos Alberto Grespan Bonacim, pelas valiosas contribuições oferecidas, sempre de maneira gentil, para o aprimoramento desta pesquisa (Provérbios 11:14).

Aos colegas do PCO UEM, das turmas 8 até a 12, pela companhia nos momentos bons e ruins, especialmente Ana Paula, André, Andrea, Beatriz, Bruna, Carlos, Daniel, Fernanda, Gbenga, Isabella, Janaina, Jhonatan, Julia, Mori, Rebeca, Renata e Tomás (Eclesiastes 4: 9,10).

Aos professores do PCO UEM pelos ensinamentos transmitidos durante este tempo.

À secretária Leoni que foi sempre amável, cordial e prestativa.

Ao Centro Regional de Estudos para o Desenvolvimento da Sociedade da Informação (CETIC.br), especialmente sua representante Luciana Portilho, pela disponibilização dos dados fundamentais para a realização desta pesquisa.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) pela concessão de recursos financeiros durante meu mestrado.

Obrigada!

“Eu voltei meu coração para conhecer, investigar e procurar a sabedoria e a razão por trás das coisas e para entender a maldade da insensatez e a tolice da loucura. [...] O coração do sábio discernirá o tempo certo e a maneira certa de agir. Para tudo há um tempo e uma maneira de agir, porque as dificuldades da humanidade são muitas. Visto que nenhum homem conhece o futuro, quem pode lhe dizer o que vai acontecer? [...] Eu vi tudo isso e me pus a refletir em todo o trabalho que se tem feito debaixo do sol enquanto homem domina homem para o seu prejuízo”

Salomão (Eclesiastes 7:25; 8:5-7, 9)

Rodrigues, A. P. (2025). *Inteligência Artificial: Determinantes de Adoção por Estabelecimentos de Saúde*. Dissertação de Mestrado em Ciências Contábeis, Universidade Estadual de Maringá, Maringá, PR, Brasil.

RESUMO

O objetivo do estudo foi investigar os fatores determinantes da adoção de inteligência artificial (IA) na saúde. Por meio de uma revisão sistemática foi possível reunir os principais determinantes, facilitadores ou barreiras, para a adoção de Inteligência Artificial (IA) na saúde, apontados na literatura, utilizando a Teoria da Mudança. Entre os pacientes, os fatores facilitadores abrangem benefício percebido, confiança e familiaridade, enquanto as barreiras estão relacionadas à perda de privacidade, risco percebido e preconceitos. Para os profissionais de saúde, os principais facilitadores incluem utilidade percebida, familiarização, facilidade de uso, qualidade e precisão, enquanto as barreiras envolvem falta de conhecimento e treinamento, falta de confiança e preocupações com privacidade e segurança. Já para os gestores, as barreiras envolvem questões legais e regulatórias, complexidade e proteção de dados, enquanto os facilitadores envolvem capital humano, apoio organizacional e governamental e vantagem competitiva. Dessas três partes interessadas principais, os gestores foram menos investigados, apesar de seu papel como representantes da organização e sua relevância na tomada de decisões, o que reforça a necessidade de novas pesquisas explorando sua perspectiva, inclusive nacionalmente. Nesse sentido, com base em 651 observações dos microdados da pesquisa TIC Saúde 2024, foi possível identificar os determinantes tecnológicos, organizacionais e ambientais da adoção de Inteligência Artificial por estabelecimentos de saúde brasileiros. Utilizando o framework TOE, estatísticas descritiva e qui-quadrado, análise de correspondência (ANACOR) e regressão logística multinomial, os determinantes significativos são: infraestrutura de TIC, novas tecnologias, oferta de serviços remotos (dimensão tecnológica), envolvimento do pessoal, porte do estabelecimento com 0-50 leitos (dimensão organizacional), região sudeste e políticas governamentais (dimensão ambiental). Os determinantes acesso e manutenção dos dados, segurança dos dados (dimensão tecnológica), natureza de propriedade, financiamento, treinamento (dimensão organizacional) e localização (dimensão ambiental) não mostraram significância estatística. Os resultados revelam que, embora haja um uso moderado de tecnologias de inteligência artificial por estabelecimentos de saúde brasileiros, ainda existe um potencial significativo para ampliação. Recomenda-se que gestores envolvam o corpo clínico no processo de implementação de novas tecnologias e que órgãos governamentais promovam políticas para a adoção bem-sucedida de tecnologias baseadas em IA, pois o suporte que ela dá aos profissionais é, sem dúvidas, uma oportunidade de aumentar a eficiência dos serviços de saúde.

PALAVRAS-CHAVE: Adoção de Inteligência Artificial, Estabelecimentos de saúde, Teoria da Mudança, TOE, Revisão Sistemática, Regressão Logística Multinomial.

Rodrigues, A. P. (2025). *Artificial Intelligence: Adoption Determinants from Healthcare Establishments*. Master's Dissertation, Accounting Science Graduate Program, State University of Maringá, Maringá, PR, Brazil.

ABSTRACT

The aim of this study was to investigate the determinants of artificial intelligence (AI) adoption in healthcare. Through a systematic review, it was possible to gather the main determinants, enablers or barriers, to Artificial Intelligence (AI) adoption in healthcare, as identified in the literature, using the Theory of Change. Among patients, facilitators include perceived benefit, trust, and familiarity, while barriers are related to loss of privacy, perceived risk, and bias. For healthcare professionals, the main facilitators include practicality, familiarity, ease of use, quality, and accuracy, while barriers involve lack of knowledge and training, lack of trust, and concerns about privacy and security. For managers, barriers involve legal and regulatory issues, complexity, and data protection, while facilitators involve human capital, organizational and governmental support, and competitive advantage. Of these three important stakeholders, managers have received the least research, despite their role as representatives of the organization and their relevance in decision-making, which reinforces the need for further research exploring their perspective, including at a national level. Based on 651 observations from the TIC Saúde 2024 survey microdata, it was possible to identify the technological, organizational, and environmental determinants of AI adoption by Brazilian healthcare facilities. Using the TOE framework, descriptive statistics, chi-squared tests, correspondence analysis (ANACOR), and multinomial logistic regression, the main determinants are new technologies, provision of remote services (technological dimension), staff involvement, type of facility (0-50 beds) (organizational dimension), Southeast region, and government policies (environmental dimension). The determinants ICT infrastructure, data access and maintenance, data security (technological dimension), ownership, financing, training (organizational dimension), and location (environmental dimension) were not statistically significant. The results reveal that, although there is moderate use of AI technologies by Brazilian healthcare facilities, there is still significant potential for expansion. It is recommended that investors involve clinical staff in the process of implementing new technologies and that government agencies promote policies for the successful adoption of AI-based technologies, as the support it provides to professionals is undoubtedly an opportunity to increase the efficiency of healthcare services.

KEYWORDS: Artificial Intelligence Adoption, Healthcare Establishments, Theory of Change, TOE, Systematic Review, Multinomial Logistic Regression.

SUMÁRIO

1 INTRODUÇÃO	10
1.1 CONTEXTUALIZAÇÃO	10
1.2 OBJETIVOS	11
1.2.1 Objetivo Geral	11
1.2.2 Objetivos Específicos	11
1.3 JUSTIFICATIVA E CONTRIBUIÇÕES	11
1.4 ESTRUTURA DA DISSERTAÇÃO	13
ARTIGO 1 – DETERMINANTES DA ADOÇÃO DE INTELIGÊNCIA ARTIFICIAL NA SAÚDE: UMA REVISÃO SISTEMÁTICA SOB A ÓTICA DA TEORIA DA MUDANÇA	15
1 INTRODUÇÃO	15
2 REVISÃO DE LITERATURA.....	18
2.1 INTELIGÊNCIA ARTIFICIAL NA SAÚDE (IAS).....	18
2.2 ESTUDOS ANTERIORES SOBRE IAS	20
2.3 TEORIA DA MUDANÇA COMO ESTRUTURA TEÓRICA	21
3 PROCEDIMENTOS METODOLÓGICOS	23
4 RESULTADOS	25
4.1 ANÁLISE DOS DADOS	25
4.2 DISCUSSÃO DOS DADOS	34
5 CONSIDERAÇÕES FINAIS.....	38
REFERÊNCIAS	40
APÊNDICE A	44
ARTIGO 2 – INTELIGÊNCIA ARTIFICIAL: DETERMINANTES TECNOLÓGICOS, ORGANIZACIONAIS E AMBIENTAIS DE ADOÇÃO POR ESTABELECIMENTOS DE SAÚDE BRASILEIROS.....	47
1 INTRODUÇÃO	47
2 FUNDAMENTAÇÃO TEÓRICA.....	52
2.1 INTELIGÊNCIA ARTIFICIAL NA SAÚDE (IAS).....	52
2.2 MODELOS TEÓRICOS E TÉCNICOS DE ADOÇÃO DE IA	54
2.3 TOE (TECHNOLOGY, ORGANIZATION, ENVIROMENT) COMO ESTRUTURA DE ADOÇÃO DE IA	56
2.4 DETERMINANTES DA ADOÇÃO DE INTELIGÊNCIA ARTIFICIAL NA SAÚDE E HIPÓTESES DE PESQUISA.....	57
2.4.1 Determinantes tecnológicos	58
2.4.2 Determinantes organizacionais	63

2.4.3 Determinantes ambientais	69
3 PROCEDIMENTOS METODOLÓGICOS	72
3.1 CARACTERIZAÇÃO DA PESQUISA	72
3.2 BASE DE DADOS E DEFINIÇÃO DA POPULAÇÃO E AMOSTRA	73
3.3 VARIÁVEIS DE PESQUISA	76
3.3.1 Variável Dependente	76
3.3.2 Variáveis Independentes	77
3.4 TRATAMENTO E ANÁLISE DOS DADOS	79
4 APRESENTAÇÃO E ANÁLISE DOS RESULTADOS	82
4.1 ANÁLISE DESCRITIVA	83
4.2 ANACOR (ANÁLISE DE CORRESPONDÊNCIA) E QUI-QUADRADO.....	85
4.3 ANÁLISE DE REGRESSÃO LOGÍSTICA MULTINOMIAL.....	92
4.4 DISCUSSÃO DOS RESULTADOS	97
4.4.1 Determinantes tecnológicos	98
4.4.2 Determinantes organizacionais	101
4.4.3 Determinantes ambientais	103
5 CONSIDERAÇÕES FINAIS.....	106
REFERÊNCIAS	108
APÊNDICE A	117
APÊNDICE B.....	119
APÊNDICE C	119
APÊNDICE D	121
APÊNDICE E.....	122
APÊNDICE F.....	122
APÊNDICE G	123
APÊNDICE H.....	123
CONSIDERAÇÕES FINAIS DA DISSERTAÇÃO	125
REFERÊNCIAS	127

1 INTRODUÇÃO

1.1 CONTEXTUALIZAÇÃO

O setor da saúde enfrenta desafios relacionados a alta demanda e limitados recursos e investimentos. Por um lado, a procura por atenção médica é crescente, em função do aumento da população, doenças, calamidades e pandemias (Huang et al., 2024; Papadopoulos et al., 2020). Por outro lado, hospitais costumam ter valores fixos de insumos. Tendo em vista tal contexto, é papel dos gestores, como principais tomadores de decisão, promover a utilização eficiente dos recursos, para proporcionar o maior número de atendimentos (Roppelt et al., 2024; Wubineh et al., 2024).

Um dos caminhos seguidos para alcançar a utilização eficiente dos recursos é a aplicação de tecnologias no contexto da saúde. Nesse sentido, uma tecnologia que conquistou o interesse de profissionais e acadêmicos é a inteligência artificial (Roppelt et al., 2024). A inteligência artificial (IA) refere-se a máquinas simulando a inteligência humana (Padmanabhan et al., 2021). Essa inovação disruptiva é diferente de tecnologias anteriores porque estas tem natureza previsível e determinística, definições claras do seu processo, funcionamento e papel, ao contrário da IA (Asan et al., 2020), o que, consequentemente, possui resultados potenciais diferentes.

As oportunidades da IA na assistência à saúde envolvem otimização de processos administrativos, diagnósticos mais precisos, tratamento personalizado, superação da falta de mão de obra, aprimoração da eficiência organizacional e redução de custos (Campelo et al., 2024; Cheng et al., 2022; Roppelt et al., 2024; Sun, 2021; Wubineh et al., 2024). Os benefícios da adoção de IA em hospitais não são refletidos financeiramente de forma imediata, mas percebidos a longo prazo (Pham et al., 2024).

No entanto, essa tecnologia não é livre de riscos, preocupações e desafios. As ameaças envolvidas na adoção de IA são alvo de atenção por profissionais de saúde, que temem o impacto do uso de IA nas capacidades e competências clínicas, na introdução de erros e na perda de controle na tomada de decisões (Terry et al., 2022), isto é, perda de autonomia (Khanijahani et al., 2022). Além disso, os riscos associados aos sistemas de IA também envolvem ameaças à privacidade (Khanijahani et al., 2022), ameaças e vulnerabilidades de cibersegurança e viés algorítmico (NIC.br, 2025).

Apesar desses riscos e dos custos envolvidos na implementação de IA na saúde, as oportunidades e benefícios desse tipo de tecnologia são enxergadas por órgãos internacionais,

como a Organização Mundial da Saúde (WHO, 2021) e a Organização para a Cooperação e Desenvolvimento Econômico (Anderson & Sutherland, 2024; OECD, 2024), e órgãos nacionais (Anahp, 2023; Minsitério da Saúde, 2023), bem como hospitais públicos e privados. Visto que as potencialidades de transformação que a IA apresenta ao setor da saúde são notáveis, os fatores envolvidos na sua adoção são dignos de investigação.

1.2 OBJETIVOS

A seguir são apresentados o objetivo geral e os objetivos específicos investigados neste estudo.

1.2.1 Objetivo Geral

Investigar os fatores determinantes da adoção de inteligência artificial (IA) na saúde

1.2.2 Objetivos Específicos

- a) Reunir os principais determinantes, facilitadores ou barreiras, para a adoção de Inteligência Artificial (IA) na saúde, apontados na literatura, utilizando a Teoria da Mudança;
- b) Identificar os determinantes tecnológicos, organizacionais e ambientais da adoção de Inteligência Artificial por estabelecimentos de saúde brasileiros.

1.3 JUSTIFICATIVA E CONTRIBUIÇÕES

O estudo da adoção de IA nos estabelecimentos de saúde brasileiros se justifica devido a relevância econômica e social desse segmento, que engloba o Sistema Único de Saúde (SUS) e a saúde suplementar. Os hospitais naturalmente exigem capacidade superior de processamento de informações, visto que suas tarefas envolvem mais incerteza e interdependência complexa. Portanto, precisam aprimorar sua capacidade de processamento de informações para lidar com essa questão de forma eficaz (Pham et al., 2024), o que pode ser alcançado com a adoção de IA.

Além disso, o setor hospitalar, apesar de complexo, tem impacto social significativo, pois o alto desempenho de hospitais é benéfico para os usuários dos serviços de saúde e para a

sociedade como um todo. Por isso, nota-se a importância de estudar e investigar a possibilidade de adotar melhorias tecnológicas que afetem positivamente os hospitais, especialmente ao economizar tempo e esforço dos profissionais de saúde.

Embora pesquisas anteriores tenham investigado a adoção de IA na saúde, muitas se baseiam em apenas uma das partes interessadas, especialmente profissionais de saúde (Alshehri et al., 2024; Alsobhi et al., 2022; Asan et al., 2020; Cheng et al., 2022; Hasan et al., 2024; Kujala & Hörhammer, 2022; Wenderott et al., 2024) e pacientes (Antes et al., 2021; Armero et al., 2022; Cao et al., 2023; Esmailzadeh, 2020; Huang et al., 2024; Kerstan et al., 2024) como principais usuários dessas tecnologias. A investigação dos fatores envolvidos na adoção ou resistência à IA a partir da perspectiva de organizações é menos frequente em comparação a perspectiva dos outros dois grupos (Khanijahani et al., 2022; Pham et al., 2024; Yang et al., 2024).

Diversos autores têm expressado a necessidade de identificar determinantes influenciando a adoção de IA em organizações de saúde (Bajgain et al., 2023; Khanijahani et al., 2022; Pham et al., 2024). Portanto, é válido explorar os determinantes de organizações quanto a adoção de IA, uma vez que podem ser diferentes daqueles dos pacientes ou médicos, em função de interesses conflitantes (Padmanabhan et al., 2021), diferenças no conhecimento prévio, na experiência na área médica e nos relacionamentos de confiança (Asan et al., 2020). Além disso, organizações também enfrentam desafios normativos, relacionados a regulamentação no contexto ambiental no qual estão inseridas (Wang & Chiou, 2020).

À medida que a saúde digital, incluindo a IA, exerce um papel central no sistema de saúde, é necessário que as regulamentações e as políticas públicas andem lado a lado desse progresso, a fim de colaborar sinergicamente na criação de um ambiente seguro e confiável e na supervisão das atividades das organizações de saúde (Gonçalo et al., 2025). As novas tecnologias e seus sistemas devem ser seguros e eficazes para o uso pretendido para todas as partes envolvidas (NIC.br, 2024).

Nesse sentido a regulação da IA na saúde deve levar em conta a legislação existente sobre proteção de dados, os princípios éticos e a necessidade de transparência dos algoritmos, a fim de garantir o direito à explicação e à revisão das decisões automatizadas na assistência à saúde (Gonçalo et al., 2025). Por exemplo, no contexto brasileiro, a questão legislativa teve seu pontapé inicial com a Lei Geral de Proteção de Dados (LGPD), que introduz no ordenamento jurídico brasileiro as bases legais do direito à explicação e à revisão de decisões automatizadas (NIC.br, 2024). No entanto, outros órgãos reguladores, além da Autoridade Nacional de Proteção de Dados, devem ser inseridos na discussão e na promoção de diretrizes para uso da

IA, como a Agência Nacional de Vigilância Sanitária e as autoridades reguladoras de profissões regulamentadas, como os conselhos de medicina (Dourado & Aith, 2022).

Por fim, com este estudo, espera-se gerar informações para as partes interessadas do contexto de saúde, como pesquisadores do tema, gestores de estabelecimentos de saúde, fornecedores e desenvolvedores de tecnologias baseadas em IA, formuladores de políticas e sociedade no geral. Assim, a presente pesquisa busca contribuir de forma teórica, prática e social.

De forma teórica, reúne determinantes elencados na literatura sob a ótica da teoria da mudança, uma teoria ainda não empregada em estudos desse tipo e fornece sugestões de atividades para facilitar a adoção. Primeiramente, explora a perspectiva de três partes interessadas principais, com posterior foco empírico nos gestores. Espera-se contribuir para o desenvolvimento da literatura sobre a aplicação da IA na saúde (IAS) ao testar o efeito dos fatores que possibilitam ou atrapalham sua adoção, bem como fornecer evidências reais sobre a utilização dessas tecnologias no setor de saúde brasileiro.

De forma prática, espera-se contribuir para os estabelecimentos de saúde identificando determinantes que podem estar associados a adoção de IA, especialmente no cenário brasileiro de saúde. Inicialmente, fornece informações para auxiliar os gestores de hospitais, do setor público e privado, quanto à tomada de decisão que envolva uso de IA. Também auxilia fornecedores e desenvolvedores de tecnologias baseadas em IA a compreender o atual estágio de adoção de tais tecnologias pelo setor da saúde brasileiro e a refletir em iniciativas de aprimoramento. Também pode auxiliar órgãos governamentais no que diz respeito à formulação de políticas eficazes para promover a adoção bem-sucedida de tecnologias baseadas em IA.

Espera-se, com os resultados desse estudo, contribuir para a melhora no relacionamento entre pacientes, médicos, gestores de organizações de saúde, fornecedores de tecnologia, e formuladores de políticas. Além de contribuir para a sociedade em geral, visto que a saúde é um setor representativo para a economia do país e essencial para a garantia da vida. Assim, será possível aprimorar a compreensão de como a IA, uma das mais populares tecnologias emergentes, está sendo utilizada no país e instigar futuras discussões sobre como explorar ao máximo o potencial dela em contribuir efetivamente para a eficiência no setor hospitalar nacional.

1.4 ESTRUTURA DA DISSERTAÇÃO

Com relação à estrutura do estudo, este foi desenvolvido sob a forma de dois artigos. A Figura 1, a seguir, ilustra o *framework* de pesquisa e os artigos que foram desenvolvidos.




Figura 1 – *Framework* da pesquisa

No primeiro artigo, que é teórico, foi realizado um estudo qualitativo, que reuniu, por meio de revisão sistemática, os determinantes facilitadores e barreiras da adoção de IA na saúde. Alguns desses determinantes encontrados na literatura foram testados de forma empírica no contexto brasileiro, por meio do segundo artigo.

No segundo artigo, foram utilizados os microdados da pesquisa TIC Saúde 2024, com 651 observações cujo foco foram os gestores de estabelecimentos de saúde brasileiros. Os dados foram analisados utilizando-se estatísticas descritivas, qui-quadrado e regressão logística multinomial.

ARTIGO 1 – DETERMINANTES DA ADOÇÃO DE INTELIGÊNCIA ARTIFICIAL NA SAÚDE: UMA REVISÃO SISTEMÁTICA SOB A ÓTICA DA TEORIA DA MUDANÇA

RESUMO

Este estudo busca reunir os principais determinantes, facilitadores ou barreiras, para a adoção de Inteligência Artificial (IA) na saúde, apontados na literatura, utilizando a Teoria da Mudança. Foi realizada uma revisão sistemática seguindo o *Checklist* 2020 PRISMA, a partir de pesquisas publicadas em bases de dados da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), no período de 2019-2024. Os 39 estudos analisados foram categorizados em três perspectivas: pacientes ou público em geral, profissionais de saúde que podem ser médicos ou enfermeiros e gestores de organizações de saúde. Entre os pacientes, os fatores facilitadores abrangem benefício percebido, confiança e familiaridade, enquanto as barreiras estão relacionadas à perda de privacidade, risco percebido e preconceitos. Para os profissionais de saúde, os principais facilitadores incluem utilidade percebida, familiarização, facilidade de uso, qualidade e precisão, enquanto as barreiras envolvem falta de conhecimento e treinamento, falta de confiança e preocupações com privacidade e segurança. Já para os gestores, as barreiras envolvem questões legais e regulatórias, complexidade e proteção de dados, enquanto os facilitadores envolvem capital humano, apoio organizacional e governamental e vantagem competitiva. Os resultados mostram que, apesar do interesse crescente na adoção da IA, desafios significativos para superar as barreiras identificadas permanecem. A resistência de médicos e pacientes destaca a necessidade de estratégias para superar preocupações e ampliar o conhecimento sobre o potencial da IA. Além disso, há uma lacuna na pesquisa sobre a perspectiva organizacional, reforçando a importância de estudos futuros que aprofundem a tomada de decisão dos gestores na adoção dessas tecnologias. Este estudo contribui na compreensão do papel da IA como suporte aos profissionais de saúde. Promover uma integração eficaz entre inovação tecnológica e recursos humanos pode aprimorar a eficiência e a qualidade da assistência médica bem como o bem-estar dos pacientes.

PALAVRAS-CHAVE: Adoção de Inteligência Artificial, Estabelecimentos de saúde, Teoria da Mudança, Revisão Sistemática.

1 INTRODUÇÃO

A Inteligência Artificial (IA) é uma área da tecnologia que utiliza máquinas programadas para imitar ações e pensamentos humanos, especialmente para atingir uma meta de forma otimizada (Sun, 2021). Ela tem sido aplicada em vários tipos de organizações de saúde, além de hospitais, e, dentre as formas de utilização da tecnologia, destaca-se a exploração de seu poder preditivo (Kumar et al., 2023; Mohammed et al., 2023; Wu, 2023) e apoio à decisão clínica (Kfoury et al., 2020; Rezaee et al., 2024; Tokgöz et al., 2024). Estudos sobre IA destacam as possibilidades de superar a falta de mão de obra, aprimorar a eficiência organizacional e maximizar a precisão diagnóstica e, conseqüentemente, reduzir custos ao

evitar ineficiências e tratamentos desnecessários (Cheng et al., 2022; Hill et al., 2023; Jiao et al., 2023; Roppelt et al., 2024; Sun, 2021; Wubineh et al., 2024).

Nesse sentido, estudos anteriores demonstraram que a IA pode aumentar a eficiência clínica em diversos aspectos, como ao encurtar o tempo de trabalho ou a jornada do paciente na clínica (Jiao et al., 2023). Evidências empíricas sugerem que os hospitais que adotam tecnologias de IA podem aprimorar vários aspectos de desempenho, incluindo receita total de atendimento ambulatorial, receita total de internação, produtividade e ocupação, obtendo assim benefícios operacionais (Pham et al., 2024).

Devido a tal potencial, a IA tem conquistado o interesse de governos, instituições, acadêmicos e profissionais que buscam utilizar de forma eficiente os recursos, a fim de proporcionar maior número de atendimentos (Roppelt et al., 2024; Wubineh et al., 2024). Assim, uma preocupação comum entre gestores e demais profissionais envolvidos no processo de tomada de decisão é repensar práticas atuais e impulsionar a inovação no setor da saúde (Roppelt et al., 2024), o que pode ser alcançado por meio da adoção de novas tecnologias.

O processo envolvido na adoção de novas tecnologias para aprimorar a prestação de serviços de saúde tem sido o foco de várias pesquisas acadêmicas e empíricas (Marco-Ruiz et al., 2024; Müller et al., 2021; Pham et al., 2024; Strohm et al., 2020; Tokgöz et al., 2024; Weinert et al., 2022; Wenderott et al., 2024). Apesar da existência de revisões anteriores envolvendo o processo de aplicar Inteligência Artificial na Saúde, com emprego de diversas teorias, ainda há espaço para revisões sistemáticas, em função de diferentes resultados obtidos, com diferentes limitações (Khanijahani et al., 2022).

Para explicar esse complexo processo, pesquisadores utilizaram diversos modelos, técnicas e teorias, como a Teoria Unificada de Aceitação e Uso de Tecnologia (UTAUT) e o Modelo de Aceitação de Tecnologia (TAM). Embora estudos tenham confirmado a validade de tais abordagens na avaliação da intenção de adoção de tecnologia por profissionais de saúde, pesquisadores afirmam que a IA é diferente das tecnologias anteriores (Cheng et al., 2022).

Por um lado, as tecnologias tradicionais têm natureza relativamente previsível e determinística, tem definições claras do seu processo, funcionamento e papel e são utilizadas apenas por médicos (Asan et al., 2020; Yang et al., 2024). Por outro lado, a IA tem uma natureza complexa, pode analisar eficientemente grandes conjuntos de dados, capturar dinâmicas e padrões em evolução, gerar saídas diferentes cada vez que um determinado conjunto de entradas é recebido e, em alguns casos, podem ser acessadas diretamente por pacientes (Gama et al., 2022; Olawade et al., 2023; Yang et al., 2024).

Portanto, em função das diferenças mencionadas e devido à alta complexidade de adoção de IA na área de saúde, sua explicação pode exigir teorias e abordagens complementares as até então utilizadas para as tecnologias tradicionais (Gama et al., 2022). Nesse sentido, uma das distinções da nossa revisão é apresentar uma abordagem inovadora para entender o fenômeno da adoção das IAS: A Teoria da Mudança.

Essa teoria visa explicar detalhadamente como e por que uma iniciativa funcionará para gerar os resultados esperados (Adedeji et al., 2022; Gertler, 2015). Sua adaptabilidade no que diz respeito à captura das interações resultantes de intervenções complexas (Adedeji et al., 2022) demonstra seu potencial em orientar a investigação e análise do complexo processo de integração de IA em saúde (Omisade et al., 2023). Dentre os elementos que compõe essa teoria, destacam-se: partes interessadas, insumos, atividades e resultados.

Além disso, um dos caminhos para garantir o sucesso da aplicação da Inteligência Artificial na Saúde (IAS) é identificar determinantes internos e externos, às partes interessadas, que podem influenciar seu uso. Ou seja, identificar possíveis facilitadores e barreiras à adoção dessas tecnologias e, depois, desenvolver táticas eficazes para superá-las (Hameed et al., 2023; Roppelt et al., 2024). Ao investigar os determinantes, as revisões sistemáticas anteriores geralmente focam apenas uma parte interessada, como médicos (Asan et al., 2020; Padmanabhan et al., 2021). Embora a revisão de Yang et al. (2024) tenha investigado tanto médicos quanto pacientes, não explorou os elementos relacionados à organização. A revisão de Khanijahani et al. (2022), que examinou características das três partes interessadas mencionadas, tem um foco limitado a fatores que impactam a adoção individual e não aborda, por exemplo, fatores tecnológicos.

Tendo em vista o que foi mencionado, este estudo busca responder a seguinte questão de pesquisa: **Quais são os fatores determinantes da adoção de Inteligência Artificial na saúde?** Assim, o objetivo do estudo foi reunir os principais determinantes, facilitadores ou barreiras, para a adoção de Inteligência Artificial (IA) na saúde, apontados na literatura, utilizando a Teoria da Mudança. Para tanto, foi utilizada a técnica de revisão sistemática para levantar as pesquisas publicadas nas bases de dados disponibilizadas pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES). Obteve-se um total de 39 estudos, os quais foram analisados e categorizados a partir das premissas pautadas na Teoria da Mudança.

Esta pesquisa é uma das poucas revisões disponíveis que examinam abrangente e sistematicamente os fatores determinantes – tanto facilitadores quanto barreiras – da adoção da IA na saúde a partir de múltiplas perspectivas das partes interessadas, e, assim, contribui para o desenvolvimento teórico sobre o tema. Também contribui com a incrementação de uma

abordagem ainda não investigada neste contexto, a Teoria da Mudança, que fornece ideias iniciais para um caminho causal hipotético da implementação bem-sucedida de IA no setor de saúde. Os elementos aqui apresentados poderão servir como base ou modelo para criação de futuras cadeias de resultado personalizadas às circunstâncias de cada projeto. Ainda será possível instigar futuras discussões sobre o impacto a longo prazo e o potencial da IA em contribuir efetivamente para a eficiência no setor hospitalar.

Como contribuição prática, este estudo fornece informações úteis a pelo menos três partes interessadas principais: gestores de hospitais, fornecedores ou desenvolvedores de tecnologias de IA e órgãos governamentais. O primeiro grupo, gestores de hospitais (do setor público e privado), pode ter maior condição de tomar decisões que envolvam uso de IA. Ao decidir adotar essa tecnologia na organização, os gestores podem se beneficiar por analisar os fatores determinantes aqui apontados e evitar aqueles que são identificados como barreiras. O segundo grupo, fornecedores e desenvolvedores de IA, pode refletir sobre iniciativas de aprimoramento, ao entender que características do seu produto enxergadas pelos seus clientes e usuários como barreiras podem e devem ser alteradas. O terceiro grupo, órgãos governamentais, pode ser auxiliado na formulação de políticas eficazes para promover a adoção bem-sucedida de tecnologias baseadas em IA.

Por fim, ao considerar o impacto social significativo que a alta performance de hospitais tem, a possibilidade de adotar melhorias tecnológicas que afetem positivamente os hospitais – especialmente ao economizar tempo e esforço dos profissionais de saúde – é benéfica para os usuários dos serviços de saúde e para a sociedade como um todo.

2 REVISÃO DE LITERATURA

2.1 INTELIGÊNCIA ARTIFICIAL NA SAÚDE (IAS)

A IA é uma área da tecnologia que utiliza máquinas programadas para imitar ações e pensamentos humanos, a fim de executar tarefas que normalmente exigiriam inteligência humana (Sun, 2021). Qualquer aplicativo ou dispositivo que perceba o ambiente de maneira semelhante aos humanos e atue para atingir uma meta de forma otimizada pode ser considerado IA (Sun, 2021). Várias atividades do cotidiano estão sendo aprimoradas por meio de IA, por vezes até superando a capacidade humana, tais como: reconhecimento de fala, reconhecimento facial, recomendação, transporte autônomo, mecanismos de busca na web e assistência virtual (Ali et al., 2024). No entanto, ainda está subjugado à capacidade humana o ato de decidir como usar, onde usar e em que medida usar a IA (Deveci, 2023; Kfoury et al., 2020).

Vários setores utilizam a IA para diversos motivos e em diferentes condições (Deveci, 2023). Uma das áreas em que a aplicação de IA está se tornando cada vez mais comum é na da saúde e ocorre nas mais variadas esferas da prestação de serviços: desde prevenção até diagnóstico, triagem, análise de risco, cirurgias com robôs, acompanhamento e tratamento de doenças (Cheng et al., 2022; Jiao et al., 2023; Olawade et al., 2023; Wolff et al., 2021; Yang et al., 2024). Em ambientes de saúde, as funções da IA incluem processamento de linguagem natural para interpretar dados não estruturados, como notas clínicas ou declarações de pacientes, e aprendizado de máquina para interpretar dados estruturados, como imagens médicas ou informações genéticas (Yamaoka & Watanabe, 2023). Os benefícios dessas tecnologias atingem tanto os destinatários da assistência médica – por reduzir os tempos de espera e tornar os cuidados de saúde mais acessíveis – quanto os profissionais de saúde – por diminuir o esgotamento causado pela papelada e tarefas administrativas (Pham et al., 2024).

Devido a tais características, a implementação de tecnologias baseadas em IA tem o potencial de revolucionar a assistência médica e causar um impacto significativo em todo o setor de saúde (Hameed et al., 2023; Li et al., 2023; Marco-Ruiz et al., 2024; Tezpal et al., 2024; Wolff et al., 2021) e na ampla esfera de políticas públicas acerca do tema (Olawade et al., 2023). A IA, além de ser um campo em evolução, está sendo cada vez mais impulsionada a fim de fornecer suporte na tomada de decisões clínicas na área da saúde (Deveci, 2023). O crescente volume de dados de saúde, o papel em rápida expansão das tecnologias digitais na assistência médica e a disponibilidade de diversas opções de tratamento tornam o desenvolvimento e o uso de ferramentas baseadas em IA na prestação de cuidados uma inovação oportuna e necessária (Bajgain et al., 2023).

Nesse contexto, a adoção de IAS pode ser entendida como o estágio em que uma decisão é tomada por hospitais ou usuários individuais (como pacientes e médicos) para adotar uma tecnologia de IA (Sun, 2021). A adoção e posterior implementação da IA é altamente complexa, exigindo atividades que envolvem uma ampla gama de partes interessadas, incluindo desenvolvedores de tecnologia, reguladores de sistemas, organizações e indivíduos – profissionais, pacientes e cuidadores (Gama et al., 2022; Hill et al., 2023; Strohm et al., 2020). Um dos caminhos para garantir o sucesso da aplicação da IAS é identificar determinantes internos e externos a tais partes interessadas que podem influenciar seu uso, ou seja, identificar possíveis facilitadores e barreiras à adoção dessas tecnologias e, depois, desenvolver táticas eficazes para superá-las (Hameed et al., 2023; Roppelt et al., 2024).

2.2 ESTUDOS ANTERIORES SOBRE IAS

Estudos sobre adoção de Inteligência Artificial na saúde focam geralmente aspectos como aplicações clínicas, artigos técnicos, considerações éticas, estudos econômicos em saúde e pesquisas que examinam a adoção de IA por usuários que trabalham em instituições de saúde (Roppelt et al., 2024). A Tabela 1 reúne as principais informações das revisões de literatura anteriores sobre adoção de IAS.

Tabela 1

Síntese das revisões sistemáticas anteriores

Autor (Ano)	Contribuição e principais descobertas	Comentários
Papadopoulos et al. (2020)	Identifica prazer e personalização como os principais facilitadores da implementação de robôs. Problemas técnicos e capacidades limitadas dos robôs são as maiores barreiras.	Aplicação específica de IA para um nicho de usuários (robôs humanoides de assistência social para idosos). Faltam evidências e fatores relacionados com cuidadores formais/informais, com o ambiente, a política, a sociedade e a organização.
Asan et al. (2020)	Aponta determinantes da confiança em IA por profissionais da saúde e sugere maneiras de melhorar a confiança (justiça, transparência e robustez).	Foco limitado aos especialistas da área da saúde, ou seja, clínicos.
Padmanabhan et al. (2021)	Revela os obstáculos à implementação de IAS e descreve esforços necessários para potenciais soluções.	Perspectiva centrada no clínico, aplicado à hipertensão.
Gama et al. (2022)	Usando a Taxonomia de Nilsen, destaca a carência de desenvolvimento teórico na pesquisa sobre implementação de IAS. Confirma que potenciais desafios específicos em torno da implementação de IA são desconhecidos.	Baixa qualidade dos artigos incluídos em termos de clareza e rigor metodológicos. Amostra insuficiente, com apenas 7 artigos incluídos.
Khanijahani et al. (2022)	Usando a TAM, apresenta características organizacionais (tamanho, fluxo de trabalho, treinamento, segurança), profissionais e do paciente (utilidade percebida, desempenho, expectativa de esforço, influência social) que influenciam a adoção de IAS.	Foco limitado a fatores que impactam a adoção individual. Não aborda, por exemplo, fatores macroeconômicos, tecnológicos e regulatórios.
Van Der Vegt et al. (2023)	Mapeia onde e quando 14 barreiras e 26 facilitadores surgem no processo de implementação de algoritmos de predição de sepse.	Foco limitado a ambientes hospitalares para adultos, com pequeno número de estudos empíricos.
Olawade et al. (2023)	Destaca como a IA (modelagem preditiva) foi empregada para conter a pandemia: Previsão de doenças e de risco, Modelagem espacial, Vigilância em saúde pública, Diagnóstico.	Abordagem superficial de desafios para implementação de IA, sem apontar qual a parte interessada envolvida.
Li et al. (2023)	Identifica e categoriza 19 barreiras em três níveis: Técnico/Algoritmo, Stakeholder e Social (TASS).	Baixa qualidade dos artigos incluídos em termos de clareza e rigor metodológicos.
Terranova et al. (2024)	Aponta aplicações e benefícios do uso da IA no campo médico forense para avaliação da responsabilidade profissional.	Falta de descrição detalhada da metodologia adotada e dos critérios de inclusão e exclusão dos artigos.

Yang et al. (2024)	Usa a Teoria da resistência à inovação e visão sociotécnica para identificar antecedentes, intervenções e manifestações de resistência à IAS entre médicos e pacientes, incluindo barreiras funcionais e psicológicas.	Apesar de abordar a perspectiva de duas partes interessadas (provedores e destinatários de cuidados de saúde), não explora os elementos relacionados à organização.
--------------------	--	---

Nota: TAM (*Technology Acceptance Model*). TOE (*Technology-Organization-Environment Framework*). Elaborado pelas autoras com base nos estudos correlatos.

A Tabela 1 revela que, apesar da existência de revisões anteriores envolvendo Inteligência Artificial aplicada na Saúde, ainda há espaço para pesquisas adicionais e lacunas que precisam ser preenchidas. Devido à alta complexidade de adoção desse tipo de tecnologia na área de saúde, alguns pesquisadores também recorreram a teorias e modelos a fim de descrever e explicar tal processo.

Conforme observado na Tabela 1, diversos modelos e teorias foram empregados nas revisões e obtiveram diferentes resultados, com diferentes limitações. Embora os estudos existentes tenham sustentado a validade de modelos como TAM e UTAUT na avaliação da intenção de adoção de tecnologia tradicional por profissionais de saúde, pesquisadores afirmam que a IA é diferente das tecnologias anteriores (Cheng et al., 2022). Portanto, sua explicação pode exigir teorias complementares as até então utilizadas. Nesse sentido, uma das distinções da nossa revisão é apresentar uma abordagem inovadora: A Teoria da Mudança.

2.3 TEORIA DA MUDANÇA COMO ESTRUTURA TEÓRICA

A origem do termo Teoria da Mudança (do inglês *Theory of Change*) remete aos debates promovidos pelo Aspen Institute nos anos 1990 (Romão et al., 2023). A pesquisadora Carol Weiss, uma das participantes desses debates, foi a principal responsável pela popularização do termo e definiu uma “teoria da mudança” como uma teoria de como e por que uma iniciativa funcionará (Adedeji et al., 2022). Ou seja, é a explicação detalhada de como uma intervenção foi concebida, incluindo a lógica causal, para gerar os resultados esperados (Gertler, 2015).

A Teoria da Mudança possibilita reunir atributos para avaliar, mensurar e acompanhar o impacto, alinhado ao contexto específico da comunidade objeto da intervenção (Sugahara & Rodrigues, 2019). Essa abordagem flexível é um dos primeiros passos na elaboração de um desenho de avaliação e pode ser articulada ou modelada a partir de uma Cadeia de Resultados, a qual estabelece a relação e sequência dos principais elementos envolvidos na Teoria da Mudança, os quais são apresentados na Tabela 2 (Gertler, 2015).

Tabela 2*Principais elementos da Teoria da Mudança*

Elemento	Termo original	Conceito
1. Insumos	<i>Inputs</i>	Recursos financeiros, humanos, e outros, à disposição da iniciativa
2. Atividades	<i>Activities</i>	Ações tomadas, intervenções ou trabalho desenvolvido
3. Produtos	<i>Outputs</i>	Saídas ou Resultados intermediários
4. Resultados	<i>Outcomes</i>	Resultados prováveis de serem atingidos
5. Impacto	<i>Impact</i>	Objetivo final, que causa mudança no sistema social a longo prazo
6. Pressupostos e Riscos	<i>Assumptions and Risks</i>	Evidências da literatura ou referências ao desempenho de iniciativas semelhantes e riscos que podem afetar a obtenção dos resultados
7. Partes Interessadas	<i>Stakeholders</i>	Pessoas direta ou indiretamente envolvidas ou afetadas pelo sucesso ou fracasso da iniciativa
8. Indicadores	<i>Indicators</i>	Medidas quantitativas ou qualitativas para avaliação da iniciativa

Nota: Adaptado de Gertler (2015), Sugahara e Rodrigues (2019) e Adedeji et al. (2022)

Os três primeiros elementos, Insumos, Atividades e Produtos, dizem respeito a fase de implementação da mudança, e podem ser diretamente monitorados pelo órgão responsável pelo projeto. Os elementos quatro e cinco, Resultados e Impacto, consistem nos resultados que não estão sob o controle direto do projeto e são contingentes às mudanças comportamentais dos demais atores envolvidos na iniciativa. O sexto elemento, Pressupostos e Riscos, refere-se a evidências sobre a lógica causal proposta, obtidas na literatura ou em projetos parecidos, e riscos identificados com potencial de afetar os resultados, bem como qualquer estratégia de mitigação proposta para gerir tais riscos (Gertler, 2015). Geralmente, esses elementos são organizados de forma sequencial para formar o mapa da iniciativa, o qual é desenvolvido antes, durante e após a implementação de um programa (Adedeji et al., 2022; Breuer et al., 2018; Romão et al., 2023).

Para criar um mapa de Teoria da Mudança é usado o processo de mapeação reversa de resultados, em que se começa definindo o impacto final e os resultados de longo prazo que se deseja alcançar. A partir disso, trabalhar de forma reversa envolve apontar os resultados intermediários, intervenções e precondições ou fatores determinantes – incluindo possíveis facilitadores ou barreiras a serem superadas – necessários para atingir o impacto desejado (Breuer et al., 2018; Gilissen et al., 2017, 2018). Quando esses elementos são mapeados é possível visualizar o caminho da mudança, ou seja, o que precisará mudar, em que medida e por qual responsável (Dolan et al., 2019; Gilissen et al., 2018). A fim de mensurar e acompanhar o impacto gerado pela iniciativa, é necessário selecionar indicadores adequados na cadeia de resultados. Bons indicadores devem ser específicos, mensuráveis, atribuíveis, realistas e direcionados (Gertler, 2015). Para tanto, as partes interessadas – que podem incluir equipe, gestores, especialistas, usuários e avaliadores – devem ser envolvidas em todo esse processo (Dolan et al., 2019) e apontar indicadores ao longo da cadeia de resultados.

Essa abordagem geralmente é utilizada para implantação e avaliação de programas e projetos sociais (Ahmed & Sargent, 2021). Também está ganhando reconhecimento na área de saúde pública em relação à concepção, planejamento, implementação e avaliação de sistemas de saúde, sendo aplicada tanto para entender o problema, como também em todo o ciclo da intervenção (Adedeji et al., 2022; Chaudhuri et al., 2022). Dentre os estudos que a empregaram no contexto da saúde, destaca-se programas de promoção da saúde que buscam alcançar melhorias por meio da mudança individual e social (Dolan et al., 2019). Alguns exemplos são os seguintes: saúde mental (Breuer et al., 2018), planejamento antecipado de cuidado em casas de repouso para idosos (Gilissen et al., 2018), roteiro para cobertura universal de saúde (Chaudhuri et al., 2022), implementação de registros eletrônicos de saúde na atenção primária (Adedeji et al., 2022), uso de tecnologias geoespaciais para programação de imunização de crianças (Chaney et al., 2021), entre outros.

Apesar de raramente ter sido usada no campo da pesquisa sobre IA em saúde, a Teoria da Mudança possui potencial em orientar a investigação e análise do complexo processo de integração de IAS (Omisade et al., 2023). Esse potencial se deve especialmente a sua adaptabilidade no que diz respeito à captura das interações resultantes de intervenções complexas (Adedeji et al., 2022). Por isso, a presente revisão fez uso da abordagem da Teoria da Mudança como estrutura teórica para investigar os fatores determinantes da adoção de IAS existentes na literatura.

3 PROCEDIMENTOS METODOLÓGICOS

A fim de identificar e interpretar as pesquisas sobre o tema, foi realizada uma Revisão Sistemática entre maio e setembro de 2024. Para tanto, buscou-se responder a seguinte questão de revisão: **Quais são os fatores determinantes da adoção de Inteligência Artificial na saúde?** Com isso, o objetivo da revisão foi reunir os principais determinantes, facilitadores ou barreiras, para a adoção de Inteligência Artificial (IA) na saúde, apontados na literatura, utilizando a Teoria da Mudança. A fim de alcançar tal objetivo, a pesquisa é descritiva e a estratégia de busca consistiu na busca em bibliotecas digitais. As fontes de busca incluíram o Portal de Periódicos da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), bem como as bases nele incluídas. Os resultados foram relatados de acordo com o *checklist* PRISMA 2020 (*Preferred Reporting Item for Systematic Reviews and Meta-Analyses*)

(Page et al., 2021). Para organizar, classificar e manusear os registros encontrados foi utilizado um *software* gerenciador de referências e citações chamado *Zotero*.

O comando ou *string* de busca foi com os seguintes termos: estabelecimentos de saúde (ou hospitais ou *healthcare* ou *hospitals*), determinantes (ou fatores ou *determinants* ou *factors*), adoção (ou *adoption* ou implementação ou *implementation*) e Inteligência Artificial (ou *Artificial Intelligence*). O processo de seleção dos artigos considerou três critérios, sendo: (a) artigos escritos em inglês e português; (b) o período compreendido entre 2019 e 2024, a fim de investigar as tendências recentes de pesquisa; e (c) artigos revisados por pares, para garantir a qualidade dos estudos. Por último, artigos cujos periódicos constam entre os estratos B3 e C da Qualis Capes foram removidos, como mecanismo de controle de qualidade.

Ao iniciar a aplicação das estratégias de buscas, considerando apenas a *string* de busca e o critério (a), foram encontrados 1.615 artigos no Portal Capes. A partir do Portal Capes foram acessados artigos de diversas bases acopladas, tais como: *Elsevier BV*, *Wiley*, *JMIR Publications*, *SAGE Publishing*, *Frontiers Media*, *Emerald Publishing*, *Springer Science*, *DOAJ Directory of Open Access Journals*, *PubMed*, entre outras. Na sequência, foram eliminados os artigos que não atendiam os critérios (b) e (c). Posteriormente, procedeu-se à leitura do resumo e título, para exclusão de estudos que não estavam adequados ao tema. Artigos com foco em aspectos técnicos da IA, que simplesmente investigaram o projeto ou desenvolvimento de modelos, sistemas e aplicações de IA no setor de saúde, sem explorar os fatores envolvidos para sua adoção, foram excluídos. Em seguida, foram eliminados os artigos cujos periódicos constam entre os estratos B3 e C da Qualis. Por fim, foi realizada a leitura integral do texto, sendo considerados 39 artigos ao final dessa análise prévia.

A Figura 1 apresenta um resumo do *design* do protocolo de buscas da revisão sistemática:




Figura 1. Protocolo PRISMA (2020) da Revisão Sistemática. Adaptado de Page et al. (2021)

Com base nessas classificações, foram validados, ao final da revisão sistemática, 39 artigos que atenderam ao objetivo proposto e estão apresentados no Apêndice A. A análise dos 39 estudos visou apresentar as principais informações a respeito dos seguintes aspectos: análise temporal ao longo dos últimos cinco anos estudados, análise dos periódicos nos quais foram feitas as publicações, abordagem metodológica, ambiente de pesquisa, teorias utilizadas, perspectiva analisada e técnicas de análise de dados. Em seguida, foram apontados os principais fatores determinantes na adoção da IAS, sejam eles barreiras ou facilitadores, a partir das perspectivas das partes interessadas identificadas.

Nesse sentido, os critérios de enquadramento para fatores facilitadores ou barreiras são em função do tom e opinião encontrados nos estudos. Facilitadores envolvem características ou aspectos positivos, enquanto barreiras dizem respeito às características ou aspectos negativos. Por fim, tais fatores foram apresentados a partir da ótica Teoria da Mudança, para fornecer uma explicação lógica sobre o papel que os determinantes identificados podem causar no processo de adoção de IAS.

4 RESULTADOS

4.1 ANÁLISE DOS DADOS

Ao fazer uma análise temporal, foi possível observar que houve um aumento no número de artigos sobre determinantes do uso de Inteligência Artificial na saúde publicados nos últimos anos. Isso demonstra não só a atualidade do tema como também a preocupação dos pesquisadores em entender os fatores envolvidos na adoção de IA por estabelecimentos de saúde. Foi possível constatar que a maioria das publicações se concentrou nos anos de 2023 e 2024, representando mais de 50% dos artigos e pelo menos uma publicação por ano foi encontrada.

A Tabela 3 mostra a distribuição dos artigos revisados por área. Isso demonstra a multidisciplinariedade do tema e é evidência que o uso de IA na saúde interessa a acadêmicos de uma variada gama de cursos. Também revela a necessidade de clínicos, instituições e organizações trabalharem unidos na aplicação dessa tecnologia para melhorar processos, preservar recursos de saúde e melhorar os resultados dos pacientes (Yamaoka & Watanabe, 2023).

Tabela 3
Distribuição dos artigos revisados por área

Área do periódico	N. de artigos
Saúde Coletiva	11
Medicina	11
Interdisciplinar	5
Engenharias	5
Administração Pública e de Empresas, Ciências Contábeis e Turismo	3
Geociências	1
Computação	2
Odontologia	1

Com relação à fundamentação teórica, a maior parte dos artigos analisados não especificaram de forma explícita as suas teorias ou modelos de pesquisa, o que indica a não utilização de uma teoria. No entanto, em relação àqueles que o fizeram, destaca-se a Teoria Unificada de Aceitação e Uso da Tecnologia (do inglês, *Unified Theory of Acceptance and Use of Technology – UTAUT*), utilizada por três artigos (ID14, ID24, ID34), bem como o Modelo de Aceitação de Tecnologia (do inglês, *Technology Acceptance Model - TAM*), que foi utilizado por um estudo (ID36). Essas duas teorias, como o nome indica, exploram a aceitação tecnológica na dimensão do indivíduo, explicando sua percepção (Roppelt et al., 2024) e, por vezes, avaliam apenas a intenção individual de adoção. Embora a literatura sustente a validade de modelos como TAM e UTAUT na avaliação da intenção de adoção de tecnologia tradicional por profissionais de saúde (Cheng et al., 2022), a investigação de outras partes interessadas pode ser beneficiada por diferentes teorias.

Uma das teorias utilizadas para outra parte interessada, isto é, a organização, foi o *Framework TOE* (do inglês, *Technology-Organization-Environment*). Esse *framework* foi usado por três estudos (ID18, ID21, ID27) e explica que a adoção de tecnologias é influenciada pelas dimensões: tecnológica, organizacional e ambiental. Nesse sentido, também vale destacar o Modelo HOT-fit (do inglês, *Human-Organization-Technology-fit model*), utilizado por três estudos (ID18, ID27, ID35), que explora a influência da dimensão humana nesse fenômeno de adoção de novas tecnologias.

A Tabela 4 apresenta a teoria utilizada e os métodos de análise informados nos artigos da amostra.

Tabela 4

Teoria e método de análise

ID	Teoria	Método de análise
1	<i>Resistance theory</i>	Quantitativo. Questionário, análise fatorial confirmatória (AFC)
2	Não especificada	Quantitativo. Questionários, análise fatorial exploratória e confirmatória
3	NASSS	Qualitativo. Estudo de caso múltiplo incorporado, 24 entrevistas semiestruturadas de sete hospitais holandeses
4	Não especificada	Quantitativo. Questionário com 307 indivíduos nos Estados Unidos
5	TDF e COM-B	Qualitativo. Análise de conteúdo de Mayring. Entrevistas telefônicas semiestruturadas com dentistas e pacientes (amostragem bola de neve)
6	Não especificada	Quantitativo. Análises fatoriais exploratórias e confirmatórias. Análises descritivas e correlacionais. Modelo de regressão multivariável
7	Poder social	Qualitativo. Estudo de casos múltiplos de 3 hospitais na China. Entrevistas semiestruturadas, observações participativas e análise de documentos. <i>Software NVivo 11</i>
8	Não especificada	Qualitativo. Estudo de caso de uso do GPT-3
9	Não especificada	Misto. Questionário com profissionais de saúde que usam verificadores de sintomas para triagem na Finlândia. Modelo de regressão linear OLS e regressão logística. <i>Software Atlas.ti</i>
10	Não especificada	Quantitativo. Questionário, estatística descritiva. <i>Software REDCap e SPSS</i>
11	Não especificada	Qualitativo. Entrevistas telefônicas semiestruturadas, Análise de Mayring
12	Não especificada	Quantitativo. Experimento com Deep Learning, estatística descritiva com dados de MRI
13	Não especificada	Qualitativo. Análise temática de dados. 14 entrevistas com stakeholders de assistência médica e saúde digital em Ontário. <i>Software NVivo</i>
14	UTAUT e HCT	Quantitativo. Modelagem de equações estruturais, Análise Fatorial Confirmatória
15	Não especificada	Misto. Questionário 22 perguntas (algumas abertas). Análise de conteúdo temática. Estatística Descritiva. Regressão Logística binária e Multivariada. <i>Software SPSS</i> .
16	Não especificada	Qualitativo. Entrevistas, análise temática
17	Não especificada	Quantitativo. Questionário (escala <i>likert</i>) software REDCap. <i>Software SAS</i>
18	TOE e HOT-fit	Misto. <i>Rough SWARA</i> usado para classificar fatores de adoção de IA
19	Não especificada	Qualitativo. Workshops com grupo multidisciplinar de partes interessadas, incluindo desenvolvedores, pacientes, profissionais de saúde e reguladores
20	<i>Swiss Cheese</i>	Qualitativo. Relato de caso
21	DOI e TOE	Quantitativo. Questionário com 512 gerentes seniores de TI/SI em organizações públicas/privadas localizadas na Jordânia. PLS-SEM
22	Não especificada	Qualitativo. Discussões de grupo focal e 38 entrevistas por videoconferência: 22 pacientes com histórico de infarto do miocárdio e 16 profissionais de saúde
23	Não especificada	Quantitativo. Questionário, PLS-SEM. <i>Software Smart-PLS 3</i>

24	UTAUT	Quantitativo. Questionário, estatísticas descritivas, equações estruturais, análise fatorial confirmatória. <i>Software R</i>
25	DOI	Misto. Estudo de caso. Metodologia LMAW baseada em Aczel–Alsina
26	10 Princípios heurísticos de Nielsen	Quantitativo. Método de inspeção com 3 especialistas e 346 usuários finais válidos, método de avaliação heurística, teste ANOVA e análises de regressão linear múltipla
27	Estrutura HTOE (HOT-fit/TOE)	Quantitativo. Questionário escala <i>likert</i> , abordagem híbrida de tomada de decisão <i>fuzzy</i> , método DEMATEL, algoritmo MMDE
28	CFIR	Qualitativo. Entrevistas semiestruturadas, análise temática
29	Não especificada	Misto. Revisão da literatura. Questionário com 22 participantes (pesquisadores, provedores de tecnologia, equipe hospitalar e formuladores de políticas), escala <i>likert</i> de 5 pontos. <i>Software Microsoft Excel</i>
30	OIPT	Quantitativo. Dados secundários. 246 hospitais com adoção de IA e 246 hospitais que não incorporaram a IA. Regressão logística e OLS
31	Não especificada	Quantitativo. Questionário. Estatísticas descritivas, inferenciais, testes t, regressão logística, análise temática de respostas abertas. <i>Software SPSS</i>
32	Processo duplo de julgamento e tomada de decisão	Quantitativo. Questionário com 378 participantes, Teste IAT
33	Não especificada	Qualitativo. 46 Entrevistas semiestruturadas com implementadores de IA clínica de países europeus e da América do Norte e do Sul, analisadas com o método de estrutura
34	UTAUT	Quantitativo. Questionário, PLS-SEM. <i>Software Stata</i>
35	HOT fit	Quantitativo. Pesquisa online com 118 gerentes de hospitais alemães sobre fatores para implementação de sistema de suporte à decisão. Estatísticas descritivas, escala <i>likert</i> de cinco pontos. <i>Software Excel, SPSS</i>
36	Workflow Integration e TAM	Qualitativo. Estudo de caso com entrevistas, análise de conteúdo. <i>Software MAXQDA</i>
37	TTM e SRT	Quantitativo. Questionário <i>likert</i> , experimento FSE, PLS-SEM
38	Não especificada	Quantitativo. Questionário com 5 pontos <i>likert</i> . Teste t independente, ANOVA (unidirecional), correlação de Pearson, regressão linear múltipla e regressão logística. <i>Software SPSS</i>
39	Não especificada	Quantitativo. Questionário online, estatística descritiva, teste de correlação de <i>Spearman</i> . <i>Software IBM SPSS</i>

Nota: ID (Identificação dos artigos). NASSS (*Non-adoption, Abandonment, Scale-up, Spread, and Sustainability*); TDF (*Theoretical Domains Framework*); COM-B (*Capabilities, Opportunities and Motivations influencing Behaviors*); UTAUT (*Unified Theory of Acceptance and Use of Technology*); HCT (*Human–Computer Trust Theory*); TAM (*Technology Acceptance Model*); TOE (*Technology-Organization-Environment Framework*); HOT-fit (*Human-Organization-Technology fit Framework*); R-SWARA (*Rough Step-wise Assessment Ratio Analysis*); DOI (Teoria da Difusão da Inovação); OLS (*Ordinary Least Squares*); PLS-SEM (*Partial least square structural equation modelling*); LMAW (*Logarithm Methodology of Additive Weights*); DEMATEL (*fuzzy Decision-Making Trial and Evaluation Laboratory*); MMDE (*Maximum Mean de-Entropy*); CFIR (*Consolidated Framework for Implementation Research*); OIPT (*Organizational information processing theory*); IAT (*Implicit associations test*); TTM (*Trust in Technology Model*); SRT (*Social Response Theory*); FSE (*Free simulation experiment*); ANOVA (Análise de variância).

A Tabela 4 revela que os artigos da amostra utilizaram diferentes teorias. Além disso, demonstra que variados métodos qualitativos ou quantitativos são úteis para compreender o fenômeno da adoção de inteligência artificial bem como identificar os fatores determinantes. Quanto ao *design* metodológico, percebe-se que os artigos apresentaram desenhos de estudo heterogêneos.

Alguns estudos utilizaram métodos quantitativos com aplicação de questionários e testes estatísticos, enquanto outros treze utilizaram abordagem qualitativa ou mista. É possível

perceber uma preferência pelo uso de entrevistas e estudos de caso quando a abordagem é qualitativa. Nos estudos quantitativos a tendência foi de questionários e testes estatísticos diversos. Entre os testes estatísticos mais utilizados estão os modelos de regressão logística e linear, bem como análise de variância e fatorial, acompanhados de estatísticas descritivas.

Além da abordagem metodológica adotada, é importante analisar o objeto e amostra de realização dos estudos. Embora o setor hospitalar, com seus pacientes e profissionais, tenha sido o foco principal da revisão, percebe-se que as pesquisas estão sendo realizadas em vários tipos de organizações relacionadas saúde. Análises realizadas em cadeias de suprimentos (ID18, ID25) e com profissionais de odontologia (ID5, ID14), fisioterapia (ID15) e farmácia (ID38) também podem contribuir para o entendimento acerca dos determinantes envolvidos no uso de IAS. Estudos sobre a IA nesses variados contextos estão surgindo cada vez mais devido ao interesse e uso crescente desse tipo de tecnologia. Além disso, nota-se que as pesquisas são todas internacionais, abrangendo principalmente contextos norte-americanos, europeus e asiáticos, refletindo a abrangência global do tema.

Ainda sobre o objeto de estudo, percebe-se a possibilidade de uma divisão da pesquisa existente em três categorias de partes interessadas (ou *stakeholders*) de acordo com o sétimo elemento da Teoria da Mudança: pacientes, profissionais de saúde e instituições de saúde (por exemplo, hospitais, clínicas). Dezesete artigos investigaram a percepção dos médicos, enfermeiros e outros profissionais sobre IAS. Dez estudos exploraram o ponto de vista dos tomadores de serviço de saúde, ou seja, os pacientes. Apenas seis estudos focaram no papel da administração das organizações de saúde, ou seja, a partir da percepção de seus gestores (ID3, ID10, ID18, ID21, ID27, ID35), o que indica que pesquisas a partir dessa parte interessada ainda estão em fase de desenvolvimento conceitual e são necessárias pesquisas empíricas adicionais.

Para diferentes adotantes, há diferentes fatores que influenciam a adoção da tecnologia, e os modelos de pesquisa também diferem. No que diz respeito aos fatores determinantes da adoção de tecnologias de inteligência artificial na saúde, foi percebido que alguns estudos enfatizaram os elementos facilitadores à adoção de IAS enquanto outros focaram em barreiras que influenciam a resistência a IAS. A relação entre os fatores determinantes (facilitadores ou barreiras) identificados nos artigos e as partes interessadas (perspectivas de profissionais, pacientes ou organizações) são apresentadas na Tabela 5.

Tabela 5

Facilitadores e Barreiras por perspectiva (*Stakeholder* ou parte interessada) analisada

Perspectiva (Stakeholder)	Facilitadores	Barreiras
Profissionais de saúde	Utilidade/usabilidade percebida (ID9, ID22, ID24, ID28, ID36) Expectativa de desempenho (ID14, ID23) Benefícios percebidos (ID9, ID31) Qualidade e precisão (ID5, ID16, ID28) Familiarização (ID22, ID36, ID38) Influência social/Motivação de colegas (ID24, ID36) Apoio organizacional (ID9) Qualificação educacional e experiência (ID15) Expectativa de esforço (ID14, ID23) Carga de trabalho reduzida (ID5) Transparência (ID36, ID38) Presença de estratégias de inovação no hospital (ID3) Facilidade de uso (ID16, ID28, ID31) Confiança (ID23, ID28) Acesso a evidências sobre potencial (ID28) Treinamento (ID28, ID39) Funcionamento colaborativo (ID28)	Falta/variação de confiança (ID3, ID15, ID31) Preocupação com privacidade/segurança (ID31, ID28, ID38, ID39) Medo ou resistência a mudança (ID1, ID9) Ameaça a Autonomia (ID9, ID28) Preocupação com perda de emprego (ID16, ID38) Alto custo (ID15, ID31) Preocupação com dependência (ID5, ID16, ID20, ID28) Problemas de integração, interoperabilidade, infraestrutura (ID31, ID36) Falta de conhecimento, treinamento ou afinidade com tecnologia (ID1, ID9, ID15, ID20, ID31) Responsabilidade (ID5) Desempenho instável (ID3, ID36) Falta de regulamentação (ID38) Falta de interesse (ID22) Falta de necessidade (ID1) Preocupação com qualidade dos dados (ID16, ID20) Usabilidade ruim (ID1, ID36) Preocupação legais e éticas (ID20, ID38) Viés de automação (ID20)
Pacientes	Expectativa de desempenho (ID4, ID34) Benefício percebido (ID4, ID17, ID32) Influência social (ID34) Nível de escolaridade (ID17) Qualidade e precisão (ID2, ID5, ID6) Confiança (ID6, ID7, ID37) Familiarização (ID17, ID22) Expectativa de esforço (ID34) Usabilidade e satisfação (ID26) Tomada de decisão compartilhada (ID2) Elemento humano do atendimento (ID2)	Perda de privacidade (ID2, ID4, ID6, ID7, ID17, ID37) Responsabilidade (ID4, ID5) Preconceitos e injustiça (ID2, ID4, ID6) Falta de confiança (ID4, ID17) Risco percebido (ID4, ID32, ID37) Alto custo (ID2, ID6) Falta de interesse (ID22) Falta de transparência (ID6, ID7) Falta de regulamentação (ID4) Preferência por contato humano (ID22)
Gestores	Capital humano, Competência e treinamento da equipe (ID10, ID18, ID27, ID35) Prontidão para inovação, mudança/agilidade (ID18, ID27, ID35) Sofisticação tecnológica, e equipamento técnico (ID18, ID21, ID35) Recursos financeiros (ID18, ID33) Apoio de políticas governamentais (ID18, ID21, ID27) Pressão e ambiente competitivo (ID18, ID21, ID27) Estratégia org. inovadora (ID3, ID21) Tamanho da empresa (ID18, ID27) Expectativa do valor agregado (ID3, ID35) Cultura organizacional (ID18, ID27) Apoio organizacional e do nível de gestão (ID18, ID21, ID27, ID35) Qualidade e integridade de dados (ID10, ID18) Facilidade de uso do sistema (ID35) Confiança (ID35)	Falta de recursos humanos (ID10) Falta de recursos financeiros (ID10) Falta de compatibilidade ou interoperabilidade (ID10) Custo envolvido (ID27) Processos de implementação não estruturados (ID3) Complexidade (ID21) Questões legais e Regulação governamental (ID10, ID21) Aspectos éticos (ID10) Preocupação com privacidade e proteção de dados (ID10, ID27) Complexidade (ID21, ID27)

Vantagem competitiva (ID10, ID18, ID21, ID27)
 Alívio da carga de trabalho (ID10)
 Interoperabilidade (ID18)
 Compatibilidade (ID21, ID27, ID35)
 Participação de usuários na fase de desenvolvimento e implantação (ID35)

Nota: Elaborado pelas autoras com base nos achados da revisão.

A Tabela 5 revela uma lista longa, mas não exaustiva, de determinantes que influenciam a adoção ou rejeição de IA por pacientes, profissionais de saúde, gestores e outros. Muitos dos fatores incluídos são compartilhados pelos diferentes atores envolvidos, enquanto outros foram percebidos para apenas um grupo. Percebe-se também que algumas variáveis mencionadas nos estudos podem assumir um papel facilitador ou impeditivo, a depender do contexto. A presença de algumas variáveis foi apontada por algumas pesquisas como fator facilitador (exemplo: Confiança), enquanto a ausência das mesmas variáveis foi apontada por outras pesquisas como barreira (exemplo: Falta de confiança). Isso mostra que alguma atividade ou ação pode ser tomada para preencher essa ausência, desenvolver esses sentimentos ou transformar o status quo, ideia condizente com a Teoria da Mudança.

Os achados da revisão concretizam o fato de que os médicos têm opiniões diversas sobre IA (Marco-Ruiz et al., 2024), e a intenção de sua adoção pelos profissionais de saúde pode se alterar devido a mudanças tecnológicas e ambientais (Cheng et al., 2022). Para médicos e enfermeiros os determinantes facilitadores principais são Utilidade ou usabilidade percebida, Familiarização, Facilidade de uso, Qualidade e precisão. As barreiras que inibem a adoção por parte de profissionais de saúde são Falta de conhecimento, treinamento ou afinidade com tecnologia, Falta ou variação de confiança, Preocupação com privacidade e com segurança. Isso mostra que, embora os profissionais conheçam o potencial da IA e acreditem que ela pode contribuir para que trabalhem de forma mais eficiente, ainda são necessários programas para educar os prestadores de serviço de saúde sobre o potencial e as limitações da IA (Marco-Ruiz et al., 2024).

A pesquisa disponível que examina os pontos de vista dos pacientes sobre IA indica que o público percebe benefícios e riscos e tem disposição mista para adotar essas tecnologias (Antes et al., 2021). Para pacientes, os determinantes facilitadores principais são Benefício percebido, Confiança, Familiaridade e Qualidade e precisão. As barreiras comumente mencionadas são preocupações relacionadas à Perda de privacidade, Risco percebido e Preconceitos e injustiça. Por exemplo, Pelly et al. (2023) investigaram pacientes com histórico de infarto e médicos dessa especialidade e descobriram que a preferência por humanos em vez

de máquinas, recursos de usabilidade, interesse (ou falta dele) e familiaridade são elementos capazes de influenciar a implementação, disseminação e uso da IA.

O terceiro grupo cuja perspectiva foi identificada – gestores de organizações de saúde – não recebeu a mesma atenção dos pesquisadores, pois foi encontrada uma menor quantidade de barreiras. As barreiras envolvidas na adoção de IAS por gestores são: Preocupação com privacidade e proteção de dados, Complexidade, Questões legais e Regulação governamental. Os principais determinantes facilitadores identificados para os gestores são: Capital humano, Competência e treinamento da equipe; Apoio organizacional e do nível de gestão; Vantagem competitiva; Apoio de políticas governamentais; e Compatibilidade.

Alguns artigos abordaram, de forma conjunta, as perspectivas de diversos atores envolvidos no processo de implementação de sistemas de IAS, como desenvolvedores, fornecedores, clínicos e gestores envolvidos na adoção. Marco-Ruiz et al. (2024) descobriram que os seguintes fatores para facilitar a implementação: envolver ativamente os profissionais clínicos, e não apenas os pesquisadores clínicos, no início dos projetos de pesquisa de IA; melhores estruturas e processos de informação para gerenciar o acesso a dados e a aprovação ética de projetos de IA; melhor suporte para conformidade regulatória e aprovação de gerenciamento de dados; aumento da alfabetização de clínicos e cidadãos no que diz respeito aos benefícios e limitações da IA; e melhores esquemas de financiamento para dar suporte à implementação, incorporação e validação da IA no fluxo de trabalho clínico.

De forma geral os resultados demonstram que os pesquisadores se interessaram em estudar os fatores determinantes para adoção relação de IAS. No entanto, a grande quantidade de barreiras identificadas na literatura exprime como pode ser desafiador para as partes interessadas, como gestores de hospitais e empresas de TI, persuadir os médicos a usar novas tecnologias (Sun, 2021) e a pacientes aceitá-las. Por isso, alguns estudos também apresentam ações que podem ser tomadas para mitigar as iniciais barreiras e, assim, realçar os aspectos facilitadores. Essas ações, que são apresentadas na Tabela 6, representam o elemento “atividades” ou “intervenções” da abordagem da Teoria da Mudança.

Tabela 6

Exemplos de sugestões de ações para facilitar a adoção de IAS dadas pelos artigos da revisão, por categoria

Barreira (Input)	Ação (Activities)	Condição favorável (Output)	Categoria
Alto custo	Buscar suporte financeiro ou incentivos governamentais para implantação (ID10)	Disponibilidade de recursos	Organização
Alto custo	Garantir a integração com plataformas de computação em nuvem (ID8)	Economia de custos operacionais com <i>hardware</i>	Organização
Falta de conhecimento	Organizar conferências, seminários e workshops (ID15, ID39)	Profissionais conscientes e familiarizados com IA	Organização

Falta de conhecimento	Incluir educação em IA no currículo de profissionais de saúde (ID39)	Profissionais conscientes e familiarizados com IA	Organização
Falta de pessoal capacitado	Promover treinamentos para os usuários (ID1, ID11)	Capital humano competente	Organização
Falta de interesse	Criar políticas governamentais para impulsionar a adoção (ID27)	Apoio governamental	Ambiente
Falta de interesse	Envolver ativamente os profissionais clínicos nos projetos de IA (ID33)	Maior envolvimento do pessoal	Organização
Falta de confiança	Disponibilizar evidências de validação clínica comprovada (ID11, ID28)	Maior confiança	Organização
Falta de confiança	Utilizar IA mais transparentes compreensíveis, como IA explicável (ID10, ID11)	Maior confiança	Tecnologia
Problemas técnicos	Oferta de suporte em caso de dúvidas durante o uso (ID1, ID11)	Maior confiança	Tecnologia
Perda de autonomia	Envolvimento humano no desenvolvimento da IA (ID11, ID28)	Funcionamento colaborativo	Tecnologia
Preocupação: ética e viés	Envolvimento humano na supervisão das decisões do sistema (ID8, ID19)	Modelo não enviesado	Ambiente
Preocupação: ética e viés	Treinar IA com dados representativos de grupos minoritários (ID19)	Dados representativos sem preconceito	Ambiente
Preocupação: privacidade	Assegurar supervisão regulatória rigorosa por agências governamentais (ID37)	Implementação de configurações de proteção da privacidade	Ambiente
Preocupação: segurança dos dados	Avaliação dos riscos à cyber segurança (ID27)	Ferramentas de segurança dos dados confiáveis	Tecnologia

Nota: Elaborado pelas autoras com base nos achados da revisão.

A Tabela 6 agrupou algumas das já mencionadas barreiras em três grupos ou categorias de determinantes: tecnologia, organização e ambiente. Além disso, é interessante destacar que, segundo a literatura examinada nesta revisão, uma mesma barreira pode ser contornada por diferentes tipos de intervenções. De forma parecida, um mesmo tipo de atividade ou ação pode ser eficaz em mitigar mais de uma barreira no processo de transformar a situação em uma condição favorável à adoção de IAS.

Quanto a relação entre as dimensões de determinantes, os achados da revisão revelam que, além de influenciar a decisão de adotar ou não IAS, esses tipos de variáveis podem ter influência sobre as outras. Por exemplo, dimensões como humana, ambiente e tecnologia podem assumir papel de causa e as dimensões como organização e custo podem assumir o papel de efeito (Dastjerdi et al., 2023).

Os achados da revisão também demonstram a importância de incluir no processo de implementação de tecnologias baseadas em IA outro elemento característico da Teoria da Mudança: os indicadores para avaliação. O desenvolvimento de métricas mais robustas para avaliar as iniciativas de IA no domínio da assistência médica é necessário antes que a adoção significativa possa ser alcançada (Sezgin et al., 2022).

4.2 DISCUSSÃO DOS DADOS

A discussão sobre a utilização de IA em serviços de saúde recebe interesse internacional e a aplicação das referidas tecnologias está sendo incentivada por investimentos crescentes de fontes públicas e privadas. Apesar de seu potencial de transformar a assistência médica, a adoção da IA tem sido mais lenta do que o esperado e a literatura existente destaca numerosos desafios ou características que podem justificar tal cenário (Li et al., 2023). Assim, analisar o contexto de implementação de IAS a partir do ponto de vista das partes interessadas envolvidas, sejam eles profissionais de saúde, pacientes ou, especialmente, gestores pode ser um diferencial no fortalecimento do sistema de saúde e no avanço para inovação tecnológica da área.

A maioria dos estudos investigou os fatores envolvidos na adoção ou resistência à IAS a partir das perspectivas de médicos e pacientes, com menos pesquisas sob a perspectiva de organizações, resultado que condiz com os achados de outras revisões de literatura (Yang et al., 2024). Os estudos que abordaram a perspectiva de organizações, utilizaram um número limitado de gestores na amostra (Kumar et al., 2023; Tokgöz et al., 2024) ou um número limitado de variáveis para análise (Pham et al., 2024). Além disso, os estudos ainda estão limitados a contextos de países específicos, como Índia (Kumar et al., 2023), Estados Unidos (Pham et al., 2024) e Alemanha (Tokgöz et al., 2024).

Portanto, é uma sugestão válida que pesquisas futuras explorem os determinantes de organizações quanto a adoção e resistência à IAS, pois estes podem ser muito diferentes daqueles dos pacientes ou médicos, em função de interesses conflitantes (Padmanabhan et al., 2021), diferenças no conhecimento prévio e nos relacionamentos de confiança (Asan et al., 2020). A investigação desses determinantes adicionais pode ajudar na compreensão do que está envolvido na tomada de decisão quanto à adoção de IAS, pelo ponto de vista dos gestores, como representantes das organizações e principais responsáveis por decisões de investimento e implantação (Tokgöz et al., 2024).

No estudo ID30, de Pham et al. (2024), os autores analisaram evidências de hospitais dos EUA para identificar fatores determinantes e avaliar efeitos da adoção de IA no desempenho financeiro. Porém, analisaram apenas as variáveis “participação de mercado” e “tempo médio de permanência”. Os autores sugeriram analisar as variáveis: número de médicos, capacidade dos médicos, contagem de artefatos ou sistemas de Tecnologia de Informação (TI) usados e extensão das especialidades ou serviços oferecidos; e considerar as variações nas técnicas de IA utilizadas bem como o grau de adoção (adotar em todo o hospital versus departamentos específicos). No entanto, observa-se que alguns dos estudos incluídos

sobre adoção de IAS não exploram a adoção das IAS em si, com comportamento real, mas a intenção de uso de tais tecnologias (ID1, ID14, ID21, ID23, ID24, ID25, ID34, ID37) o que deve ser levado em consideração ao examinar seus resultados (Prakash & Das, 2024).

As lacunas identificadas nos estudos sobre determinantes do uso de IA em estabelecimentos de saúde apontam para desafios significativos. A ausência de dados abrangentes impacta negativamente a generalização dos resultados, uma vez que muitos estudos utilizam conjuntos limitados de informações. Por exemplo, a pesquisa de Müller et al. (2021) teve por objetivo identificar barreiras e facilitadores para a implementação de IA em diagnósticos odontológicos, especificamente radiográficos. Os autores reconhecem que o tamanho da amostra afeta sua representatividade e que é difícil transferir as descobertas para outros cenários em função das particularidades do contexto da saúde alemã e do campo do diagnóstico odontológico.

Outro caso semelhante é o do estudo de Cheng et al. (2022), que teve por objetivo investigar os fatores que influenciam a intenção de adoção de diagnóstico e tratamento assistidos por IA por 343 profissionais de saúde odontológica de hospitais na província de Anhui, na China. Embora os autores tenham afirmado que o estudo contribui ao propor um modelo integrado da Teoria Unificada de Aceitação e Uso da Tecnologia (do inglês, *Unified Theory of Acceptance and Use of Technology – UTAUT*) e da Teoria Confiança Humano-Computador (do inglês, *Human-Computer Trust – HCT*), auxiliando departamentos de odontologia, está limitado no que diz respeito a representatividade global e aplicação a outros departamentos.

Os achados desta revisão corroboram os resultados de algumas revisões sistemáticas anteriores (apresentadas na Tabela 1). Assim como na revisão de Padmanabhan et al. (2021), ficou claro que a colaboração entre médicos e especialistas de IA é essencial para aplicações bem-sucedidas, seguras e confiáveis de IA na assistência médica. Este estudo também concorda com Khanijahani et al. (2022), que mencionaram a influência de fatores como treinamento e segurança na dimensão organizacional. Outras similaridades foram encontradas na revisão de Yang et al. (2024).

Assim como neste estudo, os autores também sinalizaram que para compreender o fenômeno da adoção de IA no contexto da saúde é necessário analisar antecedentes e intervenções, isto é, fatores que podem causar resistência a adoção de IA e características que podem mitigar tal resistência, respectivamente (Yang et al., 2024). Por exemplo, os autores também encontraram os seguintes determinantes: alto custo, apoio de políticas, infraestrutura tecnológica, perda de privacidade. Os autores apontaram as seguintes intervenções como

formas de mitigar as barreiras: usar IA explicável, recebimento de incentivos financeiros, pessoal com conhecimento especializado, envolvimento e colaboração entre IA e humanos (Yang et al., 2024).

A partir dos achados da revisão foi possível estabelecer uma conexão com diversos elementos da Teoria da Mudança (Tabela 2). Primeiramente, foram identificadas três partes interessadas principais, também conhecidas como Stakeholders. Dentre as pessoas direta ou indiretamente envolvidas ou afetadas pelo sucesso ou fracasso da iniciativa destacam-se: (a) gestores, pois são os tomadores de decisão sobre adoção de IA na organização; (b) médicos e enfermeiros, pois são os prestadores de serviços de saúde e, em muitos casos, são os responsáveis pelo uso das tecnologias; e (c) pacientes, pois são os usuários finais dos serviços de saúde e principais beneficiários das inovações aplicadas nesse setor.

No entanto, alguns estudos não especificaram a parte interessada objeto da pesquisa (Sezgin et al., 2022), enquanto outros investigaram grupos multidisciplinares formados por partes interessadas que também incluem pesquisadores com experiência ou interesse em saúde digital e IA (Marco-Ruiz et al., 2024; Shevtsova et al., 2024; Terry et al., 2022), desenvolvedores (Hill et al., 2023; Marco-Ruiz et al., 2024), reguladores (Hill et al., 2023) e formuladores de políticas (Shevtsova et al., 2024). Isso revela que, apesar das três partes interessadas destacadas neste estudo serem as principais, outras partes interessadas também podem estar envolvidas nesse processo.

Para cada uma das três partes interessadas principais este estudo reuniu fatores determinantes da adoção de IA, os quais podem ser facilitadores ou barreiras, conforme apresentado na Tabela 5. Como mencionado anteriormente, algumas variáveis mencionadas na amostra podem assumir um papel facilitador ou impeditivo, a depender do contexto. Isso evidencia que alguma atividade ou ação pode ser tomada para preencher essa ausência, desenvolver esses sentimentos ou transformar o status quo, ideia condizente com a Teoria da Mudança.

Nesse sentido, a Tabela 6 permite compreender a relação entre os quatro primeiros elementos da Teoria da Mudança. O primeiro elemento diz respeito aos recursos ou às condições existentes inicialmente, e neste estudo pode ser traduzido como as barreiras encontradas na organização de saúde. O segundo elemento envolve as atividades, intervenções ou ações tomadas a partir do primeiro elemento, ou seja, o trabalho desenvolvido para mitigar as barreiras iniciais.

O terceiro elemento é referente aos produtos, isto é, as saídas das atividades realizadas ou resultados intermediários, que foram elencados na Tabela 6 como “condições favoráveis”.

Tais condições, alcançadas após a realização do segundo elemento (atividades), equivalem aos fatores determinantes facilitadores da adoção de IA na saúde. Dessa forma, a adoção de IA na organização pode ser entendida como o quarto elemento da Teoria da Mudança – resultados ou *outcomes*. Assim, esta revisão identifica os seguintes elementos da Teoria da Mudança: *inputs*, *activities*, *outputs*, *outcome* e *stakeholders*.

Como mencionado nos capítulos 1 e 2, a adoção bem-sucedida de IA tem o potencial de gerar benefícios em termos de eficiência, ao aprimorar vários aspectos de desempenho e promover práticas eficientes (Jiao et al., 2023; Pham et al., 2024). Com isso em mente, é possível estabelecer mais uma relação com a Teoria da Mudança: o impacto (quinto elemento) da adoção de IA nas organizações de saúde. Um dos impactos possíveis é a melhoria da eficiência, uma vez que a IA possibilita reduzir os tempos de espera, diminuir o esgotamento causado pela papelada e tarefas administrativas, maximizar a precisão diagnóstica e, consequentemente, reduzir custos ao evitar ineficiências e tratamentos desnecessários (Cheng et al., 2022; Hill et al., 2023; Jiao et al., 2023; Pham et al., 2024; Roppelt et al., 2024; Sun, 2021; Wubineh et al., 2024).

Fica claro que entender os determinantes da adoção de inovações na prática clínica é imprescindível para tomar decisões assertivas e projetar estratégias de implementação que alavanquem os facilitadores e minimizem as barreiras (Bajgain et al., 2023). No contexto hospitalar, a integração bem-sucedida das tecnologias IA nas atividades apresenta-se como um fator positivo na promoção de práticas eficientes, o que confirma resultados de revisões anteriores (Jiao et al., 2023). Uma evidência empírica sugere que os hospitais que adotam tecnologias de IA podem aprimorar vários aspectos de desempenho, incluindo receita total de atendimento ambulatorial, receita total de internação, produtividade e ocupação, obtendo assim benefícios operacionais (Pham et al., 2024).

De forma geral, os estudos da revisão sistemática pontuam que a aplicação de IA em hospitais ou outros estabelecimentos de saúde apresentam fatores que atuam como barreiras e/ou como facilitadores. Estudos qualitativos possibilitaram descobrir fatores por meio de entrevistas e discussões com os (potenciais) usuários das tecnologias. Porém, pesquisadores concordam que são raros os estudos empíricos (Sun, 2021) que testam e avaliam o impacto que fatores determinantes podem ter na adoção e rejeição utilizando uma base de dados robusta (Pham et al., 2024). No contexto nacional, na exploração desse tópico não foram encontrados estudos desse tipo.

Visto que a pesquisa sobre adoção e implementação de tecnologias baseadas em Inteligência Artificial está dando seus primeiros passos, é vital reconhecer essas lacunas que

demandam preenchimento. Pesquisas futuras, devidamente planejadas e contextualizadas, têm o potencial de aprimorar significativamente a compreensão dos fatores responsáveis por facilitar ou dificultar a adoção de tais tecnologias que já são uma realidade em diversos estabelecimentos de saúde. Compreender esses fatores é de extrema importância, pois pode não apenas acelerar o processo de adoção da IAS, mas também aumentar a capacidade dos hospitais de aproveitar plenamente os benefícios que a IA oferece (Pham et al., 2024).

5 CONSIDERAÇÕES FINAIS

Este artigo revisou os estudos sobre a adoção de IA na saúde, identificando os fatores determinantes (facilitadores e barreiras), e apontando-os como elementos da Teoria de Mudança para a implantação de IAS. A abordagem da Teoria da Mudança permitiu identificar múltiplos determinantes ou recursos envolvidos e facilitou uma descrição de possíveis atividades ou intervenções necessárias para atingir o resultado desejado: adoção de tecnologias baseadas em IA em estabelecimentos de saúde. Além disso, ao destacar as perspectivas de diferentes partes interessadas, proporcionou uma visão holística desse processo complexo.

Este estudo contribui para o avanço teórico ao oferecer uma revisão abrangente dos determinantes (facilitadores e barreiras) que influenciam a adoção da IA na saúde, considerando múltiplas perspectivas das partes interessadas. Além disso, introduz a Teoria da Mudança como uma nova lente para a implementação bem-sucedida dessas tecnologias, a qual pode fornecer um modelo para orientar futuras pesquisas e adaptações em diferentes contextos. Do ponto de vista prático, os achados auxiliam gestores hospitalares na tomada de decisão que envolva adoção de IAS, pois ao decidir adotar essa tecnologia na organização, os gestores podem se beneficiar por analisar os fatores determinantes aqui apontados e evitar aqueles que são identificados como barreiras.

Os resultados também incentivam fornecedores e desenvolvedores de IA no aprimoramento de suas soluções, ao entender que características do seu produto enxergadas pelos seus clientes e usuários como barreiras podem e devem ser alteradas. Além disso, os achados estimulam a formulação de políticas públicas eficazes para promover a adoção bem-sucedida de tecnologias baseadas em IA. Por fim, ao promover maior eficiência no setor hospitalar, a adoção estratégica de IAS pode gerar impactos sociais positivos, otimizando o trabalho dos profissionais de saúde e melhorando a experiência dos pacientes, beneficiando, assim, toda a sociedade.

Apesar das contribuições mencionadas, este estudo possui limitações, sobretudo na seleção da amostra. Primeiramente, algumas pesquisas não estavam disponíveis gratuitamente a partir das bases de dados consultadas e não foram incluídos. Além disso, um dos critérios para seleção diz respeito a remoção de artigos cujos periódicos constam entre os estratos B3 e C da Qualis Capes, como mecanismo de controle de qualidade. No entanto, a partir de 2025 ocorrerá uma alteração nos parâmetros de avaliação de qualidade desse portal. Futuras pesquisas podem utilizar os novos parâmetros para suas revisões. Por fim, as observações apresentadas neste estudo baseiam-se em evidências da literatura existente. Ao passo que mais estabelecimentos de saúde ganhem experiência na integração de tecnologias baseadas em IA, espera-se que as melhores práticas contribuam para aprimorar a compreensão do processo de adoção de IAS sob a lente da teoria da mudança. A partir disso, será possível oferecer diretrizes sobre planejamento, etapas progressivas e indicadores de avaliação que favoreçam a adoção dessas tecnologias com potencial de aprimorar a prestação de serviços de saúde.

Sugere-se que futuras pesquisas realizem estudos longitudinais, analisando a evolução da adoção de IA, pode fornecer informações valiosas que explicam as relações entre variáveis. Estudos qualitativos, explorando as experiências e percepções dos profissionais da saúde, dos gestores e dos pacientes acerca do uso de tecnologias de IA, também são sugeridos para uma compreensão ainda mais profunda dos desafios e oportunidades no contexto nacional e internacional. Outra possibilidade é utilizar a os elementos da Teoria da Mudança aqui propostos para elaborar uma teoria da mudança específica e adaptada às circunstâncias do estabelecimento de saúde em questão. Uma última sugestão é testar de forma robusta se os elementos da Teoria da Mudança aqui sugeridos são aplicáveis a estabelecimentos de saúde brasileiros, o que aumentará a capacidade de generalização dos achados. Esses testes estatísticos podem ser realizados especialmente para verificar se os determinantes (recursos/insumos) e as atividades neles envolvidas, realmente têm efeito sobre os resultados intermediários (adoção de IA). A literatura recente, representada pelos 39 artigos estudados, fortalece a necessidade de fornecer provas estatísticas sobre quais fatores têm efeito sobre a adoção da IA por estabelecimentos de saúde, sobretudo brasileiros.

Nota-se a necessidade de cada parte interessada compreender o potencial papel da IA como aliadas para dar suporte aos profissionais da saúde, promovendo uma relação sinérgica entre recursos tecnológicos e recursos humanos. Dessa forma, será possível combinar qualidade e eficiência a fim de proporcionar maior número de atendimentos e melhorar a prestação de assistência médica e o bem-estar do paciente.

REFERÊNCIAS

- Adedeji, T., Fraser, H., & Scott, P. (2022). Implementing electronic health records in primary care using the theory of change: Nigerian case study. *JMIR Medical Informatics*, 10(8), e33491. <https://doi.org/10.2196/33491>
- Ahmed, A., & Sargent, J. (2021). Theory of change: Driving a digital school in rural Pakistan. *First Monday*. <https://doi.org/10.5210/fm.v26i9.10304>
- Ali, O., Murray, P. A., Momin, M., Dwivedi, Y. K., & Malik, T. (2024). The effects of artificial intelligence applications in educational settings: Challenges and strategies. *Technological Forecasting and Social Change*, 199, 123076. <https://doi.org/10.1016/j.techfore.2023.123076>
- Almeida, V. A. F. (2023). Recomendações para o avanço da inteligência artificial no Brasil: GT-IA da Academia Brasileira de Ciências. Academia Brasileira de Ciências.
- Antes, A. L., Burrous, S., Sisk, B. A., Schuelke, M. J., Keune, J. D., & DuBois, J. M. (2021). Exploring perceptions of healthcare technologies enabled by artificial intelligence: An online, scenario-based survey. *BMC Medical Informatics and Decision Making*, 21(1), 221. <https://doi.org/10.1186/s12911-021-01586-8>
- Asan, O., Bayrak, A. E., & Choudhury, A. (2020). Artificial intelligence and human trust in healthcare: Focus on clinicians. *Journal of Medical Internet Research*, 22(6), e15154. <https://doi.org/10.2196/15154>
- 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. <https://doi.org/10.1136/bmjopen-2022-068373>
- Breuer, E., Subba, P., Luitel, N., Jordans, M., De Silva, M., Marchal, B., & Lund, C. (2018). Using qualitative comparative analysis and theory of change to unravel the effects of a mental health intervention on service utilisation in Nepal. *BMJ Global Health*, 3(6), e001023. <https://doi.org/10.1136/bmjgh-2018-001023>
- Brown, C., Nazeer, R., Gibbs, A., Le Page, P., & Mitchell, A. R. (2023). Breaking bias: The role of artificial intelligence in improving clinical decision-making. *Cureus*. <https://doi.org/10.7759/cureus.36415>
- Chaney, S. C., Mechael, P., Thu, N. M., Diallo, M. S., & Gachen, C. (2021). Every child on the map: A theory of change framework for improving childhood immunization coverage and equity using geospatial data and technologies. *Journal of Medical Internet Research*, 23(8), e29759. <https://doi.org/10.2196/29759>
- Chaudhuri, A., Biswas, N., Kumar, S., Jyothi, A., Gopinath, R., Mor, N., John, P., Narayan, T., Chatterjee, M., & Patel, V. (2022). A theory of change roadmap for universal health coverage in India. *Frontiers in Public Health*, 10, 1040913. <https://doi.org/10.3389/fpubh.2022.1040913>
- Cheng, M., Li, X., & Xu, J. (2022). Promoting healthcare workers' adoption intention of artificial-intelligence-assisted diagnosis and treatment: The chain mediation of social influence and human-computer trust. *International Journal of Environmental Research and Public Health*, 19(20), 13311. <https://doi.org/10.3390/ijerph192013311>

- Dastjerdi, M., Keramati, A., & Keramati, N. (2023). A novel framework for investigating organizational adoption of AI-integrated CRM systems in the healthcare sector; using a hybrid fuzzy decision-making approach. *Telematics and Informatics Reports*, 11, 100078. <https://doi.org/10.1016/j.teler.2023.100078>
- Deveci, M. (2023). Effective use of artificial intelligence in healthcare supply chain resilience using fuzzy decision-making model. *Soft Computing*. <https://doi.org/10.1007/s00500-023-08906-2>
- Dolan, J. E., Lonsdale, H., Ahumada, L. M., Patel, A., Samuel, J., Jalali, A., Peck, J., DeRosa, J. C., Rehman, M., Varughese, A. M., & Fernandez, A. M. (2019). Quality initiative using theory of change and visual analytics to improve controlled substance documentation discrepancies in the operating room. *Applied Clinical Informatics*, 10(03), 543–551. <https://doi.org/10.1055/s-0039-1693688>
- Gama, F., Tyskbo, D., Nygren, J., Barlow, J., Reed, J., & Svedberg, P. (2022). Implementation frameworks for artificial intelligence translation into health care practice: Scoping review. *Journal of Medical Internet Research*, 24(1), e32215. <https://doi.org/10.2196/32215>
- Gertler, P. J. (with Martinez, S., Premand, P., Rawlings, L. B., & Vermeersch, C. M. J.). (2015). *Avaliação de impacto na prática* (1^a ed). World Bank Publications.
- Gilissen, J., Pivodic, L., Gastmans, C., Vander Stichele, R., Deliens, L., Breuer, E., & Van Den Block, L. (2018). How to achieve the desired outcomes of advance care planning in nursing homes: A theory of change. *BMC Geriatrics*, 18(1), 47. <https://doi.org/10.1186/s12877-018-0723-5>
- Gilissen, J., Pivodic, L., Smets, T., Gastmans, C., Vander Stichele, R., Deliens, L., & Van Den Block, L. (2017). Preconditions for successful advance care planning in nursing homes: A systematic review. *International Journal of Nursing Studies*, 66, 47–59. <https://doi.org/10.1016/j.ijnurstu.2016.12.003>
- Hameed, B. Z., Naik, N., Ibrahim, S., Tatkar, N. S., Shah, M. J., Prasad, D., Hegde, P., Chlosta, P., Rai, B. P., & Somani, B. K. (2023). Breaking barriers: Unveiling factors influencing the adoption of artificial intelligence by healthcare providers. *Big Data and Cognitive Computing*, 7(2), 105. <https://doi.org/10.3390/bdcc7020105>
- Hill, E. R., Mitchell, C., Brigden, T., & Hall, A. (2023). Ethical and legal considerations influencing human involvement in the implementation of artificial intelligence in a clinical pathway: A multi-stakeholder perspective. *Frontiers in Digital Health*, 5, 1139210. <https://doi.org/10.3389/fdgth.2023.1139210>
- Jiao, W., Zhang, X., & D'Souza, F. (2023). The economic value and clinical impact of artificial intelligence in healthcare: A scoping literature review. *IEEE Access*, 11, 123445–123457. <https://doi.org/10.1109/ACCESS.2023.3327905>
- Khanijahani, A., Iezadi, S., Dudley, S., Goettler, M., Kroetsch, P., & Wise, J. (2022). Organizational, professional, and patient characteristics associated with artificial intelligence adoption in healthcare: A systematic review. *Health Policy and Technology*, 11(1), 100602. <https://doi.org/10.1016/j.hlpt.2022.100602>
- Kumar, A., Mani, V., Jain, V., Gupta, H., & Venkatesh, V. G. (2023). Managing healthcare supply chain through artificial intelligence (AI): A study of critical success factors.

- Computers & Industrial Engineering*, 175, 108815.
<https://doi.org/10.1016/j.cie.2022.108815>
- Li, L. T., Haley, L. C., Boyd, A. K., & Bernstam, E. V. (2023). Technical/Algorithm, Stakeholder, and Society (TASS) barriers to the application of artificial intelligence in medicine: A systematic review. *Journal of Biomedical Informatics*, 147, 104531.
<https://doi.org/10.1016/j.jbi.2023.104531>
- Marco-Ruiz, L., Hernández, M. Á. T., Ngo, P. D., Makhlysheva, A., Svenning, T. O., Dyb, K., Chomutare, T., Llatas, C. F., Muñoz-Gama, J., & Tayefi, M. (2024). A multinational study on artificial intelligence adoption: Clinical implementers' perspectives. *International Journal of Medical Informatics*, 184, 105377.
<https://doi.org/10.1016/j.ijmedinf.2024.105377>
- Mohammed, E. Z., Jameel, N. G. M., Shukr, A. I., & Ghareeb, A. (2023). Strategic planning for cancer control: Utilizing machine-learning models to predict future incidences. *Results in Control and Optimization*, 13, 100322. <https://doi.org/10.1016/j.rico.2023.100322>
- Müller, A., Mertens, S. M., Göstemeyer, G., Krois, J., & Schwendicke, F. (2021). Barriers and enablers for artificial intelligence in dental diagnostics: A qualitative study. *Journal of Clinical Medicine*, 10(8), 1612. <https://doi.org/10.3390/jcm10081612>
- Neto, M. K. (2020). Inteligência artificial e big data no diagnóstico e tratamento da Covid-19 na América Latina: Novos desafios à proteção de dados pessoais. *Revista Brasileira De Direitos Fundamentais & Justiça*, 14(1), 149–178. <https://doi.org/10.30899/dfj.v0i0.974>
- Olawade, D. B., Wada, O. J., David-Olawade, A. C., Kunonga, E., Abaire, O., & Ling, J. (2023). Using artificial intelligence to improve public health: A narrative review. *Frontiers in Public Health*, 11, 1196397. <https://doi.org/10.3389/fpubh.2023.1196397>
- Omisade, O., Gegov, A., Zhou, S.-M., Good, A., Tryfona, C., Sengar, S. S., Prior, A.-L., Liu, B., Adediji, T., & Toptan, C. (2023). Explainable artificial intelligence and mobile health for treating eating disorders in young adults with autism spectrum disorder based on the theory of change: A Mixed Method Protocol. Em V. Bhateja, F. Carroll, J. M. R. S. Tavares, S. S. Sengar, & P. Peer (Orgs.), *Intelligent Data Engineering and Analytics*, 371, 31–44. Springer Nature Singapore. https://doi.org/10.1007/978-981-99-6706-3_3
- Padmanabhan, S., Tran, T. Q. B., & Dominiczak, A. F. (2021). Artificial intelligence in hypertension: Seeing through a glass darkly. *Circulation Research*, 128(7), 1100–1118. <https://doi.org/10.1161/CIRCRESAHA.121.318106>
- Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J., Grimshaw, J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-Wilson, E., McDonald, S., Moher, D. (2021). The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. *PLOS Medicine*, 18(3), e1003583.
<https://doi.org/10.1371/journal.pmed.1003583>
- Papadopoulos, I., Koulouglioti, C., Lazzarino, R., & Ali, S. (2020). Enablers and barriers to the implementation of socially assistive humanoid robots in health and social care: A systematic review. *BMJ Open*, 10(1), e033096. <https://doi.org/10.1136/bmjopen-2019-033096>
- Pelly, M., Fatehi, F., Liew, D., & Verdejo-Garcia, A. (2023). Artificial intelligence for secondary prevention of myocardial infarction: A qualitative study of patient and health

- professional perspectives. *International Journal of Medical Informatics*, 173, 105041. <https://doi.org/10.1016/j.ijmedinf.2023.105041>
- Pham, P., Zhang, H., Gao, W., & Zhu, X. (2024). Determinants and performance outcomes of artificial intelligence adoption: Evidence from U.S. Hospitals. *Journal of Business Research*, 172, 114402. <https://doi.org/10.1016/j.jbusres.2023.114402>
- Prakash, A. V., & Das, S. (2024). (Why) Do We Trust AI?: A case of AI-based health chatbots. *Australasian Journal of Information Systems*, 28. <https://doi.org/10.3127/ajis.v28.4235>
- Rezaee, M., Onari, M., & Saberi, M. (2024). A data-driven decision support framework for DEA target setting: An explainable AI approach. *Engineering Applications Of Artificial Intelligence*, 127. <https://doi.org/10.1016/j.engappai.2023.107222>
- Romão, D. M. M., Setti, C., Arruda, L. H. M., De Melo, R. C., De Araujo, B. C., Tan, A. R., DeMaio, P. N., & Kuchenmüller, T. (2023). Integration of evidence into theory of change frameworks in the healthcare sector: A rapid systematic review. *PLOS ONE*, 18(3), e0282808. <https://doi.org/10.1371/journal.pone.0282808>
- Roppelt, J. S., Kanbach, D. K., & Kraus, S. (2024). Artificial intelligence in healthcare institutions: A systematic literature review on influencing factors. *Technology in Society*, 76, 102443. <https://doi.org/10.1016/j.techsoc.2023.102443>
- Sezgin, E., Sirrianni, J., & Linwood, S. L. (2022). Operationalizing and implementing pretrained, large artificial intelligence linguistic models in the US health care system: Outlook of generative pretrained transformer 3 (GPT-3) as a Service Model. *JMIR Medical Informatics*, 10(2), e32875. <https://doi.org/10.2196/32875>
- Strohm, L., Hehakaya, C., Ranschaert, E. R., Boon, W. P. C., & Moors, E. H. M. (2020). Implementation of artificial intelligence (AI) applications in radiology: Hindering and facilitating factors. *European Radiology*, 30(10), 5525–5532. <https://doi.org/10.1007/s00330-020-06946-y>
- Sugahara, C. R., & Rodrigues, P. P. (2019). Avaliação de impacto de negócios sociais e teoria da mudança. *Revista Nacional de Gerenciamento de Cidades*, 7(46). <https://doi.org/10.17271/2318847274620192080>
- Sun, T. Q. (2021). Adopting artificial intelligence in public healthcare: The effect of social power and learning algorithms. *International Journal of Environmental Research and Public Health*, 18(23), 12682. <https://doi.org/10.3390/ijerph182312682>
- Terranova, C., Cestonaro, C., Fava, L., & Cinquetti, A. (2024). AI and professional liability assessment in healthcare. A revolution in legal medicine? *Frontiers in Medicine*, 10, 1337335. <https://doi.org/10.3389/fmed.2023.1337335>
- Tezpal, M., Ghosh, S., Lalwani, R., Yadav, J., & Yadav, A. K. (2024). Artificial intelligence in health care – A study on perceptions of and readiness for artificial intelligence in health-care professionals. *Journal of Marine Medical Society*, 26(3), 376–381. https://doi.org/10.4103/jmms.jmms_161_23
- Tokgöz, P., Krayter, S., Hafner, J., & Dockweiler, C. (2024). Decision support systems for antibiotic prescription in hospitals: A survey with hospital managers on factors for implementation. *BMC Medical Informatics and Decision Making*, 24(1), 96. <https://doi.org/10.1186/s12911-024-02490-7>

- Van Der Vegt, A. H., Scott, I. A., Dermawan, K., Schnetler, R. J., Kalke, V. R., & Lane, P. J. (2023). Deployment of machine learning algorithms to predict sepsis: Systematic review and application of the SALIENT clinical AI implementation framework. *Journal of the American Medical Informatics Association*, 30(7), 1349–1361. <https://doi.org/10.1093/jamia/ocad075>
- Weinert, L., Müller, J., Svensson, L., & Heinze, O. (2022). Perspective of information technology decision makers on factors influencing adoption and implementation of artificial intelligence technologies in 40 german hospitals: Descriptive analysis. *JMIR Medical Informatics*, 10(6), e34678. <https://doi.org/10.2196/34678>
- Wenderott, K., Krups, J., Luetkens, J. A., & Weigl, M. (2024). Radiologists' perspectives on the workflow integration of an artificial intelligence-based computer-aided detection system: A qualitative study. *Applied Ergonomics*, 117, 104243. <https://doi.org/10.1016/j.apergo.2024.104243>
- Wolff, J., Pauling, J., Keck, A., & Baumbach, J. (2021). Success factors of artificial intelligence implementation in healthcare. *Frontiers in Digital Health*, 3. <https://doi.org/10.3389/fdgth.2021.594971>
- Wu, J.-S. (2023). Applying frontier approach to measure the financial efficiency of hospitals. *Digital health*, 9, 20552076231162987–20552076231162987. <https://doi.org/10.1177/20552076231162987>
- Wubineh, B. Z., Deriba, F. G., & Woldeyohannis, M. M. (2024). Exploring the opportunities and challenges of implementing artificial intelligence in healthcare: A systematic literature review. *Urologic Oncology: Seminars and Original Investigations*, 42(3), 48–56. <https://doi.org/10.1016/j.urolonc.2023.11.019>
- Yamaoka, T., & Watanabe, S. (2023). Artificial intelligence in coronary artery calcium measurement: Barriers and solutions for implementation into daily practice. *European Journal of Radiology*, 164, 110855. <https://doi.org/10.1016/j.ejrad.2023.110855>
- Yang, Y., Ngai, E. W. T., & Wang, L. (2024). Resistance to artificial intelligence in health care: Literature review, conceptual framework, and research agenda. *Information & Management*, 61(4), 103961. <https://doi.org/10.1016/j.im.2024.103961>

APÊNDICE A

Artigos selecionados

ID	TÍTULOS	AUTORES/ANO
1	<i>The Simulation Model of the Resistance Factors Affecting the Adoption of Healthcare Robot Technology in Tertiary Care Center of Thailand</i>	Vichitkraivin & Naenna (2019)
2	<i>Parental Attitudes toward Artificial Intelligence-Driven Precision Medicine Technologies in Pediatric Healthcare</i>	Sisk et al. (2020)
3	<i>Implementation of artificial intelligence (AI) applications in radiology: hindering and facilitating factors</i>	Strohm et al. (2020)
4	<i>Use of AI-based tools for healthcare purposes: a survey study from consumers' perspectives</i>	Esmailzadeh (2020)
5	<i>Barriers and Enablers for Artificial Intelligence in Dental Diagnostics: A Qualitative Study</i>	Müller et al. (2021)
6	<i>Exploring perceptions of healthcare technologies enabled by artificial intelligence an online, scenario-based survey</i>	Antes et al. (2021)

7	<i>Adopting Artificial Intelligence in Public Healthcare: The Effect of Social Power and Learning Algorithms</i>	Sun (2021)
8	<i>Operationalizing and Implementing Pretrained, Large Artificial Intelligence Linguistic Models in the US Health Care System: Outlook of Generative Pretrained Transformer 3 (GPT-3) as a Service Model</i>	Sezgin et al. (2022)
9	<i>Health Care Professionals' Experiences of Web-Based Symptom Checkers for Triage: Cross-sectional Survey Study</i>	Kujala & Hörhammer (2022)
10	<i>Perspective of Information Technology Decision Makers on Factors Influencing Adoption and Implementation of Artificial Intelligence Technologies in 40 German Hospitals: Descriptive Analysis</i>	Weinert et al. (2022)
11	<i>Determinants of the implementation of an artificial intelligence-supported device for the screening of diabetic retinopathy in primary care – a qualitative study</i>	Held et al. (2022)
12	<i>Fairness-related performance and explainability effects in deep learning models for brain image analysis</i>	Stanley et al. (2022)
13	<i>Is primary health care ready for artificial intelligence? What do primary health care stakeholders say?</i>	Terry et al. (2022)
14	<i>Promoting Healthcare Workers' Adoption Intention of Artificial-Intelligence-Assisted Diagnosis and Treatment: The Chain Mediation of Social Influence and Human-Computer Trust</i>	Cheng et al. (2022)
15	<i>Facilitators and Barriers of Artificial Intelligence Applications in Rehabilitation: A Mixed-Method Approach</i>	Alsobhi et al. (2022)
16	<i>Many roads lead to Rome and the Artificial Intelligence only shows me one road": an interview study on physician attitudes regarding the implementation of computerised clinical decision support systems</i>	Van Cauwenberge et al (2022)
17	<i>A survey of pregnant patients' perspectives on the implementation of artificial intelligence in clinical care</i>	Armero et al. (2022)
18	<i>Managing healthcare supply chain through artificial intelligence (AI): A study of critical success factors</i>	Kumar et al. (2023)
19	<i>Ethical and legal considerations influencing human involvement in the implementation of artificial intelligence in a clinical pathway: A multi-stakeholder perspective</i>	Hill et al. (2023)
20	<i>Breaking Bias: The Role of Artificial Intelligence in Improving Clinical Decision-Making</i>	Brown et al (2023)
21	<i>The critical determinants impacting artificial intelligence adoption at the organizational level</i>	Horani et al. (2023)
22	<i>Artificial intelligence for secondary prevention of myocardial infarction: A qualitative study of patient and health professional perspectives</i>	Pelly et al. (2023)
23	<i>Breaking Barriers: Unveiling Factors Influencing the Adoption of Artificial Intelligence by Healthcare Providers</i>	Hameed et al (2023)
24	<i>Attitudes Toward the Adoption of 2 Artificial Intelligence-Enabled Mental Health Tools Among Prospective Psychotherapists: Cross-sectional Study</i>	Kleine et al. (2023)
25	<i>Effective use of artificial intelligence in healthcare supply chain resilience using fuzzy decision-making model</i>	Deveci (2023)
26	<i>Barriers and Enablers to the Implementation of Intelligent Guidance Systems for Patients in Chinese Tertiary Transfer Hospitals: Usability Evaluation</i>	Cao et al. (2023)
27	<i>A novel framework for investigating organizational adoption of AI-integrated CRM systems in the healthcare sector; using a hybrid fuzzy decision-making approach</i>	Dastjerdi et al (2023)
28	<i>Physicians' Perspectives on AI in Clinical Decision Support Systems: Interview Study of the CURATE.AI Personalized Dose Optimization Platform</i>	Vijayakumar et al. (2023)
29	<i>Trust in and Acceptance of Artificial Intelligence Applications in Medicine: Mixed Methods Study</i>	Shevtsova et al. (2024)
30	<i>Determinants and performance outcomes of artificial intelligence adoption: Evidence from U.S. Hospitals</i>	Pham et al. (2024)

31	<i>A Comprehensive Evaluation of AI-Assisted Diagnostic Tools in ENT Medicine Insights and Perspectives from Healthcare Professionals</i>	Alshehri et al. (2024)
32	<i>Choosing human over AI doctors? How comparative trust associations and knowledge relate to risk and benefit perceptions of AI in healthcare</i>	Kerstan et al. (2024)
33	<i>A multinational study on artificial intelligence adoption Clinical implementers' perspectives</i>	Marco-Ruiz et al. (2024)
34	<i>Applying the UTAUT2 framework to patients' attitudes toward healthcare task shifting with artificial intelligence</i>	Huang et al. (2024)
35	<i>Decision support systems for antibiotic prescription in hospitals a survey with hospital managers on factors for implementation</i>	Tokgöz et al. (2024)
36	<i>Radiologists' perspectives on the workflow integration of an artificial intelligence-based computer-aided detection system: A qualitative study</i>	Wenderott et al. (2024)
37	<i>(Why) Do We Trust AI? A Case of AI-based Health Chatbots</i>	Prakash & Das (2024)
38	<i>Ethical considerations and concerns in the implementation of AI in pharmacy practice: a cross-sectional study</i>	Hasan et al. (2024)
39	<i>Artificial Intelligence in Health Care – A Study on Perceptions of and Readiness for Artificial Intelligence in Health-care Professionals</i>	Tezpal et al. (2024)

Nota: ID (Identificação dos artigos). Elaborado pelas autoras com base nas informações coletadas por meio do protocolo.

ARTIGO 2 – INTELIGÊNCIA ARTIFICIAL: DETERMINANTES TECNOLÓGICOS, ORGANIZACIONAIS E AMBIENTAIS DE ADOÇÃO POR ESTABELECIMENTOS DE SAÚDE BRASILEIROS

RESUMO

Este estudo busca identificar os determinantes tecnológicos, organizacionais e ambientais da adoção de Inteligência Artificial por estabelecimentos de saúde brasileiros. Para tanto, considerou 651 observações, a partir da base de microdados da pesquisa TIC Saúde 2024, publicada pelo Núcleo de Informação e Coordenação do Ponto BR (NIC.br). Para testar a relação entre a intensidade do uso de IA e os determinantes categorizados de acordo o Framework Tecnologia-Organização-Ambiente (TOE), foram utilizadas estatística descritiva, estatística qui-quadrado, análise de correspondência (ANACOR) e regressão logística multinomial. Os determinantes que se mostraram significativos para explicar o fenômeno são: infraestrutura de TIC, novas tecnologias, oferta de serviços remotos (dimensão tecnológica), envolvimento do pessoal, porte do estabelecimento com 0-50 leitos (dimensão organizacional), região sudeste e políticas governamentais (dimensão ambiental). Os determinantes acesso e manutenção dos dados, segurança dos dados (dimensão tecnológica), natureza de propriedade, financiamento, treinamento (dimensão organizacional) e localização (dimensão ambiental) não mostraram significância estatística. Os resultados revelam que, embora haja um uso moderado de tecnologias de inteligência artificial por estabelecimentos de saúde brasileiros, ainda existe um potencial significativo para ampliação. A investigação da perspectiva dos gestores é uma contribuição da pesquisa, pois são a parte interessada responsável pela tomada de decisão, mas estudada com menor frequência. Como contribuição prática, este estudo fornece informações para auxiliar (a) gestores de hospitais, do setor público e privado, quanto à tomada de decisão que envolva uso de IA e estratégias de implementação; (b) fornecedores de IA, quanto a reflexão em iniciativas de aprimoramento; (c) órgãos governamentais, quanto à formulação de políticas eficazes para promover a adoção bem-sucedida de tecnologias baseadas em IA. Por fim, a possibilidade de adotar melhorias tecnológicas que afetem positivamente o desempenho e promovam a eficiência de estabelecimentos de saúde é benéfica para os usuários dos serviços de saúde e para a sociedade como um todo.

PALAVRAS-CHAVE: Adoção de Inteligência Artificial, Estabelecimentos de saúde, Regressão Logística Multinomial, Análise de Correspondência, TOE.

1 INTRODUÇÃO

A relação entre a oferta e a demanda dos serviços de saúde não é equilibrada. Aspectos como epidemias, aumento e envelhecimento da população, surgimento de novas doenças, desastres naturais e mudanças climáticas podem causar um aumento na busca por atendimento médico (Huang et al., 2024; Papadopoulos et al., 2020). Enquanto hospitais costumam ter recursos limitados, com valores fixos de insumos, a necessidade de atendimento hospitalar é crescente e, conseqüentemente, os custos aumentam. A partir desse contexto, gestores e demais agentes envolvidos no processo de tomada de decisão precisam constantemente refletir quanto

a utilização eficiente dos recursos, a fim de proporcionar maior número de atendimentos (Roppelt et al., 2024; Wubineh et al., 2024).

Tendo em vista tais desafios, uma tecnologia que surgiu como promessa para enfrentá-los, conquista, cada vez mais, o interesse de acadêmicos e profissionais: a inteligência artificial (Roppelt et al., 2024). Uma das definições mais simples para inteligência artificial (IA) é inteligência humana simulada por máquinas (Padmanabhan et al., 2021). Em ambientes de saúde, as funções da IA incluem processamento de linguagem natural para interpretar dados não estruturados, como notas clínicas ou declarações de pacientes, e aprendizado de máquina para interpretar dados estruturados, como imagens médicas ou informações genéticas (Yamaoka & Watanabe, 2023).

Os benefícios dessas tecnologias atingem tanto os destinatários da assistência médica – por reduzir os tempos de espera e tornar os cuidados de saúde mais acessíveis – quanto os profissionais de saúde – por diminuir o esgotamento causado pela papelada e tarefas administrativas (Pham et al., 2024). Essa inovação disruptiva é diferente de tecnologias anteriores porque estas tem natureza previsível e determinística, definições claras do seu processo, funcionamento e papel, ao contrário da IA (Asan et al., 2020), o que, consequentemente, possui resultados potenciais diferentes.

As potencialidades de transformação que a IA apresenta ao setor da saúde são enxergadas por vários atores e tomadores de decisão do contexto nacional e internacional. Diversas ações realizadas no país evidenciam o interesse público não só em investir, mas também em procurar parcerias internacionais a fim de viabilizar e apoiar a implementação da IA no Brasil (Oliveira, 2022). Evidências empíricas sugerem que os hospitais que implementam tecnologias de IA podem aprimorar vários aspectos de desempenho, incluindo receita total de atendimento ambulatorial, receita total de internação, produtividade e ocupação, obtendo assim benefícios operacionais (Pham et al., 2024).

Vários pesquisadores revisaram a produção científica existente com o objetivo de entender os fatores que influenciam o uso ou resistência à inteligência artificial na saúde (Li et al., 2023; Roppelt et al., 2024; Yang et al., 2024). Dentre os pontos em comum encontrados nessas pesquisas, destaca-se a investigação de tais fatores a partir de percepções de profissionais de saúde (Alshehri et al., 2024; Alsobhi et al., 2022; Asan et al., 2020; Cheng et al., 2022; Hasan et al., 2024; Kujala & Hörhammer, 2022; Wenderott et al., 2024) e de pacientes (Antes et al., 2021; Armero et al., 2022; Cao et al., 2023; Esmaeilzadeh, 2020; Huang et al., 2024; Kerstan et al., 2024). No entanto, a investigação dos fatores envolvidos na adoção ou resistência à IA a

partir da perspectiva de organizações é menos frequente (Yang et al., 2024) em comparação a perspectiva dos dois grupos anteriores (Rodrigues & Abbas, 202X).

Os estudos que abordaram a perspectiva de organizações estão limitados as circunstâncias de países específicos, como Índia (Kumar et al., 2023) Estados Unidos (Pham et al., 2024) e Alemanha (Tokgöz et al., 2024) e utilizaram um número limitado de gestores na amostra (Kumar et al., 2023; Tokgöz et al., 2024; Weinert et al., 2022). Além da insuficiente exploração da perspectiva da gerência, algo menos observado é a análise de contextos emergentes (Roppelt et al., 2024) e algo fortemente sugerido é a investigação de evidências reais com métodos quantitativos (Kumar Singh et al., 2023; Tokgöz et al., 2024).

Outra característica dos estudos anteriores é a exploração de um número limitado de determinantes na análise. Sun (2021) investigou apenas determinantes relacionados ao poder social, relacionados ou não ao conhecimento: poder de especialista, poder informacional e poder de referência, poder de recompensa, poder coercitivo e poder legítimo. Pham et al. (2024), por exemplo, analisaram apenas dois determinantes na adoção de IA: participação de mercado e tempo médio de internação.

Portanto, é válido explorar os fatores determinantes de organizações quanto a adoção e resistência à IA, pois estes podem ser muito diferentes daqueles dos pacientes ou médicos. Essa diferença entre partes interessadas se deve especialmente aos seguintes fatores: diferença no conhecimento prévio e na experiência na área médica (Asan et al., 2020), diferença nos relacionamentos de confiança (Asan et al., 2020), bem como possível conflito de interesses (Padmanabhan et al., 2021). Ademais, a investigação desses determinantes pode auxiliar no entendimento da tomada de decisão a respeito da adoção de IA, pelo ponto de vista dos gestores, uma vez que são os principais representantes das organizações (Rodrigues & Abbas, 202X), responsáveis por escolhas de investimento e implantação (Tokgöz et al., 2024) e intermediários importantes entre desenvolvedores, empresas de tecnologia e autoridades reguladoras (Weinert et al., 2022).

Um estudo realizado com gestores alemães apontou que a facilidade de uso e a compatibilidade com estruturas técnicas existentes são os fatores tecnológicos que mais influenciam a implementação de sistemas baseados em IA (Tokgöz et al., 2024). Um estudo empírico realizado nos Estados Unidos concluiu que os hospitais com maior participação de mercado são ótimos candidatos para adotar tais tecnologias (Pham et al., 2024). Outro estudo norte americano, realizado com dados da American Hospital Association (AHA), concluiu que hospitais com maior número de leitos, com departamentos ambulatoriais cirúrgicos, de

propriedade privada sem fins lucrativos e com status de ensino apresentam maior probabilidade de adotar diferentes formas de IA (Baten, 2024).

Dentre as principais teorias usadas para investigar a adoção de tecnologias, destacam-se a Teoria Unificada de Aceitação e Uso de Tecnologia (UTAUT) e o Modelo de Aceitação Tecnológica (TAM) (Cheng et al., 2022; Huang et al., 2024; Kleine et al., 2023; Wenderott et al., 2024). Geralmente essas duas teorias explicam a aceitação tecnológica na dimensão e percepção do indivíduo e, muitas vezes, avaliam apenas a intenção de adoção (Roppelt et al., 2024). Para investigar o uso de fato de tecnologias no contexto organizacional, pesquisadores optaram pelo *framework* Tecnologia-Organização-Ambiente (TOE) (Dastjerdi et al., 2023). Esse *framework*, diferentemente das teorias UTAUT e TAM, permite compreender o fenômeno da implementação de novas tecnologias não só na dimensão individual, mas na dimensão organizacional e com a incorporação de elementos ambientais.

Embora existam pesquisas que explorem o uso de tecnologias de informação e comunicação em estabelecimentos de saúde, os estudos que investigam a realidade população brasileira são atípicos (Fontan, 2023). Quando envolvem tecnologias baseadas em inteligência artificial são ainda menos frequentes (Silva, 2023). As particularidades do Brasil, especialmente no que se refere ao Sistema Único de Saúde (SUS), aos dados coletados por ele, à diversidade populacional e à legislação, expressam oportunidades para a aplicação da IA na saúde nacional (NIC.br, 2024). Essas características apontam para a possibilidade do Brasil ser diferente do panorama internacional e indicam potencial para que as relações esperadas sejam diferentes das de outros contextos.

Nacionalmente, um mapeamento realizado pela Associação Nacional de Hospitais Privados, em parceria com a Associação Brasileira de Startups de Saúde, revelou que hospitais privados do país estão investindo em IA (Anahp, 2023). Embora os gestores dos hospitais apontem a falta de interoperabilidade sistêmica, custo elevado de implantação, dificuldade em engajar corpo clínico quanto às novas tecnologias e preocupações quanto a privacidade e segurança dos dados como alguns desafios para a aplicação de IA, mais da metade da amostra utiliza a tecnologia em seus processos (Anahp, 2023). No entanto, o contexto teórico nacional carece de pesquisas quantitativas e com evidências estatísticas que objetivem investigar os determinantes à adoção de tecnologias baseadas em IA por estabelecimentos de saúde.

Assim, é necessário realizar uma análise focada no contexto brasileiro, com exploração dos fatores envolvidos na adoção e uso da IA por estabelecimentos de saúde, de acordo com seus gestores, especialmente com fornecimento de provas estatísticas. Tendo em vista o que foi mencionado, este estudo busca responder a seguinte questão de pesquisa: **Quais são os**

determinantes (tecnológicos, organizacionais e ambientais) da adoção de Inteligência Artificial por estabelecimentos de saúde brasileiros? Assim, objetiva identificar os determinantes tecnológicos, organizacionais e ambientais da adoção de Inteligência Artificial por estabelecimentos de saúde brasileiros.

Para tanto, este estudo utiliza dados secundários produzidos e divulgados pelo Centro Regional de Estudos para o Desenvolvimento da Sociedade da Informação (Cetic.br), por meio da pesquisa TIC Saúde, referente ao ano-base 2024. A pesquisa TIC Saúde 2024 entrevistou os gestores responsáveis pela área de Tecnologia da Informação ou, no caso da ausência desses, os gestores administrativos dos estabelecimentos de saúde. O questionário foi aplicado por meio de entrevistas telefônicas assistidas por computador. Para realização de testes estatísticos, este estudo utilizará análise de correspondência e o modelo de regressão logística multinomial, com uma abordagem quantitativa e exploratória. Ao utilizar a base de microdados TIC Saúde 2024, esta pesquisa visa identificar os determinantes que influenciam a adoção ou rejeição de IA por estabelecimentos de saúde brasileiros, o que pode ser um passo inicial no desenvolvimento de intervenções de implementação. Dessa forma, espera-se contribuir para o desenvolvimento da literatura sobre a aplicação da IA na saúde (IAS) ao testar o efeito dos fatores que possibilitam ou atrapalham sua adoção, bem como fornecer evidências reais sobre a utilização dessas tecnologias no setor de saúde brasileiro. Assim, é possível aprimorar a compreensão de como a IA, uma das mais populares tecnologias emergentes, está sendo utilizada no país e instigar futuras discussões sobre o potencial dela em contribuir efetivamente para a eficiência no setor hospitalar nacional.

Como contribuição prática, este estudo fornece informações para auxiliar os gestores de hospitais, do setor público e privado, quanto à tomada de decisão que envolva uso de IA. Também auxilia fornecedores e desenvolvedores de tecnologias baseadas em IA a compreender o atual estágio de adoção de tais tecnologias pelo setor da saúde brasileiro e a refletir em iniciativas de aprimoramento. Também pode auxiliar órgãos governamentais no que diz respeito à formulação de políticas eficazes para promover a adoção bem-sucedida de tecnologias baseadas em IA. Ao considerar o impacto social significativo que a alta performance de hospitais tem, a possibilidade de adotar melhorias tecnológicas que afetem positivamente os hospitais, especialmente ao economizar tempo e esforço dos profissionais de saúde, pode ser benéfica para os usuários dos serviços de saúde e para a sociedade como um todo.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 INTELIGÊNCIA ARTIFICIAL NA SAÚDE (IAS)

A IA é uma área da tecnologia que utiliza máquinas programadas para imitar ações e pensamentos humanos. (Sun, 2021). Qualquer aplicativo ou dispositivo que perceba o ambiente de maneira semelhante aos humanos e atue para atingir uma meta de forma otimizada pode ser considerado IA (Sun, 2021). Várias atividades do cotidiano estão sendo aprimoradas por meio de IA, por vezes até superando a capacidade humana, tais como: reconhecimento de fala, reconhecimento facial, recomendação, transporte autônomo, mecanismos de busca na web e assistência virtual (Ali et al., 2024). No entanto, ainda está subjugado à capacidade humana o ato de decidir como usar, onde usar e em que medida usar a IA (Deveci, 2023; Kfoury Neto et al., 2020).

Vários setores utilizam IA para diversos motivos e em diferentes condições (Deveci, 2023). Em ambientes de saúde, as funções da IA incluem processamento de linguagem natural para interpretar dados não estruturados, como notas clínicas ou declarações de pacientes, e aprendizado de máquina para interpretar dados estruturados, como imagens médicas ou informações genéticas (Yamaoka & Watanabe, 2023). Os benefícios dessas tecnologias atingem tanto os destinatários da assistência médica – por reduzir os tempos de espera e tornar os cuidados de saúde mais acessíveis – quanto os profissionais de saúde – por diminuir o esgotamento causado pela papelada e tarefas administrativas (Pham et al., 2024). Devido a tais características, a implementação de tecnologias baseadas em inteligência artificial tem o potencial de revolucionar a assistência médica e causar um impacto significativo em todo o setor de saúde (Li et al., 2023; Marco-Ruiz et al., 2024; Wolff et al., 2021) e na ampla esfera de políticas públicas acerca do tema (Olawade et al., 2023). A IA, além de ser um campo em evolução, está sendo cada vez mais impulsionada a fim de fornecer suporte na tomada de decisões clínicas na área da saúde (Deveci, 2023). O crescente volume de dados de saúde, o papel em rápida expansão das tecnologias digitais na assistência médica e a disponibilidade de diversas opções de tratamento tornam o desenvolvimento e o uso de ferramentas baseadas em IA na prestação de cuidados uma inovação oportuna e necessária (Bajgain et al., 2023).

A adoção de IA pode ser entendida como uma decisão tomada por hospitais ou usuários individuais (como pacientes, médicos e pessoal médico) para adotar uma tecnologia de IA (Sun, 2021). A adoção e posterior implementação da IA é altamente complexa (Weinert et al., 2022), exigindo atividades que envolvem uma ampla gama de partes interessadas, incluindo

desenvolvedores de tecnologia, reguladores de sistemas, organizações e indivíduos – profissionais, pacientes e cuidadores (Gama et al., 2022; Strohm et al., 2020).

A literatura existente e relevante sobre adoção de IA é predominantemente de países europeus, como Alemanha (Roppelt et al., 2024; Tokgöz et al., 2024; Weinert et al., 2022; Wenderott et al., 2024), da China (Cheng et al., 2022; Du et al., 2023) e dos Estados Unidos (Antes et al., 2021; Armero et al., 2022; Asan et al., 2020; Esmaeilzadeh, 2020; Pham et al., 2024). Países considerados em desenvolvimento têm recebido menor atenção de pesquisadores (Deveci, 2023; Kumar et al., 2023), como é o caso do Brasil, apesar do potencial que algumas de suas características oferecem.

Ao considerar as vantagens potenciais que o Brasil tem para utilização de IA no seu sistema de saúde, quatro características despertam o interesse (NIC.br, 2024). A primeira vantagem consiste na heterogeneidade e diversidade populacional, ou seja, a presença de múltiplas etnias, grupos e ambientes (Belli, 2023). As informações dessa população variada, quando coletadas corretamente, são insumos valiosos para um banco de dados inigualável. Um segundo argumento favorável é a existência de um marco legal inicial capaz de orientar regulações futuras e moldar a implementação de tecnologias digitais na área da saúde como a IA – a Lei Geral de Proteção de Dados, ou LGPD (Belli, 2023; Gonçalo et al., 2025). Essa legislação, apesar de não tratar especificamente da regulação de IA, estabelece princípios norteadores que auxiliam a discutir a questão da sensibilidade dos dados e as problemáticas quanto a privacidade da informação (Dourado & Aith, 2022; Kfourri et al., 2020).

A terceira vantagem é a magnitude do Sistema Único de Saúde (SUS), um sistema universal de saúde que, além de permitir a descentralização das ações de maneira estruturada, viabiliza a coleta de dados da população como um todo. Os dados representam o insumo vital para os sistemas de inteligência artificial, sendo o acesso a informações diversificadas e de alta qualidade crucial para o treinamento e aprimoramento dos modelos de IA (Belli, 2023). No entanto, com uma grande variedade de dados disponíveis, surge o desafio de transformá-los em informações e indicadores para auxiliar os tomadores de decisão bem como a gestão participativa do sistema de saúde (Belli, 2023; Haddad & Lima, 2024).

Nesse sentido, uma última particularidade positiva do país é a Rede Nacional de Dados em Saúde (RNDS), uma plataforma para integração de dados em saúde (NIC.br, 2025). Apesar de estar em seus primeiros estágios de desenvolvimento, a RNDS é uma aposta promissora para gradual e progressivamente subsidiar a interoperabilidade das bases de dados sensíveis – isto é, dados pessoais relativos à saúde, quando vinculados a uma pessoa natural (Haddad & Lima, 2024; Kfourri et al., 2020; Lemes & Lemos, 2020) – possibilitando a troca segura de informações

entre sistemas de diferentes níveis de atenção à saúde e entre estabelecimentos de saúde públicos e privados (NIC.br, 2025). Tais oportunidades da IA na saúde brasileira e os fatores favoráveis do contexto nacional são observados na Figura 1.




Figura 1. Oportunidades da IA na Saúde no Brasil. Extraída de NIC.br (2024)

As características e vantagens apresentadas apontam para o potencial do Brasil em assumir a posição como polo de consolidação de um grande sistema de integração de dados, algo essencial para a expansão da IA. No entanto, as oportunidades são acompanhadas por desafios que demandam atenção de diferentes atores para impulsionar uma adoção de IA bem-sucedida.

2.2 MODELOS TEÓRICOS E TÉCNICOS DE ADOÇÃO DE IA

Para explicar o fenômeno da adoção de novas tecnologias no setor da saúde, pesquisadores já utilizaram diversos modelos e estruturas teóricas (Dastjerdi et al., 2023), advindos de áreas como inovação e sistemas de informação (Roppelt et al., 2024). Tais modelos também têm sido empregados para investigar a adoção de tecnologias baseadas em inteligência artificial. Dentre as principais lentes, destacam-se a Teoria Unificada de Aceitação e Uso de Tecnologia (do inglês, Unified Theory of Acceptance and Use of Technology – UTAUT)

(Cheng et al., 2022; Huang et al., 2024; Kleine et al., 2023) e o Modelo de Aceitação de Tecnologia (do inglês, Technology Acceptance Model - TAM) (Wenderott et al., 2024). Geralmente, essas duas teorias mencionadas visam investigar a aceitação tecnológica na dimensão e percepção do indivíduo (Roppelt et al., 2024) e, muitas vezes, avaliam sua intenção de adoção.

No entanto, pesquisadores enfatizaram a necessidade de ir além de uma abordagem focada na aceitação individual da inovação (Dastjerdi et al., 2023) e nas atribuições de IA e sua usabilidade para considerar o nível organizacional (Roppelt et al., 2024) e as demais influências mais amplas, como sociais e institucionais, que impactam a adoção de IA (Tokgöz et al., 2024). Variadas categorizações foram realizadas por autores, a partir de diversas lentes teóricas, a fim de melhor compreender o fenômeno da adoção de IA. O Apêndice A apresenta uma síntese dos estudos anteriores sobre o assunto, identificando a lente teórica utilizada e as técnicas de análise.

Os estudos são variados no que se refere a métodos qualitativos ou quantitativos e tipos de estabelecimento. Pesquisas realizadas utilizaram estudo de caso (Deveci, 2023; Kumar et al., 2023; Strohm et al., 2020; Sun, 2021), entrevistas (Strohm et al., 2020; Vijayakumar et al., 2023), questionários (Cheng et al., 2022; Dastjerdi et al., 2023; Horani et al., 2023; Kleine et al., 2023; Kumar et al., 2023; Tokgöz et al., 2024) e estatística baseada em dados documentais (Pham et al., 2024).

Tais estudos foram realizados tendo como base hospitais (Pham et al., 2024), ao investigar a perspectiva dos profissionais de saúde que neles trabalham (Cheng et al., 2022; Kleine et al., 2023; Vijayakumar et al., 2023), dos gestores que deles administram (Dastjerdi et al., 2023; Horani et al., 2023; Tokgöz et al., 2024) ou ambos (Deveci, 2023; Strohm et al., 2020; Sun, 2021). Alguns estudos foram realizados em outros contextos, como por exemplo cadeia de suprimentos (Kumar et al., 2023). Dos determinantes mais investigados, os que apresentaram resultados significativos são: Apoio ou Políticas governamentais (Dastjerdi et al., 2023; Deveci, 2023; Kumar et al., 2023), suporte da alta gestão (Dastjerdi et al., 2023; Horani et al., 2023) e pressão competitiva (Dastjerdi et al., 2023; Horani et al., 2023; Kumar et al., 2023).

Além disso, também é possível perceber que diferentes lentes teóricas são úteis para compreender o fenômeno da adoção de inteligência artificial e identificar determinantes em variadas dimensões. Por exemplo, para investigar os determinantes de adoção de um Sistema de gerenciamento de relacionamento com o cliente (CRMS) baseado em IA em hospitais iranianos, Dastjerdi et al. (2023) utilizaram o Framework TOE, integrada com as dimensões Humano e Custos. Os resultados da pesquisa revelaram os Suporte da Alta Gerência, Preocupações com Segurança e Privacidade de Dados, Vantagens Relativas, Tamanho do

Hospital, Política Governamental, Pressão do Cliente, Custos de Manutenção e Treinamento de Pessoal como determinantes principais para adoção da tecnologia.

De acordo com a análise apresentada, os determinantes para a adoção da IA podem ser considerados como parte de categorias variadas, a depender da ótica teórica aplicada. Com base nos dados disponíveis na pesquisa TIC Saúde 2024, em consonância com pesquisadores anteriores e considerando o potencial para explicar o fenômeno da adoção de IA na saúde, foi selecionado o Framework Tecnologia-Organização-Ambiente (do inglês, Technology-Organization-Environment – TOE) para direcionar as análises. Maiores explicações sobre essa lente teórica são apresentadas na seção seguinte.

2.3 TOE (TECHNOLOGY, ORGANIZATION, ENVIROMENT) COMO ESTRUTURA DE ADOÇÃO DE IA

O modelo TOE foi proposto em 1990 por Louis G. Tornatzky e Mitchell Fleischer, no livro “The Processes of Technological Innovation”. Esse framework é útil para analisar os fatores que influenciam o processo decisório de adotar e implementar uma inovação tecnológica dentro da organização (Horani et al., 2023; Wang & Chiou, 2020). Os autores reforçam a importância do contexto, em que a organização está inserida, para a mudança e argumentam que existem três dimensões contextuais: tecnologia, organização e ambiente (Lian et al., 2014; Roppelt et al., 2024; Tornatzky & Fleischer, 1990; Wang & Chiou, 2020).

O contexto tecnológico, como o nome indica, descreve tecnologias relevantes para a organização, o que inclui características, práticas e equipamentos usados na organização, bem como tecnologias disponíveis no mercado. O contexto organizacional refere-se a medidas como estrutura, tamanho, centralização, formalização e complexidade gerencial, processos internos, qualidade e disponibilidade dos recursos internos. O contexto ambiental é a arena na qual uma empresa desempenha seus negócios — sua localização, setor, concorrentes, fornecedores, regulamentos e relações com o governo – e pode envolver oportunidades ou ameaças (Dastjerdi et al., 2023; Horani et al., 2023; Roppelt et al., 2024; Tornatzky & Fleischer, 1990; Wang & Chiou, 2020).

O modelo TOE é uma estrutura conceitual que não indica quais fatores especificados devem ser incluídos em cada contexto, mas fornece aos pesquisadores uma direção para contemplar e explorar os fatores de influência. Os fatores determinantes devem ser escolhidos a partir do tema da pesquisa e do tipo de inovação tecnológica (Wang & Chiou, 2020). O modelo original proposto pode ser visualizado na Figura 2.




Figura 2. Estrutura Tecnologia, Organização e Ambiente. Adaptada de Tornatzky e Fleischer (1990)

Embora as variáveis entre alguns estudos acadêmicos correspondam a contextos ligeiramente diferentes no TOE, sua estrutura tem sido apoiada por muitos estudos empíricos e pode ser usada para prever, analisar, compreender e explicar os comportamentos de tomada de decisão das organizações corporativas para adotar tecnologias inovadoras (Wang & Chiou, 2020), especialmente tecnologias de informação (Lian et al., 2014).

Como evidenciado na seção 2.2, pesquisas anteriores também enxergaram o potencial do *Framework* TOE em explicar o fenômeno da adoção e implementação de IA na saúde (Dastjerdi et al., 2023; Horani et al., 2023; Kumar et al., 2023). Em comparação com outras teorias que investigam a percepção, aceitação ou intenção de uso de tecnologias no nível do indivíduo, a TOE é um *Framework* a nível organizacional (Horani et al., 2023). Por isso, neste estudo, ela será utilizada para seleção de determinantes (variáveis), elaboração das hipóteses e discussão dos resultados. Nesse sentido, a expressão “variáveis” será utilizada como sinônimo de “determinantes”, especialmente na apresentação da metodologia e nas análises estatísticas.

2.4 DETERMINANTES DA ADOÇÃO DE INTELIGÊNCIA ARTIFICIAL NA SAÚDE E HIPÓTESES DE PESQUISA

Com base nas três dimensões do *Framework* TOE foram selecionados os fatores determinantes que podem ter relação com a tomada de decisão por parte de gestores envolvendo a adoção de IA. Para a escolha dos determinantes, foi consultada a base de dados da pesquisa TIC Saúde 2024 (que será detalhadamente explicada no capítulo 3) e investigada a literatura

atual existente por meio de uma revisão sistemática prévia (Rodrigues & Abbas, 2025). No entanto, alguns determinantes encontrados na revisão de literatura realizada previamente não foram investigados no presente estudo por não serem mensuradas pela pesquisa TIC Saúde do ano 2024.

Os determinantes aqui utilizados correspondem a atributos que são diretamente medidos pela pesquisa TIC Saúde, o que torna possível uma pesquisa com uma amostra estatisticamente representativa, coletada com rigor metodológico e procedimentos robustos. Assim, neste estudo, as categorias utilizadas para classificação são: (i) determinantes tecnológicos; (ii) determinantes organizacionais; e (iii) determinantes ambientais.

2.4.1 Determinantes tecnológicos

O uso de tecnologias digitais, como prontuários eletrônicos, atendimentos remotos, aplicativos móveis e digitalização de prescrições, pode transformar de maneira significativa as práticas clínicas (NIC.br, 2025). De acordo com o *Framework* TOE, a dimensão tecnológica contém todas as tecnologias relacionadas à organização, independentemente de a tecnologia estar atualmente disponível na organização ou existente no mercado, mas não estar sendo utilizada (Dastjerdi et al., 2023). No que diz respeito a adoção de IA em estabelecimentos de saúde, os fatores tecnológicos são os preditores mais significativos (Esmaeilzadeh, 2020) e podem envolver infraestrutura existente, o acesso e manutenção dos dados do paciente por meio do sistema eletrônico de saúde, a segurança dos dados e privacidade da informação, adoção de tecnologias emergentes e prestação de serviços de maneira remota, como telemedicina e telessaúde.

A infraestrutura do estabelecimento, especialmente no que diz respeito aos sistemas e tecnologias de informação e comunicação, consiste em recursos físicos, incluindo disponibilidade e qualidade de requisitos de software, hardware, meios e ferramentas de rede, que contribuem para a transição ou execução da informação (Dastjerdi et al., 2023; Deveci, 2023; Kumar et al., 2023). A falta de infraestrutura de TIC adequada para adotar sistemas de saúde foi reconhecida como um desafio prevalente na adoção de inovação enquanto a presença de equipamento técnico e a compatibilidade da IA com estruturas técnicas existentes é um fator facilitador (Tokgöz et al., 2024).

Roppelt et al. (2024) revelaram que o status da configuração e da infraestrutura de TI de uma organização de saúde é decisivo para adoção de IA. Os autores apontam que alguns dos desafios nesse sentido são infraestruturas de TI inflexíveis, incapazes de incorporar *software*

externo, *hardware* desatualizado que não consegue lidar com a capacidade computacional necessária e não é energeticamente eficiente. Fica claro que a infraestrutura certa é decisiva para uma implementação bem-sucedida de IA (Marco-Ruiz et al., 2024) e desafios logísticos podem afetar negativamente a adoção de IA na organização (Li et al., 2023).

Tokgoz et al. (2024) revelaram que 56% dos respondentes de sua pesquisa concordam que o determinante “Equipamento técnico” é “Muito importante” e 30% que ele é “Moderadamente importante” (Tokgöz et al., 2024). Deveci (2023) investigou o uso de IA na cadeia de suprimentos de saúde turca e identificou a dimensão “Infraestrutura técnica” como a mais significativa no modelo. Dentro dessa dimensão, o determinante “Intensidade tecnológica”, que se refere a disponibilidade e qualidade de requisitos tecnológicos, como *hardware* e *software*, foi o mais significativo. Nesse sentido, o autor ressalta que as tecnologias existentes preparam os usuários para as novas tecnologias (Deveci, 2023).

Assim, é pertinente investigar o efeito que a infraestrutura de TIC existente no estabelecimento, medida pela contagem de artefatos ou sistemas de TI usados (Pham et al., 2024), pode ter sobre a adoção de IA, como demonstra a primeira hipótese deste estudo:

H1: A infraestrutura de TIC existente está positivamente associada com a adoção de IA nos estabelecimentos de saúde.

Todas as atividades desenvolvidas por IA, como previsão de doenças, por exemplo, dependem da qualidade e integridade dos dados usados para treinar os algoritmos (Marco-Ruiz et al., 2024; Olawade et al., 2023). É a partir da análise de grandes conjuntos de dados complexos que modelos de aprendizado de máquina encontram padrões, fazem novas previsões e analisam tendências (López-Martínez et al., 2020). Além disso, a confiabilidade, integridade e a sustentabilidade dos dados são uma grande preocupação para os adotantes no processo de adoção – tanto para persuadir os pacientes a usar os sistemas quanto para poder confiar na eficiência do sistema (Deveci, 2023; Kumar et al., 2023).

Autores concordam que a disponibilidade de dados está entre os desafios mais críticos para a implementação bem-sucedida de IA na área da saúde (Marco-Ruiz et al., 2024; Olawade et al., 2023; Vijayakumar et al., 2023) e o suporte que dados padronizados e de alta qualidade podem dar para a adoção de IA é vital (Terry et al., 2022). Por exemplo, algoritmos de aprendizado de máquina precisam de dados para seu aprendizado e treinamento, pois são eles que permitem à máquina processar informações, gerar resultados mais precisos e contribuir para a resolução ou otimização de processos por meio da automatização (Costa & Kremer, 2022). Logo, o acesso a dados atualizados e de qualidade é necessário para monitorar o desempenho de uma IA, em termos de especificidade e sensibilidade (Marco-Ruiz et al., 2024).

Tal ponto de vista é compartilhado por Tokgoz et al. (2024) que investigaram a percepção de gestores de hospitais alemães sobre os fatores associados a implementação bem-sucedida de um sistema de apoio a decisão para prescrição de antibiótico – uma tecnologia baseada em IA. Outro estudo que também investigou hospitais alemães foi o de Weinert et al. (2022). Os autores concluíram que “Disponibilidade dos dados” é a quarta barreira mais comum na implementação e uso de IA, “Quantidade de dados” a sétima e “Base de dados” é o sexto recurso mais importante para implementação de IA (Weinert et al., 2022). Diferentemente das pesquisas de Tokgoz et al. (2024) e Weinert et al. (2022) que investigaram apenas os gestores, Terry et al. (2022) expandiram seu objeto de pesquisa a outras partes interessadas como profissionais de saúde e acadêmicos. Por meio de um estudo qualitativo baseado em entrevistas, os autores concluíram que dentre os elementos necessários que atuam como facilitadores da adoção de IA, o segundo mais mencionado nas entrevistas é “Disponibilidade e uso de dados com alta qualidade” (Terry et al., 2022).

Nesse contexto, os estabelecimentos de saúde que tem acesso aos dados relacionados ao paciente e possibilidades de manutenção desses dados talvez possuam uma vantagem relativa em comparação com estabelecimentos de saúde que não tem as mesmas condições (Marco-Ruiz et al., 2024). Portanto, o seu efeito na adoção de IA deve ser investigado, conforme a hipótese a seguir:

H2: O acesso e manutenção dos dados do paciente está positivamente associado com a adoção de IA nos estabelecimentos de saúde.

Vários fatores relacionados a inteligência artificial podem influenciar a opinião e o comportamento da sociedade de forma abrangente. Algumas das preocupações compartilhadas por pacientes, profissionais da saúde, gestores e estudantes são quanto às questões éticas e quanto a segurança e privacidade dos dados (Dastjerdi et al., 2023; Hasan et al., 2024; Li et al., 2023; Marco-Ruiz et al., 2024; Olawade et al., 2023; Yamaoka & Watanabe, 2023).

Em função do risco de privacidade, países tem utilizado regulamentos para controlar como os dados são coletados, armazenados e usados (Li et al., 2023). No cenário nacional, o amparo advém da Lei Geral de Proteção aos Dados (LGPD), que é o marco inicial regulatório (Dourado & Aith, 2022) e, assim como as legislações de outros países, pode apoiar o desenvolvimento de políticas e práticas de saúde (Olawade et al., 2023). A segurança dos dados tem sido considerada um dos determinantes mais críticos na dimensão tecnológica do *Framework* TOE (Lian et al., 2014).

Dastjerdi et al. (2023) revelaram que o determinante “Preocupações com segurança dos dados e privacidade”, assumiu a sexta posição (entre 22) como mais significativo para adoção

de uma tecnologia baseada em IA em hospitais iranianos. Esse achado é condizente com o de Terry et al., (2022) que apresentaram “privacidade e segurança dos dados” como uma das principais preocupações dos participantes entrevistados. De forma semelhante, Weinert et al. (2022) elencaram “Proteção de dados” como a sétima barreira que mais afeta a implementação de IA, percebida por 55% dos participantes.

Nesse sentido, espera-se que a utilização de ferramentas e medidas de segurança no estabelecimento de saúde diminua tais preocupações e facilite o uso de IAS. A fim de investigar a relação entre uso de ferramentas de segurança e proteção de dados e a adoção de IA, estabelece-se a seguinte hipótese:

H3: O uso de ferramentas de segurança e proteção de dados influencia positivamente a adoção de IA nos estabelecimentos de saúde.

A experiência com a implementação de outras tecnologias digitais, por exemplo, telemedicina na atenção primária, foi apontada por profissionais da saúde como influenciadora de sua atitude em relação às novas tecnologias digitais (Held et al., 2022). Ou seja, profissionais que utilizam tecnologias relacionadas a telemedicina e telessaúde podem ter diferentes percepções e atitudes sobre uso de outras tecnologias inovadoras, como IA. A telemedicina é uma plataforma emergente de saúde que permite aos pacientes acessar serviços de saúde sem esforço (Kabir et al., 2024).

No Brasil, a telessaúde engloba várias facetas do atendimento remoto, complementando o atendimento presencial, pois alcança áreas distantes que convivem com um serviço precário, aprimora a gestão das filas de espera, reduz custos e aumenta a praticidade (NIC.br, 2024). A maior disponibilização de serviços de telessaúde foi apontada como uma das alternativas eficazes para aumentar a eficiência do atendimento, ao facilitar o contato com profissionais da área, ampliar o acesso a especialidades médicas, a determinados exames e diagnósticos, bem como monitorar condições crônicas, sem a necessidade de deslocamento (NIC.br, 2024).

No entanto, muitos procedimentos de maior complexidade, como a análise de imagens, monitoramento de pacientes, caracterizar e prognosticar doenças, viabilizar o uso de sensores e cirurgias, não podem ser realizados apenas com a utilização de métodos tradicionais de telessaúde (NIC.br, 2024) e requerem a incorporação de tecnologias avançadas. Nesse contexto, a articulação da telemedicina com recursos da IA permite impulsionar aplicações dedicadas a diagnóstico de doenças infecciosas, prescrição de antibióticos, bem como a vigilância da pandemia de COVID-19, realizando avaliação de risco sobre os sintomas e sinais associados por meio de pesquisas na web ou dispositivos móveis, (Gomez et al., 2024; NIC.br, 2024; Shen et al., 2021).

Evidências empíricas revelam que, no Brasil, já existem startups desenvolvendo sistemas que utilizam IA para auxiliar no atendimento remoto, tais como ferramentas para análise de sintomas e diagnósticos preliminares a partir do relato do paciente (NIC.br, 2024). Por exemplo, um estudo exploratório divulgado pelo NIC.br, intitulado “Inteligência Artificial na saúde: diagnóstico qualitativo sobre o cenário brasileiro”, com autoria de Graziela Castello, Monise Picanço, Priscila Faria e Rodrigo Brandão coletou percepções de atores estratégicos envolvidos em IA. Um dos *stakeholders* do mercado entrevistado foi responsável por construir uma ferramenta de IA para triagem voltada às consultas remotas, a qual busca identificar a demanda do paciente e realizar a triagem para o tipo de atendimento necessário (NIC.br, 2024).

Até o momento deste estudo, não foram encontradas pesquisas empíricas que testem a relação entre serviços remotos de saúde e adoção de inteligência artificial. No entanto, como apontado pela literatura mencionada anteriormente, estabelecimentos que já implementaram atividades remotas relacionadas a saúde podem otimizar seus resultados com a adoção da IA. Assim, faz sentido pensar que estabelecimentos que já disponibilizam serviços de telemonitoramento, teleconsulta, teleconsultoria, telediagnóstico, ensino e pesquisa à distância (ou seja, atividades remotas relacionadas à saúde) estão mais inclinados a adotar IA. Nesse sentido, convém explorar a seguinte hipótese:

H4: A prestação de serviços de saúde de forma remota, por meio de telemedicina e telessaúde, influencia positivamente a adoção de IA nos estabelecimentos de saúde.

Por último, cabe destacar que as ferramentas baseadas em inteligência artificial fazem parte de um conjunto de tecnologias emergentes, também conhecidas como tecnologias 4.0 (Tortorella et al., 2020). Tais tecnologias são advindas da chamada quarta revolução industrial. Além da inteligência artificial, especialmente aprendizado de máquina, estão incluídos nesse conjunto Internet das coisas (IoT – do inglês, *Internet of Things*), *Big data*, *Blockchain*, robótica e *cloud computing* (Tortorella et al., 2020).

As tecnologias de *Big data* permitem reunir grandes volumes de dados estruturados e não estruturados de diferentes fontes em um repositório para serem examinados e analisados (López-Martínez et al., 2020). Como já mencionado anteriormente, os dados são os insumos principais para aprendizado e treinamento da IA (Terry et al., 2022; Tokgöz et al., 2024; Weinert et al., 2022). Pesquisas sobre IA na saúde apontam que os recursos de *big data* são essenciais no processo de uso das fontes de dados (Roppelt et al., 2024). Por isso, estabelecimentos de saúde que utilizam *big data* tem maior facilidade no acesso aos dados para treinar e validar modelos de IA (López-Martínez et al., 2020).

As tecnologias de *Blockchain* contribuem para solucionar problemas de segurança de dados, interoperabilidade e propriedade de dados de pacientes, gerenciando dados sensíveis de saúde de forma descentralizada, segura e transparente (Mazhar et al., 2025). Como mencionado anteriormente, a preocupação com a segurança dos dados é uma das principais barreiras para a adoção da IA (Dastjerdi et al., 2023; Weinert et al., 2022), por isso estabelecimentos de saúde se preocupam em utilizar e armazenar dados de pacientes de forma segura (Mazhar et al., 2025). Pesquisadores apontam que o uso conjunto dessas duas tecnologias disruptivas – IA generativa e *Blockchain* – pode não só potencializar os benefícios à eficiência hospitalar, mas melhorar a confidencialidade, a precisão e a integridade dos dados (Mazhar et al., 2025).

As tecnologias de IoT, robótica e *cloud computing* também podem estar relacionadas com a adoção de IA. Essas tecnologias atuam para coletar dados, automatizar tarefas, até mesmo cirurgias e suprir a falta de capacidade local de hospitais e clínicas para processar grandes volumes de dados (Javaid et al., 2025; Tortorella et al., 2020). Até o momento deste estudo, não foram encontradas pesquisas empíricas que testem a relação entre o uso das demais novas tecnologias e adoção de inteligência artificial na saúde. No entanto, evidências da literatura mostram que o uso dessa gama de tecnologias inovadoras tende a ser acompanhado da aplicação de IA, pois aquelas tem o potencial de reduzir barreiras e facilitar a adoção desta (Mazhar et al., 2025). Por isso, faz sentido investigar se a utilização das demais tecnologias inovadoras influencia a adoção de IA nos estabelecimentos de saúde.

H5: O uso de novas tecnologias influencia positivamente a adoção de IA nos estabelecimentos de saúde.

2.4.2 Determinantes organizacionais

A dimensão organizacional alude às características e posses de uma organização que podem restringir ou permitir a adoção de tecnologia inovadora (Dastjerdi et al., 2023). No que diz respeito a adoção de IA em estabelecimentos de saúde, os fatores organizacionais, isto é, características dos hospitais, podem envolver natureza de propriedade, porte do estabelecimento, disponibilidade de recursos financeiros, treinamento e envolvimento do pessoal. A literatura mostra que existe uma série de particularidades organizacionais capazes de influenciar a adoção ou rejeição de tecnologias disruptivas, como a IA (Dastjerdi et al., 2023).

Em termos de natureza de propriedade, hospitais públicos em economias emergentes são mais propensos a carecer de recursos (por exemplo, pessoal, equipamentos e infraestrutura)

do que os privados (Tortorella et al., 2020). Tal escassez de recursos pode impor barreiras adicionais à adoção de novas tecnologias. Internacionalmente, estudos comprovam que a adoção de sistemas de informação hospitalares foi significativamente afetada pelo tipo de propriedade (Tsagaankhuu et al., 2018). Na Mongólia, hospitais privados possuem maior associação com a adoção de sistemas de informação, especialmente no que diz respeito a tecnologias clínicas e estratégicas (Tsagaankhuu et al., 2018).

Um estudo norte americano, realizado com dados da *American Hospital Association* (AHA), concluiu que hospitais de propriedade privada sem fins lucrativos (em comparação com os hospitais públicos) apresentam maior probabilidade de adotar diferentes formas de IA, enquanto hospitais privados com fins lucrativos tem uma probabilidade significativamente menor (Baten, 2024). Já pesquisadores na Alemanha que investigaram o determinante “natureza de propriedade” não encontraram resultados relevantes para adoção de IA (Weinert et al., 2022). No entanto, esse achado deve ser interpretado com cautela, pois, como os próprios autores apontam, o tamanho da amostra pode ser pequeno demais para produzir resultados significativos.

O estudo de Tortorella et al. (2020), sobre uso de novas tecnologias na saúde, descobriu que, considerando o fator “propriedade do hospital”, apenas o nível de adoção da computação em nuvem é significativamente diferente, sendo predominante em hospitais públicos. Estudos de caso realizados em hospitais nacionais, privados e lucrativos, revelaram o uso de ferramentas baseadas em IA nesses estabelecimentos e instigaram a análise a partir de diferentes modelos de gestão, como hospitais públicos do SUS (Silva, 2023).

Visto que as pesquisas antecedentes apresentam resultados divergentes quanto a esse determinante, possível é necessário estabelecer um consenso sobre o potencial explicativo da natureza de propriedade para adoção de IA. Nesse sentido, é plausível avaliar se a natureza de propriedade de um hospital (ou seja, privado ou público) pode afetar a adoção de IA. Além disso, no contexto de IAS ainda não se localizou pesquisa que analise o potencial do determinante natureza de propriedade dos estabelecimentos de saúde brasileiros em afetar a adoção de tecnologias baseadas em IA, portanto, é uma oportunidade de pesquisa a ser explorada.

H6: A natureza de propriedade privada está positivamente associada com a adoção de IA nos estabelecimentos de saúde, em comparação com a pública.

O tamanho ou porte da organização é importante para atender às necessidades financeiras, lidar com os riscos potenciais e gerenciar com eficiência os recursos de capital humano (Deveci, 2023; Kumar et al., 2023). Dentro do contexto organizacional, o tamanho da

empresa e a estrutura podem influenciar a adoção de tecnologias disruptivas por meio da disponibilidade e acesso a recursos financeiros e técnicos, pois são um reflexo de sua capacidade de investir, mobilizar recursos humanos e financeiros e absorver riscos ao adotar o novo modelo de negócios (Dastjerdi et al., 2023; Kumar et al., 2023).

No contexto específico da saúde, um parâmetro utilizado como medição do tamanho de estabelecimentos é o número de leitos de internação (Baten, 2024; Tsagaankhuu et al., 2018; Yang et al., 2022) ou número de empregados (Chang et al., 2007). O tamanho de um estabelecimento de saúde também pode variar em função do tipo de atividades desenvolvidas nele, como por exemplo, tipo de hospital, no sentido de psiquiátrico, de urgência, entre outros (Baten, 2024). Hospitais grandes norte-americanos tem 1.48 mais chances de adotar IA quando comparados a hospitais pequenos, ou seja, o tamanho de hospital pode ser uma característica associada a adoção de IA (Baten, 2024). O estudo de Kumar et al. (2023) apontou que o determinante “Tamanho e estrutura da organização”, assumiu a vigésima posição (entre 22) como mais significativo para adoção de uma tecnologia baseada em IA na cadeia de suprimentos de saúde indiana.

Hospitais maiores tendem a ter mais recursos em termos de pessoal e equipamentos e maior capacidade de investimento, o que poderia favorecer a aquisição e a adoção de tecnologias médicas e de informação sofisticadas (Tortorella et al., 2020). Estudos realizados em outros setores também revelaram que o tamanho influencia significativamente a adoção de IA (Pai & Chandra, 2022). No entanto, um estudo realizado com hospitais do Brasil, Índia, México e Argentina, descobriu que os hospitais menores (considerando o número de leitos como *proxy* para o tamanho) apresentam um maior nível de adoção de tecnologias H4.0 (Tortorella et al., 2020). Esses argumentos divergentes motivaram a análise do efeito do porte do estabelecimento de saúde (analisado a partir do número de leitos e do tipo de atendimento) na adoção de IA.

H7: O porte de estabelecimento de saúde influencia a adoção de IA.

Outro fator observado é que a adoção de tecnologias de IA exige que as organizações invistam financeiramente em tais tecnologias, o que implica que existe um custo associado à sua aquisição (Horani et al., 2023). Tal preocupação com custos elevados para adoção de IA é compartilhada não só pelos gerentes que tomam a decisão quanto a implantação dessas ferramentas (Weinert et al., 2022), mas também pelos profissionais de saúde e pacientes que pretendem utilizá-las. Globalmente, agências de financiamento estão alocando fundos para pesquisas em IA (Marco-Ruiz et al., 2024) e no Brasil, investimentos públicos e privados estão

sendo realizados para o avanço dessa tecnologia. No entanto, estudos de implementação e avaliação de IA carecem de financiamento adequado (Marco-Ruiz et al., 2024).

Como mencionado, em muitos contextos a infraestrutura presente nos estabelecimentos de saúde pode não ser compatível com as necessidades tecnológicas de IAS (Weinert et al., 2022), o que indica que sistemas de informação de saúde hospitalar devem ser renovados antes da implantação de IA (Marco-Ruiz et al., 2024). Além dos custos de TI necessários, também são destacáveis os custos de mão de obra para implementação (Yang et al., 2022). Essas ações envolvidas no empreendimento de IA nos estabelecimentos de saúde geram custos e exigem disponibilidade de financiamento para cobrir as despesas, ou seja, investimento de recursos financeiros (Horani et al., 2023; Kumar et al., 2023; Marco-Ruiz et al., 2024; Weinert et al., 2022).

Apesar da adoção da IA prometer, a longo prazo, redução de custos e aumento da eficiência, ao automatizar muitas tarefas, dúvidas sobre a relação custo-benefício ainda persistem (Horani et al., 2023). Nesse sentido, a pesquisa de Weinert et al. (2022), realizada com 40 tomadores de decisão de TI de hospitais na Alemanha, elencou “Recursos financeiros” como o quarto recurso mais importante para implementação de IA. No entanto, os autores também apontaram que 80% dos participantes acreditam que sua organização não possui recursos financeiros suficientes para implantação de IA e apenas 40% dos participantes concordavam com a ideia de que a IA poderia gerar economia financeira (Weinert et al., 2022).

Kumar et al. (2023) apontaram que o determinante “Recursos financeiros”, assumiu a última posição (entre 22) como mais significativo para adoção de uma tecnologia baseada em IA na cadeia de suprimentos de saúde indiana. Ou seja, as descobertas dos autores sobre a importância relativamente baixa dos recursos financeiros como um fator para a adoção da IA no contexto da cadeia de suprimentos de saúde contradizem os resultados de outros pesquisadores.

Por um lado, a necessidade maior de recursos financeiros para investimento em sistemas eletrônicos inovadores é uma preocupação que merece ser investigada, pois a falta de recursos financeiros pode estar associada a não adoção, assim como a existência de capacidade de investimento é altamente eficaz na sua decisão de adaptação tecnológica e no sucesso do processo (Deveci, 2023). Por outro lado, os altos custos envolvidos na adoção de IA podem atuar como uma barreira, conforme os resultados da literatura apontam (Kumar et al., 2023; Weinert et al., 2022). Devido a tais circunstâncias, vale a pena investigar se a existência de estruturas de financiamentos adequadas pode estar relacionada com a aceitação e adoção da IAS.

H8: Suficientes recursos financeiros para investimento em sistemas eletrônicos estão positivamente associados com a adoção de IA nos estabelecimentos de saúde.

O fortalecimento da capacitação de profissionais são aspectos fundamentais para ampliar o acesso ao sistema de saúde e contribuir para que ele seja mais eficiente, acessível e equitativo (NIC.br, 2025). Nesse sentido, outro determinante fundamental para a implementação de IA é a competência e treinamento da equipe de recursos humanos (Kumar et al., 2023). Esse determinante se refere à disponibilidade de capital humano com expertise em questões técnicas e gestão de tecnologia para sua integração. Também leva em conta as facilidades de treinamento e oportunidades que estão sendo estendidas aos membros da equipe existentes (Kumar et al., 2023), como treinamento de médicos (Tezpal et al., 2024; Vijayakumar et al., 2023).

As tecnologias baseadas em IA são naturalmente de alta complexidade e os gerentes reconhecem a importância da experiência e do conhecimento prévios como fatores-chave que impulsionam o sucesso da adoção da IA (Dastjerdi et al., 2023; Horani et al., 2023). Quando o estabelecimento de saúde não conta com pessoas capacitadas para utilizar as ferramentas baseadas em IA, os gestores podem optar por não as adotar. À medida que a força de trabalho da organização possui as habilidades e talentos necessários ou está pronta para obtê-los, o ritmo de adoção acelera (Deveci, 2023). Assim, os administradores hospitalares devem perceber a forte necessidade de motivação e formação contínua dos médicos (Tokgöz et al., 2024), especialmente no que diz respeito a literacia sobre os benefícios e limitações da IA (Marco-Ruiz et al., 2024).

Essas ideias são confirmadas por Dastjerdi et al. (2023) que elencaram o determinante “Competência técnica”, isto é, o grau de conhecimento de TI e habilidades funcionais possuídas pelos funcionários, na quarta posição (entre 22) como mais significativo para adoção de uma tecnologia baseada em IA em hospitais iranianos. Visto que nem todos os funcionários possuem a competência necessária, o mesmo estudo também concluiu que “custo relacionado a manutenção e treinamento de pessoal” é o mais significativo na dimensão de custos e conquistou a oitava posição no *ranking* geral entre 22 determinantes (Dastjerdi et al., 2023).

Com uma lógica de *ranking* semelhante, Kumar et al. (2023) encontraram resultados diferentes. Os autores elencaram o determinante “Competência dos recursos humanos e treinamento da equipe” na décima nona posição (entre 22) como mais significativo para adoção de uma tecnologia baseada em IA na cadeia de suprimentos de saúde indiana (Kumar et al., 2023). No contexto alemão, Tokgoz et al. (2024) concluíram que o determinante “Treinamento de potenciais usuários” foi o mais significativo na dimensão organizacional, com 86% dos

respondentes concordando que esse determinante é “Muito importante” e os demais 14% “Moderadamente importante” (Tokgöz et al., 2024).

Apesar dos resultados não convergirem totalmente, nota-se que, durante o processo de adoção, as capacidades, habilidades e o conhecimento de TI da equipe desempenham um papel fundamental em ajudar os hospitais a vivenciarem uma adoção mais fácil, por isso, os estabelecimentos devem prestar atenção ao treinamento (Dastjerdi et al., 2023). Nesse sentido, faz sentido pensar que a organização com um ambiente facilitador que ajude a lidar com a falta de conhecimento do usuário e que tem capacidade de criar condições favoráveis ao treinamento da equipe (Tokgöz et al., 2024) pode ter maiores chances de adotar uma tecnologia inovadora como a IA. Assim, apresenta-se a seguinte hipótese de pesquisa:

H9: O treinamento do pessoal para o uso de sistemas eletrônicos está positivamente associado com a adoção de IA nos estabelecimentos de saúde.

Autores apontam que um dos fatores facilitadores para adoção e uso de IA na saúde é a participação e o envolvimento dos usuários, isto é, o pessoal do estabelecimento – que pode incluir médicos e enfermeiros – na fase de desenvolvimento e implementação da tecnologia (Marco-Ruiz et al., 2024; Terry et al., 2022; Tokgöz et al., 2024; Van Der Vegt et al., 2023, 2024). Alguns autores destacam que o envolvimento de profissionais de saúde (usuários) em processos de desenvolvimento e *co-design* da tecnologia desde o início de sua criação é um elemento necessário para a adoção bem sucedida, além de evitar a incorporação tardia de elementos essenciais (Terry et al., 2022).

Conforme explorado no estudo de Tokgöz et al. (2024) o envolvimento de médicos como um grupo de usuários relevante na fase de planejamento, desenvolvimento e implementação, garantindo transparência e participação, é considerado um elemento-chave para o sucesso desse processo. Nessa pesquisa, o determinante “Participação dos usuários relevantes na fase de desenvolvimento e implementação” foi apontado como “Muito importante” por 42% dos respondentes e “Moderadamente importante” por 43% deles. Quando os médicos se percebem como partes interessadas ativas, tornam-se mais dispostos a mudar suas rotinas de trabalho tradicionais por meio do uso das novas tecnologias (Tokgöz et al., 2024).

Paralelamente, Terry et al. (2022) concluíram que os usuários finais de ferramentas baseadas em IA, isto é, médicos e enfermeiros, devem ser envolvidos no desenvolvimento das mesmas e engajados até na fase de *design*. Os autores argumentam que esse é um dos três principais facilitadores de uma implementação bem-sucedida, especialmente em função da

natureza não explicativa, ou “caixa preta” do processo de criação de algumas tecnologias (Terry et al., 2022).

O envolvimento do pessoal no desenvolvimento e implantação das tecnologias baseadas em IA pode ser algo mais alcançável quando a organização já tem uma cultura de envolvimento dos médicos e enfermeiros na seleção, desenvolvimento e implantação dos sistemas eletrônicos do estabelecimento. Portanto, faz sentido investigar essa relação por meio da seguinte hipótese:

H10: O envolvimento do pessoal na implantação dos sistemas eletrônicos do estabelecimento está positivamente associado com a adoção de IA nos estabelecimentos de saúde.

2.4.3 Determinantes ambientais

O contexto ambiental se refere ao ambiente externo em que a organização está localizada, incluindo fatores como características do setor, leis e regulamentos, diferenças entre áreas urbanas e rurais, concorrentes e governo (Wang & Chiou, 2020). No que diz respeito a adoção de IA em estabelecimentos de saúde, os fatores ambientais podem envolver região e localização do estabelecimento, bem como políticas governamentais.

Na literatura, há estudos que buscaram investigar se a região e a localização de estabelecimentos de saúde afeta a disponibilidade e, conseqüentemente, a oferta de serviços digitais em saúde no Brasil (Fontan, 2023). Internacionalmente, estudos comprovam que a adoção de sistemas de informação hospitalares foi significativamente afetada pela localização do hospital, no quesito urbana quando comparada a rural (Tsagaankhuu et al., 2018). Pesquisadores norte-americanos demonstraram que os hospitais rurais são significativamente menos propensos a adotar qualquer forma de IA do que os hospitais urbanos (Baten, 2024).

Geralmente, as áreas urbanas são mais desenvolvidas em termos de atividades econômicas, e os hospitais nelas inseridos têm melhores oportunidades de parceria com diversos setores, agências governamentais e instituições de ensino superior e pesquisa, e podem obter recursos financeiros externos e obter informações sobre novas tecnologias (Tsagaankhuu et al., 2018). Por exemplo, no Brasil, um em cada três municípios lida com a escassez de médicos para atendimento da população, pois cerca de 55% dos médicos atuam nas capitais, atendendo 23,8% da população (Portilho et al., 2025). Tal desigualdade no capital humano disponível nos estabelecimentos brasileiros pode ser uma indicação de desigualdade em outros aspectos, como a adoção de novas tecnologias.

Além disso, pesquisadores sugerem a importância de considerar fatores regionais, culturais e contextuais na formação de atitudes em relação à IA, pois diferentes grupos

demográficos podem se perceber como mais vulneráveis a serem afetados pela IA (Hasan et al., 2024). Assim, investigar as condições de localização do estabelecimento de saúde também pode ser um elemento relevante para entender os fatores que influenciam a adoção de IA, visto que a dimensão territorial pode ser um desafio no contexto brasileiro. Tal análise também é válida levando em consideração que o contexto socioeconômico, caracterizado pela localização geográfica afeta o nível de implementação de tecnologias digitais disruptivas (Tortorella et al., 2020). Por isso, vale a pena investigar se essa diferenciação em localização também se aplica ao contexto brasileiro e, além disso, se estende a capital e interior.

H11a: A localização geográfica de estabelecimentos de saúde influencia a adoção de tecnologias baseadas em IA.

H11b: A localização de estabelecimentos de saúde na capital está associada a uma maior probabilidade de adotar tecnologias baseadas em Inteligência Artificial em comparação com estabelecimentos de saúde localizados no interior.

As hipóteses buscam verificar se, no Brasil, a adoção de tecnologias baseadas em Inteligência Artificial é diferente, a depender da região geográfica do país em que o estabelecimento de saúde for localizado (Norte, Nordeste, Centro-oeste, Sul ou Sudeste) e a localidade em termos de capital ou interior.

Autores apontam que o apoio governamental e o quadro de políticas na organização são alguns dos fatores chave para o sucesso na implantação de IA (Horani et al., 2023; Kumar et al., 2023). Os governos têm o poder e a autoridade necessários para conduzir ou impedir os hospitais de aceitarem novos sistemas (Dastjerdi et al., 2023), por meio de suas políticas e regulamentos (Horani et al., 2023). A formulação de políticas pode favorecer a integração de tecnologias digitais aos sistemas de saúde nacionais, partindo do pressuposto que estas tem o potencial de transformar de maneira significativa as práticas clínicas (NIC.br, 2025).

Pesquisas nacionais anteriores investigaram o impacto que a presença de políticas governamentais nos estabelecimentos de saúde brasileiros pode ter na oferta de serviços de saúde digital e encontraram uma relação positiva (Fontan, 2023). Em uma pesquisa internacional, focada no contexto iraniano, o fator “Política Governamental” foi o determinante mais importante na dimensão ambiental (Dastjerdi et al., 2023), e assumiu a segunda posição (entre 22) como mais significativo para adoção de uma tecnologia baseada em IA. O estudo de Kumar et al. (2023) apontou que o determinante “Apoio governamental”, assumiu a quarta posição (entre 22) como mais significativo para adoção de uma tecnologia baseada em IA na cadeia de suprimentos de saúde indiana.

Tais resultados anteriores deixam claro que políticas governamentais têm impacto positivo nos hospitais que tentam adotar novas tecnologias de sistemas de informação (Lian et al., 2014). Subsídios ou apoios fornecidos pelo governo ou pelo quadro político que visa acelerar a difusão da tecnologia têm efeitos positivos no processo de adoção (Deveci, 2023).

Nesse sentido, é pertinente mencionar que o Poder Público tem impulsionado iniciativas para promoção de IAS, que envolvem criação de estratégias e planos nacionais, centros de pesquisa, observatórios e projetos de investimento (Brasil, 2021; CCT, 2024; OBIA, 2024). Assim, faz sentido investigar se a concordância entre os gestores (respondentes) em relação ao estímulo das políticas públicas também pode influenciar a adoção de IA.

H12: A presença de políticas governamentais nos estabelecimentos de saúde tem um impacto positivo na adoção de tecnologias baseadas em IA.

A fim de sintetizar a motivação por trás da escolha dos determinantes, a Tabela 1 apresenta a análise das três categorias e as hipóteses, bem como os autores que abordam tal elemento na literatura:

Tabela 1

Determinantes da adoção de IAS, por categoria do *Framework* TOE

Categoria	Hipótese	Determinante	Autor (ano)
Tecnologia	H1	Infraestrutura de TIC	Dastjerdi et al. (2023); Deveci (2023); Horani et al. (2023); Kumar et al. (2023); Marco-Ruiz et al. (2024); Roppelt et al. (2024); Tokgöz et al. (2024)
	H2	Acesso e manutenção dos dados	Marco-Ruiz et al. (2024); Terry et al. (2022); Tokgöz et al. (2024); Weinert et al. (2022)
	H3	Segurança dos dados	Dastjerdi et al. (2023); Lian et al. (2014); Weinert et al. (2022)
	H4	Remoto	NIC.br (2024)
	H5	Novas tecnologias	Roppelt et al. (2024); Mazhar et al. (2025)
Organização	H6	Natureza de propriedade	Baten (2024); Tortorella et al. (2020); Weinert et al. (2022)
	H7	Porte	Baten (2024); Deveci (2023); Kumar et al. (2023); Tortorella et al. (2020)
	H8	Financiamento	Deveci (2023); Fontan (2023); Horani et al. (2023); Kumar et al. (2023); Marco-Ruiz et al. (2024); Weinert et al. (2022); Yang et al. (2022)
	H9	Treinamento	Dastjerdi et al. (2023); Kumar et al. (2023); Tezpal et al. (2024); Tokgöz et al. (2024); Vijayakumar et al. (2023)
	H10	Envolvimento	Marco-Ruiz et al. (2024); Terry et al. (2022); Tokgöz et al. (2024); Van Der Vegt et al. (2024)
Ambiente	H11a	Região	Fontan (2023); Tortorella et al. (2020)
	H11b	Localização	Fontan (2023)
	H12	Políticas Governamentais	Dastjerdi et al. (2023); Deveci (2023); Fontan (2023); Horani et al. (2023); Kumar et al. (2023); Lian et al. (2014)

Com base nas hipóteses e determinantes evidenciados na Tabela 1, foi desenhado o modelo teórico, conforme mostra a Figura 3:




Figura 3. Modelo teórico do estudo

A Figura 3 apresenta o Modelo Teórico do estudo a partir dos fatores discutidos, desenhado para cumprir o objetivo de identificar os determinantes para a adoção de inteligência artificial por estabelecimentos de saúde brasileiros. A instrumentalização dos determinantes selecionados nesta pesquisa e os procedimentos metodológicos adotados são apresentados no próximo tópico.

3 PROCEDIMENTOS METODOLÓGICOS

3.1 CARACTERIZAÇÃO DA PESQUISA

A fim de identificar os determinantes que influenciam a adoção de IA por estabelecimentos de saúde no Brasil, esta pesquisa classifica-se como. No que tange a abordagem do problema, a pesquisa é classificada como quantitativa, pois fará uso de dados observados no mundo real a fim de testar hipóteses por meio de análise estatística (Sampieri et al., 2013). Nesse sentido, foi utilizado o modelo de regressão logística multinomial e a análise

de correspondência. Teve como base os dados secundários produzidos e divulgados pelo Centro Regional de Estudos para o Desenvolvimento da Sociedade da Informação (Cetic.br), por meio da pesquisa TIC, referente ao ano-base 2024, devido a serem os mais recentes quando da realização do estudo.

3.2 BASE DE DADOS E DEFINIÇÃO DA POPULAÇÃO E AMOSTRA

Para avaliação quanto aos determinantes da adoção de IA por estabelecimentos de saúde brasileiros, o estudo foi desenvolvido a partir dos microdados da pesquisa TIC Saúde 2024. Por consequência, a amostra final desta pesquisa foi composta pelos estabelecimentos de saúde que participaram do estudo TIC Saúde 2024. Esse estudo é realizado desde 2013 e publicado pelo Centro Regional de Estudos para o Desenvolvimento da Sociedade da Informação (Cetic.br), departamento do Núcleo de Informação e Coordenação do Ponto BR (NIC.br), a agência que regula e controla a *internet* brasileira e está vinculada ao Comitê Gestor da *Internet* no Brasil (CGI.br). O objetivo do TIC Saúde é investigar a infraestrutura de tecnologia da informação e comunicação nos estabelecimentos de saúde do país, bem como a apropriação pelos profissionais da área, ou seja, como médicos e enfermeiros fazem uso dessas ferramentas em seu trabalho e as principais barreiras para a sua adoção (NIC.br, 2025).

O estudo, que serve como base de dados secundários, segue orientações publicadas pela Organização para a Cooperação e Desenvolvimento Econômico (OECD), pela Comissão Econômica para a América Latina e o Caribe (CEPAL) e pela Organização Pan-Americana da Saúde (OPAS). Tal aderência aos referenciais internacionais aumenta o potencial de comparação dos resultados a nível global, além de contribuir para a produção de indicadores relevantes para pesquisas acadêmicas e para a formulação e a avaliação de políticas públicas relacionadas ao uso destas tecnologias pelos estabelecimentos que formam o sistema de saúde brasileiro, visando melhorias na qualidade da assistência (NIC.br, 2025).

A população-alvo do estudo TIC Saúde 2024 foi composta por estabelecimentos de saúde brasileiros, públicos e privados. O processo de seleção foi realizado aleatoriamente pelo Cetic.br a partir do Cadastro Nacional de Estabelecimentos de Saúde (CNES), mantido pelo Ministério da Saúde (MS). Foram selecionados os estabelecimentos que possuem Cadastro Nacional da Pessoa Jurídica (CNPJ), podendo ser próprio ou de uma entidade mantenedora, e que possuem instalações físicas destinadas exclusivamente a atividades na área de saúde e pelo menos um médico ou um enfermeiro. Cada estabelecimento é tratado como um conglomerado composto de profissionais com cargos de administração, isto é, os gestores responsáveis por

fornecer as informações sobre os estabelecimentos e profissionais de atendimento assistencial – médicos(as) e enfermeiros(as) (NIC.br, 2025).

Para a construção da base de dados da pesquisa TIC Saúde 2024, os estabelecimentos de saúde foram contatados por meio de entrevistas telefônicas assistidas por computador (CATI - *Computer Assisted Telephone Interviewing*). Os questionários foram aplicados por pesquisadores do Inteligência em Pesquisa e Consultoria Estratégica (Ipec Inteligência), que é o instituto de pesquisa responsável por coletar as informações dos estabelecimentos e profissionais de saúde. Em cada estabelecimento pesquisado, buscou-se entrevistar, preferencialmente, o responsável pela área de Tecnologia da Informação ou, no caso da ausência desse, o gestor administrativo (NIC.br, 2025).

Além disso, cabe mencionar que o órgão responsável pela pesquisa TIC Saúde também realizou, como pré-teste, oito entrevistas com gestores gerais ou de TI de estabelecimentos de saúde entre os dias 9 e 20 de fevereiro de 2024, em diferentes tipos de estabelecimentos de saúde. Segundo o relatório de coleta de dados, tal distribuição objetivou testar a adequação e validade das perguntas bem como dos indicadores construídos e o tempo decorrido para aplicação dos questionários (NIC.br, 2025).

A escolha desta base de microdados para a atual pesquisa justifica-se pelos seguintes motivos: (a) disponibilidade dos dados; (b) abrangência nacional da amostra; e (c) presença de indicadores relacionados à Inteligência Artificial. O acesso a esses microdados ocorre por meio de convênios que o CGI.br realiza com pesquisadores de instituições de ensino superior brasileiras. Os critérios de seleção permitem que estabelecimentos de saúde de todas as cinco regiões do país participem. Quanto a última justificativa, cabe destacar que na pesquisa TIC Saúde 2024, bem como na TIC Saúde 2023, foram incluídos novos indicadores sobre adoção de IA, que detalham tipos de ferramentas, aplicações e motivos para a não adoção, itens que não estavam presentes nas pesquisas dos anos anteriores.

O desenho amostral da pesquisa TIC Saúde 2024 considera a amostragem estratificada simples de estabelecimentos de saúde, isto é, de sorteio dos estabelecimentos por amostragem aleatória simples sem reposição dentro dos estratos porventura definidos (NIC.br, 2025). Entre os meses de fevereiro e agosto de 2024, foram realizadas 2.057 entrevistas com o principal gestor do estabelecimento ou um gestor que conhecesse a organização como um todo, inclusive no que diz respeito a seus aspectos administrativos e à infraestrutura de TIC presente na organização (NIC.br, 2025). Os cargos dos entrevistados envolvem os seguintes: gestor geral, diretor, administrador, proprietário ou sócio, diretor clínico, diretor, gerente ou supervisor de

TI, entre outros. Não foi considerado o profissional que não ocupa cargo de gestão, coordenação ou supervisão (NIC.br, 2025).

Dos 2.057 estabelecimentos da pesquisa, apenas os 651 estabelecimentos de saúde com área (ou setor ou departamento) de TI responderam ao módulo de novas tecnologias, que inclui os novos indicadores sobre adoção de IA já mencionados. Assim, foram excluídos os dados dos estabelecimentos que não possuem um setor de TI, e mantidos na amostra os 651 que possuem área de TI – 31,65% do total. Essa decisão reflete a atitude de outros pesquisadores quando deparados com a mesma situação (Ribeiro & Segatto, 2025; Rosa & Kubota, 2024, 2025).

Pesquisas nacionais anteriores também reconheceram o rigor metodológico empregado e o potencial dos dados produzidos pelo Cetic.br e, portanto, utilizaram as informações contidas no estudo TIC Saúde de outros anos. Além da TIC Saúde, esse órgão produz outras bases de microdados, as quais também estão sendo utilizadas pela academia, como a TIC Domicílios (Araujo et al., 2018; Cancelier, 2024; Fontan, 2023; Oliveira, 2021; Portilho et al., 2025; Siqueira & Moreira, 2023), TIC Educação (Andrade & Campos, 2017; Migliora, 2016; Tarouco et al., 2024), TIC Cultura (Doretto, 2016; Lima & Coelho, 2019), TIC Governo (Mello Filho & Vieira, 2024; Ribeiro & Segatto, 2025; Siqueira & Moreira, 2023), TIC Empresas (Rosa & Kubota, 2024, 2025; Souza et al., 2017), entre outros.

Os dados disponibilizados na TIC Saúde estão sendo aplicados para os mais diversos objetivos por vários pesquisadores. Desde pesquisadores que inicialmente vislumbravam apresentar uma radiografia da disponibilidade e da adoção das TICs em estabelecimentos de saúde públicos e privados no Brasil (Senne et al., 2014), até acadêmicos que recentemente almejaram descrever a utilização destas tecnologias para o apoio à prática clínica e educação permanente pelas equipes de saúde da atenção primária à saúde (Bender et al., 2024). Outros analisaram o uso das tecnologias da informação e comunicação em saúde sob a perspectiva de enfermeiros (Machado et al., 2020). E ainda outros se propuseram a investigar os antecedentes relacionados à oferta e ao uso de serviços digitais na saúde pública brasileira, considerando tanto os estabelecimentos de saúde quanto os cidadãos (Fontan, 2023).

No entanto, não foi percebida, até o momento, a existência de produção científica que utilize os novos indicadores da pesquisa TIC Saúde sobre adoção de IA. Uma justificativa para tal ausência pode ser o fato de que esses itens – os quais envolvem os tipos de aplicação de IA, e os motivos para a não adoção de IA em estabelecimentos de saúde – são inéditos e foram incluídos apenas na pesquisa TIC Saúde do ano 2023 e 2024. Nesse sentido, a fim de expandir o conhecimento científico sobre o tema e contribuir para a exploração de evidências nacionais, convém investigar tais indicadores.

3.3 VARIÁVEIS DE PESQUISA

Em conformidade com o objetivo do estudo e diante das evidências das pesquisas abordadas na literatura, foram estabelecidas algumas variáveis de pesquisa, as quais também foram extraídas do questionário TIC Saúde 2024. As questões contidas na pesquisa “TIC Saúde” abordam uma grande variedade de blocos temáticos e estão divididas em seis módulos, os quais são descritos na Tabela 2.

Tabela 2

Temática abordada pelo TIC Saúde 2024

MÓDULOS	DESCRIÇÃO
Módulo A	Perfil do estabelecimento de saúde e do respondente
Módulo B	Infraestrutura de TIC no estabelecimento
Módulo C	Registro eletrônico em saúde e Intercâmbio de Informações
Módulo D	Registro pessoal de saúde e telemedicina
Módulo G	Percepção do gestor em relação ao sistema eletrônico disponível e apropriação das TICs
Módulo H	Uso de novas tecnologias pelos estabelecimentos de saúde

As variáveis foram obtidas de todos os módulos da pesquisa TIC Saúde, visto que eles possuem informações a respeito da infraestrutura de tecnologias de informação e comunicação (TIC), gestão de TI, registro eletrônico em saúde, troca de informações, telessaúde e novas tecnologias (NIC.br, 2025). Especialmente o módulo H – Novas tecnologias – possui mais de 20 questões ligadas a investigação acerca do uso de IA no estabelecimento de saúde.

3.3.1 Variável Dependente

O Apêndice B apresenta os itens do questionário que formaram a variável dependente deste estudo “**int_artif**”, bem como os códigos correspondentes na base de microdados da pesquisa TIC Saúde 2024. Para essa variável foi utilizado apenas o Módulo H.

Para todas as variáveis do Apêndice B (bem como das demais variáveis) as opções de resposta podem incluir: 1 = "Sim"; 0 = "Não"; 97 = “Não sabe”; 98 = "Não respondeu" e 99 = "Não se aplica". As respostas 97, 98 e 99 serão tratadas como 0, assumindo-se que o desconhecimento e a ausência de resposta indicam a não utilização. Assim, os dados encontrados nos itens H4 e H5 do Módulo H da pesquisa são utilizados para obter indicadores binários (0/1) sobre a adoção de IA. A fim de criar a variável dependente “**int_artif**” para cada estabelecimento, foi somada a pontuação obtida, como score, o que resultou numa escala de 0

(estabelecimentos que não utilizam nenhuma forma de IA mencionada) a 13 (estabelecimentos que utilizam todas as formas de IA elencadas).

A partir disso, seguindo parâmetros de modelos internacionais (Baten, 2024), os estabelecimentos foram categorizados com base no número de itens (áreas de aplicação e tipos de técnicas de IA) adotados. Primeiramente, foi criado um grupo para os não adotantes, cuja pontuação na variável dependente foi 0 (zero). Para os valores acima de zero, foram identificados os percentis 33,3333 (3) e 66,6666 (6) a serem usados como base das categorias. Assim, a categorização foi do seguinte modo: (1) “Não uso” — nenhuma adoção de IA; (2) “Baixo uso” — adoção de 1 ou 2 itens; (3) “Médio uso” — adoção de 3, 4 ou 5 itens; e (4) “Alto uso” — adoção de 6 itens ou mais.

Essa consideração da variável dependente qualitativa com base na estratificação em faixas permite analisar as probabilidades que cada observação tem de pertencer a cada faixa, em função do comportamento de outras variáveis explicativas (Fávero, 2017). Pesquisadores anteriores apontaram que utilizar exclusivamente uma variável indicadora para medir o status de adoção de IA é uma limitação (Pham et al., 2024), pois essa abordagem simplificada pode negligenciar variações nas técnicas de IA utilizadas e o grau de adoção de IA.

3.3.2 Variáveis Independentes

Para as variáveis independentes deste estudo, foram utilizados outros módulos da pesquisa TIC Saúde 2024. Os Apêndices C, D, E, F, G e H mostram os itens utilizados para criar variáveis relacionadas a: acesso e manutenção dos dados; ferramentas de proteção e segurança da informação; realização de atividades remotas ou à distância; uso de novas tecnologias; e características diversas do estabelecimento, respectivamente.

A variável “acesso” diz respeito ao grau de acesso e manutenção dos dados relacionados à saúde do paciente pelo estabelecimento, a partir de seu sistema eletrônico. Para essa variável foi utilizado apenas o Módulo C. A variável “segurança”, que diz respeito ao uso de Ferramentas de proteção e segurança da informação pelo estabelecimento. Para essa variável foi utilizado apenas o Módulo B.

Além da questão da segurança e proteção das informações do paciente por parte do estabelecimento de saúde, outro aspecto identificado na pesquisa TIC Saúde 2024 é relacionado ao Módulo D (Registro pessoal de saúde e telemedicina). Foi possível construir outra variável independente “remoto”, que corresponde a soma dos itens D2, ou seja, a medida de cada estabelecimento no quesito atividades remotas/à distância relacionadas à saúde. A variável “novtecn” é relacionada ao módulo H (Novas tecnologias), envolve a adoção e o uso de outras

tecnologias inovadoras além da IA e utiliza apenas o Módulo H. Outra variável diz respeito a infraestrutura existente nos estabelecimentos de saúde e foi baseada no módulo B (Infraestrutura de TIC no estabelecimento).

Finalmente, algumas variáveis adicionais foram selecionadas para compreender fatores externos ao estabelecimento, como porte, região, localização e esfera administrativa (isto é, natureza de propriedade) – todas categóricas. Além disso, também foi investigada a percepção dos gestores por meio de outras variáveis (também categóricas) relacionadas a fatores internos do estabelecimento, como treinamento, envolvimento, financiamento e políticas governamentais. As informações detalhadas sobre essas variáveis independentes os itens correspondentes na base de microdados estão no apêndice.

A variável “região” corresponde à divisão regional do Brasil em macrorregiões (Norte, Centro-Oeste, Nordeste, Sudeste e Sul), segundo critérios do Instituto Brasileiro de Geografia e Estatística (IBGE). A variável “localização” refere-se à informação de que o estabelecimento está localizado na capital ou interior de cada UF. Para a variável natureza de propriedade é utilizada a classificação de esfera administrativa, dada pelo CNES, e considera como sendo públicos os estabelecimentos administrados pelos governos federal, estadual ou municipal. Os demais estabelecimentos (privado com fins lucrativos e privado sem fins lucrativos) são classificados como privados.

A variável porte classifica o estabelecimento de saúde de acordo com os critérios definidos no relatório metodológico da TIC Saúde 2024 e, anteriormente, adotados pela pesquisa AMS do IBGE. Essa classificação é dada pela combinação de características dos estabelecimentos relativas ao tipo de atendimento e ao número de leitos de internação. Neste sentido, leitos de internação equivalem a instalações físicas específicas destinadas à acomodação de pacientes para permanência por um período mínimo de 24 horas.

A classificação dessa variável define os seguintes quatro grupos mutuamente exclusivos de estabelecimentos: 0 = "Sem internação", estabelecimentos que não possuem leitos e que realizam outros tipos de atendimento (urgência, ambulatorial, etc.); 1 = "Com Internação (0-50 leitos)", estabelecimentos que realizam internação e possuem ao menos um leito e até, no máximo, 50 leitos; 2 = "Com Internação (+50 leitos)", estabelecimentos que realizam internação e possuem 51 leitos ou mais; 3 = "SADT", estabelecimentos sem internação (que não possuem leitos) e destinados exclusivamente a serviços de apoio à diagnose e terapia, definidos como unidades onde são realizadas atividades que auxiliam a determinação de diagnóstico e/ou complementam o tratamento e a reabilitação do paciente, tais como laboratórios.

As quatro últimas variáveis (de percepção) possuem sete rótulos de resposta no questionário original, que podem incluir: 1 = "Concorda"; 2 = "Não concorda nem discorda"; 3 = "Discorda"; 4 = "Não se aplica neste estabelecimento"; 97 = "Não sabe"; 98 = "Não respondeu"; 99 = "Não possui sistema eletrônico". As respostas 4, 97, 98 e 99 serão tratadas como 2 (opção de resposta neutra), assumindo-se que o desconhecimento, a ausência de resposta, e a não aplicação não permitem indicar concordância ou discordância.

3.4 TRATAMENTO E ANÁLISE DOS DADOS

O acesso a base de microdados da TIC Saúde 2024 foi possível graças a um acordo firmado entre a organização detentora da base de dados (NIC.br) e a instituição de ensino (UEM). A liberação ocorreu por meio do preenchimento e envio dos seguintes documentos: (i) Formulário para Solicitação da Base de Microdados; e (ii) Termo de Acesso e Uso de Bases de Microdados das Pesquisas sobre o Uso das Tecnologias de Informação e Comunicação.

Tendo em vista que o objetivo desta pesquisa é investigar quais determinantes estão relacionados a adoção ou não de Inteligência Artificial por estabelecimentos de saúde, o tratamento dos dados pode ser realizado mediante a ferramenta de regressão. A análise de regressão diz respeito ao estudo da dependência de uma variável – a variável dependente ou resposta – em relação a uma ou mais variáveis, que são chamadas de variáveis explanatórias ou explicativas (Gujarati & Porter, 2011). Em casos em que a variável dependente é categórica e não-métrica, o modelo estatístico mais indicado é a regressão logística (Hair et al., 2009).

Dentre os estudos examinados na revisão sistemática anterior, cinco utilizaram a regressão logística em seus procedimentos metodológicos. Essa modelagem estatística foi incorporada especialmente para investigar relacionamentos complexos entre variáveis (Alsobhi et al., 2022; Hasan et al., 2024; Kujala & Hörhammer, 2022; Pham et al., 2024), como a influência de fatores demográficos na adoção e percepção de ferramentas de IA na prática de otorrinolaringologia (Alshehri et al., 2024).

O objetivo da análise de regressão logística é estimar ou prever a probabilidade de ocorrência de um evento, ou seja, a probabilidade de que algo aconteça (variável dependente) dado um conjunto de variáveis explanatórias (Fávero, 2017; Gujarati & Porter, 2011; Hair et al., 2009). Um dos principais elementos da regressão logística é a função *logit*, a qual transforma a combinação linear de variáveis independentes em um intervalo limitado entre 0 e 1. O *logit* apresenta-se como a razão de probabilidade, chamada de chance de ocorrência de um

evento (do inglês, *odds*). Seguindo a mesma lógica, para modelos de regressão logística multinomial a chance (*odds ratio* - *OR*) também é chamada de razão de risco relativo (*relative risk ratio* - *RRR*) (Fávero, 2017).

Como a variável dependente deste estudo é categórica, não-métrica e possui 4 opções de resposta (não uso, baixo uso, médio uso e alto uso), o modelo estatístico mais indicado é a regressão logística multinomial, que também é conhecida como regressão logística politômica (Gujarati & Porter, 2011). Um de seus principais elementos é a função *mlogit*, que ajusta um modelo *logit* multinomial (MNL) para uma variável dependente categórica com resultados que não possuem uma ordenação natural. Nesse tipo de modelo, os coeficientes exponenciados são referentes a razão de risco relativo, ou seja, *RRR* (do inglês, *relative risk ratio*) (Fávero, 2017). Pesquisadores com objetivos semelhantes aos esta pesquisa – investigar a adoção de IA em hospitais – também utilizaram a regressão logística multinomial (Baten, 2024).

Essa forma de regressão é mais vantajosa que outras semelhantes, como a análise discriminante, por sua característica de ser mais robusta e menos afetada quando as suposições básicas não são satisfeitas, por exemplo a suposição de normalidade das variáveis (Hair et al., 2009). Para atender o objetivo da pesquisa, o evento de interesse a ser considerado no modelo é a adoção da IA.

Diante da escolha da variável dependente, apresentada na Tabela 4, e das outras variáveis independentes selecionadas, a equação ou o modelo matemático do estudo para a regressão logística multinomial é:

$$\text{logit} = \ln \left[\frac{P(\text{resultado} = 1|X)}{P(\text{resultado} = 0|X)} \right] = \sigma + \beta_1 \text{novtecn} + \beta_2 \text{remoto} + \beta_3 \text{acesso} + \beta_4 \text{seguranca} + \beta_5 \text{infraestrutura} + \beta_6 \text{envolv} + \beta_7 \text{polit_gov} + \beta_8 \text{esf_admin} + \beta_9 \text{regiao} + \beta_{10} \text{porte} + \beta_{11} \text{cap_inter} + \beta_{12} \text{trein} + \beta_{13} \text{financ} + \varepsilon$$

Os coeficientes de regressão estimados (coeficientes beta) representam o tipo de relação, a qual pode ser positiva ou negativa, e a força da relação entre variáveis independentes e dependente na regressão, ou seja, mostra a variação no valor dependente cada vez que a variável independente varia em uma unidade (Hair et al., 2009). Após o ajuste do modelo, é necessária sua estimação, o que ocorre com o procedimento ou método de verossimilhança máxima, que é o mais indicado em casos de regressão logística multinomial (Fávero, 2017).

A fim de reforçar os resultados obtidos, também foram aplicados outros testes estatísticos, especialmente de análise bivariada para medidas de correlação e associação. Para

as variáveis quantitativas, isto é, segurança, acesso, remoto, novtecn e infraestrutura, foi analisado o coeficiente de correlação de Pearson, uma medida que varia entre -1 e 1, em que -1 representa uma correlação linear negativa perfeita e 1 representa uma correlação linear positiva perfeita. Se o coeficiente for nulo (zero) não existe correlação entre as variáveis. Quanto mais próximo dos valores extremos, mais forte é a correlação entre duas variáveis (Fávero, 2017). A força da correlação foi classificada em nula (0,00), fraca (0,10-0,39), moderada (0,40-0,69), forte (0,70-0,89), muito forte (0,90-0,99) e perfeita (1,00) (Schober et al., 2018).

Para as demais variáveis, que são qualitativas, foi empregado o modelo estatístico análise de correspondência (CA ou ANACOR). A ANACOR, que se ampara no teste qui-quadrado, estuda a relação entre variáveis qualitativas e permite ao pesquisador visualizar proximidades entre variáveis categóricas, por meio de mapas perceptuais (Fávero, 2017). Também possibilita testar as associações entre variáveis independentes categóricas e a variável dependente e resulta em uma representação gráfica, que nada mais é do que um diagrama de dispersão (Fávero, 2017).

A estatística qui-quadrado (χ^2) é uma medida de associação usada com variáveis nominais e ordinais. Seu objetivo é medir a discrepância entre as frequências observadas e esperadas para cada variável em uma tabela de contingência. Caso a distribuição de frequência real das variáveis seja igual ou muito próxima da distribuição esperada, o resultado da estatística qui-quadrado é baixo e as variáveis são consideradas independentes, ou seja, uma não influencia a outra (Fávero, 2017).

Em casos de associação entre as duas variáveis de forma não aleatória, com significância estatística observada, foi realizada adicionalmente a análise dos resíduos padronizados ajustados. Essa análise é útil para estudar a relação de dependência entre os pares de categorias. Se o valor do resíduo ajustado for maior que 1.96, a diferença é significativa (Fávero, 2017). A estatística qui-quadrado permitiu testar as seguintes associações: (a) uso de IA x região; (b) uso de IA x localização; (c) uso de IA x natureza de propriedade; (d) uso de IA x porte de estabelecimento; (e) uso de IA x treinamento; (f) uso de IA x financeiro; (g) uso de IA x políticas governamentais e (h) uso de IA x envolvimento.

Para a operacionalização dos dados e para as análises descritiva, do modelo de regressão logística multinomial, análise de correlação e análise de correspondência foi utilizado o *software* STATA 16. Primeiramente, foram realizadas as adequações na base de dados com codificação das variáveis para que pudessem ser compreendidas e utilizadas no *software*. A partir disso, foram feitas análises descritivas e a análise de correlação de Pearson para

estabelecer qualquer associação significativa entre variáveis explicativas numéricas. O estudo também utilizou testes de frequência e qui-quadrado para variáveis qualitativas.

Em seguida, foi utilizado o modelo de regressão logística multinomial para avaliar a influência de cada variável explicativa no nível de adoção de IA. A categoria de referência foi “não uso”, por se tratar da opção com mais respostas, conforme eleição habitual do *software*. Ao rodar o modelo apresentado pela equação, também é alvo de análise o valor da Probabilidade χ^2 ($\text{Prob} > \chi^2$), responsável por indicar se o modelo como um todo é significativo para explicar a adoção de IA. Além disso, é analisada a Probabilidade z ($P > |z|$), que se refere a probabilidade individual dos determinantes em explicar o modelo. Adotou-se o intervalo de confiança de 95%, com nível de significância de 5% ($p \leq 0,05$) para as análises (Fávero, 2017).

Como não há um consenso quanto à abordagem ideal para seleção de variáveis, foi usado um método ou critério *forward*, sendo as variáveis de maior significância inseridas primeiro. Além disso, para eliminação de variáveis na seleção do melhor modelo final foi considerado o critério AIC (Gardner et al., 2019).

O critério de informação de Akaike (do inglês, *Akaike information criterion* – AIC) é utilizado para avaliar o ajuste do modelo, uma vez que o modelo ajustado ótimo é identificado pelo valor mínimo de AIC. Ou seja, ao compararmos dois ou mais modelos é preferível o modelo com o menor valor de AIC (Gujarati & Porter, 2011). Essa medida, que é útil como critério de seleção do melhor modelo (Gujarati & Porter, 2011), pode ser observada no *software Stata* ao incluir o comando *estat ic*. Por último, foi observado o valor do pseudo R^2 de McFadden, que indica o percentual de determinantes do modelo que foram capazes de explicar o uso de IAS. Esse critério é utilizado para a escolha de um modelo em detrimento de outro, sendo que o melhor modelo é o de maior pseudo R^2 (Fávero, 2017).

Considerando a maneira pela qual os dados do estudo foram coletados e tratados, e como os procedimentos metodológicos foram seguidos, o próximo capítulo apresenta os resultados encontrados no estudo e a análise dos achados em relação à literatura.

4 APRESENTAÇÃO E ANÁLISE DOS RESULTADOS

Esta seção destina-se à apresentação e análise dos resultados da pesquisa. Inicialmente, serão expostas as estatísticas descritivas dos determinantes, abrangendo medidas de tendência central (média e mediana), dispersão (desvio padrão e variância) e forma da distribuição (assimetria e curtose), bem como os valores mínimos e máximos observados. Em seguida, será

apresentada a estatística inferencial, que inclui testes qui-quadrado, análise dos resíduos padronizados ajustados e análise de correspondência. Na sequência, serão reportados os resultados do modelo de regressão logística multinomial, com a devida aplicação de testes para robustez. Por fim, os achados empíricos serão discutidos à luz do referencial teórico, visando identificar convergências e divergências em relação à literatura especializada.

4.1 ANÁLISE DESCRITIVA

A pesquisa TIC Saúde 2024 revelou que 14,29% (93/651) dos estabelecimentos de saúde considerados fazem uso de tecnologias baseadas em inteligência artificial. Conforme apresentado na seção 3, a variável dependente “int_artif” foi categorizada em quatro grupos, seguindo parâmetros de modelos internacionais (Baten, 2024), a saber: (1) “Não uso” — nenhuma adoção de IA; (2) “Baixo uso” — adoção de 1 ou 2 itens; (3) “Médio uso” — adoção de 3, 4 ou 5 itens; e (4) “Alto uso” — adoção de 6 itens ou mais. Os resultados iniciais para a variável dependente “int_artif” são apresentados na Tabela 3.

Tabela 3

Distribuição de frequência da variável dependente

Uso de IA	Freq.	Percentual	Cum.
Alto uso	35	5.38	5.38
Médio uso	21	3.23	8.60
Baixo uso	37	5.68	14.29
Não uso	558	85.71	100.00

As técnicas mais utilizadas foram referentes a: automatização de processos de fluxos de trabalho, com 9,83% (64/651); aplicação ou uso de recursos como o ChatGPT e o Bard, entre outros, com 9,52% (62/651); e mineração de texto e análise da linguagem escrita ou falada (processamento de linguagem natural), com 7,53% (49/651). A técnica menos utilizada foi reconhecimento e processamento de sinais e imagens, que identificam objetos ou pessoas, com apenas 2,76% (18/651).

Quanto as finalidades, a principal utilização de IA foi para: segurança digital, com 6,45% (42/651); e organização de processos clínicos e administrativos, com 5,38% (35/651). O menor interesse dos gestores em IA se mostrou para: gestão de recursos humanos ou recrutamento, com apenas 3,07% (20/651) bem como auxiliar na dosagem de medicamentos de acordo com o paciente atendido, com apenas 3,23% (21/651). Esses resultados indicam o potencial para adoção de variadas tecnologias baseadas em IA no setor de saúde brasileiro.

A Tabela 4 apresenta as estatísticas descritivas para a variável dependente e as variáveis explicativas numéricas da análise.

Tabela 4

Estatística descritiva

Variáveis	Mínimo	Máximo	Média	Mediana	Desvio Padrão	Variância	Assimetria	Curtose
int_artif	0	13	,711	0	2,099	4,406	3,382	14,599
Segurança	0	17	11,212	12	3,922	15,383	-0,587	2,602
Acesso	0	43	26,247	27	10,601	112,380	-0,405	2,263
Remoto	0	6	1,579	1	1,738	3,020	0,922	2,819
Novtecn	0	15	3,682	3	3,104	9,636	1,168	3,892
Infraestrutura	2	7	5,602	6	1,302	1,695	-0,942	3,286

A variável dependente, adoção de IA no estabelecimento de saúde (int_artif), apresenta valor mínimo igual a 0, o que significa que alguns estabelecimentos não utilizaram nenhum tipo de técnica baseada em inteligência artificial. Nota-se também que os determinantes segurança, acesso, remoto e novtecn apresentam valor 0 para a coluna mínimo. Isso indica que alguns estabelecimentos não pontuaram nesses critérios. Dos determinantes independentes métricos, a infraestrutura foi a única com valor mínimo superior a 0, ou seja, todos os estabelecimentos pontuaram pelo menos 2 itens do questionário sobre infraestrutura de TIC no estabelecimento. Os resultados encontrados na coluna máximo (para int_artif, segurança, acesso, remoto, novtecn e infraestrutura) revelam que alguns estabelecimentos pontuaram o máximo valor possível para as variáveis.

A Tabela 5 apresenta o valor de estatística descritiva (média) das variáveis quantitativas para cada uma das quatro categorias da variável dependente.

Tabela 5

Comportamento das médias das variáveis quantitativas, de acordo com o uso de IAS

Variáveis	Uso de IAS (int_artif)			
	Não uso	Baixo uso	Médio uso	Alto uso
Infraestrutura	5,509	6,048	6,108	6,286
Segurança	10,860	11,857	13,135	14,400
Acesso	25,478	24,285	29,595	36,143
Remoto	1,401	1,714	2,351	3,514
Novtecn	3,251	4,095	5,622	8,257

De acordo com a Tabela 5, as variáveis quantitativas comportam-se de forma positiva em relação a adoção e uso de inteligência artificial. O alto uso de IAS, de maneira geral, vem acompanhada por aumentos: (a) no nível de infraestrutura de TIC do estabelecimento; (b) no nível de segurança digital, medido pelo uso de ferramentas de segurança; (c) no nível de acesso

e manutenção dos dados relacionados à saúde do paciente; (d) na medida de cada estabelecimento no quesito atividades remotas/à distância relacionadas à saúde e (e) no uso de outras tecnologias inovadoras além da IA.

No entanto, para alguns determinantes, as relações não são uniformes para todos os níveis de uso de IAS. Na transição da categoria “não uso” para “baixo uso”, os estabelecimentos de saúde apresentam uma leve diminuição no nível de acesso e manutenção dos dados relacionados à saúde do paciente. Nos demais determinantes as transições entre um nível e outro se comportam de maneira relativamente uniforme.

Ainda analisando as variáveis quantitativas, é importante testar a correlação entre as variáveis independentes numéricas para verificar se há problemas de multicolinearidade. A Tabela 6 apresenta a matriz de correlação de Pearson entre as variáveis quantitativas.

Tabela 6

Matriz de correlação das variáveis quantitativas

	seguranca	novtecn	acesso	infraestrutura	remoto
seguranca	1				
novtecn	0.3691***	1			
acesso	0.2493***	0.3145***	1		
infraestrutura	0.3967***	0.2324***	0.1155***	1	
remoto	0.2384***	0.3297***	0.4551***	0.0993**	1

Nota: *Nível de significância de 10%; ** Nível de significância de 5%; ***Nível de significância de 1%.

A Tabela 6 apresenta a matriz de correlação para as variáveis independentes quantitativas, que foi medida antes do modelo de regressão. Conforme observado, nenhuma das variáveis apresenta correlação forte (entre 0,70-0,89) ou muito forte (entre 0,90-0,99). A maioria é fraca (0,10-0,39) e apenas a relação entre infraestrutura/segurança e remoto/acesso é moderada (entre 0,40-0,69). Assim, não são identificados problemas de multicolinearidade entre as variáveis independentes quantitativas. Além disso, ao analisar os *outliers* (mediante comando *iqr* no software), não foi identificada presença de nenhum.

4.2 ANACOR (ANÁLISE DE CORRESPONDÊNCIA) E QUI-QUADRADO

Avançando as estatísticas descritivas, o próximo passo da abordagem empírica avalia a relação entre variáveis qualitativas independentes e a variável dependente, também categórica, por meio da análise de correspondência. A ANACOR, que se ampara na estatística qui-quadrado, possibilita testar as associações entre variáveis e resulta em uma representação

gráfica (Fávero, 2017). Nesse sentido, a região do Brasil à qual o estabelecimento de saúde pertence foi o primeiro determinante testado e o resultado está na Tabela 7.

Tabela 7

Estatística qui-quadrado – associação entre região e adoção de IA

Região	Não uso		Baixo uso		Médio uso		Alto uso		Total
	freq abs	freq %	freq abs	freq %	freq abs	freq %	freq abs	freq %	
Centro-oeste	90	90%	2	2%	3	3%	5	5%	100
Nordeste	150	83,80%	6	3,35%	10	5,59%	13	7,26%	179
Norte	55	82,09%	4	5,97%	2	2,99%	6	8,96%	67
Sudeste	166	86,91%	8	4,19%	14	7,33%	3	1,57%	191
Sul	97	85,09%	1	0,88%	8	7,02%	8	7,01%	114
Total	558	85,71%	21	3,23%	37	5,68%	35	5,38%	651

Nota. Pearson $\chi^2(12) = 16.8874$ Pr = 0.1539

A partir do resultado observado na Tabela 7, pode-se afirmar, para o nível de significância de 5%, que **não existe associação estatisticamente significativa** entre o determinante região e adoção de IA, uma vez que $\chi^2(12) = 16.8874$ (χ^2 calculado para 12 graus de liberdade) e Prob. > 0,05 (Pr = 0.1539). Apesar disso, cabe destacar que a região Norte apresentou o maior percentual de estabelecimentos de saúde com Alto uso de IA, 8,96% (6/67), seguida da região Nordeste com 7,26% (13/179). Esses números são interessantes ao considerar apenas essas duas regiões contêm mais da metade dos estabelecimentos com Alto uso de IA analisados (19/35). A região Sudeste apresentou o maior percentual de estabelecimentos de saúde com Médio uso de IA – 7,33% (14/191).

Tabela 8

Estatística qui-quadrado – associação entre localização e adoção de IA

Localização	Não uso		Baixo uso		Médio uso		Alto uso		Total
	freq abs	freq %	freq abs	freq %	freq abs	freq %	freq abs	freq %	
Capital	205	82,33%	11	4,42%	15	6,02%	18	7,23%	249
Interior	353	87,81%	10	2,49%	22	5,47%	17	4,23%	402
Total	558	85,71%	21	3,23%	37	5,68%	35	5,38%	651

Nota. Pearson $\chi^2(3) = 4.9710$ Pr = 0.1739

Com base na Tabela 8, pode-se afirmar, para o nível de significância de 5%, que **não existe associação estatisticamente significativa** entre o determinante localização e adoção de

IA, uma vez que $\chi^2(3) = 4.9710$ (χ^2 calculado para 3 graus de liberdade) e Prob. > 0,05 (Pr = 0.1739).

Tabela 9

Estatística qui-quadrado – associação entre natureza de propriedade e adoção de IA

Natureza de propriedade	Não uso		Baixo uso		Médio uso		Alto uso		Total
	freq abs	freq %	freq abs	freq %	freq abs	freq %	freq abs	freq %	
Privado	359	83,49%	14	3,26%	27	6,28%	30	6,98 %	249
Público	199	90,04%	7	3,17%	10	4,52%	5	2,26%	402
Total	558	85,71%	21	3,23%	37	5,68%	35	5,38%	651

Nota. Pearson $\chi^2(3) = 7.5604$ Pr = 0.0560

Com base na Tabela 9, pode-se afirmar, para o nível de significância de 5%, que **não existe associação estatisticamente significativa** entre o determinante natureza de propriedade e adoção de IA, uma vez que $\chi^2(3) = 7.5604$ (χ^2 calculado para 3 graus de liberdade) e Prob. > 0,05 (Pr = 0.0560). No entanto, se considerarmos um nível de significância de 10%, o resultado é **estatisticamente significativo**, pois Prob. < 0,10 (Pr = 0.0560). Nesse sentido, convém investigar também os resíduos padronizados ajustados, como mostrado na Tabela 10.

Tabela 10

Resíduos padronizados ajustados – associação entre natureza de propriedade e adoção de IA

Natureza de propriedade	Não uso		Baixo uso		Médio uso		Alto uso	
	freq obs	freq esp	freq obs	freq esp	freq obs	freq esp	freq obs	freq esp
Privado	359	368.571	14	13.871	27	24.439	30	23.118
Resíduo ajustado		-2.264		0.060		0.915		2.525
Público	199	189.429	7	7.129	10	12.561	5	11.882
Resíduo ajustado		2.264		-0.060		-0.915		-2.525

Nota. Freq. Obs. (Frequência observada). Freq. Esp. (Frequência esperada).

Pearson $\chi^2(3) = 7.5604$ Pr = 0.0560. Likelihood-ratio $\chi^2(3) = 8.5298$ Pr = 0.0360

A partir da Tabela 10, é possível verificar que há uma tendência a dependência entre natureza de propriedade e adoção de IA, pois o resultado é quase significativo (Pr = 0.0560). Especialmente entre as categorias “Alto uso” e “Privado” e entre “Não uso” e “Público”, uma vez que os resíduos padronizados das células correspondentes são, respectivamente, iguais a 2.525 e 2.264 (ambos positivos e maiores que 1,96).

Tabela 11

Estatística qui-quadrado – associação entre porte de estabelecimento e adoção de IA

Porte	Não uso		Baixo uso		Médio uso		Alto uso		Total
	freq abs	freq %	freq abs	freq %	freq abs	freq %	freq abs	freq %	
Internação (+50 leitos)	168	82,35%	8	3,92%	14	6,86%	14	6,86%	204
Internação (0-50 leitos)	102	91,89%	2	1,80%	1	0,90%	6	5,41%	111
Sem Internação	221	87,35%	6	2,37%	16	6,32%	10	3,95%	253
SADT	67	80,72%	5	6,02%	6	7,23%	5	6,02%	83
Total	558	85,71%	21	3,23%	37	5,68%	35	5,38%	651

Nota. SADT (Serviço de Apoio à Diagnose e Terapia). Pearson $\chi^2(9) = 12.0295$ Pr = 0.2117

A partir do resultado observado na Tabela 11, pode-se afirmar, para o nível de significância de 5%, que **não existe associação estatisticamente significativa** entre o determinante porte do estabelecimento e adoção de IA, uma vez que $\chi^2(9) = 12.0295$ (χ^2 calculado para 9 graus de liberdade) e Prob. > 0,05 (Pr = 0.2117).

Tabela 12

Estatística qui-quadrado – associação entre treinamento (dos médicos e enfermeiros do estabelecimento para o uso de sistemas eletrônicos) e adoção de IA

Treinamento	Não uso		Baixo uso		Médio uso		Alto uso		Total
	freq abs	freq %	freq abs	freq %	freq abs	freq %	freq abs	freq %	
Concorda	386	84,84%	16	3,52%	27	5,93%	26	5,71%	455
Discorda	46	88,46%	2	3,85%	1	1,92%	3	5,77%	52
Neutro	126	87,50%	3	2,08%	9	6,25%	6	4,17%	144
Total	558	85,71%	21	3,23%	37	5,68%	35	5,38%	651

Nota. Pearson $\chi^2(6) = 2.8331$ Pr = 0.8295

A partir do resultado observado na Tabela 12, pode-se afirmar, para o nível de significância de 5%, que **não existe associação estatisticamente significativa** entre o determinante treinamento (que corresponde à percepção do respondente quanto ao treinamento dos médicos e enfermeiros do estabelecimento para o uso de sistemas eletrônicos) e adoção de IA, uma vez que $\chi^2(6) = 2.8331$ (χ^2 calculado para 6 graus de liberdade) e Prob. > 0,05 (Pr = 0.8295).

Tabela 13

Estatística qui-quadrado – associação entre recursos financeiros (suficientes para investimento em sistemas eletrônicos) e adoção de IA

Financeiro	Não uso		Baixo uso		Médio uso		Alto uso		Total
	freq abs	freq %	freq abs	freq %	freq abs	freq %	freq abs	freq %	
Concorda	230	84,56%	9	3,31%	16	5,88%	17	6,25%	272
Discorda	159	88,83%	4	2,23%	8	4,47%	8	4,47%	179
Neutro	169	84,50%	8	4,00 %	13	6,50%	10	5,00%	200
Total	558	85,71%	21	3,23%	37	5,68%	35	5,38%	651

Nota. Pearson $\chi^2(6) = 2.6323$ Pr = 0.8530

A partir do resultado observado na Tabela 13, pode-se afirmar, para o nível de significância de 5%, que **não existe associação estatisticamente significativa** entre o determinante recursos financeiros (que corresponde à percepção do respondente quanto a existência de recursos financeiros suficientes para investimento em sistemas eletrônicos) e adoção de IA, uma vez que $\chi^2(6) = 2.6323$ (χ^2 calculado para 6 graus de liberdade) e Prob. > 0,05 (Pr = 0.8530).

Tabela 14

Estatística qui-quadrado – associação entre políticas governamentais (incentivarem a implantação e o uso de sistemas eletrônicos no estabelecimento) e adoção de IA

Políticas governamentais	Não uso		Baixo uso		Médio uso		Alto uso		Total
	freq abs	freq %	freq abs	freq %	freq abs	freq %	freq abs	freq %	
Concorda	306	82,93%	11	2,98%	29	7,86%	23	6,23%	369
Discorda	112	92,56%	5	4,13%	0	0,00%	4	3,31%	121
Neutro	140	86,96%	5	3,11	8	4,97%	8	4,97%	161
Total	558	85,71%	21	3,23%	37	5,68%	35	5,38%	651

Nota. Pearson $\chi^2(6) = 13.0222$ Pr = 0.0427

A partir do resultado observado na Tabela 14, pode-se afirmar, para o nível de significância de 5%, que **existe associação estatisticamente significativa** entre o determinante políticas governamentais (que corresponde à percepção do respondente quanto as políticas governamentais incentivarem a implantação e o uso de sistemas eletrônicos no estabelecimento) e adoção de IA, uma vez que $\chi^2(6) = 13.0222$ (χ^2 calculado para 6 graus de liberdade) e Prob. < 0,05 (Pr = 0.0427).

Visto que o resultado foi estatisticamente significativo, pode-se afirmar que a associação entre as duas variáveis não se dá de forma aleatória. Nesse sentido, é possível, por meio da análise dos resíduos padronizados ajustados, estudar a relação de dependência entre os pares de categorias, conforme Tabela 15.

Tabela 15

Resíduos padronizados ajustados – associação entre políticas governamentais e adoção de IA

Políticas governamentais	Não uso		Baixo uso		Médio uso		Alto uso	
	freq obs	freq esp	freq obs	freq esp	freq obs	freq esp	freq obs	freq esp
Concorda	306	316.286	11	11.903	29	20.972	23	19.839
Resíduo ajustado		-2.325		-0.404		2.742		1.109
Discorda	112	103.714	5	3.903	0	6.877	4	6.505
Resíduo ajustado		2.386		0.625		-2.993		-1.119
Neutro	140	138.000	5	5.194	8	9.151	8	8.656
Resíduo ajustado		0.519		-0.100		-0.451		-0.264

Nota. Freq. Obs. (Frequência observada). Freq. Esp. (Frequência esperada).

Pearson $\chi^2(6) = 13.0222$ Pr = 0.0427. Likelihood-ratio $\chi^2(6) = 19.6698$ Pr = 0.003

É possível verificar que há dependência entre as categorias “Médio uso” e “Concorda”, entre “Não uso” e “Discorda”, uma vez que os resíduos padronizados das células correspondentes são, respectivamente, iguais a 2.742, 2.386 (ambos positivos e maiores que 1,96). Esse achado também é visível no mapa perceptual da análise de correspondência apresentado na Figura 4.




Figura 4. Análise de correspondência entre políticas governamentais e adoção de IA

É visível um agrupamento do lado esquerdo entre as categorias Discorda e Não uso, enquanto do lado direito do gráfico há um agrupamento das categorias Concorda, Médio uso e Alto uso. Esse achado sugere que existe uma relação de dependência entre as variáveis, visto que o resultado foi estatisticamente significativo a um intervalo de confiança de 95%.

Tabela 16

Estatística qui-quadrado – associação entre envolvimento (dos médicos e enfermeiros na implantação dos sistemas eletrônicos do estabelecimento) e adoção de IA

Envolvimento	Não uso		Baixo uso		Médio uso		Alto uso		Total
	freq abs	freq %	freq abs	freq %	freq abs	freq %	freq abs	freq %	
Concorda	256	81,53%	7	2,23%	24	7,64%	27	8,60%	314
Discorda	152	92,12%	5	3,03%	7	4,24 %	1	0,60%	165
Neutro	150	87,21%	9	5,23%	6	3,49%	7	4,07%	172
Total	558	85,71%	21	3,23%	37	5,68%	35	5,38%	651

Nota. Pearson $\chi^2(6) = 22.3877$ Pr = 0.001

A partir do resultado observado na Tabela 16, pode-se afirmar, para o nível de significância de 5%, que **existe associação estatisticamente significativa** entre o determinante Envolvimento (que corresponde à percepção do respondente quanto ao envolvimento dos médicos e enfermeiros na seleção, desenvolvimento e implantação dos sistemas eletrônicos do estabelecimento) e adoção de IA, uma vez que $\chi^2(6) = 22.3877$ (χ^2 calculado para 6 graus de liberdade) e Prob. < 0,05 (Pr = 0.001).

Levando em consideração que o resultado foi estatisticamente significativo, pode-se afirmar que a associação entre as duas variáveis não se dá de forma aleatória. Assim, também é possível, por meio da análise dos resíduos padronizados ajustados, verificar a relação de dependência entre as categorias, conforme Tabela 17.

Tabela 17

Resíduos padronizados ajustados – associação entre envolvimento e adoção de IA

Envolvimento	Não uso		Baixo uso		Médio uso		Alto uso	
	freq obs	freq esp	freq obs	freq esp	freq obs	freq esp	freq obs	freq esp
Concorda	256	269.143	7	10.129	24	17.846	27	16.882
Resíduo ajustado		-2.946		-1.389		2.085		3.519
Discorda	152	141.429	5	5.323	7	9.378	1	8.871
Resíduo ajustado		2.722		-0.165		-0.925		-3.144
Neutro	150	147.429	9	5.548	6	9.776	7	9.247
Resíduo ajustado		0.653		1.737		-1.450		-0.886

Nota. Freq. Obs. (Frequência observada). Freq. Esp. (Frequência esperada).

Pearson $\chi^2(6) = 22.3877$ Pr = 0.001. Likelihood-ratio $\chi^2(6) = 25.7405$ Pr = 0.000

É possível verificar que há dependência entre as categorias “Alto uso” e “Concorda”, “Medio uso e Concorda”, entre “Não uso” e “Discorda”, uma vez que os resíduos padronizados

das células correspondentes são, respectivamente, iguais a 3.519, 2.085, 2.722 (positivos e maiores que 1,96). Esse achado também é visível no mapa perceptual da análise de correspondência apresentado na Figura 5.




Figura 5. Análise de correspondência entre envolvimento e adoção de IA

É visível um agrupamento do lado esquerdo entre as categorias Discorda e Não uso, enquanto do lado direito do gráfico há um agrupamento das categorias Concorde, Médio uso e Alto uso. Esse achado sugere que existe uma relação de dependência entre as variáveis, visto que o resultado foi estatisticamente significativo a um intervalo de confiança de 95%.

Apesar da ANACOR permitir a exploração de associações dentro de conjuntos de dados categóricos de uma maneira visualmente intuitiva, essa análise oferece profundidade limitada e não permite identificar com clareza efeitos causais ou análise preditiva. Por isso, a próxima seção abordará o modelo de regressão logística multinomial.

4.3 ANÁLISE DE REGRESSÃO LOGÍSTICA MULTINOMIAL

A Tabela 18 apresenta os resultados da regressão logística multinomial realizada com todas as variáveis do modelo. Essa técnica é útil para avaliar se as características descritas anteriormente podem ajudar a prever padrões de adoção de IA. Isso esclarecerá a importância relativa dos determinantes em impulsionar o uso de IAS.

Tabela 18

Modelo multinomial não clusterizado, com variável dependente “i_artif”

Variáveis	coef	z	prob	coef	z	prob	coef	z	prob
Não uso (base de comparação)	Baixo uso			Médio uso			Alto uso		
Novas tecnologias	0.0699	0.83	0.407	0.1640	2.80	0.005	0.3072	4.32	0.000
Remoto	0.1467	0.90	0.369	0.1313	1.18	0.239	0.3614	2.86	0.004
Acesso	-0.0192	-0.66	0.507	0.0234	0.98	0.326	0.0693	1.84	0.066
Segurança	0.0099	0.12	0.901	0.0582	0.82	0.410	0.1468	1.49	0.135
Infraestrutura	0.4217	1.72	0.085	0.3124	1.55	0.120	0.3687	1.34	0.179
Envolvimento									
Discorda	0.1423	0.20	0.839	-0.3097	-0.60	0.551	-2.4717	-2.20	0.028
Neutro	1.1210	1.91	0.056	-0.700	-1.28	0.200	-0.4927	-0.80	0.422
Políticas governamentais									
Discorda	0.4542	0.71	0.480	-15.7965	-0.02	0.985	0.6099	0.80	0.421
Neutro	0.2314	0.37	0.711	-0.3528	-0.75	0.455	0.6066	1.02	0.306
Natureza de propriedade									
Publico	0.5278	0.89	0.375	-0.2120	-0.43	0.670	-1.1217	-1.55	0.120
Região									
Nordeste	0.8011	0.93	0.353	1.0048	1.38	0.168	0.9089	1.30	0.194
Norte	1.0410	1.13	0.260	0.6831	0.69	0.489	1.5494	1.87	0.062
Sudeste	1.0395	1.23	0.218	1.5264	2.10	0.036	-0.5598	-0.61	0.542
Sul	-0.5051	-0.39	0.696	1.2898	1.66	0.097	1.1552	1.44	0.150
Porte									
0-50 leitos	-0.6648	-0.79	0.431	-2.1712	-2.01	0.045	-0.5819	-0.86	0.391
Sem internação	-0.4738	-0.78	0.434	0.0715	0.16	0.870	-0.8178	-1.46	0.144
SADT	0.5176	0.70	0.483	0.2923	0.47	0.640	-0.1263	-0.16	0.870
Localização									
Interior	-0.4674	-0.89	0.373	-0.0354	-0.08	0.932	0.0346	0.07	0.944
Treinamento									
Discorda	0.0910	0.10	0.918	-0.3238	-0.29	0.775	0.0831	0.08	0.939
Neutro	-1.0430	-1.36	0.174	0.5771	1.16	0.245	0.8045	1.18	0.239
Financeiro									
Discorda	-0.5197	-0.69	0.493	0.5138	0.94	0.346	0.2234	0.37	0.712
Neutro	0.2963	0.50	0.615	0.8183	1.78	0.076	0.7520	1.30	0.193
_cons	-6.6760	-3.16	0.002	-7.7488	-4.09	0.000	-12.0701	-4.44	0.000

Nota. SADT (Serviço de Apoio à Diagnose e Terapia). Modelo não clusterizado – LR $\chi^2(66) = 204.29$ – Prob = 0,000 – 651 observações. Pseudo R² = 0,2787. AIC: 666.7902. Intervalo de confiança de 95%. O valor de p em negrito indica as variáveis estatisticamente significativas.

Como é possível perceber pela Tabela 18, a categoria que ficou fora do modelo, foi “não uso”, pois possui maior frequência. Cada uma das outras três categorias (“baixo uso”, “médio uso” e “alto uso”) foi comparada a esse grupo de referência da variável resposta. Inicialmente, observa-se que a probabilidade do qui-quadrado do modelo (LR $\chi^2(66) = 204.29$, Prob > $\chi^2 = 0,0000$) foi inferior ao nível de significância de 0,05 ($p < 0,05$), ou seja, o modelo é estatisticamente significativo. Com base no teste χ^2 (Prob > $\chi^2 = 0.0000$), podemos rejeitar a hipótese nula de que todos os parâmetros sejam estatisticamente iguais a zero ao nível de

significância de 5%. Logo, pelo menos uma variável X é estatisticamente significativa para explicar a probabilidade de ocorrência de pelo menos um dos eventos em estudo (Fávero, 2017). Isso sugere que todas as variáveis independentes, em conjunto, melhoram o modelo em relação ao modelo com apenas intercepto (ou seja, sem variáveis adicionadas). Em outras palavras, a inclusão das variáveis independentes gera um modelo estatisticamente significativo.

Os coeficientes associados as variáveis na Tabela 18 indicam a mudança na probabilidade de uso de IA, por parte dos estabelecimentos de saúde com departamento de TI no Brasil. Apesar do modelo completo ter sido significativo ($\text{Prob} > \chi^2 = 0.0000$), alguns dos determinantes não apresentaram significância em nenhuma das três categorias da variável dependente. É possível perceber que nenhuma das variáveis apresentou significância estatística na categoria “Baixo uso”.

Na dimensão tecnológica, apenas o determinante “Novas tecnologias” apresentou coeficiente positivo e com significância estatística nas categorias “Médio uso” (coef.: 0.1640; $\text{Prob} > \chi^2 = 0.004$) e “Alto uso” (coef.: 0.3072; $\text{Prob} > \chi^2 = 0.000$). Isso quer dizer que à medida que o nível de uso de novas tecnologias aumenta, é ampliada a probabilidade de estabelecimentos utilizarem mais IA. O determinante “Remoto” apresentou coeficiente (0.3614) com significância estatística apenas na categoria “Alto uso” ($\text{Prob} > \chi^2 = 0.004$).

Na dimensão organizacional, o determinante envolvimento apresentou coeficiente negativo e significância estatística (coef.: -2.4717; $\text{Prob} > \chi^2 = 0.028$) na opção “Discorda”, quando comparada a referência “Concorda”. Isso significa que estabelecimentos cujo gestor discorda da afirmação que “os médicos e enfermeiros são envolvidos na seleção, desenvolvimento e implantação dos sistemas eletrônicos do estabelecimento” apresentam menor chance de alto uso de IA do que estabelecimentos cujo gestor concorda.

Ainda na dimensão organizacional, o determinante “porte” de estabelecimento apresentou coeficiente negativo e significância estatística (coef.: -2.1712; $\text{Prob} > \chi^2 = 0.045$) na opção “0-50 leitos”, isto é, estabelecimentos com poucos leitos de internação, ou menores. Ou seja, quando comparados a estabelecimentos de saúde maiores (com mais de 50 leitos), os estabelecimentos menores apresentam menor chance de usar IA de forma moderada.

Na dimensão ambiental, a região Sudeste apresentou significância estatística apenas na comparação da categoria “Médio uso” e “Não uso” (coef.: 1.5264; $\text{Prob} > \chi^2 = 0.036$). Isso quer dizer que estabelecimentos de saúde localizados na região Sudeste possuem maior probabilidade de usar IA de forma moderada, especialmente quando comparados a estabelecimentos da região Centro-Oeste.

A fim de encontrar o modelo com melhor ajuste, especialmente no valor AIC, foi efetuado um segundo teste. Foi realizada novamente a análise de regressão logística multinomial – dessa vez com a especificação de *cluster* (Fávero, 2017). A fim de verificar se há correlação dentro dos grupos, a Tabela 19 apresenta o modelo clusterizado, com erro padrão ajustado para os 5 *clusters* na variável região.

Tabela 19

Modelo multinomial clusterizado, com variável dependente “i_artif”

Variáveis	Coef	z	prob	coef	z	prob	coef	z	prob
Não uso (base de comparação)	Baixo uso			Médio uso			Alto uso		
Novas tecnologias	0.0699	0.56	0.578	0.1640	2.43	0.015	0.3072	3.34	0.001
Remoto	0.1467	1.72	0.086	0.1313	2.47	0.013	0.3614	3.03	0.002
Acesso	-0.0192	-0.41	0.682	0.0234	1.01	0.313	0.0693	1.77	0.076
Segurança	0.0099	0.3	0.761	0.0582	0.62	0.534	0.1468	1.28	0.200
Infraestrutura	0.4217	3.1	0.002	0.3124	2.39	0.017	0.3687	1.76	0.078
Envolvimento									
Discorda	0.1423	0.18	0.858	-0.3097	-1.21	0.226	-2.4717	-2.56	0.011
Neutro	1.1210	1.22	0.221	-0.700	-0.82	0.413	-0.4927	-1.1	0.269
Políticas governamentais									
Discorda	0.4542	0.7	0.482	-15.7965	-19.81	0.000	0.6099	0.51	0.610
Neutro	0.2314	0.28	0.779	-0.3528	-0.52	0.605	0.6066	1.09	0.277
Natureza de propriedade									
Publico	0.5278	1.01	0.313	-0.2120	-0.68	0.497	-1.1217	-1.66	0.097
Região									
Nordeste	0.8011	3.69	0.000	1.0048	6.89	0.000	0.9089	3.74	0.000
Norte	1.0410	11.32	0.000	0.6831	3.52	0.000	1.5494	5.48	0.000
Sudeste	1.0395	9.41	0.000	1.5264	20.95	0.000	-0.5598	-3.15	0.002
Sul	-0.5051	-1.56	0.119	1.2898	10.74	0.000	1.1552	2.4	0.017
Porte									
0-50 leitos	-0.6648	-1.05	0.296	-2.1712	-2.01	0.044	-0.5819	-0.91	0.362
Sem internação	-0.4738	-1.07	0.285	0.0715	0.16	0.881	-0.8178	-1.17	0.243
SADT	0.5176	0.5	0.620	0.2923	0.47	0.742	-0.1263	-0.11	0.911
Localização									
Interior	-0.4674	-2.69	0.007	-0.0354	-0.11	0.911	0.0346	0.06	0.952
Treinamento									
Discorda	0.0910	0.18	0.857	-0.3238	-0.25	0.801	0.0831	0.09	0.929
Neutro	-1.0430	-2.42	0.015	0.5771	0.89	0.376	0.8045	1.47	0.141
Financeiro									
Discorda	-0.5197	-0.8	0.423	0.5138	0.88	0.378	0.2234	0.89	0.374
Neutro	0.2963	0.76	0.449	0.8183	2.2	0.028	0.7521	1.64	0.100
_cons	-6.6760	-10.36	0.000	-7.7488	-4.19	0.000	-12.0701	-4.44	0.000

Nota. SADT (Serviço de Apoio à Diagnose e Terapia). Modelo clusterizado – 651 observações. Pseudo R2 = 0,2787. AIC: 538.7902. Intervalo de confiança de 95%. O valor de p em negrito indica as variáveis estatisticamente significativas.

O segundo modelo de regressão logística multinomial apresenta melhor ajuste quando analisado o critério AIC: 538.7902 é menor do que 666.7902 do primeiro modelo (Tabela 18). Na Tabela 19 pode-se perceber que alguns valores permaneceram constantes em comparação com a Tabela 18. Além dos coeficientes terem sido mantidos, alguns valores p também não apresentaram alterações significativas. No entanto, alguns determinantes apresentaram maior significância estatística após o ajuste do erro padrão por meio do agrupamento das observações na variável região.

Na dimensão tecnológica, o determinante “Novas tecnologias” apresentou coeficiente positivo e com significância estatística nas categorias “Médio uso” (coef.: 0.1640; Prob > chi2 = 0.015) e “Alto uso” (coef.: 0.3072; Prob > chi2 = 0.001). Isso quer dizer que à medida que o nível de uso de novas tecnologias aumenta, é ampliada a probabilidade de estabelecimentos utilizarem mais IA. O determinante “Remoto” também apresentou coeficiente positivo e com significância estatística nas categorias “Médio uso” (coef.: 0.1313; Prob > chi2 = 0.013) e “Alto uso” (coef.: 0.3614; Prob > chi2 = 0.002). Isso quer dizer que à medida que o nível de oferta de atividades de saúde a distância aumenta, é ampliada a probabilidade de estabelecimentos utilizarem mais IA.

Diferentemente do primeiro modelo, na Tabela 19 é possível perceber que o determinante “Infraestrutura” foi significativo para as categorias “Baixo uso” (coef.: 0.4217; Prob > chi2 = 0.002) e “Médio uso” (coef.: 0.3124; Prob > chi2 = 0.017). Isso quer dizer que estabelecimentos com maior disponibilidade de infraestrutura de TIC possuem maiores chances de usar IA de forma baixa ou média, 42,17% e 31,24%, respectivamente.

Na dimensão organizacional, os determinantes “envolvimento” (coef.: -2.4717; Prob > chi2 = 0.011) e “porte” (coef.: -2.1712; Prob > chi2 = 0.044), com coeficientes negativos, apresentaram uma significância estatística levemente maior que no primeiro modelo. Ou seja, os achados iniciais são mantidos. Estabelecimentos cujos gestores não concordam com a afirmação que “os médicos e enfermeiros são envolvidos na seleção, desenvolvimento e implantação dos sistemas eletrônicos do estabelecimento” apresentam menor chance de alto uso de IA. Estabelecimentos com menor capacidade de internação de pacientes (0-50 leitos) apresentam menor chance de usar IA de forma moderada quando comparados a estabelecimentos com maior capacidade de internação (com mais de 50 leitos).

Na dimensão ambiental, o segundo modelo apresentou coeficiente negativo e significância estatística no determinante “Localização”, apenas na comparação da categoria “Baixo uso” com “Não uso” (coef.: -0.4674; Prob > chi2 = 0.007). Esse determinante diz respeito a localização do estabelecimento no interior em comparação com a capital.

Estabelecimentos de saúde localizados no interior possuem menor probabilidade de usar IA de forma baixa, quando comparados a estabelecimentos localizados na capital. Já para o “Médio uso” e “Alto uso” de IA, esse determinante não parece importar tanto, visto que não houve significância estatística.

As demais variáveis do modelo não são estatisticamente significativas, ou seja, não tem relevância no modelo. Além disso, é interessante destacar que os valores máximos do logaritmo da função de verossimilhança para o modelo completo e para o modelo nulo são, respectivamente, -264.39511 (*Log likelihood*) e -366.54136 (*Iteration 0: log likelihood*).

Com base na força da relação logística multinomial dada pela medida pseudo R^2 , o modelo final explicou cerca de 27,87% da variação da variável dependente. Ou seja, ao atuarem conjuntamente, as variáveis explicativas individuais, conforme pseudo R^2 , explicam 27,87% da variação na adoção de IA por parte dos estabelecimentos.

4.4 DISCUSSÃO DOS RESULTADOS

Esta pesquisa acrescenta novos conhecimentos à literatura existente sobre a implementação de IA, examinando os fatores que influenciam sua adoção em estabelecimentos de saúde, sob a perspectiva do nível de gestão de TI como autoridade de tomada de decisão. Deve-se enfatizar que, da perspectiva gerencial, as três dimensões do modelo TOE (aspectos tecnológicos, organizacionais e ambientais) desempenham papéis importantes na adoção da IA – algumas com mais intensidade do que outras.

Dos 651 estabelecimentos analisados, 93 utilizam IA, enquanto 558 não utilizam. Esse resultado indica que o uso de IAS ainda está em seu estágio inicial. Uma das possíveis explicações para esse achado é que, assim como ocorre em outros contextos, como a administração pública (Ribeiro & Segatto, 2025), o setor da saúde, devido a sua complexidade, pode considerar com maior peso os riscos e incertezas quanto aos benefícios dessas tecnologias, o que pode dificultar sua adoção pelo setor hospitalar.

Dos 93 que usam, há predominância do uso de forma moderada (37) e alta (35), e apenas 21 estabelecimentos se enquadram em baixo uso. Para esses 21 estabelecimentos da categoria baixo uso, nenhum dos determinantes apresentou significância estatística no modelo multilogístico. Inicialmente, uma explicação possível para tal achado encontra-se na relação entre o tamanho da amostra e o erro amostral. Sabe-se que quanto maior o tamanho da amostra menor o erro amostral. Então, o resultado das variáveis dentro da faixa “Baixo uso” não deu significativo possivelmente por causa do tamanho da amostra (apenas 21 estabelecimentos com

baixo uso em comparação com 558 estabelecimentos que não usam IA). Além disso, faz sentido pensar que os fatores determinantes do alto e médio uso de IA não são exatamente os mesmos fatores determinantes do baixo uso de IA, uma vez que variáveis apresentaram significância estatística apenas na categoria “Baixo uso”, enquanto outras apresentaram apenas na categoria “Alto uso”. Nesse sentido, são necessárias investigações adicionais, especialmente qualitativas, sobre como o uso de IA em diferentes graus de adoção pode ser afetado pelos determinantes.

Ainda pensando na questão do tamanho da amostra, outro fato que pode ter contribuído para esse resultado, conforme mencionado na seção 3, foi a decisão tomada no desenho da pesquisa de utilizar como amostra os 651 respondentes que tem setor de TI. Por um lado, essa foi uma decisão necessária, visto que esses 651 são os únicos que responderam às perguntas sobre adoção de Novas Tecnologias (o que inclui IA).

Por outro lado, essa decisão pode ter contribuído para superestimar a adoção de IA nos graus médio e alto por estabelecimentos de saúde. É provável que estabelecimentos sem área de TI também utilizem IA, mas com grau menor e maior heterogeneidade, como também foi apontado por outros autores que utilizaram as pesquisas TIC como fonte de dados (Ribeiro & Segatto, 2025; Rosa & Kubota, 2024, 2025). Além disso, outro ponto negativo derivado dessa escolha é a impossibilidade de generalização dos resultados, pois a utilização da amostra parcial e a não utilização dos pesos amostrais faz com que a amostra não seja representativa do território nacional. Nesse contexto, os resultados são aplicáveis e interpretáveis apenas ao conjunto de estabelecimentos de saúde que possuem a área de TI.

Resumidamente, a análise das estatísticas descritivas mostrou que o comportamento das variáveis explicativas quantitativas, isto é, da dimensão tecnológica, de forma geral, acompanha o comportamento da variável dependente – adoção de IA. A análise de correspondência e as estatísticas qui-quadrado encontraram significância apenas para duas variáveis categóricas: políticas governamentais e envolvimento. O modelo de regressão logística multinomial apresentou significância estatística para os determinantes: infraestrutura, novas tecnologias, remoto, porte (0-50 leitos), envolvimento (discorda) e região (sudeste).

A fim de compreender melhor os resultados, eles serão discutidos à luz do *Framework* TOE.

4.4.1 Determinantes tecnológicos

A dimensão tecnológica foi a mais significativa no modelo multilogístico. Esse achado condiz com pesquisas anteriores (Esmaeilzadeh, 2020), especialmente as que utilizaram o *Framework* TOE para analisar a adoção e uso de tecnologias emergentes (Kumar et al., 2023).

Por isso, tomadores de decisão devem dar prioridade a melhoria desse aspecto tendo em vista sua influência na adoção de IA, quando comparado às demais dimensões.

Os resultados da Tabela 18 demonstram que os determinantes remoto e novas tecnologias tem coeficiente positivo e foram estatisticamente significativos, especialmente para explicar a opção “Médio uso” e “Alto uso” da variável dependente. Isso implica no **suporte das hipóteses H4 e H5**. A média das duas variáveis acompanha o resultado da variável dependente, ou seja, quanto maior o nível de atividades remotas/à distância relacionadas à saúde e quanto maior o nível de adoção de novas tecnologias, maior a chance de usar inteligência artificial no estabelecimento.

Como mencionado na seção 2, até o momento deste estudo, não haviam sido encontradas pesquisas empíricas cujo objetivo fosse testar a relação entre adoção de inteligência artificial e: (I) serviços remotos de saúde e (II) uso das demais novas tecnologias. A validação dessas duas hipóteses exploratórias indica a necessidade de novas pesquisas para aprofundamento desses determinantes. Além disso, destaca-se que a implementação de tecnologias mais avançadas, como a IA, não deve ser analisada isoladamente.

É possível apontar que dependerá de camadas e elementos subjacentes capazes de viabilizar sua utilização. Por exemplo, novas tecnologias como IoT, computação em nuvem e *big data*, podem viabilizar soluções de IA. Além disso, foi possível perceber que estabelecimentos que disponibilizam atividades remotas relacionadas a saúde, isto é, telemonitoramento, teleconsulta, teleconsultoria, telediagnóstico, ensino e pesquisa à distância, tendem a utilizar IA também. Isso demonstra uma conexão entre ter experiências anteriores com a implementação de outras facetas tecnológicas (como a telemedicina) e usar IA (Held et al., 2022; Mazhar et al., 2025).

Ademais, é importante olhar para a infraestrutura de TIC presente no estabelecimento, pois entender como a utilização de IA se relaciona com as características do estabelecimento, como a presença de recursos de TI, é vital (Ribeiro & Segatto, 2025). Ao olhar para o determinante “Infraestrutura”, é nítido que quanto maior o nível de infraestrutura de TIC, maior a chance de usar inteligência artificial de forma baixa ou moderada. Isso implica no **suporte da hipótese H1**. Essa descoberta converge com os achados de Marco-Ruiz et al. (2024), que apontaram como infraestrutura certa é decisiva para uma implementação bem-sucedida de IA, e de Tokgöz et al. (2024), os quais comprovaram que a falta de infraestrutura de TIC adequada é um desafio prevalente na adoção de inovação enquanto a presença de equipamento técnico e a compatibilidade da IA com estruturas técnicas existentes é um fator facilitador.

O grau de acesso e manutenção dos dados relacionados à saúde do paciente pelo estabelecimento, apesar de não se mostrar significativo no modelo, pode ter relação com a adoção de IA, uma vez que o comportamento das médias das variáveis se comporta de forma parecida. A variável acesso vai de 2 (estabelecimentos que pontuaram em apenas 2 itens relacionados ao acesso e manutenção dos dados do paciente) a 25 (seis estabelecimentos que pontuaram em todos os 25 itens). É interessante notar que 63,44% dos estabelecimentos que usam IA pontuaram de 20 a 25 pontos nesse quesito. À medida que o nível de acesso aos dados aumenta, o uso de inteligência artificial também aumenta. No entanto, essa associação não se dá de forma proporcional, pois a categoria “Não uso” de IA tem maior grau de acesso que a categoria “Baixo uso” da variável dependente.

Nesse sentido, os achados desta pesquisa divergem de estudos anteriores. Apesar de autores frisarem a importância da qualidade e integridade dos dados para treinamento dos algoritmos de IA (Marco-Ruiz et al., 2024; Olawade et al., 2023), a **hipótese H2 não foi suportada**. Uma das possíveis explicações para esse achado é que os dados dos pacientes registrados no sistema eletrônico tradicional dos estabelecimentos podem não ser suficientes para as necessidades da IA. Os dados para alimentar algoritmos de IA devem ser padronizados e de alta qualidade (Terry et al., 2022) em termos de especificidade e sensibilidade (Marco-Ruiz et al., 2024). Por isso, entende-se que a disponibilidade de dados ainda está entre os desafios mais críticos para a implementação bem-sucedida de IA na área da saúde (Marco-Ruiz et al., 2024; Olawade et al., 2023; Vijayakumar et al., 2023), mesmo levando em consideração os dados existentes no sistema eletrônico do estabelecimento.

Como a presença de ferramentas e medidas de segurança digital não se mostrou significativa no modelo, a **hipótese H3 não foi suportada**. Apesar disso, pode ter relação com a adoção de IA, uma vez que o comportamento das médias das variáveis se comporta de forma parecida. À medida que o nível de segurança digital (medido pelo uso de ferramentas de segurança) aumenta, o uso de inteligência artificial também aumenta.

Estudos anteriores mostraram que a preocupação com segurança e privacidade é uma barreira comum para uso de IAS por parte de várias partes interessadas, como profissionais de saúde (Alshehri et al., 2024; Hasan et al., 2024; Tezpal et al., 2024; Vijayakumar et al., 2023), pacientes (Antes et al., 2021; Armero et al., 2022; Esmaeilzadeh, 2020; Prakash & Das, 2024; Sisk et al., 2020; T. Q. Sun, 2021) e, especialmente, gestores dos estabelecimentos de saúde (Dastjerdi et al., 2023; Weinert et al., 2022). Conforme o estudo de Rodrigues & Abbas (2025), uma das formas de mitigar essa preocupação e transformar a inicial barreira em uma condição favorável é incorporar medidas de segurança no estabelecimento. Nesse contexto, percebe-se

que estabelecimentos que implantam e utilizam ferramentas de segurança conseguem diminuir o nível de preocupação com privacidade dos dados, e, conseqüentemente, aumentar a confiança e o uso de IA.

Essa necessidade é ainda mais acentuada para hospitais, pois os dados de saúde exigem um ambiente mais seguro para armazenamento e recuperação (Lian et al., 2014). Nesse cenário, a anonimização de dados se destaca como uma estratégia útil para reduzir os riscos relacionados à exposição de informações sensíveis. Essa técnica consiste em remover ou modificar dados que possam identificar diretamente uma pessoa, garantindo que as informações possam ser utilizadas sem comprometer a identidade dos indivíduos. Esse processo é importante para conciliar a análise de dados com a preservação da privacidade dos pacientes (Gonçalo et al., 2025).

Apesar do potencial da IA em melhorar os resultados da assistência médica, ela apresenta dilemas éticos e legais notáveis (Esmaeilzadeh, 2020; Marco-Ruiz et al., 2024; Terranova et al., 2024). Os desafios éticos emergentes da implementação de IA em ambientes clínicos (Terry et al., 2022) incluem preocupações sobre justiça em virtude de dados insuficientes para considerar grupos minoritários (Roppelt et al., 2024), uma vez que representação desigual em conjuntos de dados pode exacerbar o viés e a discriminação (Li et al., 2023). Tal viés tem suas consequências significativamente expressas até mesmo na determinação da responsabilidade profissional em casos de erro ou negligência (Terranova et al., 2024), além de prejudicar desproporcionalmente pessoas vulneráveis (Asan et al., 2020; Olawade et al., 2023).

Ainda que a intersecção de IA e ética biomédica seja uma área relativamente inexplorada (Hasan et al., 2024), as pesquisas enfatizam a importância de diretrizes éticas para o uso responsável de IAS. Embora a presente pesquisa não tenha incluído um determinante específico referente aos aspectos éticos, cabe investigar futuramente a relação entre a preocupação quanto às questões éticas e a adoção de IA.

4.4.2 Determinantes organizacionais

Na análise de correspondência e estatística qui-quadrado, apenas um determinante da dimensão organizacional apresentou significância estatística: “Envolvimento”. Apesar disso, os gestores das instituições de saúde também devem considerar a totalidade dessa dimensão com atenção. O determinante envolvimento diz respeito ao engajamento do corpo clínico na seleção, desenvolvimento e implantação dos sistemas eletrônicos do estabelecimento. Estabelecimentos em que os médicos e enfermeiros não são envolvidos apresentam menor

chance de alto uso de IA. Esse determinante também se mostrou significativo no modelo de regressão logística multinomial, na opção “Discorda”, o que implica no **suporte da hipótese H10**. Isso revela que estabelecimentos com maior envolvimento do pessoal adotam mais IA. Nota-se que os gestores devem buscar engajar o corpo clínico em processos de implantação de novas tecnologias, especialmente a IA. Este resultado sugere que os médicos devem participar ativamente no processo de implementação e tomada de decisão, de forma integrada com os gestores, como apontam estudos anteriores (Terry et al. (2022); Tokgöz et al., 2024). Outra ideia para atingir esse objetivo é promover a expansão de conhecimento dos médicos e enfermeiros sobre IA.

Outro fator que se mostrou parcialmente significativo nos dois modelos (clusterizado ou não) foi referente ao porte de estabelecimento. Estabelecimentos com menor capacidade de internação de pacientes (0-50 leitos) apresentam menor chance de usar IA de forma moderada quando comparados a estabelecimentos com maior capacidade de internação (com mais de 50 leitos). Assim, conclui-se que a **hipótese H7 foi parcialmente suportada**. Isso está de acordo com a literatura analisada, que relacionava a diferença na adoção de IA com a diferença no tamanho do hospital. Essa relação foi justificada por autores anteriores da seguinte forma: hospitais maiores geralmente possuem recursos financeiros, humanos e experiência suficientes para alterar suas estratégias de negócios, adotando novas tecnologias (Dastjerdi et al., 2023).

Ainda na dimensão organizacional, outro determinado testado foi a natureza de propriedade. Os estabelecimentos de saúde privados usuários de IA possuem maior número de observações (71) quando comparados aos estabelecimentos públicos que usam IA (22). Na estatística qui-quadrado, esse determinante apresentou uma tendência a significância (Pearson $\chi^2(3) = 7.5604$ Pr = 0.0560), ou seja, foi quase significativa. Nesse sentido, foi verificada que poderia haver dependência entre as categorias “Alto uso” e “Privado”, bem como entre “Não uso” e “Público”, a partir do exame dos resíduos ajustados. No entanto, no modelo de regressão logística multinomial, o determinante não apresentou significância estatística a um intervalo de confiança de 95%. Assim, a **hipótese H6 não foi suportada**.

Apesar disso, achados de estudos anteriores apontam que a natureza de propriedade privada poderia ser um fator associado à adoção de IA. Conforme apontado na seção 2, nos Estados Unidos, hospitais de propriedade privada sem fins lucrativos apresentam maior probabilidade de adotar diferentes formas de IA em comparação com os públicos (Baten, 2024). Na Mongólia, hospitais privados possuem maior associação com a adoção de sistemas de informação em comparação com públicos, especialmente no que diz respeito a tecnologias

clínicas e estratégicas (Tsagaankhuu et al., 2018). Portanto, mais estudos são necessários para confirmar se esse determinante é realmente relevante para a adoção de IA na saúde.

As outras duas hipóteses da dimensão organizacional referentes a financiamento e treinamento **(H8 e H9) não foram suportadas**. Embora 45,16% dos estabelecimentos que usam IA concordem com a afirmação que “os recursos financeiros para investimento em sistemas eletrônicos são suficientes para as necessidades do estabelecimento”, esse determinante não se mostrou significativo em nenhuma das análises estatísticas. Embora 74,19% dos estabelecimentos que utilizam IA concordem com a afirmação que “os médicos e enfermeiros do estabelecimento estão treinados para o uso de sistemas eletrônicos”, esse o determinante não se mostrou significativo na regressão multilogística nem nas estatísticas qui-quadrado.

No entanto, muitos autores anteriores apontaram como determinantes de adoção de IA o financiamento (Deveci, 2023; Horani et al., 2023; Kumar et al., 2023; Marco-Ruiz et al., 2024; Weinert et al., 2022) e os custos envolvidos na adoção de IA (Weinert et al., 2022), bem como o treinamento dos usuários (Dastjerdi et al., 2023; Kumar et al., 2023; Tezpal et al., 2024; Tokgöz et al., 2024; Vijayakumar et al., 2023). Por isso, esses fatores merecem mais atenção em pesquisas futuras. Por exemplo, a reformulação das perguntas nos questionários aplicados pode contribuir para uma exploração e compreensão mais profundas. Além disso, uma situação que não pode ser descartada é a possibilidade de que não tenham sido alcançadas as pessoas mais indicadas no estabelecimento para responder essas questões e, portanto, elas não conseguiram avaliar de forma adequada.

4.4.3 Determinantes ambientais

Na análise de correspondência e estatística qui-quadrado, apenas um da dimensão ambiental apresentou significância estatística: “Políticas governamentais”. Portanto, a **hipótese H12 é suportada**. É interessante apontar que 67,74% dos estabelecimentos que usam IA concordam com a afirmação que políticas governamentais incentivam a implantação e o uso de sistemas eletrônicos.

O estudo de Deveci (2023) apontou o apoio e as políticas governamentais como o terceiro fator ou critério mais efetivo para influenciar a difusão da IA na gestão da cadeia de suprimentos de saúde turca. A pesquisa de Dastjerdi et al. (2023) sobre hospitais iranianos revelou que “Políticas Governamentais” é o determinante com maior peso na dimensão ambiental e o segundo maior na análise global.

À medida que a saúde digital continua a desempenhar papel cada vez mais central no sistema de saúde, torna-se imperativo que as políticas públicas e as regulamentações acompanhem esse progresso, colaborando de forma sinérgica para criar um ambiente seguro e confiável para todas as partes envolvidas, na competência de supervisionar as atividades das entidades do setor. (Gonçalo et al., 2025). Fica evidente que iniciativas públicas podem estimular a adoção de IAS, por exemplo ao promover o compartilhamento de conhecimentos sobre IA, assegurar a supervisão regulatória e facilitar a disponibilidade de recursos para financiamento.

Este estudo conclui que a localização geográfica pode influenciar mas não prevê totalmente a adoção da IA hospitalar. Nota-se que as regiões Nordeste, Sudeste e Norte possuem maior número de estabelecimentos de saúde que utilizam IA, portanto, a região (H11a) pode ser um fator associado a adoção de IA. No entanto, o determinante região não se mostrou equilibrado para as cinco opções de resposta. No primeiro modelo de regressão logística multinomial, apenas a região Sudeste foi estatisticamente significativa para a categoria “Médio uso” da variável dependente.

Quanto a localização em termos de capital ou interior (H11b), os achados não estão totalmente de acordo com a literatura, uma vez que no interior há maior ocorrência de estabelecimentos de saúde que usam IA (49 observações de 93). Estabelecimentos de saúde localizados na capital só possuem maior probabilidade de usar IA do que os estabelecimentos localizados no interior ao olhar para a categoria de “Baixo uso”.

Autores anteriores indicaram que a localização do estabelecimento de saúde poderia ter influência no uso de IA (Baten, 2024; Tsagaankhuu et al., 2018). O argumento dos autores é baseado na presunção de que estabelecimentos com proximidade do centro urbano ou metrópole – que são naturalmente mais desenvolvidos em termos de atividades econômicas – possuem vantagens sobre estabelecimentos localizados fora do perímetro urbano (Tsagaankhuu et al., 2018). No entanto, essa ideia não foi confirmada pelos resultados desta pesquisa. Assim, as **hipóteses H11a e H11b foram apenas parcialmente suportadas.**

A Tabela 20 resume os resultados das hipóteses com base nas informações apresentadas e discutidas.

Tabela 20

Resultados das hipóteses

Hipótese	Resultado
H1	Suportada
H2	Não suportada

H3	Não suportada
H4	Suportada
H5	Suportada
H6	Não suportada
H7	Parcialmente suportada
H8	Não suportada
H9	Não suportada
H10	Suportada
H11A	Parcialmente suportada
H11B	Parcialmente suportada
H12	Suportada

Para fins de robustez, outros modelos estatísticos também foram testados, como regressão logística ordinal e regressão linear. Ambos apresentaram resultados semelhantes ao modelo de regressão logística multinomial, mas nenhum apresentou um valor de AIC menor do que o modelo de regressão logística multinomial.

Conforme apresentado no terceiro capítulo, a variável criada para medir o uso de IA nos estabelecimentos foi baseada no Módulo H. O Apêndice B permite perceber que, nesse quesito, a pesquisa TIC Saúde 2024 investigou o tipo de tecnologia e o tipo de aplicação. Sobre o tipo de aplicação é possível categorizar os achados em duas finalidades: assistencial e administrativa. A Tabela 21 apresenta os resultados dos 93 estabelecimentos que utilizam IA, segregados por tipo de aplicação.

Tabela 21

Tipo de aplicação de IA dos estabelecimentos

Tipo de aplicação	freq abs	freq %
Assistencial	40	43.01
Auxiliar na dosagem de medicamentos de acordo com o paciente atendido	21	22.58
Auxiliar nos diagnósticos	26	27.96
Melhorar eficiência nos tratamentos	34	36.56
Administrativa	58	62.37
Organização de processos clínicos e administrativos	35	37.63
Logística	28	30.11
Segurança digital	42	45.16
Gestão de recursos humanos ou recrutamento	20	21.51

A pesquisa TIC Saúde 2024 também investigou os motivos para não utilização de IAS. Quando o gestor respondia que não utilizava nenhuma técnica ou aplicação de IAS, um novo bloco de itens do questionário era liberado. Visto que apenas os respondentes que afirmaram não utilizar IAS responderam esse bloco, as respostas e opções dele não foram incluídas no modelo estatístico. No entanto, uma rápida análise desses resultados pode ser conveniente à compreensão do fenômeno.

Quanto ao motivo de não utilizarem, os 85,71% (558/651) estabelecimentos que indicaram não usar deram razões variadas para sua falta de uso. O motivo mais frequente para a não utilização de IA entre os estabelecimentos foi não ser uma prioridade, com 48,08% (313/558). O segundo motivo mais apontado foi falta de necessidade ou de interesse, com 43,63% (284/558). A terceira razão selecionada foi incompatibilidade com os equipamentos, software ou sistemas existentes no estabelecimento de saúde, com 40,25% (262/558). A quarta justificativa foi que os custos parecem ser muito altos, com 40,09% (261/558).

Outros motivos também foram apontados como: falta de pessoas capacitadas no estabelecimento para usar essas tecnologias, com 38,56% (251/558); dificuldades de disponibilidade ou qualidade dos dados necessários para o uso dessas tecnologias, com 34,72% (226/558); preocupações com relação à violação da proteção de dados e privacidade, com 36,56% (238/558); e questões éticas, com 22,12% (144/558).

Evidencia-se, que ainda existe margem significativa para a expansão do uso de tecnologias de inteligência artificial no setor de saúde brasileiro. A IA só proporcionará um avanço com o ecossistema adequado de regulamentações, entidades públicas, suporte profissional, educação dos cidadãos e infraestruturas de acesso a dados (Marco-Ruiz et al., 2024). Assim, sua adoção não é apenas uma simples atividade de aquisição de *hardware* e *software*, mas um processo de interação social e econômica entre as organizações e o ambiente.

5 CONSIDERAÇÕES FINAIS

Esta pesquisa teve por objetivo identificar os determinantes tecnológicos, organizacionais e ambientais da adoção de Inteligência Artificial por estabelecimentos de saúde brasileiros. Os determinantes que se mostraram significativos para explicar o fenômeno são: infraestrutura de TIC, novas tecnologias, oferta de serviços remotos (dimensão tecnológica), envolvimento do pessoal, porte de estabelecimento com 0-50 leitos (dimensão organizacional), região sudeste e políticas governamentais (dimensão ambiental). Os determinantes acesso e manutenção dos dados, segurança dos dados (dimensão tecnológica), natureza de propriedade, financiamento, treinamento (dimensão organizacional) e localização (dimensão ambiental) não mostraram significância estatística.

Este estudo ofereceu uma contribuição inicial para a discussão acerca dos determinantes da adoção de IAS no Brasil ao evidenciar que, o uso de tecnologias de inteligência artificial por estabelecimentos de saúde brasileiros é pequeno, conforme indicam os dados da pesquisa TIC Saúde 2024. Enquanto outros estudos sobre fatores determinantes da adoção de IAS

investigaram os usuários (por exemplo, médicos, enfermeiros e demais profissionais de saúde) ou pacientes, esta pesquisa se concentrou nos tomadores de decisão – os gestores, um grupo de partes interessadas importante, mas estudado com menor frequência.

Além disso, , contribui para o desenvolvimento da literatura sobre a aplicação da IA na saúde (IAS) ao utilizar um modelo teórico bem conhecido, o *Framework* TOE, para entender o processo de adoção, bem como testar o efeito dos fatores envolvidos e fornecer evidências reais sobre a utilização dessas tecnologias no setor de saúde brasileiro.

Assim, é possível aprimorar a compreensão de como a IA, uma das mais populares tecnologias emergentes, está sendo utilizada no país e instigar futuras discussões sobre o potencial dela em contribuir efetivamente para a eficiência no setor hospitalar nacional. Nossos resultados também podem instigar a discussão holística sobre a prontidão e implementação da IAS no país, tendo em vista as características e aspectos favoráveis que o país apresenta em comparação com outros cenários.

Como contribuição prática, este estudo forneceu informações para auxiliar os gestores de hospitais, do setor público e privado, quanto à tomada de decisão que envolva uso de IA. A exploração de determinantes organizacionais possibilita aos gestores enxergar pontos fortes e pontos de melhoria dentro dos estabelecimentos de saúde, a fim de projetar estratégias de implementação que alavanquem a adoção de IA. Conforme os achados da pesquisa, um dos fatores determinantes mais significativos na dimensão organizacional para adoção de IA foi o envolvimento de médicos e enfermeiros no desenvolvimento e implementação de sistemas eletrônicos. Isso revela que os gestores devem priorizar o engajamento do corpo clínico. Uma maneira de alcançar essa meta é incluir os profissionais de saúde no processo de tomada de decisão, uma vez que eles serão os usuários finais da tecnologia (a ser) adotada.

Este estudo também ajuda fornecedores e desenvolvedores de tecnologias baseadas em IA a compreender o atual estágio de adoção de tais tecnologias pelo setor da saúde brasileiro e a refletir em iniciativas de aprimoramento. Além disso, auxilia órgãos governamentais no que diz respeito à formulação de políticas eficazes para promover a adoção bem-sucedida de tecnologias baseadas em IA, visto que o determinante mais significativo na dimensão ambiental foi justamente “Políticas governamentais”. Iniciativas públicas que promovam o compartilhamento de conhecimentos sobre IA, assegurem a supervisão regulatória e facilitem a disponibilidade de recursos para financiamento podem estimular a adoção de IAS.

Aumentar a capacidade dos estabelecimentos de saúde de aproveitar plenamente os benefícios que a IA oferece pode contribuir para a eficiência hospitalar, especialmente ao economizar tempo e esforço dos profissionais de saúde. Ao considerar o impacto social

significativo que a alta performance de hospitais tem, a possibilidade de adotar melhorias tecnológicas que afetem positivamente seu desempenho e promovam a eficiência é benéfica para os usuários dos serviços de saúde e para a sociedade como um todo.

Apesar das contribuições enxergadas, este estudo possui limitações. Primeiro, os resultados são aplicáveis e interpretáveis apenas ao conjunto de estabelecimentos de saúde que possuem departamento de TI, pois esses foram os únicos que responderam às questões sobre uso de IA, conforme apontado na seção 3.2. É provável que estabelecimentos sem área ou departamento de TI também usem IA, mas não foram considerados na amostra, como foi apontado por outros autores que utilizaram as pesquisas TIC como fonte de dados (Ribeiro & Segatto, 2025; Rosa & Kubota, 2024, 2025).

Segundo, há outros determinantes contextuais, não incluídas nesta análise ou não medidas pela pesquisa TIC Saúde 2024 que podem explicar a adoção de IAS, tais como: falta de interesse do gestor, preocupação com questões legais e éticas, cultura organizacional, prontidão para mudança, confiança na tecnologia, entre outros (Rodrigues & Abbas, 2025). Tendo em vista a importância desses determinantes, é recomendado que estudos futuros considerem sua incorporação para enriquecer a compreensão dos fatores que influenciam esse fenômeno e a implementação dessas tecnologias.

Próximas pesquisas devem seguir acompanhando a expansão das tecnologias baseadas em IA e os fatores que influenciam sua adoção, de modo a identificar oportunidades de aprimoramento ao longo do tempo. Tendo em vista que alguns dos determinantes testados neste estudo divergiram dos achados da literatura, convém examinar especialmente os seguintes determinantes: financiamento e o treinamento na adoção de IA. Estudos qualitativos com gestores e tomadores de decisão de TI hospitalar devem ser conduzidos para explorar mais detalhadamente as razões para a lenta adoção da IA no contexto brasileiro.

REFERÊNCIAS

- Ali, O, Murray, P. A, Momin, M., Dwivedi, Y. K, Malik, T. The effects of artificial intelligence applications in educational settings: Challenges and strategies, *Technological Forecasting and Social Change*, Volume 199, 2024, 123076, ISSN 0040-1625, <https://doi.org/10.1016/j.techfore.2023.123076>.
- Alshehri, S., Alahmari, K. A., & Alasiry, A. (2024). A comprehensive evaluation of ai-assisted diagnostic tools in ent medicine: Insights and perspectives from healthcare professionals. *Journal of Personalized Medicine*, 14(4), 354. <https://doi.org/10.3390/jpm14040354>

- Alsobhi, M., Sachdev, H. S., Chevidikunnan, M. F., Basuodan, R., K U, D. K., & Khan, F. (2022). Facilitators and barriers of artificial intelligence applications in rehabilitation: A mixed-method approach. *International Journal of Environmental Research and Public Health*, 19(23), 15919. <https://doi.org/10.3390/ijerph192315919>
- Anahp. (2023). *Anahp divulga dados inéditos sobre uso de Inteligência Artificial em hospitais privados*. <https://www.anahp.com.br/noticias/anahp-divulga-dados-ineditos-sobre-uso-de-ia-em-hospitais-privados/>
- Anderson, B., & Sutherland, E. (2024). *Collective action for responsible AI in health*. OECD. <https://doi.org/10.1787/f2050177-en>
- Andrade, J. J. Z. de, & Campos, G. H. B. de. (2017). Educação na cultura digital: Uma proposta de aprendizagem híbrida e adaptativa. *Revista de Estudios e Investigación en Psicología y Educación*, 153–157. <https://doi.org/10.17979/reipe.2017.0.13.2646>
- Antes, A. L., Burrous, S., Sisk, B. A., Schuelke, M. J., Keune, J. D., & DuBois, J. M. (2021). Exploring perceptions of healthcare technologies enabled by artificial intelligence: An online, scenario-based survey. *BMC Medical Informatics and Decision Making*, 21(1), 221. <https://doi.org/10.1186/s12911-021-01586-8>
- Araujo, M. H. D., Reinhard, N., & Cunha, M. A. (2018). Serviços de governo eletrônico no Brasil: Uma análise a partir das medidas de acesso e competências de uso da internet. *Revista de Administração Pública*, 52(4), 676–694. <https://doi.org/10.1590/0034-7612171925>
- Armero, W., Gray, K. J., Fields, K. G., Cole, N. M., Bates, D. W., & Kovacheva, V. P. (2022). A survey of pregnant patients' perspectives on the implementation of artificial intelligence in clinical care. *Journal of the American Medical Informatics Association*, 30(1), 46–53. <https://doi.org/10.1093/jamia/ocac200>
- Asan, O., Bayrak, A. E., & Choudhury, A. (2020). Artificial intelligence and human trust in healthcare: Focus on clinicians. *Journal of Medical Internet Research*, 22(6), e15154. <https://doi.org/10.2196/15154>
- 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. <https://doi.org/10.1136/bmjopen-2022-068373>
- Baten, R. B. A. (2024). How are US hospitals adopting artificial intelligence? Early evidence from 2022. *Health Affairs Scholar*, 2(10), 4. <https://doi.org/10.1093/haschl/qxae123>
- Belli, L. (2023). Exploring the key AI sovereignty enablers (KASE) of Brazil, towards an AI Sovereignty Stack. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.4465501>
- Bender, J. D., Facchini, L. A., Lapão, L. M. V., Tomasi, E., & Thumé, E. (2024). O uso de tecnologias de informação e comunicação em saúde na atenção primária à saúde no Brasil, de 2014 a 2018. *Ciência & Saúde Coletiva*, 29(1), e19882022. <https://doi.org/10.1590/1413-81232024291.19882022>
- Brasil. (2021). *Estratégia Brasileira de Inteligência Artificial: EBIA* (Brasília). MCTI. https://www.gov.br/mcti/pt-br/acompanhe-o-mcti/transformacaodigital/arquivosinteligenciaartificial/ebia-diagramacao_4-979_2021.pdf

- Campelo, S. R. B., Barros, T. A. D., & Cruz, A. C. N. (2024). Desafios e perspectivas da inteligência artificial (ia) na atenção à saúde: Revisão integrativa da literatura. *REVISTA FOCO*, 17(12), e7089. <https://doi.org/10.54751/revistafoco.v17n12-030>
- Cancelier, M. V. de L. (2024). Modelos de inteligência artificial aptos a reproduzir expressões da personalidade humana e o direito à privacidade no cenário brasileiro: Uso ético da tecnologia e a promoção de uma sociedade mais lúcida e cidadã. *CIVILISTICA.COM*, 13(3). <https://civilistica.emnuvens.com.br/redc/article/view/1026>
- Cao, H., Zhang, Z., Evans, R. D., Dai, W., Bi, Q., Zhu, Z., Xu, J., & Shen, L. (2023). Barriers and enablers to the implementation of intelligent guidance systems for patients in chinese tertiary transfer hospitals: Usability evaluation. *IEEE Transactions on Engineering Management*, 70(8), 2634–2643. <https://doi.org/10.1109/TEM.2021.3066564>
- CCT. (2024). *IA para o bem de todos: Proposta de plano brasileiro de inteligência artificial 2024-2028*. Conselho Nacional de Ciência e Tecnologia. https://www.gov.br/mcti/pt-br/acompanhe-o-mcti/noticias/2024/07/plano-brasileiro-de-ia-tera-supercomputador-e-investimento-de-r-23-bilhoes-em-quatro-anos/ia_para_o_bem_de_todos.pdf/view
- Chang, I.-C., Hwang, H.-G., Hung, M.-C., Lin, M.-H., & Yen, D. C. (2007). Factors affecting the adoption of electronic signature: Executives' perspective of hospital information department. *Decision Support Systems*, 44(1), 350–359. <https://doi.org/10.1016/j.dss.2007.04.006>
- Cheng, M., Li, X., & Xu, J. (2022). Promoting healthcare workers' adoption intention of artificial-intelligence-assisted diagnosis and treatment: The chain mediation of social influence and human–computer trust. *International Journal of Environmental Research and Public Health*, 19(20), 13311. <https://doi.org/10.3390/ijerph192013311>
- Chiarini, T., & Silveira, S. A. D. (2022). Exame comparativo das estratégias nacionais de inteligência artificial de Argentina, Brasil, Chile, Colômbia e Coreia do Sul: Consistência do diagnóstico dos problemas-chave identificados. *Texto para Discussão*, 1–72. <https://doi.org/10.38116/td2805>
- Costa, R., & Kremer, B. (2022). Inteligência artificial e discriminação: Desafios e perspectivas para a proteção de grupos vulneráveis diante das tecnologias de reconhecimento facial. *Revista Brasileira De Direitos Fundamentais & Justiça*, 16(1). <https://doi.org/10.30899/dfj.v16i1.1316>
- Dastjerdi, M., Keramati, A., & Keramati, N. (2023). A novel framework for investigating organizational adoption of AI-integrated CRM systems in the healthcare sector; using a hybrid fuzzy decision-making approach. *Telematics and Informatics Reports*, 11, 100078. <https://doi.org/10.1016/j.teler.2023.100078>
- Deveci, M. (2023). Effective use of artificial intelligence in healthcare supply chain resilience using fuzzy decision-making model. *Soft Computing*. <https://doi.org/10.1007/s00500-023-08906-2>
- Doretto, J. (2016). Indicadores nacionais sobre TIC e cultura: Perspectiva qualitativa. *Novos Olhares*, 5(2), 86. <https://doi.org/10.11606/issn.2238-7714.no.2016.122548>
- Dourado, D. D. A., & Aith, F. M. A. (2022). A regulação da inteligência artificial na saúde no Brasil começa com a Lei Geral de Proteção de Dados Pessoais. *Revista de Saúde Pública*, 56, 80. <https://doi.org/10.11606/s1518-8787.2022056004461>

- Esmaeilzadeh, P. (2020). Use of AI-based tools for healthcare purposes: A survey study from consumers' perspectives. *BMC Medical Informatics and Decision Making*, 20(1), 170. <https://doi.org/10.1186/s12911-020-01191-1>
- Fávero, L. (com Fávero, P.). (2017). *Manual de análise de dados: Estatística e modelagem multivariada com excel, SPSS e stata*. Elsevier.
- Fontan, E. A. (2023). *Antecedentes ao uso da tecnologia da informação e comunicação nos serviços de saúde pública no brasil*. (Tese de Doutorado). Fundação Getúlio Vargas - Escola Brasileira de Administração Pública e de Empresas, Brasil.
- Gama, F., Tyskbo, D., Nygren, J., Barlow, J., Reed, J., & Svedberg, P. (2022). Implementation frameworks for artificial intelligence translation into health care practice: Scoping Review. *Journal of Medical Internet Research*, 24(1), e32215. <https://doi.org/10.2196/32215>
- Gardner, R. C., Cheng, J., Ferguson, A. R., Boylan, R., Boscardin, J., Zafonte, R. D., Manley, G. T., The Citicoline Brain Injury Treatment Trial Investigators, Zafonte, R. D., Bagiella, E., Ansel, B. M., Novack, T. A., Friedewald, W. T., Hesdorffer, D. C., Timmons, S. D., Jallo, J., Eisenberg, H., Hart, T., Ricker, J. H., ... Okonkwo, D. O. (2019). Divergent six month functional recovery trajectories and predictors after traumatic brain injury: Novel insights from the citicoline brain injury treatment trial study. *Journal of Neurotrauma*, 36(17), 2521–2532. <https://doi.org/10.1089/neu.2018.6167>
- Gaspar, W. B., & Mendonça, Y. C. (2021). *A Inteligência Artificial no Brasil ainda precisa de uma estratégia* (Relatório de análise do Centro de Tecnologia e Sociedade). FGV Direito Rio. <https://repositorio.fgv.br/server/api/core/bitstreams/79e80da9-14bb-4ac5-86d6-3309be8a21cf/content>
- Gomez, C., Smith, B.-L., Zayas, A., Unberath, M., & Canares, T. (2024). Explainable AI decision support improves accuracy during telehealth strep throat screening. *Communications Medicine*, 4(1), 149. <https://doi.org/10.1038/s43856-024-00568-x>
- Gonçalo, W., Souza, M. C. D., Santos, W. P. D., & Oliveira, F. H. C. D. (2025). Abordagens regulatórias na proteção de dados em saúde: Uma revisão integrativa de 2018 a 2023. *Physis: Revista de Saúde Coletiva*, 35(1), e350113. <https://doi.org/10.1590/s0103-73312025350113pt>
- Gujarati, D. N., & Porter, D. C. (2011). *Econometria Básica* (5. ed). McGraw-Hill Irwin.
- Haddad, A. E., & Lima, N. T. (2024). Saúde digital no Sistema Único de Saúde (SUS). *Interface - Comunicação, Saúde, Educação*, 28, e230597. <https://doi.org/10.1590/interface.230597>
- Hair, J. F., Black, W. C., Babin, B. J., Anderson, R. E., & Tatham, R. L. (2009). *Análise Multivariada De Dados* (6º ed.). Bookman.
- Hasan, H. E., Jaber, D., Khabour, O. F., & Alzoubi, K. H. (2024). Ethical considerations and concerns in the implementation of AI in pharmacy practice: A cross-sectional study. *BMC Medical Ethics*, 25(1), 55. <https://doi.org/10.1186/s12910-024-01062-8>
- Held, L. A., Wewetzer, L., & Steinhäuser, J. (2022). Determinants of the implementation of an artificial intelligence-supported device for the screening of diabetic retinopathy in primary care – a qualitative study. *Health Informatics Journal*, 28(3), 14604582221112816. <https://doi.org/10.1177/14604582221112816>

- Horani, O. M., Al-Adwan, A. S., Yaseen, H., Hmoud, H., Al-Rahmi, W. M., & Alkhalifah, A. (2023). The critical determinants impacting artificial intelligence adoption at the organizational level. *Information Development*, 026666692311668. <https://doi.org/10.1177/02666669231166889>
- Huang, W., Ong, W. C., Wong, M. K. F., Ng, E. Y. K., Koh, T., Chandramouli, C., Ng, C. T., Hummel, Y., Huang, F., Lam, C. S. P., & Tromp, J. (2024). Applying the UTAUT2 framework to patients' attitudes toward healthcare task shifting with artificial intelligence. *BMC Health Services Research*, 24(1), 455. <https://doi.org/10.1186/s12913-024-10861-z>
- Javaid, M., Haleem, A., Pratap Singh, R., Rab, S., Suman, R., & Kumar, L. (2025). Utilization of robotics for healthcare: A scoping review. *Journal of Industrial Integration and Management*, 10(01), 43–65. <https://doi.org/10.1142/S242486222500154>
- Kabir, H., Hasan, K., Akter, N., Marma, U. S. C., Alam, T., Tutul, A. H., Biswas, L., Ara, R., & Mitra, D. K. (2024). Factors associated with the intention of telehealth service utilization among Bangladeshi people: A crosssectional study. *F1000 Research*.
- Kerstan, S., Bienefeld, N., & Grote, G. (2024). Choosing human over AI doctors? How comparative trust associations and knowledge relate to risk and benefit perceptions of AI in healthcare. *Risk Analysis*, 44(4), 939–957. <https://doi.org/10.1111/risa.14216>
- Kfoury, M. N., Silva, R. D. G., & Nogaroli, R. (2020). Inteligência artificial e big data no diagnóstico e tratamento da covid-19 na américa latina: Novos desafios à proteção de dados pessoais. *Revista Brasileira de Direitos Fundamentais & Justiça*, 14(1), 149–178. <https://doi.org/10.30899/dfj.v0i0.974>
- Kleine, A.-K., Kokje, E., Lerner, E., & Gaube, S. (2023). Attitudes toward the adoption of 2 artificial intelligence-enabled mental health tools among prospective psychotherapists: Cross-sectional study. *JMIR Human Factors*, 10, e46859. <https://doi.org/10.2196/46859>
- Kujala, S., & Hörhammer, I. (2022). Health care professionals' experiences of web-based symptom checkers for triage: Cross-sectional survey study. *Journal of Medical Internet Research*, 24(5), e33505. <https://doi.org/10.2196/33505>
- Kumar, A., Mani, V., Jain, V., Gupta, H., & Venkatesh, V. G. (2023). Managing healthcare supply chain through artificial intelligence (AI): A study of critical success factors. *Computers & Industrial Engineering*, 175, 108815. <https://doi.org/10.1016/j.cie.2022.108815>
- Kumar Singh, L., Khanna, M., & Singh, R. (2023). A novel enhanced hybrid clinical decision support system for accurate breast cancer prediction. *Measurement*, 221, 113525. <https://doi.org/10.1016/j.measurement.2023.113525>
- Lemes, M. M., & Lemos, A. N. L. E. (2020). O uso da inteligência artificial na saúde pela administração pública brasileira. *Cadernos Ibero-Americanos de Direito Sanitário*, 9(3), 166–182. <https://doi.org/10.17566/ciads.v9i3.684>
- Li, L. T., Haley, L. C., Boyd, A. K., & Bernstam, E. V. (2023). Technical/Algorithm, Stakeholder, and Society (TASS) barriers to the application of artificial intelligence in medicine: A systematic review. *Journal of Biomedical Informatics*, 147, 104531. <https://doi.org/10.1016/j.jbi.2023.104531>
- Lian, J.-W., Yen, D. C., & Wang, Y.-T. (2014). An exploratory study to understand the critical factors affecting the decision to adopt cloud computing in Taiwan hospital.

- International Journal of Information Management*, 34(1), 28–36.
<https://doi.org/10.1016/j.ijinfomgt.2013.09.004>
- Lima, L. P. B., & Coelho, I. B. (2019). Acervos digitais e o uso das tecnologias de informação e comunicação em arquivos brasileiros. *PragMATIZES - Revista Latino-Americana de Estudos em Cultura*, 127–139. <https://doi.org/10.22409/pragmatizes.v0i16.27532>
- López-Martínez, F., Núñez-Valdez, E. R., García-Díaz, V., & Bursac, Z. (2020). A case study for a big data and machine learning platform to improve medical decision support in population health management. *Algorithms*, 13(4), 102. <https://doi.org/10.3390/a13040102>
- Machado, M. E., Paz, A. A., & Da Costa Linch, G. F. (2020). Uso das tecnologias de informação e comunicação em saúde pelos enfermeiros brasileiros. *Enfermagem em Foco*, 10(5). <https://doi.org/10.21675/2357-707X.2019.v10.n5.2543>
- Marco-Ruiz, L., Hernández, M. Á. T., Ngo, P. D., Makhlysheva, A., Svenning, T. O., Dyb, K., Chomutare, T., Llatas, C. F., Muñoz-Gama, J., & Tayefi, M. (2024). A multinational study on artificial intelligence adoption: Clinical implementers' perspectives. *International Journal of Medical Informatics*, 184, 105377. <https://doi.org/10.1016/j.ijmedinf.2024.105377>
- Mazhar, T., Khan, S., Shahzad, T., Khan, M. A., Saeed, M. M., Awotunde, J. B., & Hamam, H. (2025). Generative AI, IoT, and blockchain in healthcare: Application, issues, and solutions. *Discover Internet of Things*, 5(1), 5. <https://doi.org/10.1007/s43926-025-00095-8>
- Mello Filho, R. de S., & Vieira, R. de S. (2024). Estratégia Brasileira De Inteligência Artificial (Ebia): Avanços na cidadania a partir das aplicações no poder público. *Seminário Internacional em Direitos Humanos e Sociedade*, 6.
- Migliora, R. P. (2016). Fatores associados a desigualdades regionais no desenvolvimento de habilidades de uso de computador e internet entre estudantes brasileiros de escolas públicas. *Educação e Cultura Contemporânea*, 13(31). <https://doi.org/10.5935/2238-1279.20160035>
- Ministério da Saúde. (2023). *Ministério da Saúde abre chamada pública para uso de inteligência artificial no SUS*. Ministério da Saúde. <https://www.gov.br/saude/pt-br/assuntos/noticias/2023/outubro/ministerio-da-saude-abre-chamada-publica-para-uso-de-inteligencia-artificial-no-sus>
- NIC.br, N. de I. e C. do P. B. (2024). *Inteligência Artificial na Saúde: Potencialidades, riscos e perspectivas para o Brasil* (C. G. da I. no B. CGI.br, Org.; A. Z. P. Machado, Trad.; 1º ed.). Comitê Gestor da Internet no Brasil.
- NIC.br, N. de I. e C. do P. B. (2025). *Pesquisa sobre o uso das tecnologias de informação e comunicação nos estabelecimentos de saúde brasileiros: TIC Saúde 2024* (1º ed.). Núcleo de Informação e Coordenação do Ponto BR.
- OBIA. (2024). *Observatório Brasileiro de Inteligência Artificial*. OBIA. <https://obia.nic.br/>
- OECD. (2024). *AI, data governance and privacy: Synergies and areas of international co-operation*. OECD. <https://doi.org/10.1787/2476b1a4-en>
- Olawade, D. B., Wada, O. J., David-Olawade, A. C., Kunonga, E., Abaire, O., & Ling, J. (2023). Using artificial intelligence to improve public health: A narrative review. *Frontiers in Public Health*, 11, 1196397. <https://doi.org/10.3389/fpubh.2023.1196397>

- Oliveira, C. G. B. de. (2022). Desafios da regulação do digital e da inteligência artificial no Brasil. *Revista USP*, 135, 137-162. <https://doi.org/10.11606/issn.2316-9036.i135p137-162>
- Oliveira, M. L. C. de. (2021). Letramentos em Terra Brasilis: Exclusões digitais e design crítico no ensino de língua portuguesa para além da pandemia / Literacies in Terra Brasilis: digital exclusions and critical design in portuguese language teaching beyond the pandemic. *Pensares em Revista*, 20. <https://doi.org/10.12957/pr.2021.56616>
- Padmanabhan, S., Tran, T. Q. B., & Dominiczak, A. F. (2021). Artificial intelligence in hypertension: Seeing through a glass darkly. *Circulation Research*, 128(7), 1100–1118. <https://doi.org/10.1161/CIRCRESAHA.121.318106>
- Pai, V., & Chandra, S. (2022). Exploring factors influencing organizational adoption of artificial intelligence (AI) in Corporate Social Responsibility (CSR) Initiatives. *Pacific Asia Journal of the Association for Information Systems*, 14, 82–115. <https://doi.org/10.17705/1pais.14504>
- Papadopoulos, I., Koulouglioti, C., Lazzarino, R., & Ali, S. (2020). Enablers and barriers to the implementation of socially assistive humanoid robots in health and social care: A systematic review. *BMJ Open*, 10(1), e033096. <https://doi.org/10.1136/bmjopen-2019-033096>
- Pham, P., Zhang, H., Gao, W., & Zhu, X. (2024). Determinants and performance outcomes of artificial intelligence adoption: Evidence from U.S. Hospitals. *Journal of Business Research*, 172, 114402. <https://doi.org/10.1016/j.jbusres.2023.114402>
- Portilho, L., Macaya, J. F. M., Ribeiro, M. M., & Lima, C. (2025). Transformação digital inclusiva: Panorama do uso de serviços digitais por mulheres no Brasil. *Revista Panamericana de Salud Pública*, 49, 1. <https://doi.org/10.26633/RPSP.2025.21>
- Prakash, A. V., & Das, S. (2024). (Why) Do We Trust AI?: A Case of AI-based Health Chatbots. *Australasian Journal of Information Systems*, 28. <https://doi.org/10.3127/ajis.v28.4235>
- Ribeiro, M. M., & Segatto, C. I. (2025). Inteligência artificial nas organizações públicas brasileiras: Heterogeneidades e capacidades em tecnologia da informação. *Revista de Administração Pública*, 59(1), e2024-0066. <https://doi.org/10.1590/0034-761220240066>
- Roppelt, J. S., Kanbach, D. K., & Kraus, S. (2024). Artificial intelligence in healthcare institutions: A systematic literature review on influencing factors. *Technology in Society*, 76, 102443. <https://doi.org/10.1016/j.techsoc.2023.102443>
- Rosa, M. B., & Kubota, L. C. (2024). Determinantes da adoção de inteligência artificial por empresas brasileiras. *Anais do VIII Encontro Nacional de Economia Industrial e da Inovação (ENEI)*. VIII Encontro Nacional de Economia Industrial e da Inovação (ENEI). <https://doi.org/10.29327/viii-enei.923462>
- Rosa, M. B., & Kubota, L. C. (2025). Artificial intelligence: Where does Brazil stand in global scientific production and what are the main technical determinants of adoption by Brazilian companies. *EconomiA*. <https://doi.org/10.1108/ECON-01-2025-0010>
- Sampieri, R. H., Collado, C. F., & Lucio, M. del P. B. (2013). *Metodologia de pesquisa* (5^o ed.). Penso.

- Schober, P., Boer, C., & Schwarte, L. A. (2018). Correlation coefficients: Appropriate use and interpretation. *Anesthesia & Analgesia*, 126(5), 1763–1768. <https://doi.org/10.1213/ANE.0000000000002864>
- Senne, F., Barbosa, A., Oyadomari, W., & Bittencourt, A. (2014). Desafios para as políticas de e-saúde no Brasil: Uma análise de disponibilidade e uso das TICs em estabelecimentos de saúde brasileiros. *COMPARATIVE LAW EJOURNAL*. <https://doi.org/10.2139/ssrn.2462535>
- Shen, Y.-T., Chen, L., Yue, W.-W., & Xu, H.-X. (2021). Digital Technology-Based Telemedicine for the COVID-19 Pandemic. *Frontiers in Medicine*, 8, 646506. <https://doi.org/10.3389/fmed.2021.646506>
- Silva, A. C. P. (2023). *Inteligência artificial em saúde, inovação ou ilusão? Estudo de múltiplos casos de implantação e uso de inteligência artificial em hospitais no Brasil*. (Dissertação de Mestrado). Fundação Getúlio Vargas - Escola Brasileira de Administração Pública e de Empresas, Brasil. <https://repositorio.fgv.br/items/d27dc19b-c7bc-4b96-85e5-da1c559fe97f>
- Siqueira, D. P., & Moreira, M. C. (2023). O acesso as tecnologias de informação e comunicação no Brasil: Os reflexos da exclusão e da desigualdade digital nos direitos da personalidade. *Revista Brasileira de Direito*, 19(1), 4836. <https://doi.org/10.18256/2238-0604.2023.v19i1.4836>
- Sisk, B. A., Antes, A. L., Burrous, S., & DuBois, J. M. (2020). Parental attitudes toward artificial intelligence-driven precision medicine technologies in pediatric healthcare. *Children*, 7(9), 145. <https://doi.org/10.3390/children7090145>
- Souza, C. A. D., Siqueira, É. S., & Reinhard, N. (2017). Digital divide of small and medium-sized enterprises: An analysis of influencing factors using the toe theory. *RAM. Revista de Administração Mackenzie*, 18(2), 15–48. <https://doi.org/10.1590/1678-69712017/administracao.v18n2p15-48>
- Strohm, L., Hehakaya, C., Ranschaert, E. R., Boon, W. P. C., & Moors, E. H. M. (2020). Implementation of artificial intelligence (AI) applications in radiology: Hindering and facilitating factors. *European Radiology*, 30(10), 5525–5532. <https://doi.org/10.1007/s00330-020-06946-y>
- Sun, T. Q. (2021). Adopting artificial intelligence in public healthcare: The effect of social power and learning algorithms. *International Journal of Environmental Research and Public Health*, 18(23), 12682. <https://doi.org/10.3390/ijerph182312682>
- Sun, Y. (2021). Cloud edge computing for socialization robot based on intelligent data envelopment. *Computers & Electrical Engineering*, 92, 107136. <https://doi.org/10.1016/j.compeleceng.2021.107136>
- Tarouco, L. M. R., Silva, P. F. da, & Machado, L. A. L. M. (2024). Uma análise sobre redução do uso de tecnologias educacionais nas escolas de educação básica no retorno às aulas presenciais pós pandemia de covid-19. *Revista da FUNDARTE*, 58(58), e1343. <https://doi.org/10.19179/rdf.v58i58.1343>
- Terranova, C., Cestonaro, C., Fava, L., & Cinquetti, A. (2024). AI and professional liability assessment in healthcare. A revolution in legal medicine? *Frontiers in Medicine*, 10, 1337335. <https://doi.org/10.3389/fmed.2023.1337335>

- Terry, A. L., Kueper, J. K., Beleno, R., Brown, J. B., Cejic, S., Dang, J., Leger, D., McKay, S., Meredith, L., Pinto, A. D., Ryan, B. L., Stewart, M., Zwarenstein, M., & Lizotte, D. J. (2022). Is primary health care ready for artificial intelligence? What do primary health care stakeholders say? *BMC Medical Informatics and Decision Making*, 22(1), 237. <https://doi.org/10.1186/s12911-022-01984-6>
- Tezpal, M., Ghosh, S., Lalwani, R., Yadav, J., & Yadav, A. K. (2024). Artificial intelligence in health care – A study on perceptions of and readiness for artificial intelligence in health-care professionals. *Journal of Marine Medical Society*, 26(3), 376–381. https://doi.org/10.4103/jmms.jmms_161_23
- Tokgöz, P., Krayter, S., Hafner, J., & Dockweiler, C. (2024). Decision support systems for antibiotic prescription in hospitals: A survey with hospital managers on factors for implementation. *BMC Medical Informatics and Decision Making*, 24(1), 96. <https://doi.org/10.1186/s12911-024-02490-7>
- Tornatzky, L. G., & Fleischer, M. (1990). *The Processes of Technological Innovation*. Lexington Books.
- Tortorella, G. L., Fogliatto, F. S., Espôsto, K. F., Vergara, A. M. C., Vassolo, R., Mendoza, D. T., & Narayanamurthy, G. (2020). Effects of contingencies on healthcare 4.0 technologies adoption and barriers in emerging economies. *Technological Forecasting and Social Change*, 156, 120048. <https://doi.org/10.1016/j.techfore.2020.120048>
- Tsagaankhuu, S., Zhang, X., & Ayush, E.-A. (2018). Characteristics of hospitals that adopt hospital information systems in mongolia and its impact on patient safety and quality of care. *Central Asian Journal of Medical Sciences*, 4(2), 116–125. <https://doi.org/10.24079/cajms.2018.00.003>
- Van Der Vegt, A. H., Campbell, V., Mitchell, I., Malycha, J., Simpson, J., Flenady, T., Flabouris, A., Lane, P. J., Mehta, N., Kalke, V. R., Decoyna, J. A., Es'haghi, N., Liu, C.-H., & Scott, I. A. (2024). Systematic review and longitudinal analysis of implementing Artificial Intelligence to predict clinical deterioration in adult hospitals: What is known and what remains uncertain. *Journal of the American Medical Informatics Association*, 31(2), 509–524. <https://doi.org/10.1093/jamia/ocad220>
- Van Der Vegt, A. H., Scott, I. A., Dermawan, K., Schnetler, R. J., Kalke, V. R., & Lane, P. J. (2023). Deployment of machine learning algorithms to predict sepsis: Systematic review and application of the SALIENT clinical AI implementation framework. *Journal of the American Medical Informatics Association*, 30(7), 1349–1361. <https://doi.org/10.1093/jamia/ocad075>
- Vijayakumar, S., Lee, V. V., Leong, Q. Y., Hong, S. J., Blasiak, A., & Ho, D. (2023). Physicians' perspectives on ai in clinical decision support systems: Interview study of the CURATE.AI personalized dose optimization platform. *JMIR Human Factors*, 10, e48476. <https://doi.org/10.2196/48476>
- Wang, Y.-M., & Chiou, C.-C. (2020). Factors influencing the willingness of universities' business management departments to implement online entrepreneurship program and its effectiveness. *Frontiers in Psychology*, 11, 975. <https://doi.org/10.3389/fpsyg.2020.00975>
- Weinert, L., Müller, J., Svensson, L., & Heinze, O. (2022). Perspective of information technology decision makers on factors influencing adoption and implementation of

artificial intelligence technologies in 40 german hospitals: Descriptive analysis. *JMIR Medical Informatics*, 10(6), e34678. <https://doi.org/10.2196/34678>

Wenderott, K., Krups, J., Luetkens, J. A., & Weigl, M. (2024). Radiologists' perspectives on the workflow integration of an artificial intelligence-based computer-aided detection system: A qualitative study. *Applied Ergonomics*, 117, 104243. <https://doi.org/10.1016/j.apergo.2024.104243>

WHO. (2021). *Ethics and governance of artificial intelligence for health*. <https://www.who.int/publications/i/item/9789240029200>

Wolff, J., Pauling, J., Keck, A., Baumbach, J. (2021). Success factors of artificial intelligence implementation in healthcare. *Digital Health*, 3. <https://doi.org/10.3389/fdgth.2021.594971>

Wubineh, B. Z., Deriba, F. G., & Woldeyohannis, M. M. (2024). Exploring the opportunities and challenges of implementing artificial intelligence in healthcare: A systematic literature review. *Urologic Oncology: Seminars and Original Investigations*, 42(3), 48–56. <https://doi.org/10.1016/j.urolonc.2023.11.019>

Yamaoka, T., & Watanabe, S. (2023). Artificial intelligence in coronary artery calcium measurement: Barriers and solutions for implementation into daily practice. *European Journal of Radiology*, 164, 110855. <https://doi.org/10.1016/j.ejrad.2023.110855>

Yang, J., Luo, B., Zhao, C., & Zhang, H. (2022). Artificial intelligence healthcare service resources adoption by medical institutions based on TOE framework. *DIGITAL HEALTH*, 8, 205520762211260. <https://doi.org/10.1177/20552076221126034>

Yang, Y., Ngai, E. W. T., & Wang, L. (2024). Resistance to artificial intelligence in health care: Literature review, conceptual framework, and research agenda. *Information & Management*, 61(4), 103961. <https://doi.org/10.1016/j.im.2024.103961>

APÊNDICE A

Estudos anteriores

Autor (Ano)	Lente teórica	Técnica de análise	Determinantes e principais resultados	Comentários
Strohm et al. (2020)	Estrutura NASSS	Estudo de caso, com análise documental e 24 entrevistas semiestruturadas com radiologistas e gestores em 7 hospitais holandeses	Identifica pressão para contenção de custos, altas expectativas do potencial valor agregado da IA, presença de estratégias de inovação em todo o hospital como facilitadores. As barreiras são desempenho técnico inconsistente de aplicações de IA, processos de implementação não estruturados, valor agregado incerto para a prática clínica de aplicações de IA e grande variação na aceitação e confiança dos adotantes	Aplicação específica de IA para o campo da radiologia.
Sun (2021)	Poder Social	Estudo multicaso de 3 hospitais na China. Entrevista semiestruturada, observações participativas e análise documental	Apresenta uma estrutura de poder baseada em conhecimento (habilidades, como expertise em IA, e incluem poder de especialista, poder informacional e poder de referência) e uma estrutura de poder não baseada em conhecimento (poderes relacionados a comportamentos organizacionais, como poder	Não considerou fatores institucionais e governamentais

			de recompensa, poder coercitivo e poder legítimo).	
Cheng et al. (2022)	Modelo UTAUT e teoria HCT	Questionário com 343 profissionais de saúde de hospitais da China, Modelagem SEM. Análise Fatorial Confirmatória	Aponta expectativa de desempenho e expectativa de esforço como principais determinantes da intenção de uso de IA no diagnóstico e tratamento, por parte dos profissionais de saúde.	Não analisa outros fatores relacionados ao cenário
Kumar et al. (2023)	Estrutura TOE e HOT-fit	Revisão de Literatura, estudo de caso, questionário 20 gestores da cadeia de suprimentos indiana, Método R-SWARA	Indica que os principais fatores para facilitar a implementação da IA são: a viabilidade tecnológica, a qualidade e integridade de dados sustentáveis, Suporte governamental e estrutura de políticas, Pressão competitiva, Interoperabilidade, Aceitação e fidelidade do cliente, Volatilidade da demanda para o setor, Intenção comportamental, Viabilidade de testes e solução de problemas tecnológicos e Aceitação e fidelidade do cliente.	Número limitado de especialistas fazem parte da amostra.
Horani et al. (2023)	Teoria DOI e Estrutura TOE	Questionário com 512 gerentes seniores de TI em organizações públicas e privadas na Jordânia. Método PLS-SEM	Destaca a vantagem relativa, suporte da alta gerência, custo-efetividade, pressão competitiva, suporte do fornecedor, compatibilidade, alinhamento estratégico de IA e disponibilidade de recursos como fatores que influenciam positivamente a intenção de adotar tecnologias baseadas em IA. Já a regulamentação governamental e a complexidade influenciam negativamente as intenções de adoção.	Resultados limitados ao contexto jordaniano, não generalizáveis a diferentes indústrias ou setores
Kleine et al. (2023)	Modelo UTAUT	Questionário com 206 psicólogos alemães. Equações estruturais e análise fatorial confirmatória	Descobriu que a utilidade percebida e a influência social têm efeito positivo na intenção de usar a ferramenta de <i>feedback</i> e a ferramenta de recomendação de tratamento. No entanto, a confiança e a facilidade de uso percebida não estavam relacionadas às intenções de uso	Abordagem focada em psicólogos e tecnologia, sem aspectos organizacionais ou ambientais
Deveci (2023)	Teoria DOI	Estudo de caso. Metodologia Logarítmica de Pesos Aditivos (LMAW) baseada em Aczel-Alsina.	Mostra que a intensidade da tecnologia, a experimentabilidade e o apoio e as políticas governamentais são os fatores de sucesso de IA mais importantes	Resultados limitados ao contexto de cadeia de suprimentos turco
Dast-jerdi et al. (2023)	Estrutura TOE e HOT-fit	Questionário com 15 executivos de hospitais iranianos. Método ANP, DEMATEL e algoritmo MMDE	Verifica que as variáveis mais críticas por dimensão são: Suporte da Alta Gerência (Humana), Preocupações com Segurança e Privacidade de Dados e Vantagens Relativas (Tecnologia), Tamanho do Hospital (Organização), Política Governamental e Pressão do Cliente (Ambiente) e Custos de Manutenção e Treinamento de Pessoal (Custo)	Amostra apenas com hospitais públicos e sem investigação das diferenças regionais
Vijaya-kumar et al. (2023)	Estrutura CFIR	Entrevistas semiestruturadas com 12 médicos. Análise temática.	Identifica 3 temas amplos e 9 subtemas com considerações que os médicos perceberam como significativas em vários estágios do desenvolvimento de novas tecnologias, incluindo teste, implementação clínica e adoção em massa	Foco específico na percepção de médicos de Cingapura para um sistema de suporte à decisão clínica
Pham et al. (2024)	Teoria OIPT	492 hospitais dos EUA. Regressão	Analisa a influência da participação de mercado e tempo médio de internação na adoção de IA e	Abordagem simplista da

		logística e regressão OLS	o impacto dessa adoção no desempenho financeiro e operacional hospitalar	adoção de IA (adota ou não)
Tok-göz et al. (2024)	Estrutura HOT-fit	Questionário com 118 gerentes de hospitais alemães. Estatística descritiva	Relata abertura em relação ao uso de sistemas de suporte à decisão baseados em inteligência artificial para prescrição de antibióticos em hospitais, e como estes parecem ser uma oportunidade promissora para melhorar a qualidade do atendimento e aumentar a segurança do tratamento	Foco específico em um tipo de tecnologia de IA, limitado ao contexto alemão

Nota: NASSS (*Non-adoption, Abandonment, Scale-up, Spread, and Sustainability*); TDF (*Theoretical Domains Framework*); COM-B (*Capabilities, Opportunities and Motivations influencing Behaviors*); UTAUT (*Unified Theory of Acceptance and Use of Technology*); HCT (*Human-Computer Trust Theory*); TAM (*Technology Acceptance Model*); TOE (*Technology-Organization-Environment Framework*); HOT-fit (*Human-Organization-Technology fit Framework*); R-SWARA (*Rough Step-wise Assessment Ratio Analysis*); DOI (Teoria da Difusão da Inovação); PLS-SEM (*Partial least square structural equation modelling*); DEMATEL (*fuzzy Decision-Making Trial and Evaluation Laboratory*); MMDE (*Maximum Mean de-Entropy*); ANP (*Analytic Network Process*); CFIR (*Consolidated Framework for Implementation Research*); OIPT (*Organizational information processing theory*). Elaborado com base no estudo de (Rodrigues & Abbas, 2025).

APÊNDICE B

Criação da variável dependente “int_artif” com base na pesquisa TIC Saúde 2024

Código	Descrição	Rótulo
H4_A	Nos últimos 12 meses, o estabelecimento de saúde utilizou Inteligência artificial para Mineração de texto e análise da linguagem escrita ou falada (processamento de linguagem natural)	
H4_B	Nos últimos 12 meses, este estabelecimento de saúde utilizou técnicas de Inteligência Artificial para Reconhecimento de fala, que converte a linguagem falada em formato legível para máquinas?	
H4_C	Nos últimos 12 meses, este estabelecimento de saúde utilizou técnicas de Inteligência Artificial para Reconhecimento e processamento de sinais e imagens, que identificam objetos ou pessoas?	
H4_D	Nos últimos 12 meses, este estabelecimento de saúde utilizou técnicas de Inteligência Artificial para Aprendizagem de máquina para predição e análise de dados?	
H4_E	Nos últimos 12 meses, este estabelecimento de saúde utilizou técnicas de Inteligência Artificial para Automatização de processos de fluxos de trabalho?	
H4_F	Nos últimos 12 meses, este estabelecimento de saúde utilizou técnicas de Inteligência Artificial para Aplicação ou uso de recursos como o ChatGPT e o Bard, entre outros?	
H5_A	Este estabelecimento usa técnicas de Inteligência Artificial para Auxiliar na dosagem de medicamentos de acordo com o paciente atendido?	
H5_B	Este estabelecimento usa técnicas de Inteligência Artificial para Auxiliar nos diagnósticos?	
H5_C	Este estabelecimento usa técnicas de Inteligência Artificial para Organização de processos clínicos e administrativos?	
H5_D	Este estabelecimento usa técnicas de Inteligência Artificial para Melhorar eficiência nos tratamentos?	
H5_E	Este estabelecimento usa técnicas de Inteligência Artificial para Logística?	
H5_F	Este estabelecimento usa técnicas de Inteligência Artificial para Segurança digital?	
H5_G	Este estabelecimento usa técnicas de Inteligência Artificial para Gestão de recursos humanos ou recrutamento?	

0 = "Não"
1 = "Sim"
97 = "Não sabe"
98 = "Não respondeu"
99 = "Não se aplica"

APÊNDICE C

Criação da variável independente “acesso” com base na pesquisa TIC Saúde 2024

Código	Descrição	Rótulo
C1_1	Existe no estabelecimento um sistema eletrônico para registro das informações dos pacientes?	
C4A_1	No estabelecimento, o prontuário em formato eletrônico do paciente pode ser consultado em computadores fixos distribuídos pelo estabelecimento?	
C4A_2	No estabelecimento, o prontuário em formato eletrônico do paciente pode ser consultado em uma rede interna que pode ser acessada em qualquer local do estabelecimento por um computador portátil, tablet ou celular?	
C4A_3	No estabelecimento, o prontuário em formato eletrônico do paciente pode ser consultado fora do estabelecimento, pela Internet?	
C2A_1 ^a	No estabelecimento, estão disponíveis eletronicamente dados cadastrais do paciente, por exemplo, nome, endereço, telefone e data de nascimento?	
C2A_2	No estabelecimento, estão disponíveis eletronicamente admissão, transferência e alta do paciente?	
C2A_3	No estabelecimento, estão disponíveis eletronicamente dados sobre alergias do paciente?	
C2A_4	No estabelecimento, estão disponíveis eletronicamente diagnóstico, problemas ou condições de saúde do paciente?	
C2A_5	No estabelecimento, estão disponíveis eletronicamente principais motivos que levaram o paciente ao atendimento ou consulta?	
C2A_6	No estabelecimento, estão disponíveis eletronicamente resultados de exames laboratoriais do paciente?	
C2A_7	No estabelecimento, estão disponíveis eletronicamente laudo de exames radiológicos do paciente?	
C2A_8	No estabelecimento, estão disponíveis eletronicamente imagens de exames radiológicos do paciente?	
C2A_9	No estabelecimento, estão disponíveis eletronicamente listas de medicamentos prescritos ao paciente?	0 = "Não"
C2A_10	No estabelecimento, estão disponíveis eletronicamente sinais vitais do paciente?	1 = "Sim"
C2A_11	No estabelecimento, estão disponíveis eletronicamente histórico ou anotações clínicas sobre o atendimento ao paciente?	97 = "Não sabe"
C2A_12	No estabelecimento, estão disponíveis eletronicamente anotações de enfermagem sobre o paciente?	98 = "Não respondeu"
C2A_13M	No estabelecimento, estão disponíveis eletronicamente vacinas administradas ao paciente?	99 = "Não se aplica"
C3_1	No estabelecimento, há algum sistema eletrônico que permite listar todos os pacientes por diagnóstico?	
C3_2	No estabelecimento, há algum sistema eletrônico que permite listar todos os pacientes pelos resultados dos exames laboratoriais?	
C3_3	No estabelecimento, há algum sistema eletrônico que permite listar todos os pacientes que fazem uso de determinada medicação?	
C3_2_1	No estabelecimento, há algum sistema eletrônico que permite fornecer resumos de alta dos pacientes?	
C3_2_2	No estabelecimento, há algum sistema eletrônico que permite listar todos os medicamentos que um paciente específico está fazendo uso, incluindo aqueles prescritos em outros estabelecimentos?	
C3_2_3	No estabelecimento, há algum sistema eletrônico que permite listar todos os resultados de exames laboratoriais de um paciente específico?	
C3_2_4	No estabelecimento, há algum sistema eletrônico que permite listar todos os resultados de exames radiológicos incluindo laudos e imagens de um paciente específico?	
C3_2_5	No estabelecimento, há algum sistema eletrônico que permite listar todas as vacinas que o paciente já recebeu?	
C3_3_1	No estabelecimento, há algum sistema eletrônico que permite à equipe agendar consultas, exames ou cirurgias?	
C3_3_2	No estabelecimento, há algum sistema eletrônico que permite à equipe pedir exames laboratoriais?	
C3_3_3	No estabelecimento, há algum sistema eletrônico que permite à equipe pedir exames de imagem?	

C3_3_4	No estabelecimento, há algum sistema eletrônico que permite à equipe pedir medicamentos?
C3_3_5	No estabelecimento, há algum sistema eletrônico que permite à equipe realizar prescrição médica?
C3_3_6	No estabelecimento, há algum sistema eletrônico que permite à equipe gerar pedidos de materiais e suprimentos?
C5_1	No estabelecimento, há algum sistema eletrônico que oferece diretrizes clínicas ou práticas recomendadas ou protocolos?
C5_2	No estabelecimento, há algum sistema eletrônico que oferece alertas e lembretes no sistema sobre interação medicamentosa?
C5_3	No estabelecimento, há algum sistema eletrônico que oferece alertas e lembretes no sistema sobre dosagem de medicamentos?
C5_4	No estabelecimento, há algum sistema eletrônico que oferece alertas e lembretes no sistema sobre alergia a medicamentos ou esparadrapos?
C5_5	No estabelecimento, há algum sistema eletrônico que oferece alertas e lembretes no sistema sobre alergia a alimentos?
C5_6	No estabelecimento, há algum sistema eletrônico que oferece alertas e lembretes no sistema sobre interferência de medicamentos em exames laboratoriais?
C5_7	No estabelecimento, há algum sistema eletrônico que oferece alertas e lembretes no sistema sobre contraindicação, como por exemplo contraindicações por idade, por gênero ou para gestantes?
C7_1	No estabelecimento, há algum sistema eletrônico que permite enviar ou receber informações clínicas para profissionais de saúde de outros estabelecimentos?
C7_2	No estabelecimento, há algum sistema eletrônico que permite enviar ou receber encaminhamentos de pacientes para outros estabelecimentos?
C7_3	No estabelecimento, há algum sistema eletrônico que permite enviar ou receber relatório sobre a assistência prestada ao paciente no momento em que teve alta ou foi encaminhado a outro estabelecimento?
C7_4	No estabelecimento, há algum sistema eletrônico que permite enviar ou receber lista de todos os medicamentos prescritos ao paciente para outros estabelecimentos?
C7_5	No estabelecimento, há algum sistema eletrônico que permite enviar ou receber resultados de exames laboratoriais do paciente para outros estabelecimentos?
C7_6	No estabelecimento, há algum sistema eletrônico que permite enviar ou receber resultados de exames de imagem do paciente para outros estabelecimentos?
C7_7	No estabelecimento, há algum sistema eletrônico que permite enviar ou receber plano de cuidados da enfermagem para outros estabelecimentos?
C8	O sistema eletrônico de registro das informações dos pacientes deste estabelecimento recebe ou envia informações diretamente para outros sistemas eletrônicos da rede de atenção à saúde básica, especializada ou hospitalar?

APÊNDICE D

Criação da variável independente “segurança” com base na pesquisa TIC Saúde 2024

Código	Descrição	Rótulo
C8A	O estabelecimento possui algum documento que define uma política de segurança da informação?	
C8B	E os profissionais do estabelecimento receberam treinamento em segurança da informação?	0 = "Não" 1 = "Sim"
C9A_A	Quais dessas ferramentas de segurança da informação o estabelecimento utiliza? Assinatura eletrônica	97 = "Não sabe"
C9A_B	Quais dessas ferramentas de segurança da informação o estabelecimento utiliza? Arquivos e e-mails criptografados	98 = "Não respondeu"
C9A_C	Quais dessas ferramentas de segurança da informação o estabelecimento utiliza? Proteção por senha de arquivos enviados ou recebidos	99 = "Não se aplica"
C9A_D	Quais dessas ferramentas de segurança da informação o estabelecimento utiliza? Proteção por senha do acesso ao sistema eletrônico	

C9A_E	Quais dessas ferramentas de segurança da informação o estabelecimento utiliza? Antivírus
C9A_F	Quais dessas ferramentas de segurança da informação o estabelecimento utiliza? Firewall
C9A_G	Quais dessas ferramentas de segurança da informação o estabelecimento utiliza? Criptografia da base de dados
C9A_H1	Quais dessas ferramentas de segurança da informação o estabelecimento utiliza? Certificado digital
C9A_I1	Quais dessas ferramentas de segurança da informação o estabelecimento utiliza? Biometria para acesso ao sistema eletrônico como por exemplo reconhecimento facial ou digital
C9A_J	Quais dessas ferramentas de segurança da informação o estabelecimento utiliza? Duplo-fator de autenticação
C10_A	Em relação a Lei Geral de Proteção de Dados (LGPD), o estabelecimento nomeou o Encarregado de Dados Pessoais ou DPO?
C10_B	Em relação a Lei Geral de Proteção de Dados (LGPD), o estabelecimento disponibilizou canais de atendimento pela Internet para os titulares dos dados enviarem mensagens sobre o uso de seus dados pessoais?
C10_C	Em relação a Lei Geral de Proteção de Dados (LGPD), o estabelecimento publicou a Política de Privacidade no website do estabelecimento ou no website da secretaria de saúde, com as possibilidades para tratamento de dados pessoais?
C10_E	Em relação a Lei Geral de Proteção de Dados (LGPD), o estabelecimento realizou campanha de conscientização interna sobre a Lei Geral de Proteção de Dados com mais de 50% dos funcionários?
C10_F	Em relação a Lei Geral de Proteção de Dados (LGPD), o estabelecimento implementou um plano de resposta a incidentes de segurança de dados?

APÊNDICE E

Criação da variável independente “remoto” com base na pesquisa TIC Saúde 2024

Código	Descrição	Rótulo
D2_1	No estabelecimento, estão disponíveis serviços de educação à distância em saúde?	0 = "Não" 1 = "Sim" 97 = "Não sabe" 98 = "Não respondeu" 99 = "Não se aplica"
D2_2	No estabelecimento, estão disponíveis serviços de atividades de pesquisa à distância?	
D2_5	No estabelecimento, estão disponíveis serviços de Telemonitoramento, ou seja, monitoramento remoto de pacientes à distância?	
D2_6	No estabelecimento, estão disponíveis serviços de teleconsultoria, ou seja, a troca de informações e opiniões exclusivamente entre médicos, para auxílio diagnóstico?	
D2_8	No estabelecimento, estão disponíveis serviços de telediagnóstico, isto é, emissão a distância de laudos de exames?	
D2_10	No estabelecimento, estão disponíveis serviços de Teleconsulta, ou seja, consulta feita pela Internet envolvendo a relação direta entre profissional de saúde e o paciente?	

APÊNDICE F

Criação da variável independente “novtecn” com base na pesquisa TIC Saúde 2024

Código	Descrição	Rótulo
B18_1	Nos últimos 12 meses, o estabelecimento de saúde utilizou serviços de: E-mail em nuvem	0 = "Não" 1 = "Sim" 97 = "Não sabe" 98 = "Não respondeu"
B18_2	Nos últimos 12 meses, o estabelecimento de saúde utilizou serviços de: <i>Software</i> de escritório em nuvem	
B18_3	Nos últimos 12 meses, o estabelecimento de saúde utilizou serviços de: Armazenamento de arquivos ou banco de dados em nuvem	

B18_4	Nos últimos 12 meses, o estabelecimento de saúde utilizou serviços de: Capacidade de processamento em nuvem	99 = "Não se aplica"
H1	Nos últimos 12 meses, o estabelecimento de saúde fez análises de <i>big data</i> ?	
H1_1_1	Nos últimos 12 meses, o estabelecimento fez análises de <i>big data</i> a partir de alguma das seguintes fontes de dados? Dados próprios do estabelecimento, provenientes de dispositivos inteligentes ou sensores	
H1_1_2	Nos últimos 12 meses, o estabelecimento fez análises de <i>big data</i> a partir de alguma das seguintes fontes de dados? Dados de geolocalização provenientes do uso de dispositivos portáteis, como telefone móvel, conexão wireless ou GPS.	
H1_1_3	Nos últimos 12 meses, o estabelecimento fez análises de <i>big data</i> a partir de alguma das seguintes fontes de dados? Dados gerados a partir de mídias sociais, como redes sociais, blogs, sites de compartilhamento de conteúdo de multimídia.	
H1_1_4	Nos últimos 12 meses, o estabelecimento fez análises de <i>big data</i> a partir de alguma das seguintes fontes de dados? Dados próprios do estabelecimento, provenientes de fichas cadastrais, formulários e prontuários.	
H1_1_5	Nos últimos 12 meses, o estabelecimento fez análises de <i>big data</i> a partir de alguma das seguintes fontes de dados? Outras fontes de big data	
H2_1	Nos últimos 12 meses, essas análises de <i>big data</i> foram realizadas por pessoas internas do estabelecimento?	
H2_2	Nos últimos 12 meses, essas análises de <i>big data</i> foram realizadas por fornecedores externos?	
H3_1	Nos últimos 12 meses, o estabelecimento de saúde utilizou <i>Blockchain</i> ?	
H3_3	Nos últimos 12 meses, o estabelecimento de saúde utilizou <i>Robótica</i> , como por exemplo, automação de processos para medicamentos, laboratório e cirurgias.	
H3_4	Nos últimos 12 meses, este estabelecimento de saúde utilizou Internet das coisas (IoT)?	

APÊNDICE G

Criação da variável independente “infraestrutura” com base na pesquisa TIC Saúde 2024

Código	Descrição	Rótulo
B1_A_1	Nos últimos 12 meses, o seu estabelecimento de saúde usou computador de mesa?	0 = "Não" 1 = "Sim" 97 = "Não sabe" 98 = "Não respondeu" 99 = "Não se aplica"
B1_A_2	Nos últimos 12 meses, o seu estabelecimento de saúde usou Notebook?	
B1_A_3	Nos últimos 12 meses, o seu estabelecimento de saúde usou Tablet?	
B1_B	Nos últimos 12 meses, o estabelecimento de saúde onde você trabalha forneceu às pessoas ocupadas dispositivos móveis, como notebooks, tablets ou telefones celulares para fins de trabalho?	
B2	O estabelecimento usou a Internet nos últimos 12 meses?	
B6	Este estabelecimento possui um website ou página na Internet?	
B6_1A	Este estabelecimento possui perfil ou conta próprios em alguma rede social online, como Facebook, Instagram, X, LinkedIn ou outras?	

APÊNDICE H

Seleção de demais variáveis com base na pesquisa TIC Saúde 2024

Variável	Código	Descrição	Rótulo
região	COD_REGI AO	Região: Corresponde à divisão regional do Brasil, segundo critérios do IBGE, nas macrorregiões	1 = "Norte"
			2 = "Nordeste"
			3 = "Sudeste"
			4 = "Sul"
			5 = "Centro-Oeste"
cap_inter	CAP_INT	Localização do estabelecimento	1 = "Capital"

			2 = "Interior"
esf_adm	COD_ESFADM_BASE	Esfera administrativa, isto é, natureza de propriedade	1 = "Público" 2 = "Privado"
porte	TIPO_CETIC_TAB	Tipo de estabelecimento: características quanto a quantidade de leitos de internação ou, quando não há internação, tipo de serviço realizado (ambulatorial, urgência, Serviço de Apoio à Diagnose e Terapia)	0 = "Sem internação" 1 = "Com Internação (0-50 leitos)" 2 = "Com Internação (+50 leitos)" 3 = "SADT"
trein	G3A_REC2	O quanto o respondente concorda ou discorda que os médicos e enfermeiros do estabelecimento estão treinados para o uso de sistemas eletrônicos	
financ	G3A_REC8	O quanto o respondente concorda ou discorda que os recursos financeiros para investimento em sistemas eletrônicos são suficientes para as necessidades do estabelecimento	1 = "Concorda" 2 = "Não concorda nem discorda" 3 = "Discorda" 4 = "Não se aplica neste estabelecimento"
polit_gov	G3A_REC9	O quanto o respondente concorda ou discorda que as políticas governamentais incentivam a implantação e o uso de sistemas eletrônicos no seu estabelecimento	97 = "Não sabe" 98 = "Não respondeu" 99 = "Não possui sistema eletrônico"
envolv	G3A_REC10	O quanto o respondente concorda ou discorda que os médicos e enfermeiros são envolvidos na seleção, desenvolvimento e implantação dos sistemas eletrônicos do estabelecimento	

Nota: SADT (Serviço de Apoio à Diagnose e Terapia).

CONSIDERAÇÕES FINAIS DA DISSERTAÇÃO

Neste estudo foram investigados os fatores determinantes da adoção de inteligência artificial na saúde. O primeiro passo para a realização desta pesquisa foi reunir os principais determinantes, facilitadores ou barreiras, para a adoção de Inteligência Artificial (IA) na saúde, apontados na literatura, utilizando a Teoria da Mudança. Por meio de uma revisão sistemática, foi possível observar que os fatores determinantes podem ser enquadrados a partir de três partes interessadas principais: pacientes, profissionais de saúde e gestores.

Para pacientes, benefício percebido, confiança e familiaridade são facilitadores, enquanto barreiras envolvem perda de privacidade, risco percebido e preconceitos. Para profissionais de saúde, os facilitadores são utilidade percebida, familiarização, facilidade de uso, qualidade e precisão e as barreiras envolvem falta de conhecimento e treinamento, falta de confiança e preocupações com privacidade e segurança. Para gestores, as barreiras envolvem questões legais e regulatórias, complexidade e proteção de dados, enquanto os facilitadores envolvem capital humano, apoio organizacional e governamental e vantagem competitiva.

Com base nesses resultados, foi possível perceber que permanecem desafios para superar as barreiras identificadas e estratégias são necessárias para ampliar o conhecimento sobre o potencial da IA. No entanto, as barreiras encontradas inicialmente – nos estabelecimentos e nas pessoas que estão neles – podem ser mitigadas com o planejamento de atividades e intervenções, conforme aborda a Teoria da Mudança. Dessa forma, é possível transformar as condições desfavoráveis iniciais (barreiras) em condições facilitadoras para adoção de IA, no contexto tecnológico, organizacional e ambiental, com base nas sugestões dados pelos artigos.

O estudo contribuiu com a identificação de fatores facilitadores e barreiras da adoção da IA e na compreensão do papel dessa tecnologia como suporte aos profissionais de saúde. Além disso, deixou claro que há uma lacuna na pesquisa sobre a perspectiva organizacional, reforçando a importância de estudos futuros que explorem a tomada de decisão dos gestores na adoção dessas tecnologias.

Nesse sentido, o segundo passo visou preencher essa lacuna, ao identificar os determinantes tecnológicos, organizacionais e ambientais da adoção de Inteligência Artificial por estabelecimentos de saúde brasileiros. Para tanto, foram utilizados os microdados da pesquisa TIC Saúde 2024, a qual aplicou um questionário e colheu as respostas de gestores de estabelecimentos de saúde, públicos e privados, das cinco regiões do país. Por meio da

estatística descritiva, qui-quadrado, ANACOR e do modelo de regressão logística multinomial, foram analisadas 651 observações, a partir do framework TOE.

Foi verificado que, segundo a percepção dos gestores, os determinantes que se mostraram significativos para explicar o fenômeno são: infraestrutura de TIC, novas tecnologias, oferta de serviços remotos (dimensão tecnológica), envolvimento do pessoal, porte de estabelecimento com 0-50 leitos (dimensão organizacional), região sudeste e políticas governamentais (dimensão ambiental). Os determinantes acesso e manutenção dos dados, segurança dos dados (dimensão tecnológica), natureza de propriedade, financiamento, treinamento (dimensão organizacional) e localização (dimensão ambiental) não mostraram significância estatística em nenhuma das categorias de uso.

A investigação da perspectiva dos gestores é uma lacuna na literatura, pois foi a parte interessada estudada com menor frequência. Nesse sentido, a opção pela investigação dos gestores é uma contribuição desta pesquisa, pois são responsáveis pela tomada de decisão. Recomenda-se que gestores envolvam o corpo clínico no processo de implementação de novas tecnologias e que órgãos governamentais promovam políticas para a adoção bem-sucedida de tecnologias baseadas em IA, pois o suporte que ela dá aos profissionais é, sem dúvidas, uma oportunidade de aumentar a eficiência dos serviços de saúde.

O estudo traz contribuições teóricas, práticas e sociais. De forma teórica, contribui com a literatura por utilizar a Teoria da Mudança (raramente utilizada no contexto pesquisado) e o Framework TOE para identificar os determinantes de adoção da IA na saúde. De forma prática, os achados deste estudo contribuem em auxiliar os gestores de hospitais, do setor público e privado, quanto à tomada de decisão que envolva uso de IA. Além disso, auxilia órgãos governamentais no que diz respeito à formulação de políticas eficazes para promover a adoção bem-sucedida de tecnologias baseadas em IA. Socialmente, aumentar a capacidade dos estabelecimentos de saúde de aproveitar os benefícios que a IA oferece pode contribuir para a eficiência hospitalar e beneficiar os usuários dos serviços de saúde e a sociedade como um todo.

Para futuras pesquisas, sugere-se a realização de estudos longitudinais, analisando a evolução da adoção de IA. Estudos qualitativos, explorando as experiências e percepções das partes interessadas sobre o uso de IA, também são sugeridos para uma compreensão ainda mais profunda dos desafios e oportunidades. Estudos qualitativos com gestores e tomadores de decisão de TI hospitalar devem ser conduzidos para explorar mais detalhadamente as razões para a lenta adoção da IA no contexto brasileiro. Tendo em vista que algumas das variáveis testadas no segundo artigo divergiram dos achados da literatura, convém examinar especialmente os seguintes determinantes: financiamento e treinamento na adoção de IA.

REFERÊNCIAS

- Alshehri, S., Alahmari, K. A., & Alasiry, A. (2024). A Comprehensive Evaluation of AI-Assisted Diagnostic Tools in ENT Medicine: Insights and Perspectives from Healthcare Professionals. *Journal of Personalized Medicine*, 14(4), 354. <https://doi.org/10.3390/jpm14040354>
- Alsobhi, M., Sachdev, H. S., Chevidikunnan, M. F., Basuodan, R., K U, D. K., & Khan, F. (2022). Facilitators and Barriers of Artificial Intelligence Applications in Rehabilitation: A Mixed-Method Approach. *International Journal of Environmental Research and Public Health*, 19(23), 15919. <https://doi.org/10.3390/ijerph192315919>
- Anahp. (2023). *Anahp divulga dados inéditos sobre uso de Inteligência Artificial em hospitais privados*. <https://www.anahp.com.br/noticias/anahp-divulga-dados-ineditos-sobre-uso-de-ia-em-hospitais-privados/>
- Anderson, B., & Sutherland, E. (2024). *Collective action for responsible AI in health*. OECD. <https://doi.org/10.1787/f2050177-en>
- Antes, A. L., Burrous, S., Sisk, B. A., Schuelke, M. J., Keune, J. D., & DuBois, J. M. (2021). Exploring perceptions of healthcare technologies enabled by artificial intelligence: An online, scenario-based survey. *BMC Medical Informatics and Decision Making*, 21(1), 221. <https://doi.org/10.1186/s12911-021-01586-8>
- Armero, W., Gray, K. J., Fields, K. G., Cole, N. M., Bates, D. W., & Kovacheva, V. P. (2022). A survey of pregnant patients' perspectives on the implementation of artificial intelligence in clinical care. *Journal of the American Medical Informatics Association*, 30(1), 46–53. <https://doi.org/10.1093/jamia/ocac200>
- Asan, O., Bayrak, A. E., & Choudhury, A. (2020). Artificial Intelligence and Human Trust in Healthcare: Focus on Clinicians. *Journal of Medical Internet Research*, 22(6), e15154. <https://doi.org/10.2196/15154>
- 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. <https://doi.org/10.1136/bmjopen-2022-068373>
- Campelo, S. R. B., Barros, T. A. D., & Cruz, A. C. N. (2024). Desafios e Perspectivas da Inteligência Artificial (IA) na Atenção À Saúde: Revisão Integrativa da Literatura. *Revista Foco*, 17(12), e7089. <https://doi.org/10.54751/revistafoco.v17n12-030>
- Cao, H., Zhang, Z., Evans, R. D., Dai, W., Bi, Q., Zhu, Z., Xu, J., & Shen, L. (2023). Barriers and Enablers to the Implementation of Intelligent Guidance Systems for Patients in Chinese Tertiary Transfer Hospitals: Usability Evaluation. *IEEE Transactions on Engineering Management*, 70(8), 2634–2643. <https://doi.org/10.1109/TEM.2021.3066564>
- Cheng, M., Li, X., & Xu, J. (2022). Promoting Healthcare Workers' Adoption Intention of Artificial-Intelligence-Assisted Diagnosis and Treatment: The Chain Mediation of Social

- Influence and Human–Computer Trust. *International Journal of Environmental Research and Public Health*, 19(20), 13311. <https://doi.org/10.3390/ijerph192013311>
- Dourado, D. D. A., & Aith, F. M. A. (2022). A regulação da inteligência artificial na saúde no Brasil começa com a Lei Geral de Proteção de Dados Pessoais. *Revista de Saúde Pública*, 56, 80. <https://doi.org/10.11606/s1518-8787.2022056004461>
- Esmailzadeh, P. (2020). Use of AI-based tools for healthcare purposes: A survey study from consumers' perspectives. *BMC Medical Informatics and Decision Making*, 20(1), 170. <https://doi.org/10.1186/s12911-020-01191-1>
- Gonçalo, W., Souza, M. C. D., Santos, W. P. D., & Oliveira, F. H. C. D. (2025). Abordagens regulatórias na proteção de dados em saúde: Uma revisão integrativa de 2018 a 2023. *Physis: Revista de Saúde Coletiva*, 35(1), e350113. <https://doi.org/10.1590/s0103-73312025350113pt>
- Hasan, H. E., Jaber, D., Khabour, O. F., & Alzoubi, K. H. (2024). Ethical considerations and concerns in the implementation of AI in pharmacy practice: A cross-sectional study. *BMC Medical Ethics*, 25(1), 55. <https://doi.org/10.1186/s12910-024-01062-8>
- Huang, W., Ong, W. C., Wong, M. K. F., Ng, E. Y. K., Koh, T., Chandramouli, C., Ng, C. T., Hummel, Y., Huang, F., Lam, C. S. P., & Tromp, J. (2024). Applying the UTAUT2 framework to patients' attitudes toward healthcare task shifting with artificial intelligence. *BMC Health Services Research*, 24(1), 455. <https://doi.org/10.1186/s12913-024-10861-z>
- Kerstan, S., Bienefeld, N., & Grote, G. (2024). Choosing human over AI doctors? How comparative trust associations and knowledge relate to risk and benefit perceptions of AI in healthcare. *Risk Analysis*, 44(4), 939–957. <https://doi.org/10.1111/risa.14216>
- Khanijahani, A., Iezadi, S., Dudley, S., Goettler, M., Kroetsch, P., & Wise, J. (2022). Organizational, professional, and patient characteristics associated with artificial intelligence adoption in healthcare: A systematic review. *Health Policy and Technology*, 11(1), 100602. <https://doi.org/10.1016/j.hlpt.2022.100602>
- Kujala, S., & Hörhammer, I. (2022). Health Care Professionals' Experiences of Web-Based Symptom Checkers for Triage: Cross-sectional Survey Study. *Journal of Medical Internet Research*, 24(5), e33505. <https://doi.org/10.2196/33505>
- Ministério da Saúde. (2023). *Ministério da Saúde abre chamada pública para uso de inteligência artificial no SUS*. Ministério da Saúde. <https://www.gov.br/saude/pt-br/assuntos/noticias/2023/outubro/ministerio-da-saude-abre-chamada-publica-para-uso-de-inteligencia-artificial-no-sus>
- NIC.br, N. de I. e C. do P. B. (2024). *Inteligência Artificial na Saúde: Potencialidades, riscos e perspectivas para o Brasil* (C. G. da I. no B. CGI.br, Org.; A. Z. P. Machado, Trad.; 1º ed.). Comitê Gestor da Internet no Brasil.
- OECD. (2024). *AI, data governance and privacy: Synergies and areas of international co-operation*. OECD. <https://doi.org/10.1787/2476b1a4-en>

- Padmanabhan, S., Tran, T. Q. B., & Dominiczak, A. F. (2021). Artificial Intelligence in Hypertension: Seeing Through a Glass Darkly. *Circulation Research*, 128(7), 1100–1118. <https://doi.org/10.1161/CIRCRESAHA.121.318106>
- Papadopoulos, I., Koulouglioti, C., Lazzarino, R., & Ali, S. (2020). Enablers and barriers to the implementation of socially assistive humanoid robots in health and social care: A systematic review. *BMJ Open*, 10(1), e033096. <https://doi.org/10.1136/bmjopen-2019-033096>
- Pham, P., Zhang, H., Gao, W., & Zhu, X. (2024). Determinants and performance outcomes of artificial intelligence adoption: Evidence from U.S. Hospitals. *Journal of Business Research*, 172, 114402. <https://doi.org/10.1016/j.jbusres.2023.114402>
- Roppelt, J. S., Kanbach, D. K., & Kraus, S. (2024). Artificial intelligence in healthcare institutions: A systematic literature review on influencing factors. *Technology in Society*, 76, 102443. <https://doi.org/10.1016/j.techsoc.2023.102443>
- Sun, Y. (2021). Cloud edge computing for socialization robot based on intelligent data envelopment. *Computers & Electrical Engineering*, 92, 107136. <https://doi.org/10.1016/j.compeleceng.2021.107136>
- Terry, A. L., Kueper, J. K., Beleno, R., Brown, J. B., Cejic, S., Dang, J., Leger, D., McKay, S., Meredith, L., Pinto, A. D., Ryan, B. L., Stewart, M., Zwarenstein, M., & Lizotte, D. J. (2022). Is primary health care ready for artificial intelligence? What do primary health care stakeholders say? *BMC Medical Informatics and Decision Making*, 22(1), 237. <https://doi.org/10.1186/s12911-022-01984-6>
- Wang, Y.-M., & Chiou, C.-C. (2020). Factors Influencing the Willingness of Universities' Business Management Departments to Implement Online Entrepreneurship Program and Its Effectiveness. *Frontiers in Psychology*, 11, 975. <https://doi.org/10.3389/fpsyg.2020.00975>
- Wenderott, K., Krups, J., Luetkens, J. A., & Weigl, M. (2024). Radiologists' perspectives on the workflow integration of an artificial intelligence-based computer-aided detection system: A qualitative study. *Applied Ergonomics*, 117, 104243. <https://doi.org/10.1016/j.apergo.2024.104243>
- WHO. (2021). *Ethics and governance of artificial intelligence for health*. <https://www.who.int/publications/i/item/9789240029200>
- Wubineh, B. Z., Deriba, F. G., & Woldeyohannis, M. M. (2024). Exploring the opportunities and challenges of implementing artificial intelligence in healthcare: A systematic literature review. *Urologic Oncology: Seminars and Original Investigations*, 42(3), 48–56. <https://doi.org/10.1016/j.urolonc.2023.11.019>
- Yang, Y., Zhang, C., Zhao, Q., & Zhang, Y. (2024). A sustainability evaluation framework for the urban energy Internet using the Fermatean fuzzy Aczel-Alsina hybrid MCDM method. *Expert Systems with Applications*, 238, 122115. <https://doi.org/10.1016/j.eswa.2023.122115>