

**CENTRO UNIVERSITÁRIO ALVES FARIA - UNIALFA
PROGRAMA DE PÓS-GRADUAÇÃO EM ADMINISTRAÇÃO
MESTRADO PROFISSIONAL EM ADMINISTRAÇÃO**

ALTIERY KÜMPEL

**ACEITAÇÃO DE INTELIGÊNCIA ARTIFICIAL NA PRÁTICA MÉDICA: UM
ESTUDO EM UMA REDE PRIVADA DE HOSPITAIS NO BRASIL**

GOIÂNIA

2025

ALTIERY KÜMPEL

**ACEITAÇÃO DE INTELIGÊNCIA ARTIFICIAL NA PRÁTICA MÉDICA: UM
ESTUDO EM UMA REDE PRIVADA DE HOSPITAIS NO BRASIL**

Dissertação apresentada ao Mestrado Profissional em
Administração do Centro Universitário Alves Faria,
como requisito parcial para a obtenção do título de
Mestre em Administração.

Orientador: Prof. Dr. Pedro Henrique Rodrigues de
Sousa

GOIÂNIA

2025

Catálogo na fonte: Biblioteca UNIALFA

K96a

Kümpel, Altiery.

Aceitação de inteligência artificial na prática médica: um estudo em uma rede privada de hospitais no Brasil. / Altiery Kümpel. – 2025.
81 f.: il. 30cm.

Orientador: Prof. Dr. Pedro Henrique Rodrigues de Sousa.

Dissertação (Mestrado) – Programa de Pós-Graduação em Administração, Centro Universitário Alves Faria (UNIALFA) – Goiânia, 2025.

1. Inteligência artificial. 2. Modelo de Aceitação de Tecnologia (TAM). 3. Facilidade de Uso Percebida (PEOU). 4. Assistência à saúde. I. Sousa, Pedro Henrique Rodrigues de. II. UNIALFA. III. Título.

CDU: 004.8:614.253.2(81)

**ACEITAÇÃO DE INTELIGÊNCIA ARTIFICIAL NA PRÁTICA MÉDICA: UM
ESTUDO EM UMA REDE PRIVADA DE HOSPITAIS NO BRASIL**

**Dissertação apresentada ao Mestrado Profissional em
Administração do Centro Universitário Alves Faria,
como requisito parcial para a obtenção do título de
Mestre em Administração.**

**Orientador: Prof. Dr. Pedro Henrique Rodrigues de
Sousa**

Goiânia, 6 de março de 2025

Banca examinadora:

Prof. Dr. Pedro Henrique Rodrigues de Sousa - Orientador

Prof. Dr. Bento Alves da Costa Filho - Membro Interno

Prof. Dr. Luiz Fernando Câmara Viana - Membro Externo

RESUMO

A inteligência artificial (IA) tem se destacado como uma tecnologia disruptiva na área da saúde, com potencial para aprimorar a eficiência, a precisão diagnóstica e a qualidade dos serviços médicos. Contudo, a adoção de ferramentas baseadas em IA na prática clínica enfrenta desafios significativos, como barreiras tecnológicas, resistência por uma parte dos profissionais de saúde e insuficiência de treinamento especializado. Nesse contexto, compreender os fatores que influenciam a aceitação da IA pelos médicos torna-se essencial, especialmente em redes privadas de hospitais, onde a infraestrutura tecnológica e a dinâmica profissional apresentam características distintas. Este estudo teve como objetivo geral analisar a aceitação da IA na prática médica em uma rede privada de hospitais no Brasil, com base no Modelo de Aceitação de Tecnologia (TAM). Os objetivos específicos deste estudo foram: (1) caracterizar o perfil demográfico e profissional dos médicos participantes, (2) analisar a influência de variáveis demográficas sobre a Facilidade de Uso Percebida (PEOU) e Utilidade Percebida (PU) no Modelo de Aceitação de Tecnologia (TAM) e (3) investigar as relações entre PU, PEOU e os demais fatores do modelo TAM (atitude, intenção comportamental e uso efetivo), considerando o comportamento de aceitação da IA na prática médica. A pesquisa adotou uma abordagem quantitativa e utilizou como instrumento de coleta de dados um questionário estruturado aplicado a 256 médicos, baseado em escala Likert de cinco pontos, para mensurar as dimensões teóricas do TAM. A análise dos dados foi conduzida por meio de estatística descritiva e da Modelagem de Equações Estruturais de Mínimos Quadrados Parciais (PLS-SEM), permitindo avaliar as relações entre os construtos do modelo. Os resultados indicaram que a PU teve forte influência sobre a BI, sendo esta um preditora significativa do AU. A PEOU impactou PU e ATU, confirmando que a facilidade de uso contribui para a PU e para a formação de atitudes favoráveis à IA. As variáveis idade, formação acadêmica, tempo de atuação e especialidade médica não apresentaram efeito significativo sobre PU e PEOU, sugerindo que a aceitação da IA é mais influenciada por percepções subjetivas da tecnologia do que por características individuais. O gênero teve um efeito estatisticamente significativo sobre PU e PEOU, mas com relevância prática limitada. Com base nos achados deste estudo, observa-se que PU, PEOU e BI se destacaram como os principais fatores associados à aceitação da IA na prática médica, indicando evidências favoráveis à aplicabilidade do modelo TAM no contexto investigado da saúde. Os resultados indicam que a adoção da IA na prática médica pode ser ampliada por meio de capacitações contínuas, suporte técnico adequado e uma integração eficiente da tecnologia nos fluxos de trabalho clínico. O modelo ajustado apresentado neste estudo, fundamentado na modelagem de equações estruturais, manteve a coerência teórica do TAM, ao mesmo tempo em que aprimorou sua estrutura, eliminando relações sem significância estatística e propondo um modelo mais conciso e robusto. Dessa forma, esta pesquisa contribui para o avanço das investigações sobre aceitação de tecnologia na medicina, podendo servir de base para estudos futuros voltados à compreensão e otimização da adoção da IA no contexto clínico.

Palavras-chave: Inteligência artificial; aceitação de tecnologia; modelagem de equações estruturais; assistência à saúde; modelo de aceitação de tecnologia.

ABSTRACT

Artificial intelligence (AI) has emerged as a disruptive technology in the healthcare sector, with the potential to enhance efficiency, diagnostic accuracy, and the quality of medical services. However, the adoption of AI-based tools in clinical practice faces significant challenges, such as technological barriers, resistance from some healthcare professionals, and insufficient specialized training. In this context, understanding the factors influencing AI acceptance among physicians is essential, particularly in private networks of hospitals, where technological infrastructure and professional dynamics present distinct characteristics. This study aimed to analyze AI acceptance in medical practice within a private network of hospitals in Brazil, based on the Technology Acceptance Model (TAM). The specific objectives of this study were: (1) to characterize the demographic and professional profile of the participating physicians, (2) to analyze the influence of demographic variables on Perceived Ease of Use (PEOU) and Perceived Usefulness (PU) within the TAM framework, and (3) to investigate the relationships between PU, PEOU, and other TAM factors (attitude, behavioral intention, and actual use), considering AI acceptance behavior in medical practice. A quantitative approach was adopted, utilizing a structured questionnaire applied to 256 physicians. The instrument was based on a five-point Likert scale to measure the theoretical dimensions of TAM. Data analysis was conducted using descriptive statistics and Partial Least Squares Structural Equation Modeling (PLS-SEM), allowing for the evaluation of relationships among the model's constructs. The results indicated that PU had a strong influence on BI, which was a significant predictor of AU. PEOU impacted PU and ATU, confirming that ease of use contributes to PU and the formation of favorable attitudes toward AI. Age, academic background, professional experience, and medical specialty had no significant effect on PU and PEOU, suggesting that AI acceptance is more influenced by subjective perceptions of the technology than by individual characteristics. Gender had a statistically significant effect on PU and PEOU, but with limited practical relevance. Based on the findings of this study, PU, PEOU, and BI emerged as the main factors associated with the acceptance of AI in medical practice, providing supportive evidence for the applicability of the TAM model in the investigated healthcare context. The results indicate that AI adoption in medical practice can be enhanced through continuous training, adequate technical support, and the efficient integration of technology into clinical workflows. The adjusted model presented in this study, based on structural equation modeling, maintained the theoretical consistency of TAM while refining its structure by eliminating statistically insignificant relationships and proposing a more concise and robust model. Thus, this research contributes to the advancement of studies on technology acceptance in medicine and can serve as a foundation for future investigations aimed at understanding and optimizing AI adoption in clinical settings.

Keywords: Artificial intelligence; technology acceptance; structural equation modeling; healthcare; technology acceptance model.

LISTA DE FIGURAS

Figura 1. Modelo de Aceitação de Tecnologia (TAM).	29
Figura 2. Modelo estrutural da aceitação da IA na prática médica.	51
Figura 3. Modelo estrutural ajustado de aceitação da IA na prática médica.	58

LISTA DE TABELAS

Tabela 1. Características demográficas dos médicos participantes da pesquisa.	43
Tabela 2. Influência da Idade sobre as Dimensões do Modelo TAM.	45
Tabela 3. Influência do gênero sobre as dimensões do modelo TAM.	45
Tabela 4. Classificação das Especialidades Médicas por categoria.	46
Tabela 5. Influência do tempo de atuação profissional sobre as dimensões do modelo TAM.	46
Tabela 6. Análise da confiabilidade dos construtos.	48
Tabela 7. Análise da validade discriminante pelo critério de Fornell-Larcker.	49
Tabela 8. Análise da validade discriminante pela razão HTMT.	50
Tabela 9. Avaliação da multicolinearidade entre os construtos.	50
Tabela 10. Hipóteses de efeito direto testadas no Modelo Estrutural.	53
Tabela 11. Hipóteses de efeito indireto testadas no Modelo Estrutural.	54
Tabela 12. Hipóteses de efeito total testadas no Modelo Estrutural.	57
Tabela 13. Comparação da Capacidade Preditiva do Modelo Teórico e Ajustado (R^2 Ajustado).	59

LISTA DE QUADROS

Quadro 1. Matriz de amarração do objetivo geral.....	40
Quadro 2. Matriz de amarração dos objetivos específicos.	41

LISTA DE SIGLAS

ATU	Atitude em Relação ao Uso
AU	Uso Efetivo
AVE	Variância Extraída Média
BI	Intenção Comportamental de Uso
DL	Aprendizado Profundo
HTMT	<i>Heterotrait-Monotrait Ratio</i>
IA	Inteligência Artificial
LLM	<i>Large Language Model</i>
ML	Aprendizado de Máquina
MRI	Tomografia por Ressonância Magnética
OMS	Organização Mundial da Saúde
PEOU	Facilidade de Uso Percebida
PET	Tomografia por Emissão de Pósitrons
PLS-SEM	Modelagem de Equações Estruturais de Mínimos Quadrados Parciais (<i>Partial Least Squares Structural Equation Modeling</i>)
PU	Utilidade Percebida
SADCs	Sistemas de Apoio à Decisão Clínica
SEM	Modelagem de Equações Estruturais
TAM	Modelo de Aceitação de Tecnologia
TPB	Teoria do Comportamento Planejado
TRA	Teoria da Ação Racional
UTAUT	Teoria Unificada de Aceitação e Uso de Tecnologia
VIF	Fator de Inflação da Variância (<i>Variance Inflation Factor</i>)

SUMÁRIO

1 INTRODUÇÃO	12
2 FUNDAMENTAÇÃO TEÓRICA.....	17
2.1 INTELIGÊNCIA ARTIFICIAL	17
2.1.1 Definição	17
2.1.2 Perspectivas históricas	18
2.1.3 Regulamentação e aspectos éticos	19
2.1.4 Uso e aplicações.....	20
2.2 INTELIGÊNCIA ARTIFICIAL NA ÁREA DA SAÚDE	21
2.2.1 Perspectivas históricas	21
2.2.2 Regulamentação e aspectos éticos na área da saúde	22
2.2.3 Aceitabilidade	23
2.2.4 Aplicabilidade	24
2.3 MODELOS DE ACEITAÇÃO DE TECNOLOGIAS	28
2.3.1 Modelos de Aceitação de Novas Tecnologias	28
2.3.1.1 Modelo de Aceitação de Tecnologia (TAM).....	28
2.3.1.2 Expansão do Modelo TAM: TAM 2	30
2.3.1.3 Integração de Novos Fatores: TAM 3	30
2.3.1.4 Teoria Unificada de Aceitação e Uso de Tecnologia (UTAUT)	31
2.3.2 Estudos Relacionados à Inteligência Artificial e Modelos de Adoção de Inovação.....	33
3 METODOLOGIA.....	35
3.1 CARACTERIZAÇÃO DA PESQUISA	35
3.2 PÚBLICO-ALVO.....	37
3.3 PROCEDIMENTO DE COLETA DE DADOS.....	37
3.4 PROCEDIMENTO PARA A ANÁLISE DOS DADOS.....	39
4 RESULTADOS.....	42

4.1 CARACTERÍSTICAS DEMOGRÁFICAS DOS PARTICIPANTES	42
4.2 INFLUÊNCIA DAS VARIÁVEIS DEMOGRÁFICAS SOBRE AS DIMENSÕES UTILIDADE E FACILIDADE DE USO PERCEBIDAS NO MODELO TAM	43
4.2.1 Idade	44
4.2.2 Gênero	45
4.2.3 Especialidade médica	45
4.2.4 Tempo de atuação profissional.....	46
4.2.5 Formação acadêmica.....	47
4.3 AVALIAÇÃO DO MODELO DE MENSURAÇÃO	47
4.3.1 Confiabilidade dos construtos	47
4.3.2 Validade convergente	48
4.3.3 Validade discriminante	49
4.4 AVALIAÇÃO DO MODELO ESTRUTURAL	51
4.4.1 Efeitos diretos das relações estruturais	52
4.4.2 Efeitos indiretos das relações estruturais	54
4.4.3 Efeitos totais das relações estruturais.....	55
4.5 MODELO DE ACEITAÇÃO AJUSTADO DA IA NA PRÁTICA MÉDICA	57
4.5.1 Capacidade preditiva do modelo ajustado	58
5 DISCUSSÃO	60
6 CONCLUSÃO E CONSIDERAÇÕES FINAIS	65
7 REFERÊNCIAS	67
8 APÊNDICE - A	77

1 INTRODUÇÃO

O termo inteligência artificial (IA) refere-se a sistemas que simulam aspectos específicos da inteligência humana ou de um comportamento inteligente como aprendizagem, raciocínio e solução de problemas (Chen; Decary, 2020). Tais sistemas são capazes de executar atividades que tradicionalmente exigem inteligência humana, como raciocínio lógico, análise e decisão (Thayyib *et al.*, 2023).

A IA é capaz de aprender com experiências e novas informações, desempenhando tarefas de maneira semelhante a um ser humano. Essa tecnologia tem a habilidade de modelar padrões comportamentais, superar limites de aprendizado humano e resolver problemas, mostrando experiência e intuição. Sua capacidade de perceber, compreender, aprender e agir com base na interpretação de dados permite realizar funções perceptivas, cognitivas e de interação (Thayyib *et al.*, 2023). Além de todas essas habilidades, a IA também se destaca ao oferecer soluções inovadoras para desafios complexos, utilizando técnicas avançadas, como ML e aprendizado profundo (*deep learning*, DL), o que reforça seu potencial de superar capacidades humanas em diversas áreas (Geetha *et al.*, 2023).

A IA não é uma tecnologia única, mas um conjunto de processos e condutas inteligentes gerados por modelos e algoritmos computacionais que contribuem para o processamento de grandes volumes de dados (Chen; Decary, 2020; He *et al.*, 2019). A IA possui uma grande base de dados e o seu processamento é rápido, com potencial de produzir respostas instantâneas que são frequentemente mais precisas do que as obtidas por meio da análise humana (Shen *et al.*, 2022). Portanto, suas funções consistem em melhorar o desempenho de produtos existentes, desenvolver novos produtos e otimizar operações internas, tomar decisões mais rápidas, bem como relacionar informações de diferentes processos (Thayyib *et al.*, 2023).

Diversos setores têm incorporado a IA em seus processos, destacando-se as organizações de saúde, que enfrentam como principal desafio a garantia de sua efetiva adoção na prática clínica (Davenport, 2019). Nos últimos anos, o uso da IA no setor de saúde registrou um crescimento exponencial (Sunarti *et al.*, 2021). Essa tecnologia tem se mostrado uma ferramenta promissora para agilizar o atendimento médico, especialmente em um cenário de crescimento populacional e aumento da prevalência de doenças. O envelhecimento global da população adiciona desafios significativos aos sistemas de saúde, já pressionados por custos crescentes e pela escassez de profissionais qualificados (Roppelt, 2024).

Os avanços e as funcionalidades da IA crescem continuamente, consolidando sua presença como uma realidade em diversos setores, inclusive na saúde. A incorporação de

ferramentas de IA tem o potencial de transformar a prestação de serviços, promovendo não apenas maior eficiência, mas também uma significativa melhora na qualidade dos serviços oferecidos à sociedade (Hazarika, 2020). Estudos indicam que a IA pode desempenhar tarefas vitais no diagnóstico de doenças com desempenho equivalente ou até superior ao humano (Davenport, 2019). No campo da medicina, tecnologias de IA têm se destacado em atividades como diagnósticos clínicos precisos, suporte na tomada de decisões terapêuticas, previsão de riscos, predição de doenças, redução de erros médicos, prevenção de enfermidades e aumento da produtividade (He *et al.*, 2019; Reinhart *et al.*, 2024). Esse cenário ressalta a necessidade de aprimoramentos contínuos e investimentos no setor para maximizar os benefícios dessa tecnologia (Roppelt, 2024).

A IA possui o potencial de aprimorar a eficiência organizacional e mitigar a escassez de recursos humanos, alcançando resultados no tratamento de pacientes comparáveis aos das avaliações humanas em termos de qualidade. Sua aplicação pode, ainda, reduzir custos ao eliminar ineficiências, evitar procedimentos desnecessários e acelerar o diagnóstico (Roppelt, 2024; Davenport, 2019). Do ponto de vista quantitativo, a integração da IA no setor de saúde tem levado a melhorias significativas na eficiência operacional, incluindo um aumento estimado de produtividade entre 30% e 40%, particularmente em áreas como diagnósticos e alocação de recursos (Dongari *et al.*, 2023). Contudo, é fundamental que os procedimentos sugeridos pela IA sejam validados por um profissional de saúde. A combinação entre a IA e a inteligência humana, portanto, se apresenta como uma estratégia essencial para alcançar os principais objetivos no cuidado à saúde (Hazarika, 2020).

Embora o uso de ferramentas de IA ofereça inúmeras vantagens, sua aplicação na prática clínica suscita diversas preocupações. Entre as principais estão a confiabilidade dessas ferramentas, o risco de gerar erros médicos, violações de privacidade e avaliação inadequada dos riscos associados aos pacientes (Islam, 2024). Ainda, fatores externos, como infraestrutura tecnológica insuficiente e dados enviesados, podem interferir negativamente nas ações da IA no setor de saúde, representando potenciais perigos para os sistemas de saúde (Roppelt, 2024). Esses aspectos destacam a necessidade de uma abordagem cautelosa e fundamentada em evidências para garantir a segurança e eficácia dessas tecnologias.

Algumas áreas da medicina já utilizam ferramentas de IA em diagnósticos, como na radiologia, onde algoritmos têm superado radiologistas na identificação de tumores malignos, além de orientar pesquisas clínicas de alto custo (Davenport, 2019). No entanto, a aceitação da IA pelos médicos e outros profissionais de saúde é um aspecto a ser considerado para sua implementação na prática clínica. Para facilitar essa adoção, é essencial investir em cursos de

capacitação que demonstrem os benefícios profissionais e familiarizem os usuários com os sistemas de IA (Connolly *et al.*, 2023). Esses treinamentos também podem ajudar a superar barreiras relacionadas ao medo de perda de autonomia e aos desafios de integração tecnológica, promovendo maior aceitação e entendimento sobre a IA (Lambert *et al.*, 2023).

Adicionalmente, as percepções sobre a IA variam entre os profissionais de saúde, especialmente no que se refere à sua influência na frequência de erros e na eficácia de alertas clínicos (Lambert *et al.*, 2023). Com o avanço da tecnologia, espera-se que os profissionais concentrem-se em tarefas que demandam habilidades exclusivamente humanas, como empatia, persuasão e capacidade de integrar perspectivas amplas (Lambert *et al.*, 2023). Por outro lado, aqueles que optarem por não adotar a IA podem, gradativamente, ter sua atuação limitada a determinadas especialidades em razão das vantagens que essa tecnologia oferece na prática médica (Davenport, 2019).

A Organização Mundial da Saúde (OMS) publicou, em 2021, o documento intitulado “Estratégia Global de Saúde Digital 2020-2025”, que apresenta uma visão abrangente e um plano de ação para promover a saúde digital em nível global (OMS, 2021). Nesse documento, a OMS destaca o papel das tecnologias digitais, com ênfase na IA, como ferramentas cruciais para melhorar os resultados de saúde em escala global. Além de sublinhar a importância de adotar a IA de maneira ética, responsável, transparente e equitativa, o documento enfatiza a necessidade de diretrizes claras e regulamentações específicas para garantir seu uso seguro na saúde (OMS, 2021). Esse foco reflete as preocupações globais sobre os desafios éticos, legais e sociais apresentados pela integração da IA na saúde, como autonomia do paciente, proteção de dados e justiça no acesso aos benefícios da tecnologia (Cordeiro, 2021; Brall; Schroder-Back; Maeckelberghe, 2019).

O desenvolvimento de habilidades em IA para os profissionais da saúde também é um ponto-chave abordado (OMS, 2021). A OMS (2021) propõe treinamento específico para a interpretação de resultados gerados por IA e o uso seguro dessas ferramentas no cotidiano clínico. Essa abordagem está alinhada a recomendações que destacam a necessidade de educação contínua para garantir que profissionais de saúde compreendam e utilizem a IA de maneira eficaz (Pasricha, 2023; Laksono; Darmawan, 2021). Como parte de uma estratégia de alcance global, a OMS promove a cooperação internacional na pesquisa e no desenvolvimento de soluções em IA para a saúde (OMS, 2021). Essa abordagem é essencial para alinhar esforços entre países e maximizar o impacto positivo da IA na saúde pública, equilibrando suas promessas com os desafios éticos e operacionais que a acompanham (Ishengoma, 2022).

No documento intitulado “2024 *Global Health Care Sector Outlook*”, a Deloitte, uma das maiores empresas de auditoria e consultoria empresarial do mundo, apresentou dados relevantes sobre o impacto da IA nos serviços de saúde (Siegel, 2024). Os destaques incluem: (i) o potencial de economia do uso de IA nos próximos cinco anos no sistema de saúde americano, estimado em US\$ 300 bilhões, ou 10% dos gastos em saúde no país; (ii) investimentos de US\$ 31,5 bilhões em financiamento de capital para IA na saúde entre 2019 e 2022; (iii) ferramentas de IA com modelos de *Large Language Model* (LLM) demonstraram precisão de 79% na previsão de tempo de internação de pacientes, superando em 12% os métodos convencionais; (iv) algoritmos de DL reduziram em até 60% os tempos de varredura e análise de exames de tomografia por emissão de pósitrons (PET) e tomografia por ressonância magnética (MRI), aumentando a eficiência e melhorando a experiência do paciente (Väänänen *et al.*, 2021).

Em paralelo, o avanço da tecnologia impulsionou estudos sobre os antecedentes da aceitação da IA, levando ao desenvolvimento de indicadores para mensurar a disposição dos usuários em adotar essa tecnologia. Apesar dos progressos, ainda há uma falta de síntese na literatura sobre a aceitação da IA pelos usuários, que pode ser definida como a intenção comportamental ou disposição de utilizar, adquirir ou experimentar um bem ou serviço (Yun; Yang; Lim, 2016). As percepções positivas sobre a IA, como sua capacidade de melhorar a eficiência e reduzir custos, são frequentemente balanceadas por preocupações com privacidade, regulamentação e confiança. Esses aspectos, quando gerenciados adequadamente, podem aumentar a probabilidade de aceitação e integração da IA em ambientes clínicos (Elahi, 2020).

Este estudo busca preencher uma lacuna significativa na literatura científica ao investigar a aceitação da IA por parte dos médicos. Estudos recentes identificaram desafios importantes, como a ausência de treinamento prático e o conhecimento técnico limitado entre os médicos, fatores que restringem a compreensão e a adoção eficaz dessa tecnologia (Chen *et al.*, 2022). Investigações conduzidas em diferentes contextos revelam que a aceitação da IA está diretamente relacionada ao grau de familiaridade dos médicos com essa tecnologia (Kowalewska, 2025). Dessa forma, há um consenso crescente de que iniciativas de capacitação e educação continuada são essenciais para fomentar a aceitação e o uso responsável da IA na medicina (Rony *et al.*, 2024).

A IA apresenta uma discrepância entre as altas expectativas quanto ao seu impacto em áreas como diagnóstico e tomada de decisão e a hesitação relacionada aos seus efeitos na relação médico-paciente e na preservação de habilidades clínicas fundamentais (Tamori *et al.*, 2022; Maassen *et al.*, 2021). Essa realidade evidencia a necessidade de investigar fatores

específicos que influenciem a aceitação dos médicos na IA, além de desenvolver estratégias educacionais e de implementação que superem essas barreiras. Espera-se que esta pesquisa amplie a compreensão sobre as percepções médicas em relação à IA e contribua para uma adoção mais eficaz dessa tecnologia na prática clínica, alinhada às necessidades dos profissionais de saúde e das instituições.

A adoção da IA na prática médica é desafiadora, especialmente em relação à aceitação e ao uso efetivo pelos médicos. Por isso, a problemática central da pesquisa é: quais fatores influenciam a aceitação e o uso da IA na prática clínica realizada pelos médicos? Esse questionamento direciona a investigação para identificar variáveis que possam promover ou dificultar a integração da IA no contexto médico.

Diante do avanço da IA e de seu potencial transformador na área da saúde, esta pesquisa busca compreender a aceitação dessa tecnologia pelos profissionais médicos. O objetivo geral deste estudo é analisar a aceitação de ferramentas de IA na prática médica em uma rede privada de hospitais no Brasil.

Com o intuito de alcançar o objetivo central do estudo, os objetivos específicos são: (1) descrever as características dos médicos participantes quanto à idade, gênero, especialidade médica, tempo de experiência profissional e nível de formação acadêmica; (2) analisar a influência das variáveis demográficas sobre as dimensões, PEOU e PU, do Modelo de Aceitação de Tecnologia (TAM); (3) relacionar as variáveis utilidade percebida e facilidade de uso do TAM com as variáveis demográficas e variáveis relacionadas ao comportamento de aceitação (atitude em relação ao uso, intenção comportamental de uso e uso efetivo) dos médicos quanto à aceitação da IA na prática médica.

Esta dissertação está estruturada em quatro partes principais, organizadas para garantir uma compreensão clara e objetiva do estudo. A primeira parte, "Fundamentação Teórica", apresenta uma revisão da literatura, explorando temas relevantes que influenciam a aceitação da IA na prática médica. Em seguida, o capítulo "Metodologia" detalha os procedimentos adotados para a coleta e análise dos dados, incluindo a abordagem estatística utilizada. Os capítulos "Resultados" e "Discussão" apresentam, respectivamente, os achados da pesquisa e sua interpretação à luz da teoria, evidenciando os principais fatores que influenciam a adoção da IA pelos médicos. Por fim, o capítulo "Conclusão e Considerações Finais" sintetiza os resultados do estudo, destaca suas implicações teóricas e práticas e sugere direções para pesquisas futuras.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 INTELIGÊNCIA ARTIFICIAL

2.1.1 Definição

A IA é um campo de estudo voltado para o desenvolvimento de métodos e técnicas que capacitam os computadores a realizar tarefas que, no passado, eram exclusivas dos seres humanos (Zhang; Lu, 2021). Kaplan e Haenlein (2019) ampliam essa definição, descrevendo a IA como a capacidade de interpretar e aprender a partir de dados externos, utilizando essa aprendizagem para atingir objetivos específicos por meio de uma adaptação flexível.

A IA é definida como a capacidade das máquinas de exibir inteligência semelhante à humana, enquanto o ML refere-se à capacidade das máquinas de aprender e melhorar suas análises por meio de algoritmos computacionais (Helm *et al.*, 2020). Kaplan e Haenlein (2019) destacam que a IA não é meramente uma extensão da inteligência humana; trata-se de uma entidade distinta que processa informações de forma lógica e sequencial, com base em dados e algoritmos. Segundo Angelov (2021), a IA pode ser considerada uma "imitação da inteligência humana", uma vez que utiliza modelos matemáticos e dados para simular capacidades cognitivas.

A evolução da IA está profundamente conectada à sistematização de dados promovida pela Ciência da Computação, incluindo o desenvolvimento de redes neurais artificiais, ML e processamento de linguagem natural (Baarder; Brewka; Eiter, 2001). Esses avanços consolidaram a IA como uma tecnologia com potencial disruptivo significativo na era digital, especialmente em função das inovações em ML (Borges *et al.*, 2020).

A interação entre diferentes domínios do conhecimento permite que a IA integre dados de diversas áreas para gerar *insights* abrangentes (Diaconu *et al.*, 2022). Entre os tipos de IA relevantes para este estudo, destacam-se a IA humanizada e a IA inspirada em humanos. A IA humanizada incorpora inteligência cognitiva, emocional e social, representando um estágio avançado de desenvolvimento em que sistemas são capazes de autoconsciência e autorreflexão. (Kaplan; Haenlein, 2018). Ainda de acordo com Kaplan (2018) Já a IA inspirada em humanos combina elementos de inteligência cognitiva e emocional, compreendendo emoções humanas e considerando-as em suas decisões. Os sistemas de IA atuais utilizam uma abordagem de "baixo para cima", imitando a estrutura do cérebro humano por meio de redes neurais artificiais e processando grandes volumes de dados para derivar conhecimento de maneira autônoma,

conferindo à IA a capacidade de operar de maneira robusta em contextos diversos, ampliando sua aplicação em áreas como diagnóstico médico, análise preditiva e automação de processos (Song, 2023).

2.1.2 Perspectivas históricas

Os primórdios da IA remontam ao ano de 1942, quando o autor de ficção científica americano Isaac Asimov publicou a obra "Runaround", que inspirou gerações de cientistas em robótica, Ciências da Computação e IA (Raper, 2024). A expressão "inteligência artificial" foi oficialmente proposta em 1956 por Marvin Minsky e John McCarthy, durante a histórica Conferência de Dartmouth. Este evento colaborativo reuniu pesquisadores de diversas áreas para estabelecer uma nova disciplina voltada ao desenvolvimento de máquinas capazes de simular a inteligência humana (Haenlein; Kaplan, 2019).

Na década de 1950, a IA foi formalmente estabelecida como uma disciplina acadêmica. Entretanto, permaneceu como um campo de estudos relativamente desconhecido e de interesse limitado por mais de cinquenta anos (Haenlein; Kaplan, 2019). Durante esse período, o entusiasmo inicial foi gradualmente substituído por um período de estagnação conhecido como o “Inverno da IA”, caracterizado por falta de avanços significativos devido a restrições tecnológicas e à complexidade de simular a inteligência humana (Favaron, 2024).

A partir da década de 2000, a IA começou a passar por uma transição, movendo-se de conceitos teóricos para aplicações práticas em larga escala. Esse ressurgimento foi impulsionado por novos avanços tecnológicos e maior poder computacional, permitindo aplicações tangíveis como a análise de grandes volumes de dados em tempo real, veículos autônomos e sistemas de recomendação personalizados (Helm *et al.*, 2020). Desde sua criação, a IA experimentou ciclos de otimismo excessivo e períodos de declínio, mas nos últimos anos a evolução tecnológica acelerou seu desenvolvimento. Tecnologias como ML e DL têm demonstrado desempenhos excepcionais em áreas como processamento de imagens e linguagem natural (Tjoa; Guan, 2020). Nos dias atuais, a IA vive um novo momento que envolve expectativa, sendo movido por técnicas sofisticadas de ML e pelo uso extensivo de *big data*, consolidando-se como uma das tecnologias mais promissoras da era digital (Borges *et al.*, 2020).

2.1.3 Regulamentação e aspectos éticos

O uso da IA apresenta desafios éticos, legais e filosóficos que exigem uma abordagem interdisciplinar para estabelecer bases éticas sólidas que orientem o desenvolvimento e a aplicação dessas tecnologias (Haenlein; Kaplan, 2019). O aumento da autonomia dos sistemas de IA na tomada de decisões levanta questões fundamentais sobre responsabilidade, equidade e transparência. Estudos acadêmicos devem se concentrar em examinar os processos de tomada de decisão baseados em algoritmos, identificando possíveis vieses e garantindo que os sistemas respeitem princípios éticos humanos (Dwivedi *et al.*, 2021).

A IA levanta questões complexas relacionadas à privacidade e proteção de dados, especialmente devido à coleta em larga escala de informações essenciais para seu funcionamento (Kaplan; Haenlein, 2018). A automação das decisões aliada à falta de transparência nos algoritmos podem gerar impactos sociais negativos. Por esta razão, a regulamentação da IA se torna indispensável para garantir que os benefícios dessa tecnologia sejam maximizados enquanto seus riscos sejam mitigados (Dwivedi *et al.*, 2021).

O impacto da IA no mercado de trabalho representa outro desafio. Embora a automação possa eliminar empregos existentes ao substituir tarefas rotineiras, ela também cria novas oportunidades em áreas impulsionadas por essa tecnologia, promovendo a inovação (Favaron, 2024). No entanto, essa transição exige que os trabalhadores desenvolvam novas habilidades e competências digitais para se adaptarem a essa nova realidade (Kaplan; Haenlein, 2018). A urgência em adquirir novas competências é evidente diante do potencial da IA para automatizar atividades humanas, gerando inquietações quanto ao seu desemprego em larga escala (Davenport; Kalakota, 2019).

Diante dessas preocupações, especialistas defendem que a regulamentação governamental é essencial. Contudo, muitos governos ainda não desenvolveram estratégias efetivas para regular a IA de maneira adequada, reforçando a necessidade de monitoramento constante e a criação de legislações que previnam abusos (Dwivedi *et al.*, 2019; Kaplan; Haenlein, 2018). A implementação da IA também exige uma governança sólida e ética dentro das organizações. Reformular continuamente políticas e práticas institucionais é indispensável para garantir conformidade regulatória, transparência, proteção de dados e responsabilidade. Esse compromisso ético e regulatório não apenas minimiza riscos, mas também potencializa os benefícios da IA, promovendo criatividade, eficiência e otimização de processos (Borges *et al.*, 2020; Islam, 2024).

2.1.4 Uso e aplicações

Estudos recentes em IA, especialmente com o DL, têm demonstrado resultados promissores. Modelos baseados nessa abordagem têm exibido habilidades em áreas diversas, como processamento de imagens e linguagem natural (Tjoa; Guan, 2020). O DL tem transformado a maneira como representações complexas e conceituais são processadas, possibilitando a expansão significativa das aplicações de IA. Essas capacidades têm se mostrado essenciais para enfrentar desafios e estimular a criatividade em setores como saúde e finanças (Borges *et al.*, 2020).

O uso de IA está se tornando cada vez mais prevalente nas empresas devido ao seu potencial disruptivo de transformar operações e estratégias organizacionais (Borges *et al.*, 2020). Acredita-se que a IA terá um impacto mais significativo na força de trabalho do que a Revolução Industrial de 1820-1840 (Kaplan; Haenlein, 2018). Essa tecnologia já está revolucionando setores da sociedade ao tornar processos mais eficientes e ao introduzir inovações que antes eram inviáveis. Com o avanço contínuo da tecnologia, espera-se que surjam novos usos e aplicações da IA, incluindo sistemas inspirados em humanos, capazes de identificar emoções e melhorar interações em ambientes comerciais (Kaplan; Haenlein, 2018). Empresas que adotam a IA podem beneficiar-se de maior agilidade e capacidade de resposta às mudanças do mercado, características essenciais para manter a competitividade (Borges *et al.*, 2020).

A integração da IA nas operações empresariais traz benefícios significativos, como suporte à tomada de decisão, automação de processos, engajamento de clientes e funcionários, e o desenvolvimento de novos produtos e serviços (Borges *et al.*, 2020). A IA também automatiza tarefas repetitivas, permitindo que humanos concentrem seus esforços em atividades de maior valor estratégico (Duan *et al.*, 2019). No gerenciamento de cadeias de suprimentos, a IA otimiza a previsão de demanda e o controle de estoques, promovendo operações mais eficientes e econômicas. Em *marketing*, as empresas utilizam IA para segmentar públicos com mais precisão e personalizar campanhas, aumentando sua eficácia (Borges *et al.*, 2020).

A IA permite explorar grandes quantidades de dados não estruturados, como vídeos, imagens e documentos corporativos, oferecendo *insights* para resolver problemas altamente complexos (Duan *et al.*, 2019). O uso de robôs colaborativos com capacidades avançadas de IA está se expandindo, permitindo maior sofisticação no treinamento e execução de tarefas específicas (Davenport; Kalakota, 2019). Muitas empresas têm empregado a IA para automação logística e processos gerenciais, além de melhorar a assertividade nas tomadas de decisão. No

entanto, um aspecto crucial destacado por Gunning (2019) no conceito de *Explainable Artificial Intelligence* (XAI) é a necessidade de compreender, confiar e gerenciar a IA de maneira eficaz, garantindo que as inovações tecnológicas sejam analisadas e ajustadas às demandas emergentes.

2.2 INTELIGÊNCIA ARTIFICIAL NA ÁREA DA SAÚDE

2.2.1 Perspectivas históricas

Na medicina, a IA foi inicialmente aplicada na década de 1950. Os projetos pioneiros enfrentaram diversas limitações tecnológicas e metodológicas, o que dificultou sua aceitação por muitas sociedades médicas (Kaul; Enslin; Gross, 2020). No entanto, com o surgimento do DL no início dos anos 2000, muitos desses desafios foram superados, permitindo que sistemas de IA analisassem algoritmos complexos e aprendessem de forma autônoma, ampliando suas aplicações na medicina (Kaul; Enslin; Gross, 2020). Por outro lado, a década de 1960 marcou um avanço significativo com a digitalização de informações, estabelecendo os fundamentos para o desenvolvimento e a aplicação futura da IA no campo médico (Kaul; Enslin; Gross, 2020). Esse período pavimentou o caminho para sistemas mais avançados, como o MYCIN, desenvolvido na década de 1970 (Shortliffe, 1977). Esse sistema, um dos primeiros de sua categoria, foi projetado para diagnosticar e sugerir tratamentos para infecções bacterianas no sangue, destacando-se como um marco na aplicação da IA em diagnósticos médicos (Davenport; Kalakota, 2019).

Segundo Baarder *et al.* (2001), entre as décadas de 1980 e 1990, a aplicação da IA na medicina atingiu um momento importante com o surgimento dos sistemas de apoio à decisão clínica (SADCs). Esses sistemas, também conhecidos como sistemas especialistas, foram projetados para simular o raciocínio de médicos especialistas, auxiliando no diagnóstico e no tratamento de doenças (Baarder; Brewka; Eiter, 2001). Um exemplo notável destes SADCs foi o DXplain, desenvolvido pela Universidade de Massachusetts, que funcionava como um livro eletrônico de medicina. Ele ajudava no diagnóstico diferencial, sugerindo possíveis causas para os sintomas apresentados por pacientes (Baarder; Brewka; Eiter, 2001). Esses avanços resultaram em uma ampla disseminação das tecnologias de IA, que passaram a ser implementadas de forma generalizada nos ambientes de cuidados médicos (Davis, 1989). Na década de 2000, a IBM lançou uma divisão especializada em saúde, o IBM *Health*, com o objetivo de transformar o setor de saúde por meio da aplicação de IA e análise de dados

(Baarder; Brewka; Eiter, 2001). A iniciativa visava aprimorar o cuidado com os pacientes, otimizar procedimentos e encontrar soluções inovadoras para enfrentar os desafios complexos da área médica (Gomes, 2021).

2.2.2 Regulamentação e aspectos éticos na área da saúde

A implementação da IA na medicina levanta questões éticas significativas, como a privacidade dos dados dos pacientes e a transparência dos algoritmos utilizados (Yu; Beam; Kohane, 2018). Adicionalmente, existem debates sobre como aplicar ferramentas tradicionais e métodos baseados em evidências para decisões éticas envolvendo intervenções de saúde baseadas em IA (Schwalbe; Wahl, 2020).

Embora as aplicações de IA possam melhorar consideravelmente os resultados clínicos, elas também acarretam riscos. Entre esses riscos estão a avaliação inadequada de riscos, diagnósticos imprecisos, recomendações de tratamento equivocadas e violações de privacidade (Kumar *et al.*, 2023). Embora a IA tenha o potencial de transformar a prática médica, ela deve ser implementada com cautela para assegurar a segurança e a eficácia, considerando os desafios éticos e regulatórios. Nesse contexto, a formação acadêmica e a especialização profissional permanecem indispensáveis (Secinaro *et al.*, 2021).

Questões éticas relacionadas ao uso de IA na saúde incluem responsabilidade, transparência, consentimento e privacidade (Davenport; Kalakota, 2019). No entanto, grande parte das pesquisas na área não aborda de forma ampla as implicações éticas, regulatórias ou práticas necessárias para o uso em larga escala dessas tecnologias (Schwalbe; Wahl, 2020). Há preocupações de que sistemas de suporte à decisão clínica possam ser programados para favorecer lucros, promovendo determinados medicamentos, testes ou dispositivos sem o conhecimento dos usuários clínicos (He *et al.*, 2019).

Os padrões regulatórios e as políticas de IA devem ser desenvolvidos para garantir a segurança e a eficácia dessas tecnologias, protegendo simultaneamente a privacidade dos dados dos pacientes. A transparência e a responsabilidade são fundamentais no setor médico, pois envolvem decisões que impactam diretamente a saúde e a vida dos pacientes (Tjoa; Guan, 2020; Secinaro *et al.*, 2021).

A implementação de IA na saúde enfrenta desafios como privacidade de dados, segurança e a necessidade de validação rigorosa dos algoritmos em ambientes clínicos reais (He *et al.*, 2019). Regulamentações e políticas específicas são indispensáveis para garantir a utilização ética e segura da IA, protegendo os direitos dos pacientes e assegurando a qualidade

dos cuidados prestados (Schwalbe; Wahl, 2020). Nos Estados Unidos, o ambiente regulatório inclui o desenvolvimento de padrões específicos para avaliar a segurança e a eficácia das tecnologias de IA na saúde (He *et al.*, 2019). Na União Europeia, a Regulamentação Geral de Proteção de Dados (*General Data Protection Regulation*, GDPR) define normas abrangentes para a coleta, armazenamento e uso de informações pessoais, mas ainda carece de uma política específica para a utilização de IA (He *et al.*, 2019).

Abordar os desafios éticos, de privacidade e regulamentares associados à IA é fundamental para garantir que seus benefícios sejam plenamente realizados (Secinaro *et al.*, 2021). A colaboração entre desenvolvedores de IA, profissionais de saúde e legisladores é importante para assegurar que esses avanços sejam implementados de forma ética e eficaz, beneficiando pacientes e profissionais de saúde em todo o mundo (Topol, 2019).

2.2.3 Aceitabilidade

A adoção de tecnologias médicas inteligentes por profissionais de saúde, em especial médicos, enfrenta barreiras. Entre os principais desafios estão a falta de preparo em relação ao potencial da medicina digital e o aumento da carga administrativa associada aos registros eletrônicos de saúde (Briganti; Le Moine, 2020). A maior dificuldade com as tecnologias de IA na saúde não reside em sua utilidade, mas sim em garantir sua adoção na prática clínica diária (Davenport; Kalakota, 2019).

O mercado de IA médica nos Estados Unidos apresenta um grande potencial de crescimento, prevendo-se que atinja US\$ 10 bilhões até 2025. Estima-se que 90% dos hospitais adotem essa tecnologia, a qual pode substituir até 80% das funções atualmente desempenhadas por médicos (Longoni; Bonezzi; Morewedge, 2019). Apesar de temores crescentes sobre a substituição de médicos pela IA, a opinião predominante na literatura é de que a IA será uma ferramenta aliada à inteligência médica no futuro (Briganti; Le Moine, 2020). Até o momento, não há registros significativos de eliminação de empregos na saúde devido ao uso de IA (Davenport; Kalakota, 2019).

Os sistemas de IA têm o potencial de personalizar cuidados de saúde, adaptando tratamentos às necessidades específicas de cada paciente e promovendo uma medicina mais eficaz (Secinaro *et al.*, 2021). A aceitação da IA pelos pacientes pode ser facilitada ao assegurar que o atendimento seja percebido como personalizado e complementar ao trabalho médico humano (Longoni; Bonezzi; Morewedge, 2019). No entanto, a adesão do paciente ainda é vista como o "último obstáculo" para alcançar melhores resultados de saúde (Davenport; Kalakota,

2019).. Apesar das vantagens da IA, muitos pacientes resistem ao uso de ferramentas automatizadas, preferindo a atenção médica humana. Essa relutância se estende desde a prevenção e diagnóstico até o tratamento (Longoni; Bonezzi; Morewedge, 2019). A confiança e a ansiedade dos pacientes desempenham papéis cruciais na aceitação da tecnologia, destacando a necessidade de estratégias para aumentar a confiança e reduzir a ansiedade em relação ao uso da IA (AlQudah; Al-Emran; Shaalan, 2021).

Outro desafio a ser enfrentado é a alimentação das máquinas de IA, que depende de informações precisas e específicas. Muitas empresas de tecnologia operam de forma autônoma e abordam apenas alguns aspectos do cuidado ao paciente, o que limita a implementação ampla da IA na prática clínica (Davenport; Kalakota, 2019). A transparência dos algoritmos é essencial para que médicos e pacientes confiem nas recomendações geradas pela IA (He *et al.*, 2019). Apesar das preocupações, a IA está sendo cada vez mais integrada à prática médica, oferecendo soluções inovadoras que requerem acompanhamento próximo tanto pelo setor médico quanto pelo tecnológico (Briganti; Le Moine, 2020).

Por fim, a aceitação da IA pelos pacientes será um aspecto essencial para o sucesso de sua implementação na saúde, ainda que preocupações sobre precisão e custo-eficiência existam, muitos pacientes demonstram resistência ao atendimento automatizado, devido ao receio de que a IA não atenda adequadamente às suas características e necessidades individuais (Longoni; Bonezzi; Morewedge, 2019). Sendo assim, a aceitabilidade da IA na saúde depende de múltiplos fatores inter-relacionados, que abrangem tanto aspectos técnicos, como a precisão dos algoritmos e a transparência de suas recomendações (He *et al.*, 2019), quanto questões culturais e sociais, incluindo a confiança de médicos e pacientes. Para que a IA se integre de forma efetiva à prática clínica, é essencial que essas barreiras sejam superadas por meio de estratégias que promovam o entendimento e a aceitação de suas aplicações (He *et al.*, 2019).

2.2.4 Aplicabilidade

Nos últimos anos, a IA tem revolucionado a área da saúde, especialmente em diagnósticos, pesquisa de medicamentos e identificação de riscos em pacientes, impulsionada por técnicas como ML e DL (Kumar *et al.*, 2023). Essa transformação está redefinindo a prática médica, oferecendo novas formas de diagnóstico, tratamento e monitoramento de pacientes, demonstrando um impacto em diversas aplicações na saúde (Secinaro *et al.*, 2021).

Os métodos de ML, redes neurais artificiais e interfaces cérebro-máquina têm apresentado desempenhos promissores em tarefas médicas, como diagnóstico de doenças e

melhorias nos fluxos de trabalho, embora ainda não sejam perfeitos (Tjoa; Guan, 2020). As habilidades preditivas do ML têm sido aplicadas para abordar problemas como erros de diagnóstico e tratamento, ineficiências de fluxo de trabalho e obstáculos ao cuidado baseado em valor (Helm *et al.*, 2020). Já o DL utiliza algoritmos para criar redes neurais artificiais que simulam o comportamento de neurônios interconectados, permitindo que os sistemas aprendam e tomem decisões de forma autônoma, de maneira semelhante ao cérebro humano. Essas redes têm sido amplamente utilizadas para processar imagens médicas e auxiliar no diagnóstico com alta precisão (Kaul; Enslin; Gross, 2020).

As tecnologias médicas habilitadas por IA, como algoritmos de DL, são capazes de lidar com grandes volumes de dados provenientes de dispositivos vestíveis, *smartphones* e sensores móveis, ampliando as possibilidades de monitoramento remoto de pacientes (Briganti; Le Moine, 2020). No entanto, esses algoritmos ainda requerem validação adicional para demonstrar sua eficácia e impacto nos resultados clínicos (Kaul; Enslin; Gross, 2020).

Embora a IA ofereça vantagens consideráveis, como a detecção precoce de doenças e a previsão de resultados clínicos, ela enfrenta desafios relacionados à integração de grandes volumes de dados médicos frequentemente armazenados de maneira fragmentada (Kumar *et al.*, 2023). Essa integração é importante para identificar padrões e tendências em *big data*, facilitando a tomada de decisões baseadas em evidências (Davenport; Kalakota, 2019). A fusão de *big data* e IA no setor de saúde proporciona oportunidades sem precedentes na gestão de informações e na interação entre pacientes, médicos, hospitais e autoridades de saúde (He *et al.*, 2019). Essa integração pode inaugurar uma nova era de cuidados médicos, onde a análise preditiva e o aprendizado contínuo otimizam a tomada de decisões clínicas (Secinaro *et al.*, 2021).

A IA também tem o potencial de melhorar a eficiência dos cuidados médicos ao automatizar tarefas repetitivas, permitindo que os médicos se concentrem em casos mais complexos (Longoni; Bonezzi; Morewedge, 2019). Por exemplo, a automação de processos em registros eletrônicos de saúde por meio de ML pode ajudar os médicos a focar em tarefas mais críticas, mitigando os efeitos da chamada "medicina superficial", frequentemente causada pela falta de tempo (Helm *et al.*, 2020).

Intervenções baseadas em IA têm o potencial de complementar a tomada de decisões clínicas, reduzir a carga de trabalho dos profissionais de saúde e identificar surtos de doenças de forma mais precoce do que os métodos tradicionais (Schwalbe; Wahl, 2020). A IA promete aumentar a eficiência dos diagnósticos e tratamentos, transformando o fluxo de trabalho dos

profissionais de saúde ao liberar tempo para tarefas mais complexas que exigem maior julgamento clínico (Kumar *et al.*, 2023).

A aplicação da IA em dispositivos médicos inteligentes está se tornando cada vez mais comum, permitindo diagnósticos mais precoces e precisos de várias doenças (Rong *et al.*, 2020). Essas tecnologias, aplicadas em diagnósticos, prognósticos e tratamentos, oferecem um potencial para melhorar os resultados de saúde e a qualidade dos cuidados médicos (Tjoa; Guan, 2020). Tecnologias móveis e vestíveis baseadas em ML estão sendo utilizadas para monitorar remotamente a saúde dos pacientes, fornecendo *feedback* em tempo real e melhorando a adesão aos tratamentos (Helm *et al.*, 2020). A adoção dessas tecnologias pode levar a melhorias significativas nos resultados clínicos, maior eficiência nos cuidados de saúde e experiências mais personalizadas para os pacientes (Secinaro *et al.*, 2021).

Robôs cirúrgicos assistidos por IA estão revolucionando a prática cirúrgica, aumentando a precisão e reduzindo erros, o que resulta em cirurgias mais seguras e eficientes (Connelly *et al.*, 2020). Esses avanços são significativos em áreas críticas como a cardiologia, onde algoritmos de DL têm sido aplicados com sucesso na interpretação de eletrocardiogramas e ecocardiogramas. Esses algoritmos auxiliam na detecção de arritmias e outras condições cardíacas, melhorando a precisão diagnóstica e a tomada de decisões clínicas (Topol, 2019).

A IA também tem desempenhado um papel importante na medicina de precisão, permitindo uma análise mais detalhada e abrangente dos dados de saúde para personalizar o tratamento (Davenport; Kalakota, 2019). Os SADCs baseados em IA têm demonstrado aumentar a segurança do paciente, a precisão diagnóstica e a eficiência do tratamento, acelerando a previsão de resultados e o processo de recuperação dos pacientes (Secinaro *et al.*, 2021). A IA também permite prever a propagação de doenças e personalizar os tratamentos em situações de emergência, fornecendo suporte para os médicos em decisões rápidas e precisas (Secinaro *et al.*, 2021). Esses avanços ampliam as aplicações da IA em múltiplos campos, destacando a necessidade de um rigoroso controle e compreensão das decisões automatizadas para garantir sua precisão e segurança (Tjoa; Guan, 2020).

A IA pode reduzir custos nos cuidados de saúde ao automatizar tarefas repetitivas, permitindo que os profissionais se concentrem no pensamento crítico e na criatividade clínica (Secinaro *et al.*, 2021). A IA promete melhorar a eficiência dos cuidados médicos, liberando os médicos para se dedicarem aos casos mais complexos (Longoni; Bonezzi; Morewedge, 2019). Os sistemas de IA têm o potencial de transformar os sistemas clínicos ao melhorar os registros de informações, o diagnóstico e o tratamento de doenças, aumentando a satisfação e os resultados dos pacientes, enquanto reduzem custos (Kumar *et al.*, 2023). A IA também

apresenta aplicações administrativas significativas, contribuindo para melhorar a eficiência dos processos e a sustentabilidade financeira das organizações de saúde (Davenport; Kalakota, 2019).

A implementação da IA na saúde tem gerado discussões em torno de confiança e retorno financeiro. Embora os Estados Unidos estejam na vanguarda da adoção dessa tecnologia (Longoni; Bonezzi; Morewedge, 2019), países como a Alemanha têm avaliado cuidadosamente o retorno sobre os investimentos. Para apoiar essa transição, o governo alemão criou uma legislação permitindo que hospitais e instituições que utilizam IA solicitem suporte financeiro para aquisição de equipamentos (Harhoff *et al.*, 2018). Em países de baixa e média renda, a IA oferece soluções promissoras para desafios como escassez de profissionais de saúde e fragilidade dos sistemas de vigilância em saúde pública (Schwalbe; Wahl, 2020).

Os SADCs baseados em IA têm potencial para aumentar a eficiência do diagnóstico e do tratamento de doenças, fornecendo informações precisas em tempo real para os médicos (Shortliffe; Sepúlveda, 2018). Esses avanços são especialmente visíveis em áreas como a radiologia, onde algoritmos superam radiologistas em tarefas como detecção de pneumonia e diagnóstico de nódulos pulmonares cancerígenos (Topol, 2019). He *et al.* (2019) preveem que áreas médicas baseadas em imagens, como radiologia, patologia e oftalmologia, verão a tradução mais precoce de tecnologias baseadas em IA. Para diagnósticos precisos, a utilização de diversas fontes de dados médicos é fundamental, incluindo ultrassonografia, ressonância magnética, genômica e tomografia computadorizada (Kumar *et al.*, 2023). Tecnologias de DL têm demonstrado precisão comparável ou superior a dos especialistas humanos na interpretação de imagens médicas (Topol, 2019).

Um exemplo marcante da aplicação da IA na medicina é o IBM Watson, que demonstrou capacidades impressionantes ao diagnosticar doenças cardíacas e ao fornecer conselhos médicos por meio de *chatbots* no Serviço Nacional de Saúde do Reino Unido (Longoni; Bonezzi; Morewedge, 2019). O Watson recebeu atenção da mídia por sua precisão no diagnóstico e tratamento de câncer, identificando opções de tratamento que passaram despercebidas por médicos humanos em mais de 30% dos casos analisados (Davenport; Kalakota, 2019). No entanto, dificuldades para ensinar o Watson a tratar tipos específicos de câncer e integrá-lo aos processos clínicos reduziram o entusiasmo inicial (Davenport; Kalakota, 2019).

2.3 MODELOS DE ACEITAÇÃO DE TECNOLOGIAS

Os Modelos de Aceitação de Tecnologias foram desenvolvidos para compreender e prever como as pessoas adotam e utilizam novas tecnologias (Davis, 1989). Esses modelos identificam os fatores que influenciam a aceitação de sistemas ou produtos tecnológicos, sejam eles *softwares*, aplicativos ou dispositivos físicos. A compreensão desses fatores é importante para otimizar o *design* e a implementação de tecnologias inovadoras, garantindo maior aderência e uso eficaz (Taherdoost, 2019).

2.3.1 Modelos de Aceitação de Novas Tecnologias

O Modelo de Aceitação de Tecnologia (*Technology Acceptance Model*, TAM) e a Teoria Unificada de Aceitação e Uso de Tecnologia (*Unified Theory of Acceptance and Use of Technology*, UTAUT) são os principais modelos utilizados para explicar os fatores que afetam o uso de tecnologias nas práticas de saúde (AlQudah; Al-Emran; Shaalan, 2021). Ambos os modelos têm como objetivo compreender por que os usuários aceitam ou rejeitam uma tecnologia específica e como o *design* tecnológico pode ser otimizado para melhorar a aceitação do usuário (Ammenwerth, 2020). Esses modelos ajudam a entender os comportamentos dos usuários em relação a tecnologias ou serviços específicos. Ao analisar essas dimensões, o TAM e o UTAUT fornecem *insights* valiosos para o desenvolvimento de soluções tecnológicas que atendam melhor às necessidades e expectativas dos usuários, promovendo maior adesão e eficácia em sua implementação (AlQudah; Al-Emran; Shaalan, 2021).

2.3.1.1 Modelo de Aceitação de Tecnologia (TAM)

O TAM, desenvolvido por Fred D. Davis no final dos anos 1980, baseia-se na Teoria da Ação Racional (TRA) e na Teoria do Comportamento Planejado (TPB) para explicar os fatores que influenciam a aceitação de novas tecnologias (Davis, 1989; Ammenwerth, 2020). O modelo busca identificar como variáveis como Percepção de Utilidade (PU) e Percepção de Facilidade de Uso (PEOU) afetam a adoção e o uso de tecnologias (Figura 1). A PU refere-se ao grau em que o indivíduo acredita que a utilização de uma tecnologia melhorará seu desempenho, enquanto a PEOU diz respeito à facilidade percebida no uso da tecnologia, ou seja, a ausência de esforço significativo para aprender e utilizá-la (Davis, 1989; Ammenwerth,

2020). A PEOU também influencia diretamente a PU, pois tecnologias fáceis de usar tendem a ser vistas como mais úteis (Ammenwerth, 2020).




Figura 1. Modelo de Aceitação de Tecnologia (TAM).

Fonte: Adaptado de Davis (1989)

No TAM, fatores externos, como suporte organizacional e características tecnológicas, impactam diretamente as PU e PEOU. Essas percepções, por sua vez, influenciam a atitude do usuário, a intenção comportamental de uso (*Behavioral Intention*, BI) de utilizar a tecnologia e, finalmente, o uso real (Davis, 1989; Arief *et al.*, 2023; Park; Park, 2020). A PU tem um papel central na determinação da aceitação tecnológica, enquanto a PEOU está mais associada à formação de atitudes positivas em relação à tecnologia (Walker; Hong, 2017; Sitorus *et al.*, 2016).

A BI, definida como a força da intenção de um indivíduo em utilizar uma tecnologia (Davis, 1989), é influenciada diretamente pela PU e pela PEOU (Malatji *et al.*, 2020). Quando os usuários percebem uma tecnologia como útil e fácil de usar, a intenção de utilizá-la aumenta consideravelmente (Malatji *et al.*, 2020). Pesquisas recentes confirmam que a PU é fundamental para aumentar a BI, enquanto a PEOU fomenta atitudes favoráveis (Dessilomba *et al.*, 2021; Huwaida *et al.*, 2023). A atitude pode ainda desempenhar um papel importante em contextos específicos, influenciando indiretamente a BI através da PU e da PEOU (Davis; Bagozzi; Warshaw, 1989). Esses fatores influenciam diretamente a aceitação da tecnologia em diferentes contextos, incluindo saúde, educação e comércio eletrônico (Malatji *et al.*, 2020). O TAM é frequentemente usado para identificar fatores críticos de sucesso para a implementação da IA em vários setores, incluindo a saúde (Alhashmi *et al.*, 2019). No contexto da saúde, o TAM

mostrou ser eficaz para prever a aceitação de sistemas de registros eletrônicos por enfermeiros (Tubaishat, 2017).

2.3.1.2 Expansão do Modelo TAM: TAM 2

Com o avanço das pesquisas sobre aceitação de tecnologia, Venkatesh e Davis (2000) propuseram uma extensão do TAM, denominada TAM 2, com o objetivo de ampliar a compreensão dos fatores que influenciam a adoção de novas tecnologias, especialmente em contextos organizacionais. Enquanto o modelo original enfatizava a PU e a PEOU como os principais determinantes da BI e do AU, o TAM 2 introduziu novos fatores sociais e cognitivos que impactam a PU e a BI, proporcionando um modelo mais abrangente para entender a aceitação de tecnologia no ambiente de trabalho (Venkatesh; Davis, 2000).

Entre os fatores sociais incorporados ao TAM 2, destacam-se a norma subjetiva, que se refere à influência de colegas e superiores na decisão de adotar uma tecnologia, a imagem, relacionada à percepção de *status* e prestígio associado ao uso da tecnologia, e a voluntariedade, que mede o grau de liberdade percebido na adoção da inovação. Além dos sociais, foram incluídos fatores cognitivos, como a relevância da tarefa, a qualidade dos resultados e a demonstração de benefícios, elementos que afetam diretamente a PU de uma tecnologia (Venkatesh; Davis, 2000).

No contexto da prática médica, o TAM 2 tem sido amplamente utilizado para avaliar a aceitação de tecnologias de saúde, como sistemas de prontuário eletrônico e IA, que exigem a integração de fatores sociais e organizacionais na análise de sua adoção (Cunha; Zouain, 2023). Estudos indicam que a PU da IA entre médicos está fortemente associada à qualidade dos resultados clínicos e à demonstração dos benefícios na prática diária, o que reforça a importância de fornecer evidências concretas sobre a eficácia da tecnologia para impulsionar sua aceitação (Lucena, 2023). Dessa forma, o TAM 2 aprimora a capacidade preditiva do modelo original, incorporando influências externas que moldam a percepção dos profissionais de saúde sobre a adoção tecnológica.

2.3.1.3 Integração de Novos Fatores: TAM 3

A necessidade de aprofundar a compreensão da aceitação de tecnologia levou Venkatesh e Bala (2008) a desenvolverem o TAM 3, que integra os componentes do TAM 2

com novos determinantes da PEOU. Enquanto o TAM 2 ampliou os fatores que afetam a PU e a BI, o TAM 3 incorporou elementos individuais e organizacionais que influenciam a PEOU, proporcionando uma visão mais completa dos fatores que impactam a aceitação de tecnologia pelos usuários (Venkatesh; Bala, 2008).

Dentre os novos construtos incluídos, destacam-se a autoeficácia computacional, que mede a confiança do usuário em sua capacidade de utilizar a tecnologia, a percepção de controle externo, que reflete o suporte institucional disponível, e a ansiedade em relação ao uso da tecnologia, que pode atuar como uma barreira à adoção. O TAM 3 introduziu o conceito de diversão percebida, que avalia se o uso da tecnologia é considerado agradável ou estimulante, influenciando a aceitação do usuário (Venkatesh; Bala, 2008).

No contexto da saúde, o TAM 3 tem sido utilizado para investigar a adoção de tecnologias complexas, como a IA, que requer treinamento e familiarização dos profissionais para ser efetivamente incorporada à prática clínica. Estudos indicam que a aceitação da IA na medicina é fortemente influenciada pela autoeficácia e pelo suporte técnico disponível, uma vez que a exposição prática à tecnologia reduz a ansiedade e melhora a PEOU (Martins, 2018). O modelo reforça que intervenções organizacionais, como capacitações e suporte contínuo, desempenham um papel essencial na adoção de novas ferramentas tecnológicas no setor da saúde.

Comparando o TAM, TAM 2 e TAM 3, observa-se que o TAM enfatiza PU e PEOU como principais determinantes da aceitação da tecnologia, o TAM 2 amplia essa abordagem ao incluir influências sociais e cognitivas, e o TAM 3 expande ainda mais o modelo ao considerar fatores individuais e organizacionais que afetam a percepção de facilidade de uso. Essas evoluções sucessivas tornam o TAM 3 uma ferramenta mais abrangente para analisar a aceitação da IA no setor médico, pois permite avaliar não apenas as percepções subjetivas dos profissionais, mas também o impacto de fatores externos na adoção da tecnologia (Marikyan; Papagiannidis, 2024).

2.3.1.4 Teoria Unificada de Aceitação e Uso de Tecnologia (UTAUT)

Embora o TAM 3 tenha sido uma tentativa de aprimorar a compreensão da PEOU dentro do TAM, outras abordagens buscaram expandir a análise da aceitação de tecnologia em um nível mais abrangente. Nesse sentido, Venkatesh *et al.* (2003) propuseram a Teoria Unificada de Aceitação e Uso de Tecnologia (UTAUT), um modelo que integra elementos do TAM, TAM

2 e de outras sete teorias, oferecendo uma explicação mais ampla e preditiva da adoção de novas tecnologias.

A UTAUT é baseada na análise e comparação de oito modelos de aceitação de tecnologia, incluindo o TAM, a TPB e a Teoria de Difusão da Inovação (DOI) (Venkatesh *et al.*, 2003; Ammenwerth, 2019). O UTAUT integra elementos dessas teorias para criar um modelo abrangente que explica os fatores que influenciam a aceitação e o uso de tecnologias. Os principais fatores do UTAUT são Expectativa de Desempenho, Expectativa de Esforço, Influência Social e Condições Facilitadoras (Cheng, 2018).

A Expectativa de Desempenho é definida como o grau em que um indivíduo acredita que o uso de um sistema ajudará a alcançar ganhos em seu desempenho no trabalho (Venkatesh *et al.*, 2003). Este conceito é semelhante ao de PU do TAM. Estudos indicam que a Expectativa de Desempenho é um dos fatores mais fortes na determinação da BI de adotar novas tecnologias (Ammenwerth, 2020).

A Expectativa de Esforço refere-se ao grau de facilidade associado ao uso de um sistema, sendo equivalente à PEOU do TAM (Venkatesh *et al.*, 2003). Tecnologias percebidas como fáceis de usar tendem a ser mais aceitas, pois requerem menos esforço para serem operadas (Ammenwerth, 2020).

A Influência Social é o grau em que um indivíduo percebe que pessoas importantes para ele acreditam que ele deve usar o novo sistema (Venkatesh *et al.*, 2003). Este fator destaca a relevância das pressões sociais e normas subjetivas na aceitação de tecnologias, variando de acordo com o contexto cultural e organizacional (Ammenwerth, 2020).

As Condições Facilitadoras referem-se ao grau em que o indivíduo acredita que há uma infraestrutura organizacional e técnica que apoia o uso do sistema (Venkatesh *et al.*, 2003). Isso inclui suporte técnico, treinamento e acesso a *hardware/software* adequados. A disponibilidade de recursos e apoio desempenha um papel crucial na adoção de tecnologias (Ammenwerth, 2020).

O UTAUT demonstrou alta capacidade preditiva em estudos empíricos, explicando até 70% da variância na BI de usar tecnologias (Venkatesh *et al.*, 2003). No entanto, estudos na área da saúde sugerem que ajustes podem ser necessários para acomodar fatores contextuais específicos, como normas culturais e sociais (Ammenwerth, 2020). Por exemplo, um estudo sobre aceitação de serviços de telemedicina por idosos utilizou o UTAUT com variáveis adicionais, como a opinião do médico e a segurança percebida para capturar melhor as nuances desse público (Cimperman *et al.*, 2016).

2.3.2 Estudos Relacionados à Inteligência Artificial e Modelos de Adoção de Inovação

A adoção da IA na prática médica tem sido amplamente investigada sob a perspectiva do TAM, permitindo identificar os principais fatores que influenciam sua aceitação pelos profissionais de saúde. Diversos estudos indicam que a PU e a PEOU continuam sendo os principais determinantes da BI da IA no contexto clínico, embora fatores organizacionais e individuais também desempenhem um papel relevante nesse processo.

Um estudo sobre sistemas de suporte à decisão clínica revelou que a familiarização com as ferramentas tecnológicas, proporcionada por treinamentos institucionais, impacta diretamente a aceitação da IA. Nesse contexto, Macedo *et al.* observaram que médicos que receberam treinamento adequado desenvolveram uma percepção mais favorável da utilidade da IA, aumentando sua intenção de uso. Isso reforça a necessidade de iniciativas educacionais voltadas à capacitação de profissionais da saúde, garantindo que a IA seja integrada de maneira eficiente à prática médica.

A importância do suporte organizacional também foi destacada por Sestino e D'Angelo (2024), que analisaram a implementação de sistemas de IA em instituições hospitalares. O estudo revelou que barreiras organizacionais, como resistência à mudança e infraestrutura inadequada, influenciam significativamente a BI da IA. Os autores enfatizam que a confiança na tecnologia é um fator essencial, pois médicos que percebem a IA como segura e confiável demonstram maior predisposição para incorporá-la à sua prática diária. Esses achados sugerem que estratégias institucionais que promovam transparência nos algoritmos e segurança nos dados podem contribuir para a aceitação da IA pelos profissionais de saúde.

Outro aspecto relevante foi abordado por Zhang e Ma (2024), que investigaram a aceitação de sistemas de triagem e diagnóstico baseados em IA. O estudo identificou uma correlação significativa entre eficácia percebida e aceitação da tecnologia, demonstrando que a experiência do usuário impacta diretamente a percepção de utilidade da IA. Os autores destacam que médicos que utilizaram a IA em sua rotina de trabalho avaliaram a tecnologia de forma mais positiva, enquanto aqueles sem contato prévio demonstraram maior resistência. Esse achado reforça a importância da exposição gradual à tecnologia e da integração da IA nos fluxos de trabalho clínicos, garantindo que os profissionais desenvolvam familiaridade e confiança no uso dessas ferramentas.

Esses estudos evidenciam a aplicabilidade do TAM como ferramenta de análise na aceitação da IA, ressaltando a importância de considerar fatores contextuais, como especialidade médica, experiência profissional e suporte organizacional. Os achados sugerem

que a integração bem-sucedida da IA no ambiente clínico depende não apenas da percepção individual dos profissionais, mas também de intervenções institucionais que facilitem sua adoção.

3 METODOLOGIA

Investigar cientificamente é um processo sistemático cujo objetivo é gerar novos conhecimentos e integrá-los aos já existentes por meio do método científico (Carvalho *et al.*, 2019). Esse processo começa com a formulação de uma pergunta inicial e vai até a interpretação dos resultados obtidos, garantindo a qualidade e a confiabilidade dos achados ao estabelecer ferramentas claras para coleta e análise de dados, resultando em conclusões alinhadas às teorias previamente existentes (Minayo, 2010).

Segundo Carvalho *et al.* (2019), a metodologia descreve os procedimentos e abordagens que devem ser usados na realização do estudo. Para Minayo (2010), a metodologia vai além de uma descrição formal de métodos e técnicas, funcionando como um elo entre a fundamentação teórica e os objetos a serem estudados.

A pesquisa adequada permite reflexão e experimentação do objeto de estudo (Silva, 2015). O objetivo central desta pesquisa foi compreender a aceitação e os fatores que influenciam a adoção e uso de ferramentas de IA pelos médicos de uma rede privada de hospitais. Este capítulo detalha os procedimentos metodológicos, abordando a classificação da pesquisa, o ambiente e o universo populacional, o instrumento de coleta de dados e a análise dos resultados.

Para Minayo (2010), a pesquisa é uma atividade fundamental das ciências, construída a partir da práxis e da busca constante por novos entendimentos. Este processo é inacabado, representando uma prática contínua de descoberta e evolução do conhecimento (Siena, 2024). Ao realizar uma pesquisa, busca-se ampliar o entendimento humano por meio da integração entre teoria e prática (Minayo, 2010). Essa interação permite que pesquisadores formulem questões pertinentes, colem informações relevantes e analisem os dados obtidos, desafiando constantemente os limites do conhecimento humano e gerando novas teorias (Siena, 2024).

3.1 CARACTERIZAÇÃO DA PESQUISA

A pesquisa científica apresenta classificações distintas de acordo com diferentes critérios, como abordagem (qualitativa, quantitativa ou mista), natureza (básica ou aplicada), objetivos (exploratórios, descritivos ou explicativos) e procedimentos metodológicos (bibliográfica, experimental, levantamento ou estudo de caso) (Siena, 2024; Carvalho *et al.*, 2019). Este estudo adota uma abordagem quantitativa, de natureza aplicada, com objetivos

descritivos e explicativos, utilizando procedimentos baseados no levantamento de dados e sua análise.

A pesquisa é caracterizada como quantitativa porque utiliza métodos estruturados para coleta e análise de dados numéricos, permitindo a mensuração objetiva de variáveis e a realização de análises estatísticas que suportam conclusões gerais sobre o fenômeno investigado (Siena, 2024). Essa abordagem busca testar hipóteses e verificar relações entre variáveis com base em dados mensuráveis, fornecendo resultados replicáveis e confiáveis (Carvalho *et al.*, 2019). No contexto deste estudo, a quantificação da aceitação pelos médicos em relação à adoção de ferramentas de IA é essencial para identificar padrões e tendências, garantindo um entendimento fundamentado do problema em análise (Silva, 2015).

De acordo com Carvalho *et al.* (2019), a definição do tipo de pesquisa deve ocorrer no início da abordagem do problema. A classificação como básica ou aplicada depende da finalidade do estudo: enquanto a pesquisa básica visa expandir o conhecimento científico, explorando problemas de forma ampla, a pesquisa aplicada busca soluções práticas e específicas, frequentemente relacionadas a desafios concretos (Silva, 2015). Neste contexto, o presente estudo é classificado como pesquisa aplicada, pois avalia indicadores relacionados aos desafios práticos no uso de IA na saúde, contribuindo diretamente para o desenvolvimento de soluções inovadoras (Harhoff *et al.*, 2018).

Quanto aos objetivos específicos, este estudo é descritivo, uma vez que busca caracterizar e analisar as opiniões, atitudes e crenças de uma população específica em relação à adoção de ferramentas de IA na prática clínica. Carvalho *et al.* (2019) descreve a pesquisa descritiva como aquela que busca compreender as características e peculiaridades de uma população ou fenômeno, frequentemente utilizando levantamento de dados para explorar variáveis como fatores culturais, crenças e opiniões. Segundo Harhoff *et al.* (2018), as descrições detalhadas dos dados permitem maior aproximação com o problema, possibilitando análises mais assertivas e fundamentadas. Gil (2017) complementa que o levantamento e a análise de dados fornecem *insights* que ajudam na elaboração de técnicas mais eficazes, explorando de forma abrangente as percepções de um determinado grupo populacional. Minayo (2010) aponta que a pesquisa descritiva frequentemente relaciona características de uma população com variáveis específicas, permitindo uma visão mais detalhada e abrangente do problema investigado.

3.2 PÚBLICO-ALVO

Na pesquisa de levantamento, o público-alvo é definido com base nos critérios que determinam os participantes a serem estudados, conforme apontado por Carvalho *et al.* (2019). Nesta pesquisa, os participantes foram médicos de uma rede privada de hospitais no Brasil. Esta rede possui 8 unidades hospitalares presente em 7 estados (Amazonas, Mato Grosso do Sul, Pará, Paraná, Rio de Janeiro, Rio Grande do Sul e São Paulo). Essa escolha se justifica pelo papel central que os médicos desempenham como principais tomadores de decisão nos processos de diagnóstico e tratamento de pacientes, além de serem considerados diretamente responsáveis pela integração de novas tecnologias, como a IA, na prática clínica. A inclusão deste público-alvo visou, ainda, identificar barreiras e facilitadores específicos relacionados à aceitação e ao uso efetivo da IA, uma vez que o engajamento desses profissionais é importante para garantir a melhoria na oferta e na qualidade dos serviços médicos prestados à população.

3.3 PROCEDIMENTO DE COLETA DE DADOS

Os instrumentos para a coleta de dados são recursos essenciais para obter informações e responder às questões de pesquisa, assegurando que os dados reunidos sejam relevantes e confiáveis (Minayo, 2010). A seleção da ferramenta adequada depende da natureza do estudo, dos objetivos definidos e do tipo de dados a serem adquiridos (Silva, 2024). Entre os métodos mais comuns utilizados estão questionários, entrevistas, observações e atividades documentais, cada um com características específicas que são adequadas a diferentes tipos de investigação. A escolha adequada do procedimento de coleta de dados assegura a qualidade dos dados coletados de forma confidencial, possibilitando ao pesquisador chegar a conclusões precisas e relevantes (Silva, 2015).

Neste trabalho, optou-se pelo uso do TAM em vez da UTAUT devido à simplicidade e foco específico do TAM nos dois principais fatores que determinam a aceitação tecnológica: PU e PEOU. Esses conceitos são fundamentais para o contexto da saúde, onde a adoção de tecnologias como a IA depende diretamente da percepção de que essas ferramentas são úteis e fáceis de integrar à prática clínica. Embora a UTAUT ofereça um modelo mais abrangente, incorporando fatores como influência social e condições facilitadoras, sua complexidade poderia dificultar a análise de dados em cenários altamente especializados, como o uso da IA por médicos em redes privadas de hospitais. O TAM, por sua vez, é amplamente validado, fácil

de aplicar e proporciona um *framework* eficaz para estudos que buscam explorar a aceitação de tecnologias em contextos clínicos, tornando-o mais adequado para os objetivos desta pesquisa.

Nesta pesquisa, a coleta de dados foi realizada por meio de um questionário estruturado do tipo *survey*, baseado no TAM, que tem sido utilizado para investigar a aceitação de tecnologias (Davis, 1989). O questionário conteve 27 questões objetivas, desenvolvidas para capturar as percepções dos respondentes sobre variáveis centrais do TAM, como PU, PEOU, ATU, BI e AU da IA na prática médica (Apêndice A).

Adicionalmente, variáveis demográficas, como idade, gênero, especialidade médica, tempo de experiência profissional e formação acadêmica, foram incluídas para análise como variáveis independentes. As questões utilizaram uma escala Likert de cinco pontos, variando de 1 (discordo totalmente) a 5 (concordo totalmente), permitindo medir quantitativamente as respostas dos participantes e facilitar a análise e comparação entre variáveis.

Para a análise das especialidades médicas, as 55 especialidades (Pergunta 3 do Apêndice A) originalmente informadas pelos participantes foram agrupadas em cinco categorias principais: Especialidades Terapêuticas, Especialidades Clínicas, Especialidades Diagnósticas, Especialidade Cirúrgicas e Especialidades Preventivas e Sociais. Essa categorização foi realizada com o objetivo de facilitar a identificação de padrões e tendências na aceitação da IA na prática médica, permitindo uma análise mais estruturada das variáveis investigadas. A classificação seguiu critérios baseados na natureza das atividades desempenhadas por cada especialidade, na interação dos profissionais com tecnologias e nos contextos clínicos nos quais a IA já é aplicada ou apresenta alto potencial de adoção. Dessa forma, especialidades com características semelhantes foram agrupadas, considerando tanto a demanda tecnológica quanto às práticas específicas de cada área. Essa abordagem permitiu a realização de comparações entre grupos, garantindo maior robustez às análises estatísticas subsequentes.

As respostas obtidas através do formulário eletrônico *Google Forms*, foram organizadas e tabuladas, permitindo o cálculo de notas globais para cada questão, além de categorizar as respostas em análises como médias, distribuições e relações entre variáveis. A estrutura do questionário e o uso da escala Likert foram projetados para garantir praticidade na coleta de dados e confiabilidade nos resultados, contribuindo diretamente para alcançar os objetivos da pesquisa.

3.4 PROCEDIMENTO PARA A ANÁLISE DOS DADOS

A análise dos dados foi conduzida utilizando métodos estatísticos para explorar as características dos participantes, compreender a percepção sobre o uso de ferramentas de IA na prática médica e avaliar as relações entre variáveis demográficas e dimensões do modelo TAM. Inicialmente, os dados foram tabulados e analisados com o uso do software Jamovi (versão 2.6.19), e Microsoft Excel. A técnica utilizada para cada objetivo está demonstrada nas matrizes de amarração, segundo os Quadros 1 e 2.

Inicialmente, um teste de normalidade foi conduzido para avaliar a distribuição das variáveis quantitativas. Quando o valor p foi inferior a 0,05, os dados foram considerados assimétricos, indicando o uso de métodos estatísticos não paramétricos. Caso o valor p fosse superior a 0,05, os dados seriam tratados como simétricos, permitindo o uso de métodos paramétricos. Uma vez que a amostra foi de conveniência e o número de participantes não foi conhecido previamente, o teste de normalidade apropriado foi selecionado com base no tamanho final da amostra, sendo escolhido o teste de Kolmogorov-Smirnov devido ao quantitativo de 256 participantes no estudo.

As estatísticas descritivas, como frequências e percentuais, foram realizadas para caracterizar o perfil dos participantes em termos de idade, gênero, especialidade médica, tempo de experiência profissional e nível de formação acadêmica. Os dados coletados sobre as variáveis do TAM (PU, PEOU, atitude em relação ao uso (ATU), intenção de uso (BI) e uso efetivo (AU) serão obtidas por meio da escala Likert de cinco pontos, organizadas e analisadas com base em médias, medianas, distribuições de frequência e relações entre variáveis. A análise descritiva foi utilizada para resumir os dados e explorar as tendências gerais das respostas.

Para avaliar a influência das variáveis demográficas sobre as dimensões PEOU e PU do modelo TAM foram utilizados testes não-paramétricos U de Mann-Whitney e Kruskal-Wallis para comparações equivalentes.

A Modelagem de Equações Estruturais (SEM) de mínimos quadrados parciais (*Partial Least Squares Structural Equation Modeling*, PLS-SEM) foi utilizada para realizar a análise simultânea das relações entre construtos e entre indicadores, ou seja, variáveis dependentes e variáveis independentes. Essa técnica foi escolhida devido à sua capacidade de lidar com modelos complexos que envolvem múltiplas variáveis independentes e dependentes inter-relacionadas (Hair Jr *et al.*, 2016). Esta etapa da análise de dados foi subdividida em duas fases: avaliação do modelo de mensuração e avaliação do modelo estrutural. A análise PLS-SEM foi realizada no software SmartPLS.

A abordagem de mínimos quadrados (PLS) é adequada frente a dados com distribuição não normal, característica comum em levantamentos baseados em questionários. Essa técnica também é recomendada para amostras de tamanho moderado, fornecendo resultados confiáveis mesmo em cenários onde os pressupostos estatísticos tradicionais não são plenamente atendidos. Por meio do SEM, foi possível avaliar os coeficientes de caminho (*path coefficients*), que indicam a força e a direção dos relacionamentos entre as variáveis, e validam o modelo teórico proposto com métricas específicas. Essa abordagem fornece *insights* detalhados sobre os fatores mais influentes na aceitação e no uso de IA pelos médicos, além de permitir a validação empírica do TAM no contexto da prática médica.

Os achados obtidos foram apresentados em forma de tabelas e figuras, facilitando a interpretação dos dados e a comparação entre os resultados das variáveis. As análises estatísticas foram realizadas com nível de significância de 5% ($p < 0,05$).

Quadro 1. Matriz de amarração do objetivo geral.

Objetivo geral	Técnica de coleta de dados	Técnicas de análises de dados
Analisar a aceitação de ferramentas de IA na prática médica em uma rede privada de hospitais no Brasil.	Questionário estruturado tipo <i>survey</i> contendo 33 perguntas acerca do perfil dos participantes (idade, gênero, especialidade médica, tempo de experiência profissional e nível de formação acadêmica) e variáveis do TAM (PU, PEOU, ATU, BI e AU).	- Análise estatística descritiva; - Kolmogorov-Smirnov; - U de Mann-Whitney; - Kruskal-Wallis; - PLS-SEM.

Fonte: Elaborado pelo autor (2025)

Quadro 2. Matriz de amarração dos objetivos específicos.

Objetivos específicos	Variáveis	Técnica de coleta de dados	Técnicas de análise de dados
(1) Descrever as características dos médicos participantes quanto à idade, gênero, especialidade médica, tempo de experiência profissional e nível de formação acadêmica.	- Idade - Gênero - Especialidade médica - Tempo de experiência profissional - Nível de formação acadêmica	Questionário estruturado tipo <i>survey</i>	- Análise estatística descritiva; - Kolmogorov-Smirnov; - U de Mann-Whitney; - Kruskal-Wallis; - PLS-SEM.
(2) Analisar a influência das variáveis demográficas sobre as dimensões Utilidade Percebida e Facilidade de Uso Percebida, do modelo TAM.	- Utilidade Percebida (PU) - Facilidade de Uso Percebida (PEOU)	Questionário estruturado tipo <i>survey</i>	
(3) Relacionar as variáveis Utilidade Percebida e Facilidade de Uso Percebida do TAM com as variáveis demográficas e variáveis relacionadas ao comportamento de aceitação (Atitude em Relação ao Uso, Intenção Comportamental de Uso e Uso Efetivo) dos médicos quanto à aceitação da IA na prática médica.	- Utilidade Percebida (PU) - Facilidade de Uso Percebida (PEOU) - Atitude em Relação ao Uso (ATU) - Intenção Comportamental de Uso (BI) - Uso Efetivo (AU) - Idade - Gênero - Especialidade médica - Tempo de experiência profissional - Nível de formação acadêmica	Questionário estruturado tipo <i>survey</i>	

Fonte: Elaborado pelo autor (2025)

4 RESULTADOS

Esta seção apresenta os resultados obtidos por meio do processamento e da análise dos dados coletados. Inicialmente, foi realizada uma análise estatística descritiva para caracterizar o perfil dos participantes da pesquisa, incluindo a distribuição de frequência das variáveis demográficas. Em seguida, a modelagem de equações estruturais foi empregada para validar o modelo proposto e testar as relações hipotetizadas, possibilitando a obtenção de implicações empíricas relevantes para o contexto da IA na prática médica.

4.1 CARACTERÍSTICAS DEMOGRÁFICAS DOS PARTICIPANTES

A amostra deste estudo foi composta por 256 médicos atuantes em uma rede privada de hospitais no Brasil (Tabela 1). A caracterização demográfica dos participantes abrangeu as variáveis idade, gênero, especialidade médica, tempo de atuação profissional e nível de formação acadêmica, permitindo traçar um perfil detalhado dos respondentes.

A distribuição etária revelou que a maioria dos participantes se encontra na faixa etária de 30 a 40 anos (33,2%) e 40 a 50 anos (28,1%), indicando que o grupo predominante da amostra tem entre 30 e 50 anos (61,3%). Essa distribuição sugere que a amostra é composta majoritariamente por médicos em faixas etárias com significância estatística.

A distribuição por gênero mostrou um equilíbrio entre homens e mulheres, com uma ligeira predominância feminina (50,4%). Essa distribuição sugere que não há um viés estatisticamente significativo na amostra em relação ao gênero.

Em relação à especialidade médica, a amostra incluiu uma diversidade de áreas, sendo as Especialidades Clínicas as mais representativas, com 119 médicos (46,5%). Em seguida, Especialidades Cirúrgicas foram reportadas por 90 participantes. Da totalidade, 19 participantes não especificaram sua especialidade. Esses dados refletem a diversidade de especialidades médicas na rede privada analisada, com predominância das áreas clínica e cirúrgica.

A análise do tempo de atuação profissional revelou uma predominância de médicos com mais de 20 anos de experiência (30,9%), seguidos dos médicos com 11 a 20 anos (27,3%). Profissionais com menos de 10 anos de experiência representaram 41,8% da amostra, evidenciando uma distribuição equilibrada entre médicos com experiência consolidada e profissionais em estágio inicial e intermediário de carreira.

A análise do nível de formação acadêmica revelou que a Residência Médica foi a modalidade de qualificação mais comum (50,4%), seguida pela Especialização (19,5%) e pela

Graduação (15,6%). Médicos com titulação de Mestrado e Doutorado foram menos frequentes, o que sugere que poucos profissionais médicos que atuam na rede analisada seguem a carreira acadêmica.

Tabela 1. Características demográficas dos médicos participantes da pesquisa.

Variável	Categorias	Número de participantes	Frequência (%)
Idade	Menos de 30 anos	39	15,2%
	30 - 40 anos	85	33,2%
	40 - 50 anos	72	28,1%
	Acima de 50 anos	59	23,0%
	Não informado	1	0,5%
Gênero	Masculino	127	49,6%
	Feminino	129	50,4%
Especialidade	Especialidades Terapêuticas	17	6,6%
	Especialidades Cirúrgicas	90	35,2%
	Especialidades Diagnósticas	7	2,7%
	Especialidades Clínicas	119	46,5%
	Especialidades Preventivas e Sociais	4	1,6%
	Não informado	19	7,4%
Tempo de Atuação	Menos de 5 anos	56	21,9%
	5 - 10 anos	51	19,9%
	11 - 20 anos	70	27,3%
	Acima de 20 anos	79	30,9%
Formação Acadêmica	Graduação	40	15,6%
	Especialização	50	19,5%
	Residência Médica	129	50,4%
	Mestrado	27	10,5%
	Doutorado	10	3,9%

4.2 INFLUÊNCIA DAS VARIÁVEIS DEMOGRÁFICAS SOBRE AS DIMENSÕES UTILIDADE E FACILIDADE DE USO PERCEBIDAS NO MODELO TAM

Antes de avaliar a influência das variáveis demográficas sobre as dimensões do TAM, foi realizado um teste de normalidade para verificar a distribuição dos dados. O teste de Kolmogorov-Smirnov foi aplicado às cinco dimensões do modelo, e os resultados indicaram que PU ($p = 0,042$), BI ($p = 0,044$), ATU ($p = 0,008$) e AU ($p = 0,023$) apresentaram distribuições significativamente diferentes da normal ($p < 0,05$). Apenas PEOU ($p = 0,215$) não

rejeitou a hipótese de normalidade, sugerindo uma distribuição mais próxima da normalidade para essa variável.

Diante desses achados, a seleção dos testes estatísticos para a comparação entre os grupos demográficos foi feita com o objetivo de garantir coerência metodológica e rigor analítico. Embora a variável PEOU tenha indicado distribuição normal, optou-se pelo uso de testes não paramétricos para todas as dimensões do modelo TAM, incluindo PEOU. Essa escolha se baseou em três aspectos principais: (1) a necessidade de manter uniformidade na abordagem estatística, (2) a robustez dos testes não paramétricos, como Mann-Whitney e Kruskal-Wallis, que lidam melhor com assimetria, heterogeneidade de variâncias e *outliers*, comuns em pesquisas comportamentais, e (3) o tamanho reduzido de alguns subgrupos demográficos, como idade, gênero, especialidade médica, tempo de atuação e formação acadêmica. Apesar de a amostra total ser suficientemente grande para testes de normalidade, os tamanhos reduzidos de alguns subgrupos poderiam comprometer a validade das suposições paramétricas, justificando o uso de testes estatísticos mais robustos.

Para analisar a influência das variáveis demográficas sobre as dimensões PEOU e PU, foi utilizado o teste de Kruskal-Wallis, adequado para comparar múltiplos grupos. Já para a variável gênero, que envolve a comparação entre dois grupos, aplicou-se o teste de Mann-Whitney, garantindo maior precisão na identificação de possíveis diferenças estatísticas.

4.2.1 Idade

Os resultados da influência da idade sobre as variáveis do modelo TAM estão apresentados na Tabela 2, indicando que não houve diferença estatisticamente significativa entre as faixas etárias para nenhuma das dimensões analisadas. Os resultados indicam que a idade dos médicos não influencia significativamente a aceitação da IA na prática médica.

Na dimensão PEOU, os resultados mostram que médicos de diferentes idades não percebem a IA como mais ou menos fácil de utilizar. A PU também não apresentou variação significativa entre os grupos etários, indicando que médicos de todas as idades enxergam a IA como igualmente útil em seu contexto de trabalho.

Tabela 2. Influência da Idade sobre as Dimensões do Modelo TAM.

Dimensão	χ^2 (Kruskal-Wallis)	p-valor
Facilidade de Uso Percebida (PEOU)	0,861	0,930
Utilidade Percebida (PU)	3,062	0,547

4.2.2 Gênero

Os resultados indicam que o gênero dos médicos influencia significativamente ambas dimensões, PEOU e PU, do modelo TAM. A PEOU apresentou uma diferença significativa entre os grupos ($p = 0,046$), sugerindo que os médicos do gênero masculino percebem a IA como mais fácil de usar do que as médicas. A PU também mostrou um efeito significativo ($p = 0,005$), indicando que médicos do gênero masculino avaliam a IA como mais útil do que as médicas.

Tabela 3. Influência do gênero sobre as dimensões do modelo TAM.

Dimensão	Gênero (média da dimensão)		U de Mann-Whitney	p-valor
	Feminino	Masculino		
Facilidade de Uso Percebida (PEOU)	3,18	3,34	7015	0,046
Utilidade Percebida (PU)	3,76	3,96	6549	0,005

Negrito indica valores estatisticamente significativos ($p < 0,05$).

4.2.3 Especialidade médica

As especialidades médicas foram organizadas em cinco categorias (Especialidades Cirúrgicas, Especialidades Diagnósticas, Especialidades Clínicas, Especialidades Preventivas e Sociais, e Especialidades Terapêuticas) conforme a natureza das atividades desempenhadas pelos profissionais (Tabela 4). Essa classificação permite compreender como diferentes áreas da medicina podem influenciar a percepção e adoção da IA na prática clínica.

Os achados indicam que não houve diferença estatisticamente significativa entre as categorias de especialidades para nenhuma das duas dimensões do modelo TAM analisadas, incluindo PEOU ($\chi^2 = 2,69$; $p = 0,747$) e PU ($\chi^2 = 3,68$; $p = 0,596$). A análise descritiva revelou que a amostra incluiu profissionais de diversas áreas da medicina, com maior representatividade de médicos das Especialidades Clínicas ($n = 119$) e Cirúrgicas ($n = 90$). Especialidades

terapêuticas, diagnósticas, preventivas e sociais apresentaram menor número de participantes. Apesar dessas diferenças no número de respondentes por especialidade, as médias de PEOU e PU não indicaram variações significativas entre os grupos.

O fato de alguns participantes não terem indicado a sua especialidade não afetou significativamente os resultados, indicando que a percepção sobre a utilidade e facilidade de uso da IA é consistente mesmo entre aqueles que optaram por não especificar sua área de atuação.

Tabela 4. Classificação das Especialidades Médicas por categoria.

Categoria	Especialidades Médicas
Especialidades Cirúrgicas	Cirurgia cardiovascular, Cirurgia da mão, Cirurgia de cabeça e pescoço, Cirurgia do aparelho digestivo, Cirurgia geral, Cirurgia oncológica, Cirurgia pediátrica, Cirurgia plástica, Cirurgia torácica, Cirurgia vascular, Coloproctologia, Ginecologia e obstetrícia, Mastologia, Neurocirurgia, Oftalmologia, Ortopedia e traumatologia, Otorrinolaringologia, Urologia.
Especialidades Diagnósticas	Endoscopia, Medicina nuclear, Patologia, Patologia clínica/medicina laboratorial, Radiologia e diagnóstico por imagem
Especialidades Clínicas	Alergia e imunologia, Angiologia, Cardiologia, Clínica médica, Dermatologia, Endocrinologia e metabologia, Gastroenterologia, Genética médica, Geriatria, Hematologia e hemoterapia, Homeopatia, Infectologia, Medicina de emergência, Medicina esportiva, Medicina intensiva, Nefrologia, Neurologia, Nutrologia, Pediatria, Pneumologia
Especialidades Preventivas e Sociais	Medicina de família e comunidade, Medicina de trânsito, Medicina do trabalho, Medicina legal e perícia médica, Medicina preventiva e social
Especialidades Terapêuticas	Acupuntura, Anestesiologia, Medicina física e reabilitação, Oncologia clínica, Psiquiatria, Radioterapia, Reumatologia

4.2.4 Tempo de atuação profissional

Os resultados indicam que o tempo de atuação profissional não apresentou influência significativa sobre as dimensões PEOU e PU do modelo TAM, conforme detalhado na Tabela 5. A partir das análises realizadas, sugiro apontar que: não foram encontradas diferenças estatisticamente significativas entre os grupos, independentemente do tempo de prática clínica.

Tabela 5. Influência do tempo de atuação profissional sobre as dimensões do modelo TAM.

Dimensão	χ^2 (Kruskal-Wallis)	p-valor
Facilidade de Uso Percebida (PEOU)	0,478	0,924
Utilidade Percebida (PU)	1,321	0,724

4.2.5 Formação acadêmica

Os resultados da análise da influência da formação acadêmica sobre PEOU e/ou PU do modelo TAM não apresentaram significância estatística (PEOU ($\chi^2 = 2,26$; $p = 0,688$) e PU ($\chi^2 = 2,16$; $p = 0,706$)). Isso significa que não houve influência significativa sobre estas duas dimensões do modelo, sugerindo que a formação acadêmica não representa um fator relevante para a aceitação da tecnologia.

4.3 AVALIAÇÃO DO MODELO DE MENSURAÇÃO

Para avaliar a adequação do modelo teórico aos dados observados, foi realizada uma análise do modelo de mensuração reflexivo, considerando a confiabilidade dos construtos, a validade convergente e a validade discriminante. Os indicadores avaliados incluem alfa de Cronbach, a Variância Média Extraída (AVE), a Confiabilidade Composta, o critério de Fornell-Larcker e *Heterotrait-Monotrait Ratio* (HTMT), conforme as recomendações da literatura (Hair Jr. *et al.*, 2016).

4.3.1 Confiabilidade dos construtos

Nesta pesquisa, a análise da confiabilidade foi realizada por meio do alfa de Cronbach, com o objetivo de avaliar a consistência interna dos construtos (ou dimensões) do modelo. A Tabela 6 apresenta os valores de confiabilidade para todas as dimensões analisadas. De acordo com a literatura, um alfa de Cronbach acima de 0,70 é considerado aceitável para indicar consistência interna satisfatória (Taber, 2017).

Os resultados indicam que os construtos PEOU, BI, AU e PU apresentaram valores de alfa de Cronbach acima do limite recomendado ($\geq 0,70$), demonstrando boa confiabilidade e consistência interna entre os itens que compõem cada dimensão. Entretanto, a ATU apresentou um valor negativo (-0,329), o que sugere inconsistências nos itens do questionário que mensuram essa dimensão, podendo indicar problemas na formulação dos itens ou baixa correlação entre eles.

Além do alfa de Cronbach, foi avaliada a Confiabilidade Composta, métrica que considera as cargas fatoriais dos itens e fornece uma estimativa mais robusta da confiabilidade dos construtos. Os valores de PEOU, BI, AU e PU foram superiores ao mínimo recomendado (0,70), confirmando a adequada confiabilidade interna desses construtos (Tabela 6). No entanto,

ATU apresentou um valor extremamente baixo (0,002), reforçando as limitações na sua mensuração e a necessidade de reformulação dos itens para garantir maior precisão na avaliação da atitude dos médicos em relação à IA. Sendo assim, a confiabilidade do modelo pode ser considerada satisfatória, exceto para ATU, que requer ajustes metodológicos para assegurar a validade da mensuração.

Tabela 6. Análise da confiabilidade dos construtos.

Construtos	Alfa de Cronbach	Confiabilidade Composta	AVE
Facilidade de Uso Percebida (PEOU)	0,769	0,838	0,469
Intenção de Uso (BI)	0,758	0,848	0,571
Uso Efetivo (AU)	0,892	0,925	0,756
Utilidade Percebida (PU)	0,880	0,906	0,508
Atitude em Relação ao Uso (ATU)	-0,329	0,002	0,330

AVE: Variância Média Extraída

4.3.2 Validade convergente

A validade convergente foi avaliada pela AVE, com valores superiores a 0,50 sendo considerados adequados para indicar que os itens medem suficientemente o construto subjacente (Hair Jr. *et al.*, 2016). Os construtos BI, AU e PU atingiram o critério mínimo esperado, demonstrando que mais de 50% da variância total desses construtos pode ser explicada pelos seus respectivos indicadores (questões). No entanto, PEOU (0,469) e ATU (0,330) apresentaram valores inferiores ao recomendado, sugerindo que os itens podem não estar refletindo de maneira consistente os conceitos que pretendem medir. Apesar da AVE ligeiramente abaixo do ideal, tanto o alfa de Cronbach de PEOU (0,769) quanto a Confiabilidade Composta (0,838) indicam boa consistência interna, o que reforça a validade do construto. Segundo Hair *et al.* (2021), um construto pode ser aceito caso tenha alta confiabilidade e a AVE esteja próxima do limite de 0,50. Outrossim, se a Confiabilidade Composta for superior a 0,70, isso reforça ainda mais a robustez do construto. Portanto, embora a AVE da PEOU esteja minimamente abaixo do critério, tal dimensão foi considerada válida e mantida no modelo, enquanto a AVE reduzida da ATU reforça os problemas já identificados na confiabilidade da escala.

Por outro lado, a ATU apresentou um AVE ainda menor (0,330), indicando uma possível fragilidade na consistência interna dos itens deste construto. Esse resultado é reforçado pelo alfa de Cronbach negativo (-0,329), apontando para problemas na confiabilidade interna

deste construto. Isso sugere que os itens da ATU podem não estar mensurando um único conceito de maneira consistente, o que pode demandar refinamento da escala ou exclusão de itens problemáticos.

4.3.3 Validade discriminante

A validade discriminante é um critério fundamental para garantir que os construtos de um modelo estrutural sejam conceitualmente distintos entre si. A validade discriminante foi verificada por meio do critério de Fornell-Larcker, que estabelece que a raiz quadrada da AVE de um construto deve ser maior do que a maior correlação com qualquer outro construto (Hair Jr. *et al.*, 2016). No estudo, os construtos PEOU, BI e AU atenderam a esse critério, demonstrando distinção adequada em relação aos demais (Tabela 7). No entanto, ATU (0,575) e PU (0,712) apresentaram correlações elevadas com outras dimensões, sugerindo sobreposição conceitual entre esses construtos. No caso de PU, apesar dessa inconsistência, a AVE foi de 0,508, superando o limite mínimo recomendado de 0,50, e o alfa de Cronbach foi 0,880, indicando alta confiabilidade interna. Esses fatores sugerem que a PU mantém validade aceitável, mesmo com a discrepância observada na validade discriminante.

Tabela 7. Análise da validade discriminante pelo critério de Fornell-Larcker.

Dimensões	ATU	PEOU	BI	AU	PU
Atitude em Relação ao Uso (ATU)	0,575				
Facilidade de Uso Percebida (PEOU)	0,582	0,685			
Intenção de Uso (BI)	0,696	0,598	0,756		
Uso Efetivo (AU)	0,328	0,430	0,377	0,870	
Utilidade Percebida (PU)	0,724	0,667	0,830	0,420	0,712

Duas abordagens complementares foram utilizadas para análise da validade discriminante a fim de determinar se o construto é único, sendo elas: a razão HTMT e o Fator de Inflação da Variância (*Variance Inflation Factor*, VIF). Valores elevados de HTMT (> 0,90) sugerem que dois construtos compartilham grande parte de sua variância, comprometendo a validade discriminante (Hair Jr. *et al.*, 2016). Já o VIF avalia a colinearidade entre variáveis preditoras, indicando se há redundância excessiva entre os indicadores de um mesmo modelo. Valores superiores a 3 são frequentemente considerados indicativos de multicolinearidade problemática, enquanto valores abaixo desse limite indicam colinearidade aceitável.

Nos resultados apresentados na Tabela 8, as relações $PU \rightarrow BI$ (0,980) e $PU \rightarrow ATU$ (0,938) apresentaram valores elevados na HTMT, indicando uma forte correlação entre esses

construtos e uma possível sobreposição conceitual. Ainda, o construto ATU demonstrou alta correlação com PU (0,724) e BI (0,696) (Tabela 7), sugerindo que os itens dessas dimensões podem estar capturando aspectos comuns, o que pode dificultar a distinção clara entre os fatores no modelo.

Tabela 8. Análise da validade discriminante pela razão HTMT.

Dimensões	ATU	PEOU	BI	AU	PU
Atitude em Relação ao Uso (ATU)					
Facilidade de Uso Percebida (PEOU)	0,845				
Intenção de Uso (BI)	0,868	0,718			
Uso Efetivo (AU)	0,518	0,515	0,435		
Utilidade Percebida (PU)	0,938	0,777	0,980	0,470	

Contudo, a análise de VIF revelou que todos os valores permaneceram abaixo do limite crítico de 3,0, conforme apresentado na Tabela 9. Os valores $PU \rightarrow ATU$ (1,801) e $PU \rightarrow BI$ (2,100) indicam colinearidade moderada, mas dentro de níveis aceitáveis. De forma similar, $ATU \rightarrow BI$ (2,100) apresentou um VIF um pouco mais elevado, mas ainda abaixo do limite preocupante. Os menores valores foram observados em $BI \rightarrow AU$ e $PEOU \rightarrow PU$, indicando baixa colinearidade entre esses pares de construtos, sugerindo que são estatisticamente independentes no modelo. Já a relação $PEOU \rightarrow ATU$ também apresentou moderada colinearidade, sem representar risco para a estabilidade da análise.

Tabela 9. Avaliação da multicolinearidade entre os construtos.

Relação das dimensões	VIF
$ATU > BI$	2,100
$BI > AU$	1,000
$PEOU > ATU$	1,801
$PEOU > PU$	1,018
$PU > ATU$	1,801
$PU > BI$	2,100

Dessa forma, embora os altos valores da HTMT possam indicar uma possível sobreposição conceitual entre PU, ATU e BI, a análise do VIF confirma que não há redundância excessiva entre os construtos. Isso sugere que a multicolinearidade não compromete a estabilidade estatística do modelo, mas reforça a necessidade de considerar potenciais ajustes nos itens do construto ATU para melhorar a distinção entre os fatores no modelo.

4.4 AVALIAÇÃO DO MODELO ESTRUTURAL

Após a avaliação do modelo de mensuração, procedeu-se à análise do modelo estrutural (Figura 2), com o objetivo de examinar a capacidade preditiva do modelo e a força das relações entre os construtos (Hair Jr. *et al.*, 2016). Essa abordagem permitiu identificar os fatores que influenciam diretamente e indiretamente a aceitação da IA na prática médica, analisando as inter-relações entre as variáveis e seus efeitos sobre o comportamento de adoção da tecnologia. Para isso, foram avaliados os coeficientes dos caminhos estruturais (*path coefficients*), bem como os efeitos diretos, indiretos e totais, determinando a significância estatística de cada relação por meio do método de *bootstrapping*.




Figura 2. Modelo estrutural da aceitação da IA na prática médica. A figura apresenta o modelo estrutural testado, ilustrando as relações entre variáveis demográficas e os principais construtos do TAM. As variáveis independentes, representadas em laranja, foram analisadas quanto à sua influência sobre os construtos do TAM. As variáveis dependentes do modelo, destacadas em azul, refletem os principais fatores associados à aceitação da tecnologia. Os indicadores, representados em amarelo, correspondem às variáveis observadas associadas a cada uma das dimensões do TAM. As setas direcionais evidenciam os efeitos diretos das variáveis demográficas sobre os construtos do modelo, bem como as relações internas entre os componentes do TAM. Figura elaborada no software SmartPLS.

A etapa estrutural do estudo foi projetada para responder à seguinte questão de pesquisa: quais são os principais fatores que determinam a aceitação da IA na prática médica? Para investigá-la, empregou-se a PLS-SEM (*Partial Least Squares Structural Equation Modeling*),

possibilitando a identificação das relações mais relevantes entre os construtos do Modelo TAM e as variáveis independentes analisadas. Essa metodologia permitiu testar um conjunto de hipóteses relacionadas à aceitação da IA, considerando os coeficientes padronizados (β), os valores de significância estatística (p-valor) e o tamanho do efeito (f^2). Como critério para confirmação das hipóteses, adotou-se um p-valor inferior a 0,05.

Além da significância estatística, o tamanho do efeito (f^2) foi calculado para mensurar a intensidade da influência de uma variável independente sobre uma variável dependente no modelo estrutural. Essa métrica complementa o p-valor ao fornecer uma estimativa do impacto prático das relações no modelo. No contexto da PLS-SEM, os valores de f^2 são interpretados conforme os critérios de Cohen (1988), sendo que valores inferiores a 0,02 são considerados desprezíveis, indicando que, embora a relação possa ser estatisticamente significativa ($p < 0,05$), seu efeito prático é insignificante. Dessa forma, a análise estrutural não apenas verifica a existência de associações estatisticamente relevantes, mas também avalia sua importância substantiva na aceitação da IA pelos médicos.

4.4.1 Efeitos diretos das relações estruturais

A Tabela 10 apresenta os resultados das análises das relações hipotetizadas entre as variáveis independentes e dependentes, destacando os efeitos diretos no modelo estrutural. Algumas hipóteses foram confirmadas, enquanto outras não obtiveram suporte estatístico suficiente e de tamanho de efeito, conforme detalhado na tabela.

Dentre as relações confirmadas, destaca-se a forte influência da PU sobre a BI ($\beta = 0,686$, $p < 0,001$, $f^2 = 0,769$), reforçando que os médicos tendem a adotar a IA quando percebem benefícios concretos em sua aplicação clínica. A BI demonstrou um efeito direto sobre o AU ($\beta = 0,377$, $p < 0,001$, $f^2 = 0,166$), indicando que os profissionais que manifestam intenção de utilizar a tecnologia efetivamente incorporam a IA em sua prática médica. Esses achados corroboram a literatura sobre aceitação de tecnologia, destacando que a adoção da IA na prática médica está fortemente vinculada à PU e à intenção prévia de uso.

A PEOU também demonstrou relevância, influenciando significativamente PU ($\beta = 0,659$, $p < 0,001$, $f^2 = 0,791$) e ATU ($\beta = 0,178$, $p = 0,003$, $f^2 = 0,039$). Isso sugere que médicos que percebem a IA como fácil de usar tendem a considerá-la mais útil e a adotar uma atitude mais favorável em relação à sua utilização. No entanto, o efeito da PEOU sobre ATU foi de menor magnitude, indicando que, embora a facilidade de uso tenha um impacto, sua influência na atitude é mais limitada em comparação ao da PU.

Tabela 10. Hipóteses de efeito direto testadas no Modelo Estrutural.

Hipótese	Relação	Coefficiente (β)	p-valor	Tamanho do efeito (f^2)	Hipótese confirmada?
H1	Idade $\rightarrow$ PEOU	-0,037	0,762	0,000	Não
H2	Idade $\rightarrow$ PU	0,060	0,496	0,002	Não
H3	Gênero $\rightarrow$ PEOU	-0,413	0,107	0,011	Não
H4	Gênero $\rightarrow$ PU	-0,330	0,070	0,012	Não
H5	Especialidade $\rightarrow$ PEOU	-0,047	0,463	0,002	Não
H6	Especialidade $\rightarrow$ PU	-0,003	0,952	0,000	Não
H7	Escolaridade $\rightarrow$ PEOU	-0,062	0,412	0,003	Não
H8	Escolaridade $\rightarrow$ PU	0,082	0,167	0,009	Não
H9	Tempo de atuação $\rightarrow$ PEOU	-0,001	0,994	0,000	Não
H10	Tempo de atuação $\rightarrow$ PU	-0,41	0,107	0,010	Não
H11	PEOU $\rightarrow$ PU	0,659	0,000	0,791	Sim
H12	PEOU $\rightarrow$ ATU	0,178	0,002	0,038	Sim
H13	PU $\rightarrow$ ATU	0,605	0,000	0,443	Sim
H14	ATU $\rightarrow$ BI	0,199	0,001	0,064	Sim
H15	PU $\rightarrow$ BI	0,686	0,000	0,769	Sim
H16	BI $\rightarrow$ AU	0,377	0,000	0,166	Sim

Por outro lado, as variáveis demográficas como idade, tempo de atuação, especialidade e formação acadêmica, não demonstraram influência estatisticamente significativa sobre PU e PEOU, com valores de β muito próximos de zero e f^2 insignificantes. A relação entre gênero e PEOU ($\beta = -0,413$, $p = 0,107$) e entre gênero e PU ($\beta = -0,330$, $p = 0,070$), não apresentou significância estatística, indicando que não há evidências de que o gênero dos médicos afeta diretamente a PEOU e PU da IA na prática médica. Embora o efeito sobre PU tenha sido ligeiramente maior, sua magnitude foi desprezível, sugerindo que eventuais diferenças entre gêneros na aceitação da IA não são expressivas o suficiente para impactar a adoção da tecnologia.

Esses resultados indicam que características demográficas não são determinantes na aceitação da IA, reforçando a hipótese de que a adoção da tecnologia é mais influenciada pela PU e PEOU do que por fatores individuais pré-existentes. Assim, os achados reforçam a ideia de que a adoção da IA é impulsionada majoritariamente por percepções subjetivas da tecnologia e não por características demográficas ou profissionais.

Os resultados reforçam a centralidade das variáveis PU, PEOU e BI na aceitação da IA na prática médica. Do mesmo modo, evidenciam que fatores individuais possuem baixa relevância prática.

4.4.2 Efeitos indiretos das relações estruturais

A análise dos efeitos indiretos no modelo estrutural permitiu identificar relações mediadas entre os construtos investigados, proporcionando uma compreensão mais aprofundada dos mecanismos que influenciam a aceitação da tecnologia. Esses efeitos demonstram como diferentes variáveis influenciam indiretamente o AU da IA na prática médica, reforçando o papel da mediação na estrutura do modelo.

Os resultados indicaram que todas as hipóteses de efeitos indiretos foram confirmadas ($p < 0,05$), destacando a importância das relações mediadas (Tabela 11). O efeito indireto mais expressivo foi o impacto da PEOU sobre a BI por meio da PU ($\beta = 0,453$, $p < 0,001$). Esse achado confirma que a percepção de facilidade não apenas afeta diretamente a aceitação da tecnologia, mas também potencializa a PU, tornando a IA mais atraente para adoção. Esse efeito mediado ressalta a necessidade de garantir interfaces intuitivas e acessíveis, pois estas ampliam a percepção de benefícios e incentivam a intenção de uso da tecnologia.

Tabela 11. Hipóteses de efeito indireto testadas no Modelo Estrutural.

Hipótese	Relação	Coefficiente (β)	p-valor	Hipótese confirmada?
H17	PEOU $\rightarrow$ PU $\rightarrow$ ATU $\rightarrow$ BI	0,079	0,001	Sim
H18	PEOU $\rightarrow$ PU $\rightarrow$ BI	0,453	0,000	Sim
H19	PEOU $\rightarrow$ PU $\rightarrow$ ATU $\rightarrow$ BI $\rightarrow$ AU	0,030	0,002	Sim
H20	PEOU $\rightarrow$ ATU $\rightarrow$ BI $\rightarrow$ AU	0,013	0,031	Sim
H21	PEOU $\rightarrow$ PU $\rightarrow$ BI $\rightarrow$ AU	0,171	0,000	Sim
H22	PEOU $\rightarrow$ ATU $\rightarrow$ BI	0,035	0,021	Sim
H23	PEOU $\rightarrow$ PU $\rightarrow$ ATU	0,399	0,000	Sim
H24	PU $\rightarrow$ BI $\rightarrow$ AU	0,259	0,000	Sim
H25	PU $\rightarrow$ ATU $\rightarrow$ BI	0,120	0,001	Sim
H26	PU $\rightarrow$ ATU $\rightarrow$ BI $\rightarrow$ AU	0,045	0,001	Sim
H27	ATU $\rightarrow$ BI $\rightarrow$ AU	0,075	0,001	Sim

Outro efeito indireto relevante foi a influência da PEOU sobre a ATU por meio da PU ($\beta = 0,079$, $p = 0,001$), sugerindo que médicos que percebem a IA como fácil de utilizar tendem a desenvolver uma atitude mais favorável em relação à sua adoção, desde que também percebam utilidade na tecnologia. Esse resultado reforça a interdependência entre a usabilidade e a percepção de valor agregado da IA. Da mesma forma, a PU demonstrou impacto indireto sobre o AU por meio da BI ($\beta = 0,259$, $p < 0,001$), indicando que, embora médicos reconheçam os benefícios da IA, essa percepção precisa se converter primeiro em uma intenção consolidada de uso para que ocorra a adoção efetiva.

A análise também confirmou que a PEOU exerce influência indireta sobre o AU por meio da PU e BI ($\beta = 0,171$, $p < 0,001$), evidenciando que a facilidade percebida afeta a adoção da IA quando mediada pela PU e pela intenção de adoção. A ATU impactou indiretamente o AU por meio da BI ($\beta = 0,075$, $p = 0,001$), sugerindo que uma atitude positiva em relação à IA só se traduzirá em adoção caso esteja acompanhada de uma intenção concreta de utilização.

Esses achados corroboram os pressupostos do modelo TAM, demonstrando que a PEOU e a PU são fatores essenciais para a aceitação da IA na prática médica. Os efeitos indiretos analisados evidenciam que a BI é o principal determinante do AU, ressaltando a importância de estratégias que fortaleçam a percepção de utilidade e a facilidade de uso da tecnologia. Para maximizar a adoção, é fundamental que sejam desenvolvidas iniciativas que aprimorem a usabilidade da IA e reforcem a percepção de seus benefícios práticos na rotina profissional dos médicos.

4.4.3 Efeitos totais das relações estruturais

A análise dos efeitos totais permitiu uma compreensão mais ampla das relações entre os construtos do modelo TAM, considerando tanto os efeitos diretos quanto os indiretos. Os resultados apresentados na Tabela 12 confirmam que a PU exerce a maior influência total sobre a BI ($\beta = 0,807$), consolidando-se como o principal determinante da intenção de adoção da IA na prática médica. Esse achado confirma que médicos que percebem a IA como útil estão mais propensos a incorporá-la à sua rotina profissional. Adicionalmente, a BI apresentou um efeito total significativo sobre AU ($\beta = 0,377$), indicando que a intenção de adoção se traduz diretamente na utilização da tecnologia.

Outro efeito total relevante foi o impacto da PEOU sobre a PU ($\beta = 0,659$), confirmando que a PEOU influencia diretamente a PU da IA. A PEOU também teve um efeito total expressivo sobre a BI ($\beta = 0,567$), o que sugere que tecnologias mais intuitivas favorecem tanto a PU quanto a intenção de adoção da IA. A PEOU impacta a ATU ($\beta = 0,577$), tanto de forma direta quanto indireta por meio da PU, reforçando a importância da experiência do usuário na aceitação da tecnologia.

A PU influencia de maneira significativa a ATU ($\beta = 0,605$), demonstrando que médicos que percebem a IA como útil tendem a desenvolver uma atitude mais favorável à sua adoção. Esse achado sugere a importância de enfatizar os benefícios concretos da IA no ambiente profissional dos médicos para aumentar sua aceitação.

Algumas variáveis demográficas apresentaram efeitos totais fracos ou não significativos, sugerindo que fatores individuais não são determinantes para a aceitação da IA. Idade, tempo de atuação e formação acadêmica não exerceram influência relevante sobre PEOU e PU, indicando que a adoção da tecnologia é impulsionada mais por percepções subjetivas do que por características demográficas.

Os resultados indicam que o gênero apresentou um efeito total moderado sobre PU ($\beta = -0,602$, $p = 0,015$). Isso sugere que, embora o gênero não exerça uma influência expressiva na percepção da PEOU, ele afeta significativamente a PU da IA.

Da mesma forma, a especialidade médica apresentou um efeito total negativo sobre PEOU ($\beta = -0,047$) e PU ($\beta = -0,034$), ambos sem significância estatística. Esse resultado indica que, no contexto da amostra estudada, a especialidade médica não influencia de maneira relevante a PEOU e PU da IA.

Os resultados dos efeitos totais das dimensões confirmam o papel central da PU, PEOU e BI na aceitação da IA, enquanto fatores individuais como idade, gênero e tempo de atuação não apresentaram impacto estatisticamente significativo.

Tabela 12. Hipóteses de efeito total testadas no Modelo Estrutural.

Hipótese	Hipótese	Efeito Total (β)	p-valor	Hipótese confirmada?
H1	Idade $\rightarrow$ PEOU	-0,037	0,762	Não
H2	Idade $\rightarrow$ PU	0,035	0,760	Não
H3	Gênero $\rightarrow$ PEOU	-0,413	0,107	Não
H4	Gênero $\rightarrow$ PU	-0,602	0,015	Sim
H5	Especialidade $\rightarrow$ PEOU	-0,047	0,463	Não
H6	Especialidade $\rightarrow$ PU	-0,034	0,606	Não
H7	Escolaridade $\rightarrow$ PEOU	-0,062	0,412	Não
H8	Escolaridade $\rightarrow$ PU	0,041	0,569	Não
H9	Tempo de Atuação $\rightarrow$ PEOU	-0,001	0,994	Não
H10	Tempo de Atuação $\rightarrow$ PU	-0,142	0,228	Não
H11	PEOU $\rightarrow$ PU	0,659	0,000	Sim
H12	PEOU $\rightarrow$ ATU	0,577	0,000	Sim
H13	PU $\rightarrow$ ATU	0,605	0,000	Sim
H14	ATU $\rightarrow$ BI	0,199	0,001	Sim
H28*	ATU $\rightarrow$ AU	0,075	0,001	Sim
H15	PU $\rightarrow$ BI	0,807	0,000	Sim
H16	BI $\rightarrow$ AU	0,377	0,000	Sim
H29*	PEOU $\rightarrow$ BI	0,567	0,000	Sim
H30*	PEOU $\rightarrow$ AU	0,214	0,000	Sim
H31*	PU $\rightarrow$ BI	0,807	0,000	Sim
H32*	PU $\rightarrow$ AU	0,304	0,000	Sim

* Hipóteses totais originadas da soma entre os efeitos diretos e indiretos das variáveis e que não constavam anteriormente como hipótese de efeito direto ou de efeito indireto.

4.5 MODELO DE ACEITAÇÃO AJUSTADO DA IA NA PRÁTICA MÉDICA

Com base nos resultados obtidos na modelagem de equações estruturais, propõe-se um modelo ajustado (Figura 3), inspirado no TAM, para refinar a compreensão dos fatores que impactam a aceitação e o uso efetivo da tecnologia, garantindo maior robustez teórica e consistência empírica. O modelo preserva os principais componentes do TAM, incluindo PEOU, PU, ATU, BI e AU. Entretanto, relações que não demonstraram significância estatística ou relevância prática foram removidas.

Os resultados confirmam que a PEOU tem um impacto direto e positivo sobre a PU, reforçando a ideia de que tecnologias de fácil uso tendem a ser percebidas como mais úteis pelos usuários. A PEOU também influencia diretamente a ATU, sugerindo que a facilidade de uso pode aumentar a predisposição dos usuários para adotar a tecnologia.

A PU demonstrou influência significativa sobre a BI, indicando que a percepção de utilidade da tecnologia é um fator determinante para a decisão de utilizá-la. De maneira

semelhante, a ATU impacta a BI, demonstrando que a atitude comportamental dos usuários é um fator relevante para a adoção da tecnologia.

A BI apresentou um impacto positivo e significativo sobre o AU, confirmando que a intenção de adoção de uma tecnologia está diretamente relacionada ao seu uso real. Esses achados corroboram os pressupostos do modelo TAM e reforçam a importância da PU e da BI como variáveis centrais na aceitação tecnológica.




Figura 3. Modelo estrutural ajustado de aceitação da IA na prática médica.

A figura apresenta o modelo estrutural ajustado, ilustrando as relações entre as dimensões do modelo TAM. As variáveis dependentes do modelo, destacadas em azul, refletem os principais fatores associados à aceitação da tecnologia. Os indicadores, exibidos em amarelo, correspondem às variáveis observadas associadas a cada uma das dimensões do TAM. As setas direcionais indicam os efeitos diretos das variáveis demográficas sobre os construtos do modelo, bem como as relações internas entre os componentes do TAM. Figura elaborada no software SmartPLS.

4.5.1 Capacidade preditiva do modelo ajustado

A capacidade preditiva do modelo ajustado foi avaliada por meio do Coeficiente de Determinação (R^2) e do R^2 Ajustado, que indicam a proporção da variância explicada pelos preditores em cada construto endógeno (Hair Jr. *et al.*, 2016). O R^2 reflete o percentual de variância de uma variável dependente que pode ser explicado pelo modelo, enquanto o R^2

Ajustado corrige esse valor considerando o número de preditores no modelo, sendo mais adequado para comparar modelos com diferentes quantidades de variáveis e para evitar superestimações.

A Tabela 13 apresenta os valores de R^2 ajustado para o modelo teórico (com variáveis demográficas) e para o modelo ajustado (após a exclusão dessas variáveis). Os resultados indicam que a remoção das variáveis demográficas não comprometeu a capacidade explicativa do modelo, pois os valores de R^2 ajustado permaneceram praticamente inalterados para os principais construtos do modelo TAM.

A BI obteve o maior coeficiente de determinação ajustado ($R^2 = 0.707$ no modelo final), indicando que o modelo explica 70,7% da variabilidade da intenção de uso da tecnologia. A ATU também manteve um R^2 elevado (0.541 no modelo ajustado), reforçando sua importância na aceitação da tecnologia. A PU apresentou um R^2 moderado (0.445 no modelo final), enquanto o AU teve um R^2 baixo (0.141), sugerindo que outros fatores não modelados podem influenciar a adoção prática da tecnologia.

A ATU apresentou um R^2 Ajustado de 0,540, indicando que 54% da variância nesse construto é explicada pelos preditores. Esse resultado reforça a importância das variáveis antecedentes, como a PU e a PEOU, na formação de atitudes favoráveis em relação à tecnologia. A PU obteve um R^2 Ajustado de 0,457, demonstrando que os fatores preditivos explicam 45,7% da variabilidade na percepção de utilidade da IA. Embora seja um valor moderado, reforça que a PEOU desempenha um papel relevante na percepção de utilidade da tecnologia.

A variável AU apresentou o menor valor de R^2 Ajustado em comparação às variáveis BI, ATU e PU. Esse resultado sugere que, embora a BI tenha um impacto significativo sobre o uso real da tecnologia, outros fatores não contemplados no modelo podem estar influenciando a adoção prática da IA.

Tabela 13. Comparação da Capacidade Preditiva do Modelo Teórico e Ajustado (R^2 Ajustado).

Dimensão	R^2 Ajustado - Modelo Teórico	R^2 Ajustado - Modelo Ajustado
Atitude em Relação ao Uso (ATU)	0,538	0,541
Intenção de Uso (BI)	0,706	0,707
Uso Efetivo (AU)	0,139	0,141
Utilidade Percebida (PU)	0,455	0,445

5 DISCUSSÃO

A pesquisa analisou a aceitação da IA na prática médica em uma rede privada de hospitais no Brasil, fornecendo informações sobre os fatores que influenciam sua adoção pelos médicos. Os resultados indicaram que a amostra foi composta majoritariamente por profissionais entre 30 e 50 anos, com uma distribuição equilibrada entre os gêneros (50,4% do gênero feminino). As Especialidades Clínicas foram as mais representativas, abrangendo quase 50% dos participantes, e a maioria dos médicos possuía mais de 20 anos de experiência profissional e formação em residência médica.

As variáveis demográficas — idade, tempo de experiência, especialidade médica e nível de formação acadêmica — não influenciaram significativamente a aceitação da IA. Esse achado diverge de estudos que apontam maior propensão dos profissionais mais jovens à adoção de novas tecnologias (Venkatesh; Davis, 2000), mas corrobora pesquisas recentes que indicam que a idade pode não ser um fator determinante para a aceitação de tecnologias médicas (Scherer *et al.*, 2022). A adoção da IA na medicina parece depender mais da familiaridade tecnológica e do suporte organizacional do que de características etárias (Venkatesh; Thong; Xu, 2012; Fernandes, 2024). Considerando o avanço das práticas clínicas e a necessidade de atualização contínua, todos os médicos, independentemente da idade, precisam desenvolver competências tecnológicas para manter a eficiência na prática médica (Dias, 2020).

O tempo de atuação profissional também não apresentou influência significativa sobre nenhuma das cinco dimensões do modelo TAM. Esse resultado pode estar relacionado à crescente acessibilidade das tecnologias médicas baseadas em IA, que possuem interfaces intuitivas e são adaptadas à rotina clínica, além do aumento de treinamentos institucionais que reduzem barreiras à adoção tecnológica (Coelho; Esteves; Ragognete, 2024). Estudos indicam que a aceitação da IA está mais associada à exposição prévia à tecnologia e ao suporte organizacional do que à experiência acumulada na profissão (Pereira, 2022). A confiabilidade dos sistemas e sua integração eficiente nos fluxos de trabalho clínico são fatores mais relevantes para a aceitação tecnológica do que o tempo de atuação do usuário (Coutinho, 2023).

De forma semelhante, a formação acadêmica não exerceu influência significativa na aceitação da IA, sugerindo que médicos com diferentes níveis de qualificação (graduação, especialização, residência médica, mestrado e doutorado) percebem e utilizam a tecnologia de maneira semelhante. Isso indica que a titulação acadêmica não é um fator determinante para a adoção da IA na prática médica (Costa; Santos, 2024). Embora a formação acadêmica possa contribuir para a adoção de novas tecnologias, a familiaridade prática e o contexto

organizacional têm um impacto maior na implementação bem-sucedida da IA. A formação médica tradicional ainda apresenta lacunas no ensino de novas tecnologias, tornando o aprendizado prático no ambiente clínico um fator mais determinante para a aceitação da IA (Melhem, 2024).

A especialidade médica não influenciou significativamente a aceitação da IA, sugerindo que a predisposição dos médicos para adotar a tecnologia é uniforme, independentemente da área de atuação clínica. Esse achado está alinhado a pesquisas que indicam que fatores organizacionais e humanos têm um impacto maior na aceitação da IA do que a especialidade médica em si (Quinn *et al.*, 2020; Hemmer *et al.*, 2022; Pereira *et al.*, 2022).

A variável gênero apresentou relação estatisticamente significativa com PEOU e PU, sugerindo que médicos do gênero masculino percebem a IA como mais fácil de usar e mais útil do que as médicas do gênero feminino. Essa diferença pode estar relacionada à familiaridade prévia com tecnologias digitais, visto que estudos indicam que homens tendem a demonstrar maior confiança no uso de novas ferramentas tecnológicas (Jelembi, 2023). Entretanto, essa diferença, apesar de estatisticamente significativa, teve um efeito pequeno, não configurando um fator determinante na adoção da IA. Isso indica que estratégias para promover a adoção da IA devem se concentrar em aspectos organizacionais, culturais e na capacitação contínua dos profissionais, em vez de fatores demográficos (Ferreira; Del Caro; El Rifai, 2024).

No tocante aos resultados obtidos por meio da modelagem de equações estruturais com mínimos quadrados parciais (PLS-SEM), foi possível avaliar a confiabilidade e a validade dos construtos do modelo proposto. A análise da consistência interna evidenciou que os construtos PEOU, BI, AU e PU apresentaram confiabilidade satisfatória. Em contrapartida, o construto ATU apresentou um valor negativo de alfa (-0,329), sinalizando ausência de correlação entre os itens e possíveis inconsistências na formulação das questões (Kline, 2023). Tal fragilidade pode estar associada à sobreposição conceitual com outras variáveis, à escassez de indicadores ou à inadequação na redação dos itens que compõem o construto (Benedik; Andrade; Silva, 2021).

A validade convergente, mensurada pela AVE, indicou que PU, BI e AU atenderam ao critério mínimo recomendado ($\geq 0,50$) (Fornell; Larcker, 1981). No entanto, PEOU e ATU apresentaram valores abaixo do esperado, sugerindo que seus itens podem não estar capturando o conceito teórico proposto (Roldán; Cepeda, 2022). Outrossim, a validade discriminante pelo critério de Fornell-Larcker mostrou que ATU e PU apresentaram correlações elevadas, indicando uma possível sobreposição conceitual e necessidade de reformulação dos itens (Ramayah *et al.*, 2021).

Os resultados confirmaram a centralidade da PU e da BI como principais determinantes da aceitação da IA, alinhando-se ao modelo TAM. A PU emergiu como o principal fator que impulsiona a BI, sugerindo que os médicos adotam a tecnologia quando percebem benefícios concretos para a prática clínica (Venkatesh; Davis, 2000; Ramayah *et al.*, 2018). A BI apresentou efeito significativo sobre o AU, demonstrando que médicos que expressam intenção de uso efetivamente incorporam a IA à sua rotina (Henseler *et al.*, 2015). A relação entre PEOU e PU reforçou que tecnologias percebidas como fáceis de usar são consideradas mais úteis pelos médicos, validando um dos princípios fundamentais do modelo TAM (Bagozzi; Yi, 2012). A PEOU também influenciou ATU, sugerindo que a usabilidade da IA pode contribuir para uma atitude mais positiva, embora com menor impacto. A mediação de PU na relação entre PEOU e BI foi confirmada, evidenciando que a facilidade de uso, isoladamente, não garante a adoção da IA, sendo necessário demonstrar seus benefícios concretos no ambiente clínico.

Os resultados indicam que estratégias para aumentar a aceitação da IA devem focar na PU e na PEOU, promovendo treinamentos, demonstrações práticas e integração intuitiva da tecnologia nos fluxos de trabalho clínicos. Dado o impacto limitado das variáveis demográficas, recomenda-se que futuras pesquisas incorporem fatores organizacionais, como suporte institucional, incentivos ao uso da tecnologia e sua integração nos processos clínicos (Kumar; Chauhan; Awasthi, 2023). O modelo TAM pode ser expandido com variáveis organizacionais para uma compreensão mais aprofundada dos desafios na adoção da IA no ambiente médico.

Os tamanhos de efeito (f^2) das relações entre os construtos foram avaliados para determinar o impacto prático de cada variável no modelo. A PU apresentou o maior efeito sobre a BI, indicando que médicos percebem a utilidade da IA como um fator determinante para sua adoção. A BI, por sua vez, influenciou significativamente o AU, reforçando a relação direta entre BI e adoção efetiva da tecnologia. Por outro lado, o efeito de PEOU sobre ATU foi menor, sugerindo que a PEOU pode contribuir para uma atitude mais favorável em relação à IA, mas não de forma decisiva para a aceitação. De maneira semelhante, a relação entre gênero e PU/PEOU apresentou efeitos baixos, indicando que, apesar de estatisticamente significativa, sua influência prática é limitada. Esses achados sugerem que as estratégias para aumentar a adoção da IA devem focar prioritariamente na PU e BI, ao invés de características demográficas dos profissionais.

A capacidade preditiva do modelo ajustado foi avaliada por meio do coeficiente de determinação (R^2), que indica a proporção da variância explicada por cada variável dependente. Os resultados apontaram que o R^2 da BI foi moderado, enquanto o R^2 do AU foi mais baixo, sugerindo que a intenção de adoção da IA não se traduz integralmente em comportamento real.

Esse achado reforça a literatura existente, que destaca que barreiras organizacionais e institucionais podem impedir que a intenção de adoção se converta efetivamente em uso prático da tecnologia (Venkatesh; Davis, 2000; Holden; Karsh, 2010).

Diante desses achados, foi elaborado um modelo ajustado, baseado no TAM, com o objetivo de aprimorar a compreensão dos fatores determinantes da adoção da IA na prática médica. A estrutura central do modelo foi mantida, incluindo as cinco variáveis principais (PEOU, PU, ATU, BI e AU). As variáveis demográficas, que não demonstraram significância estatística ou impacto prático relevante, foram removidas do modelo. Os efeitos indiretos destacaram que PU mediou a relação entre PEOU e BI, reforçando que apenas a PEOU não garante a adoção da IA sem que haja clareza sobre seus benefícios práticos. A relação entre ATU e BI indica que, embora uma atitude favorável seja importante, ela não garante a adoção sem que os profissionais desenvolvam uma intenção concreta de uso.

Dessa forma, o modelo ajustado melhora a capacidade explicativa do TAM no contexto médico, fornecendo uma estrutura mais eficiente para entender os fatores que impulsionam a aceitação da IA. Esses achados sugerem que políticas de implementação devem focar menos em fatores demográficos e mais na percepção de utilidade e no incentivo institucional, garantindo que os médicos compreendam e confiem na IA como uma ferramenta de suporte clínico eficaz.

Este estudo apresenta algumas limitações que devem ser consideradas na interpretação dos resultados. A amostra foi composta exclusivamente por médicos de uma rede privada de hospitais, o que pode restringir a generalização dos achados para outras instituições, especialmente do setor público, onde as condições de trabalho e a infraestrutura tecnológica podem ser significativamente diferentes. O delineamento transversal utilizado impossibilita a análise de mudanças nas percepções dos profissionais ao longo do tempo. Estudos longitudinais poderiam fornecer uma compreensão mais detalhada sobre a evolução da aceitação da IA conforme sua implementação avança. Outra limitação refere-se ao método de coleta de dados, realizado exclusivamente por meio de questionários autoaplicáveis, sem a complementação com abordagens qualitativas, como entrevistas. Embora essa abordagem permita uma análise quantitativa estruturada, pode restringir a compreensão de aspectos subjetivos e organizacionais que influenciam a aceitação da IA.

Adicionalmente, algumas questões utilizadas no estudo foram elaboradas especificamente para esta pesquisa, o que pode ter impactado a validade de certos construtos. A confiabilidade da variável ATU apresentou fragilidades, conforme evidenciado pelos baixos valores de alfa de Cronbach e AVE, sugerindo a necessidade de revisão dos itens que compõem

essa dimensão. Para estudos futuros, recomenda-se a reformulação desses itens, bem como a realização de testes estatísticos adicionais para validar sua consistência interna.

Por fim, a exclusão das variáveis demográficas do modelo ajustado, embora tenha resultado em uma estrutura mais enxuta e focada nos principais determinantes da adoção da IA, pode ter limitado a análise de interações entre fatores individuais e tecnológicos. Para aprimorar o modelo, sugere-se que pesquisas subsequentes considerem fatores organizacionais, como suporte institucional, incentivos e integração da IA nos fluxos de trabalho clínicos, visto que esses elementos podem desempenhar um papel mais relevante na aceitação da tecnologia do que características individuais dos profissionais.

6 CONCLUSÃO E CONSIDERAÇÕES FINAIS

Os resultados deste estudo reforçam a aplicabilidade do modelo TAM na explicação da aceitação da IA na prática médica. A modelagem de equações estruturais validou a estrutura central do modelo, confirmando que a PU e a BI são os principais determinantes da adoção da IA, enquanto a PEOU exerce um efeito indireto, mediado pela PU. A relação entre BI e AU foi confirmada, evidenciando que médicos que demonstram BI são os que efetivamente integram a IA à sua prática profissional.

Os fatores demográficos analisados - idade, tempo de atuação, especialidade médica e formação acadêmica - não apresentaram impacto estatisticamente significativo sobre PU e PEOU, indicando que a aceitação da IA depende mais da percepção subjetiva da tecnologia do que das características individuais dos médicos. O gênero apresentou um efeito estatisticamente significativo, mas com baixa relevância prática, o que justificou sua exclusão no modelo ajustado. Esses achados sugerem que iniciativas voltadas à implementação da IA devem priorizar aspectos funcionais e institucionais, ao invés de focar em diferenças demográficas.

Do ponto de vista prático, os resultados indicam que estratégias eficazes para aumentar a adoção da IA devem se concentrar no treinamento, no suporte técnico e na integração da IA nos fluxos de trabalho clínico. O reconhecimento da PU como mediadora entre PEOU e BI destaca que a PEOU, por si só, não garante a adoção da IA, sendo essencial demonstrar benefícios concretos para que os médicos desenvolvam uma intenção clara de uso.

Considerando os resultados obtidos para o construto ATU, sugere-se que estudos futuros revisem os itens que compõem essa dimensão, com o objetivo de aprimorar sua consistência interna e garantir maior precisão na mensuração da atitude de uso frente à IA. Outro ponto a ser considerado é a inclusão de fatores organizacionais no modelo TAM ajustado pode aprimorar a explicação da aceitação da IA, explorando variáveis como suporte institucional, incentivos ao uso da IA e infraestrutura tecnológica. Diferente dos fatores individuais, que tiveram impacto limitado, barreiras organizacionais podem representar desafios significativos para a implementação da IA na prática médica. Assim, integrar esses aspectos ao modelo pode proporcionar uma visão mais abrangente dos fatores que influenciam a adoção da IA, permitindo o desenvolvimento de estratégias mais eficazes para sua incorporação no setor da saúde.

A reformulação do modelo ajustado, baseada na modelagem de equações estruturais, preservou a validade teórica do TAM, eliminando relações sem significância estatística e propondo um modelo mais enxuto e consistente. Com isso, este estudo contribui para a

literatura sobre aceitação de tecnologia na medicina, fornecendo um arcabouço teórico e empírico robusto, que pode ser expandido em investigações futuras. Os achados fornecem subsídios práticos para gestores e desenvolvedores de tecnologia, orientando a criação de políticas institucionais voltadas à implementação eficiente da IA no setor médico.

7 REFERÊNCIAS

- ALHASHMI, S. *et al.* Implementing Artificial Intelligence in the United Arab Emirates Healthcare Sector: An Extended Technology Acceptance Model. **International Journal of Information Technology and Language Studies (IJITLS)**, v. 3, n. 3, p. 27-42, 2019.
- ALI, I.; WARRAICH, N. F.; BUTT, K. Acceptance and use of artificial intelligence and AI-based applications in education: A meta-analysis and future direction. **Information Development**, p. 02666669241257206, 2024.
- ALQUDAH, A. A.; AL-EMRAN, M.; SHAALAN, K. Technology Acceptance in Healthcare: A Systematic Review. **Appl. Sci.**, v. 11, p. 10537, 2021.
- AMMENWERTH, E. Technology Acceptance Models in Health Informatics: TAM and UTAUT. **Applied Interdisciplinary Theory in Health Informatics**, v. 263, p. 64-71, 2020.
- ANGELOV, P. P. *et al.* Explainable artificial intelligence: an analytical review. **Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery**, v. 11, n. 5, p. e1424, 2021.
- ARIEF, A. *et al.* Age-Dependent User Perception Analysis of Web Application Using Technology Acceptance Model Approach: A Case Study. **Technium: Romanian Journal of Applied Sciences and Technology**, v. 17, n. 1, p. 95–99, 2023.
- BAADER, F.; BREWKA, G.; EITER, T. Proceedings of the Joint German/Austrian Conference on AI: Advances in Artificial Intelligence. **ACM Digital Library**, 2001. Disponível em: <https://dl.acm.org/doi/proceedings/10.5555/647620>. Acesso em: 01 dez. 2024.
- BAGOZZI, R. P.; YI, Y. Specification, evaluation, and interpretation of structural equation models. **Journal of the Academy of Marketing Science**, v. 40, p. 8-34, 2012.
- BENEDIK, F. N. *et al.* Desenvolvimento e validação de aplicativo móvel para cálculo de dose pediátrica na unidade de terapia intensiva pediátrica e urgência e emergência. **Revista Eletrônica Acervo Saúde**, v. 13, n. 3, p. e6498-e6498, 2021.
- BORGES, A. F. S. *et al.* A IA pode transformar a forma como as empresas lidam com o atendimento ao cliente, proporcionando experiências mais rápidas e personalizadas, o que é crucial para a satisfação e a fidelização dos clientes. **Journal of Business Research**, v. 120, p. 1-10, 2020.
- BRALL, C.; SCHRÖDER-BÄCK, P.; MAECKELBERGHE, E. Ethical aspects of digital health from a justice point of view. **European Journal of Public Health**, v. 29, n. Supplement_3, p. 18-22, 2019.
- BRIGANTI, G.; LE MOINE, O. Artificial intelligence in medicine: today and tomorrow. **Frontiers in medicine**, v. 7, n. 27, p. 509744, 2020.
- CARVALHO, L. O. R. *et al.* **Metodologia científica: teoria e aplicação na educação a distância**. Petrolina: UNIVASF, 2019.

CHEN, M.; DECARY, M. Artificial intelligence in healthcare: An essential guide for health leaders. **Health Manage Forum**, v. 33, n. 1, p. 10-18, 2020. DOI 10.1177/0840470419873123

CHEN, M. *et al.* Acceptance of clinical artificial intelligence among physicians and medical students: a systematic review with cross-sectional survey. **Frontiers in Medicine**, v. 9, p. 990604, 2022. DOI 10.3389/fmed.2022.990604

CIMPERMAN, M.; BRENCIC, M.; TRKMAN, P. Analyzing older users' home telehealth services acceptance behavior-applying an Extended UTAUT model. **Int J Med Inform**, v. 90, p. 22-31, 2016. DOI 10.1016/j.ijmedinf.2016.03.002

COELHO, R. L. *et al.* Desafios e avanços na personalização diagnóstica e terapêutica na era da inteligência artificial na saúde. **Brazilian Journal of Implantology and Health Sciences**, v. 6, n. 1, p. 1282-1290, 2024.

CONNELLY, J. A. *et al.* Os robôs cirúrgicos assistidos por IA estão transformando a prática cirúrgica, aumentando a precisão e reduzindo erros, o que pode resultar em cirurgias mais seguras e eficazes. **Journal of Surgical Research**, v. 253, p. 30-40, 2020.

CONNOLLY, C. *et al.* Artificial Intelligence in Interprofessional Healthcare Practice Education—Insights from the Home Health Project, an Exemplar for Change. **Computers in the Schools**, v. 40, n. 4, p. 412-429, 2023.

CORDEIRO, J. V. Digital technologies and data science as health enablers: an outline of appealing promises and compelling ethical, legal, and social challenges. **Frontiers in Medicine**, v. 8, p. 647897, 2021.

CORNELISSEN, L. *et al.* The drivers of acceptance of artificial intelligence-powered care pathways among medical professionals: web-based survey study. **JMIR Formative Research**, v. 6, n. 6, p. e33368, 2022.

COSTA, M. J. M.; SANTOS, D. W. ; BOTTENTUIT JUNIOR, J. B. Inteligência artificial e metodologias ativas no ensino de medicina: percepções dos discentes de habilidades médicas de um centro universitário. **Intersaberes**, v. 19, 2024.

COUTINHO, L. G. *et al.* Inteligência artificial em cardiologia: do teorema de Bayes às redes neurais de aprendizado profundo. **Revista Científica Hospital Santa Izabel**, v. 7, n. 4, p. 148-158, 2023.

CUNHA, D. O.; ZOUAIN, D. M. Fatores determinantes da adoção de sistemas de informação em saúde: um estudo sobre o prontuário médico eletrônico em Niterói. **Revista Tecnologia e Sociedade**, v. 19, n. 58, p. 79-104, 2023.

DAVENPORT, T; KALAKOTA, R. The potential for artificial intelligence in healthcare. **Future Healthcare Journal**, v. 6, n. 2, p. 94-98, 2019.

DAVIS, F. D.; BAGOZZI, R. P.; WARSHAW, P. R. User Acceptance of Computer Technology: A Comparison of Two Theoretical Models. **Management Science**, v. 35, n. 8, p. 982-1003, 1989.

DAVIS, F. D. Perceived usefulness, perceived ease of use, and user acceptance of information technology. **MIS Quarterly**, v. 13, n. 3, p. 319-340, 1989.

DESSILOMBA, G. A.; TANAAMAH, A. R. Technology Acceptance Model (TAM) for Evaluating Acceptance Pega Application at PT. Sinar Mas Insurance Policy Services Division. **INTENSIF: Jurnal Ilmiah Penelitian Dan Penerapan Teknologi Sistem Informasi**, v. 5, n. 1, p. 134-147, 2021.

DIACONU, A. *et al.* Expending the power of artificial intelligence in preclinical research: an overview. In: **IOP Conference Series: Materials Science and Engineering**. IOP Publishing, p. 012036, 2022.

DIAS, T. F. F. **O impacto da inteligência artificial na promoção do desenvolvimento empresarial com base no aproveitamento dos efeitos pandémicos deixados pela COVID-19**. Dissertação (Mestrado em Gestão) - ISCTE Business School, Portugal, p. 73. 2020.

DONGARI, S. *et al.* Advancing Healthcare through Artificial Intelligence: Innovations at the Intersection of AI and Medicine. **Tuijin Jishu/Journal of Propulsion Technology**, v. 44, n. 2, 2023.

DUAN, Y.; EDWARDS, J. S.; DWIVEDI, Y. K. Artificial intelligence for decision making in the era of Big Data—evolution, challenges and research agenda. **International Journal of Information Management**, v. 48, p. 63–71, 2019.

DWIVEDI, Y. K. *et al.* Artificial Intelligence (AI): Multidisciplinary perspectives on emerging challenges, opportunities, and agenda for research, practice and policy. **International Journal of Information Management**, v. 57, p. 101994, 2021.

ELAHI, B. Is AI in Healthcare Doomed, or Destined for Greatness? **Journal of System Safety**, v. 55, n. 3, p. 23-27, 2020.

FATHEMA, N.; SHANNON, D.; ROSS, M. Expanding the Technology Acceptance Model (TAM) to examine faculty use of Learning Management Systems (LMSs) in higher education institutions. **Journal of Online Learning & Teaching**, v. 11, n. 2, 2015.

FAVARON, G. **Os Invernos da IA: Ciclos de Ascensão e Queda na História da Inteligência Artificial**. 2024. Disponível em: <https://www.guilhermefavaron.com.br/post/os-invernos-da-ia-ciclos-de-ascensao-e-queda-na-historia-da-inteligencia-artificial#:~:text=Introdu%C3%A7%C3%A3o%20aos%20Invernos%20da%20IA&text=Os%20Invernos%20da%20IA%20referem,o%20futuro%20dessa%20tecnologia%20transformador>. Acesso em: 10 dez. 2024.

FERNANDES, J. M. F. **Otimização das práticas de saúde: integração de big data e inteligência artificial no diagnóstico médico**. Dissertação (Mestrado em Comunicação, Cultura e Tecnologias de Informação). ISCTE - Sociologia e Políticas Públicas, Portugal, p. 70. 2024.

FERREIRA, M. D. *et al.* Uso da tecnologia na personalização de protocolos de reabilitação em pacientes pós-cirúrgico. **Brazilian Journal of Implantology and Health Sciences**, v. 6, n. 10, p. 19-31, 2024.

FORNELL, C.; LARCKER, D. F. Evaluating structural equation models with unobservable variables and measurement error. **Journal of Marketing Research**, v. 18, n. 1, p. 39-50, 1981.

GEETHA *et al.* Navigating the Ai landscape: A systematic guide to solving complex challenges. **International Journal of Scientific Research in Engineering and Management**, v. 07, n. 11, p. 1–11, 2023.

GOMES, M. **A revolução da Inteligência Artificial (IA) na saúde já começou**. São Paulo: Salvus, 2021. Disponível em <https://blog.salvus.me/a-revolucao-da-inteligencia-artificial-ia-na-saude-ja-comecou>. Acesso em: 28 de nov. 2024.

GOMES, R. S. **Aplicação do modelo de aceitação da tecnologia (TAM) para analisar os fatores que afetam o uso do Google Classroom entre estudantes do ensino médio**. Monografia (Especialização em Informática na Educação) - Instituto Federal do Espírito Santo, Vitória, p. 37, 2022.

GUNNING, D. *et al.* XAI—Explainable artificial intelligence. **Science Robotics**, v. 4, n. 37, p. eaay7120, 2019.

HAENLEIN, M.; KAPLAN, A. A Brief History of Artificial Intelligence: On the Past, Present, and Future of Artificial Intelligence. **California Management Review**, v. 61, n. 4, p. 5-14, 2019.

HAIR Jr, J. F.; HULT, G. T. M.; RINGLE, C.; SARSTEDT, M. **A primer on partial least squares structural equation modeling (PLS-SEM)**. Sage Publications, 2016.

HARHOFF, D. *et al.* Outline for a German Strategy for Artificial Intelligence. **SSRN Electronic Journal**, 2018.

HAZARIKA, I. Artificial intelligence: opportunities and implications for the health workforce. **Int Health**, v. 12, n. 4, p. 241-245, 2020.

HE, J. *et al.* The practical implementation of artificial intelligence technologies in medicine. **Nature Medicine**, v. 25, n. 1, p. 30-36, 2019.

HELM, J. M. *et al.* Machine Learning and Artificial Intelligence: Definitions, Applications, and Future Directions. **Current reviews in musculoskeletal medicine**, v. 13, p. 69-76, 2020.

HEMMER, P. *et al.* Factors that influence the adoption of human-AI collaboration in clinical decision-making. **arXiv preprint arXiv:2204.09082**, 2022.

HENSELER, J.; RINGLE, C. M.; SARSTEDT, M. A new criterion for assessing discriminant validity in variance-based structural equation modeling. **Journal of the Academy of Marketing Science**, v. 43, p. 115-135, 2015.

HOLDEN, R. J.; KARSH, B. T. The technology acceptance model: its past and its future in health care. **Journal of Biomedical Informatics**, v. 43, n. 1, p. 159-172, 2010.

HUWAIDA, H. *et al.* E-Learning Acceptance in Business Administration Department State Polytechnic of Banjarmasin. **Jurnal Multidisiplin Madani**, v. 3, n. 8, p. 1712-1725, 2023.

ISHENGOMA, F. R. Artificial intelligence in digital health: Issues and dimensions of ethical concerns. **Innovation and Software**, v. 3, n. 1, p. 81-108, 2022.

ISLAM, M. M. Exploring the Impact of Artificial Intelligence in Healthcare. **Journal of Artificial Intelligence General Science**, v. 2, n. 1, p. 171-188, 2024.

JELEMBI, A. Inteligência artificial, ética e autonomia pessoal. **Lex Medicinæ: Revista Portuguesa de Direito da Saúde**, v. 19, n. 39, 2023.

KAPLAN, A.; HAENLEIN, M. Rulers of the world, unite! The challenges and opportunities of artificial intelligence. **Business Horizons**, v. 63, n. 1, p. 37-50, 2020.

KAPLAN, A.; HAENLEIN, M; Siri, Siri, in my hand: Who's the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence. **Business Horizons**, v. 62, n. 1, p. 15-25, 2019.

KAUL, V.; ENSLIN, S.; GROSS, S. A. The history of artificial intelligence in medicine. **Gastrointestinal Endoscopy**, v. 92, n. 4, p. 807-812, 2020.

KLINE, R. B. **Principles and practice of structural equation modeling**. Guilford Publications, 2023.

KLOKA, J. A. *et al.* Expectations of anesthesiology and intensive care professionals toward artificial intelligence: Observational study. **JMIR Formative Research**, v. 7, n. 1, p. e43896, 2023.

KOWALEWSKA, Ewelina. Physicians and AI in healthcare: insights from a mixed-methods study in Poland on adoption and challenges. **Frontiers in Digital Health**, v. 7, p. 1556921, 2025.

KUMAR, P.; CHAUHAN, S.; AWASTHI, L. K. Artificial intelligence in healthcare: review, ethics, trust challenges & future research directions. **Engineering Applications of Artificial Intelligence**, v. 120, p. 105894, 2023.

KUMAR, Y. *et al.* Artificial intelligence in disease diagnosis: a systematic literature review, synthesizing framework and future research agenda. **Journal of Ambient Intelligence and Humanized Computing**, v. 14, p. 8459–8486, 2023.

LAKSONO, S.; DARMAWAN, E. S. The new leadership paradigm in digital health and its relations to hospital services. **Jurnal Ilmu Kesehatan Masyarakat**, v. 12, n. 2, p. 89-103, 2021.

LAMBERT, S. I. *et al.* An integrative review on the acceptance of artificial intelligence among healthcare professionals in hospitals. **NPJ Digit Med**, v. 6, n. 1, p. 111, 2023.

LONGONI, C.; BONEZZI, A.; MOREWEDGE, C. K. Resistance to Medical Artificial Intelligence. **Journal of Consumer Research**, v. 46, n. 4, p. 629-650, 2019.

LUCENA, G. B. **A utilização de chatbots em atendimento de consultas médicas: uma análise baseada no modelo de aceitação de tecnologia**. 2023. 50 f. Monografia (Graduação em Administração) - Faculdade de Economia, Administração, Atuariais, Contabilidade e Secretariado, Universidade Federal do Ceará, Fortaleza, 2023.

MAASSEN, O. *et al.* Future medical artificial intelligence application requirements and expectations of physicians in German university hospitals: web-based survey. **Journal of medical Internet research**, v. 23, n. 3, p. e26646, 2021.

MACEDO, A. F. *et al.* Percepção de docentes acerca do uso da inteligência artificial na formação médica. **Revista Interagir**, v. 19, n. 126, p. 109-115, 2024. Disponível em: <https://doi.org/10.12662/1809-5771ri.126.5584.p109-115.2024>

MALATJI, W. R.; VAN ECK, R.; ZUVA, T. Understanding the usage, Modifications, Limitations and Criticisms of Technology Acceptance Model (TAM). **Advances in Science, Technology and Engineering Systems Journal**, v. 5, n. 6, p. 113-117, 2020.

MARIKYAN, D.; PAPAGIANNIDIS, S. **Technology acceptance model: a review**. TheoryHub Book, 2024.

MARTINS, C. I. F. S. **Documentação e avaliação do processo clínico**. 2018. 124 f. Dissertação (Mestrado em Mestrado integrado em Engenharia e Gestão de Sistemas de Informação) - Universidade do Minho, Escola de Engenharia, Portugal, 2018.

MELHEM, A. J. J. *et al.* **Raciocínio clínico para iniciantes na educação médica: desenvolvimento de habilidades e avaliação em comparação com especialistas e inteligência artificial**. 2024. 153 f. Tese (Programa de Pós-Graduação em Desenvolvimento Comunitário - Doutorado) - Universidade Estadual do Centro-Oeste, Irati, 2024.

MINAYO, M.C.S (Org). **Pesquisa Social: Teoria, método e criatividade**. 29 ed. Petrópolis: Vozes, 2010.

OH, S. *et al.* Physician confidence in artificial intelligence: an online mobile survey. **Journal of Medical Internet research**, v. 21, n. 3, p. e12422, 2019.

Organização Mundial da Saúde. (2021). **Estratégia global sobre saúde digital 2020-2025. Organização Mundial da Saúde**. Disponível em: <https://iris.who.int/handle/10665/344249>. Acesso em: 02 dez. 2024.

PAI, F. Y.; HUANG, K. I. Applying the technology acceptance model to the introduction of healthcare information systems. **Technological Forecasting and Social Change**, v. 78, n. 4, p. 650-660, 2011.

PARK, E. S.; PARK, M. S. Factors of the technology acceptance model for construction IT. **Applied Sciences**, v. 10, n. 22, p. 8299, 2020.

PASRICHA, S. Ethics for digital medicine: A path for ethical emerging medical IoT design. **Computer**, v. 56, n. 7, p. 32-40, 2023.

PEREIRA, M. J. E. **O impacto da inteligência artificial na área da saúde**. 2022. 75 f .Dissertação (Mestrado em Gestão de Empresas) - ISCTE, Business School, Portugal, 2022.

PEREIRA, K. S. S. *et al.* Fatores que influenciam a aceitação de tecnologias de inteligência artificial na saúde. **Revista Gestão & Saúde**, v. 13, n. 01, p. 02-20, 2022.

QUINN, T. P. *et al.* Trust and medical AI: the challenges we face and the expertise needed to overcome them. **Journal of the American Medical Informatics Association**, v. 28, n. 4, p. 890-894, 2021.

RAHIMI, B. *et al.* A systematic review of the technology acceptance model in health informatics. **Applied Clinical Informatics**, v. 9, n. 03, p. 604-634, 2018.

RAMAYAH, T. J. F. H. *et al.* **Partial least squares structural equation modeling (PLS-SEM) using SmartPLS 3.0**. An updated guide and practical guide to statistical analysis, p. 967-978, 2018.

RAPER, R. Introduction: The Pursuit for Moral Machines. In: **Raising Robots to be Good: A Practical Foray into the Art and Science of Machine Ethics**. Cham: Springer Nature Switzerland, 2024. p. 1-5.

REINHART, L. *et al.* Artificial intelligence in child development monitoring: A systematic review on usage, outcomes and acceptance. **Intelligence-Based Medicine**, v. 9, p. 100134, 2024.

RONG, G. *et al.* Artificial Intelligence in Healthcare: Review and Prediction Case Studies. **Engineering**, v. 6, n. 3, p. 291-301, 2020.

RONY, Moustaq Karim Khan et al. Healthcare workers' knowledge and attitudes regarding artificial intelligence adoption in healthcare: A cross-sectional study. **Heliyon**, v. 10, n. 23, 2024.

ROPPELT, J. S.; KANBACH, D. K.; KRAUS, S. Artificial intelligence in healthcare institutions: A systematic literature review on influencing factors. **Technology in Society**, v. 76, 2024.

RUBIYANTI, N. *et al.* Perceived Usefulness: A Bibliometric Visualization. In: **2023 International Conference on Digital Business and Technology Management (ICONDBTM)**. IEEE, p. 1-6, 2023.

SCHWALBE, N.; WAHL, B. Artificial intelligence and the future of global health. **The Lancet**, v. 395, n. 10236, p. 1579-1586, 2020.

SECINARO, S. *et al.* The role of artificial intelligence in healthcare: a structured literature review. **BMC Medical Informatics and Decision Making**, v. 21, n. 1, p. 125, 2021.

SESTINO, A.; D'ANGELO, A. Elderly patients' reactions to gamification-based digital therapeutics (DTx): The relevance of socialization tendency seeking. **Technological Forecasting and Social Change**, v. 205, n. 123526, p. 123526, 2024.

SHEN, H. *et al.* Mass data processing and multidimensional database management based on deep learning. **Open Computer Science**, v. 12, n. 1, p. 300-313, 2022.

SHORTLIFFE, E. H. Mycin: A knowledge-based computer program applied to infectious diseases. In: **Proceedings of the Annual Symposium on Computer Application in Medical Care**. American Medical Informatics Association, p. 66. 1977. Disponível em: <https://pmc.ncbi.nlm.nih.gov/articles/PMC2464549/>. Acesso em: 11 dez. 2024.

SHORTLIFFE, E. H.; SEPÚLVEDA, M. J. Clinical decision support systems based on artificial intelligence can increase the efficiency of diagnosing and treating diseases, providing doctors with accurate and real-time information. **Journal of Biomedical Informatics**, v. 78, p. 80-90, 2018.

SIEGEL, S. **2024 global health care sector outlook**. 2024. Disponível em: https://www.deloitte.com/global/en/Industries/life-sciences-health-care/analysis/global-health-care-outlook.html?utm_source=chatgpt.com. Acesso em: 11 dez. 2024.

SIENA, O. *et al.* **Metodologia da Pesquisa Científica e Elementos para Elaboração e Apresentação de Trabalhos Acadêmicos**. Belo Horizonte: Editora Poisson, 2024.

SILVA, A. M. da. **Metodologia da Pesquisa**. 2 ed. Fortaleza: EDUECE, 2015.

SILVA, J. B. *et al.* Laboratórios remotos como alternativa para atividades práticas em cursos na modalidade EAD. **EaD em Foco**, v. 10, n. 2, 2020.

SITORUS, H. M. *et al.* Technology adoption: An interaction perspective. In: **IOP Conference Series: Materials Science and Engineering**. IOP Publishing, p. 012080, 2016.

SONG, Y. Artificial Intelligence Algorithms in Biomedical Application. In: **2023 International Conference on Intelligent Supercomputing and BioPharma (ISBP)**. IEEE, p. 42-47, 2023.

SUNARTI, S. *et al.* Artificial intelligence in healthcare: opportunities and risk for future. **Gaceta sanitaria**, v. 35, p. S67-S70, 2021.

TAHERDOOST, H. Importance of technology acceptance assessment for successful implementation and development of new technologies. **Global Journal of Engineering Sciences**, 2019.

TAMORI, H. *et al.* Acceptance of the use of artificial intelligence in medicine among Japan's doctors and the public: a questionnaire survey. **JMIR Human Factors**, v. 9, n. 1, p. e24680, 2022.

- THAYYIB, P. V. *et al.* State-of-the-Art of Artificial Intelligence and Big Data Analytics Reviews in Five Different Domains: A Bibliometric Summary. **Sustainability**, v. 15, n. 5, p. 4026, 2023.
- TJOA, E.; GUAN, C. A Survey on Explainable Artificial Intelligence (XAI): Toward Medical XAI. **IEEE Trans Neural Netw Learn Syst**, v. 32, n. 11, p. 4793-4813, 2020.
- TOPOL, E. J. High-performance medicine: the convergence of human and artificial intelligence. **Nature Medicine**, v. 25, p. 44-56, 2019.
- TUBAISHAT, A. Perceived usefulness and perceived ease of use of electronic health records among nurses: Application of Technology Acceptance Model. **Inform Health Soc Care**, 2017.
- VÄÄNÄNEN, A. *et al.* AI in healthcare: A narrative review. **F1000Research**, v. 10, p. 6, 2021.
- VENKATESH, V. *et al.* User acceptance of information technology: Toward a unified view. **MIS Quarterly**, v. 27, n. 3, p. 425-478, 2003.
- VENKATESH, V.; DAVIS, F. D. A theoretical extension of the technology acceptance model: four longitudinal field studies. **Management Science**, v. 46, n. 2, p. 186-204, 2000.
- VENKATESH, V.; BALA, H. . Technology Acceptance Model 3 and a Research Agenda on Interventions. **Decision Sciences**, v. 39, n. 2, p. 273-315, 2008.
- VENKATESH, V.; THONG, J. Y. L.; XU, X. Consumer acceptance and use of information technology: extending the unified theory of acceptance and use of technology. **MIS Quarterly**, p. 157-178, 2012.
- VITORINO, A. J. **Estudo do comportamento dos profissionais de saúde frente ao uso de sistema informatizado no apoio à prática clínica**. 2022. Tese (Doutorado) – Universidade de São Paulo, São Paulo, 2022.
- WALKER, S. K.; HONG, S. Workplace predictors of parenting educators' technology acceptance attitudes. **Family and Consumer Sciences Research Journal**, v. 45, n. 4, p. 377-393, 2017.
- YU, K.; BEAM, A. L.; KOHANE, I. S. Artificial intelligence in healthcare. **Nature Biomedical Engineering**, v. 2, n. 10, p. 719-731, 2018.
- YUN, Y.; YANG, Y.; LIM, H. A SNS Data-driven Comparative Analysis on Changes of Attitudes toward Artificial Intelligence. **Journal of Digital Convergence**, v. 14, n. 12, p. 173-182, 2016.
- ZHANG, C.; LU, Y. Study on artificial intelligence: The state of the art and future prospects. **Journal of Industrial Information Integration**, v. 23, p. 100224, 2021.

ZHANG, Q.; MA, L. From perceptions to actions: Unveiling factors influencing diabetic patients' attitudes and compliance intention with smart blood glucose management technology. **International Journal of Human-Computer Interaction**, p. 1–18, 2024.

8 APÊNDICE - A

O questionário estruturado do tipo *survey* consta abaixo nesta seção para possibilitar o detalhamento das questões a serem abordadas na presente pesquisa.

TAM	Identificação	Pergunta	Alternativas de Respostas	Referência
Não se aplica	1	Qual a sua idade?	☐ < 30 anos ☐ ≥ 30-40 anos ☐ ≥ 40-50 anos ☐ > 50 anos ☐ Não especificado	Pergunta padrão para caracterização demográfica.
	2	Qual o seu sexo?	☐ Masculino ☐ Feminino ☐ Prefiro não responder	Pergunta padrão para caracterização demográfica.
	3	Qual é a especialidade médica em que você mais atua durante a sua jornada semanal de trabalho?	☐ Acupuntura ☐ Alergia e imunologia ☐ Anestesiologia ☐ Angiologia ☐ Cardiologia ☐ Cirurgia cardiovascular ☐ Cirurgia da mão ☐ Cirurgia de cabeça e pescoço ☐ Cirurgia do aparelho digestivo ☐ Cirurgia geral ☐ Cirurgia oncológica ☐ Cirurgia pediátrica ☐ Cirurgia plástica ☐ Cirurgia torácica ☐ Cirurgia vascular ☐ Clínica médica ☐ Coloproctologia ☐ Dermatologia ☐ Endocrinologia e metabologia ☐ Endoscopia ☐ Gastroenterologia ☐ Genética médica ☐ Geriatria ☐ Ginecologia e obstetria	Adaptado de Cornelissen <i>et al.</i> , 2022

	☐ Hematologia e hemoterapia ☐ Homeopatia ☐ Infectologia ☐ Mastologia ☐ Medicina de emergência ☐ Medicina de família e comunidade ☐ Medicina do trabalho ☐ Medicina de trânsito ☐ Medicina esportiva ☐ Medicina física e reabilitação ☐ Medicina intensiva ☐ Medicina legal e perícia médica ☐ Medicina nuclear ☐ Medicina preventiva e social ☐ Nefrologia ☐ Neurocirurgia ☐ Neurologia ☐ Nutrologia ☐ Oftalmologia ☐ Oncologia clínica ☐ Ortopedia e traumatologia ☐ Otorrinolaringologia ☐ Patologia ☐ Patologia clínica/medicina laboratorial ☐ Pediatria ☐ Pneumologia ☐ Psiquiatria ☐ Radiologia e diagnóstico por imagem ☐ Radioterapia ☐ Reumatologia ☐ Urologia ☐ Não especificado ☐ Outro: _____
--	--

	4	Quantos anos de experiência profissional você possui?	☐ < 5 anos ☐ ≥ 5-10 anos ☐ ≥ 11-20 anos ☐ ≥ 20 anos ☐ Não especificado	Adaptado de Kloka <i>et al.</i> , 2023
	5	Qual é o seu nível de escolaridade/formação acadêmica?	☐ Graduação ☐ Especialização ☐ Residência Médica ☐ Mestrado ☐ Doutorado ☐ Pós-Doutorado	Adaptado de Kloka <i>et al.</i> , 2023
1 Percepção de Facilidade de Uso (PEOU)	6	Considero que as ferramentas de IA aplicadas à medicina são fáceis de usar.	☐ Não aplica ☐ Discordo totalmente ☐ Discordo ☐ Não concordo nem discordo ☐ Concordo ☐ Concordo totalmente	Adaptado de Cornelissen <i>et al.</i> , 2022; Sitorus <i>et al.</i> , 2016
	7	Confio que as ferramentas de IA podem ser integradas à minha prática clínica sem dificuldades.		Adaptado de Tamori <i>et al.</i> , 2022
	8	A utilização de ferramentas de IA não causaria interrupção ou atraso no atendimento clínico.		Adaptado de Huwaida <i>et al.</i> , 2023
	9	Creio que é possível utilizar ferramentas de IA sem a necessidade de suporte técnico constante.		Adaptado de Davis, 1989
	10	Estou familiarizado(a) com as aplicações de IA voltadas para a minha especialidade médica.		Proposto pelo presente estudo
	11	Acredito que o uso da IA na prática clínica não requer muito esforço mental.		Adaptado de Walker; Hong, 2017
2 Percepção de Utilidade (PU)	12	Acredito que existem oportunidades para o desenvolvimento de ferramentas de IA na minha especialidade médica.	☐ Não aplica ☐ Discordo totalmente ☐ Discordo ☐ Não concordo nem discordo ☐ Concordo ☐ Concordo totalmente	Proposto pelo presente estudo
	13	Acredito que a IA pode trazer avanços significativos na minha especialidade médica nos próximos anos.		Proposto pelo presente estudo
	14	O uso da IA reduzirá a carga de trabalho ao realizar tarefas repetitivas.		Adaptado de Cornelissen <i>et al.</i> , 2022
	15	Eu considero que as ferramentas de IA são promissoras para melhorar a precisão dos diagnósticos médicos.		Adaptado de Oh <i>et al.</i> , 2019

	16	O uso da IA na medicina levaria a serviços médicos mais eficientes sem comprometer a segurança dos pacientes.		Adaptado de Cornelissen <i>et al.</i> , 2022
	17	Eu reconheço que o uso da IA na prática clínica aumentará a minha produtividade.		Adaptado de Walker; Hong, 2017
	18	Eu acredito que o uso da IA na medicina afetará os custos médicos.		Adaptado de Tamori <i>et al.</i> , 2022
	19	Eu considero que as ferramentas de IA podem ser úteis no meu trabalho.		Adaptado de Walker; Hong, 2017
	20	Acredito que a inteligência artificial será essencial na medicina no futuro.		Adaptado de Tamori <i>et al.</i> , 2022
	29	A IA torna a prática clínica mais ágil.		Adaptado de Walker; Hong, 2017
3 Intenção Comportam ental de Uso (BI)	21	Utilizarei ferramentas de inteligência artificial se elas estiverem disponíveis na minha prática clínica.		Adaptado de Sitorus <i>et al.</i> , 2016
	22	Estou disposto(a) a adotar inteligência artificial na minha prática clínica se houver suporte adequado para sua implementação.	☐ Não aplica ☐ Discordo totalmente ☐ Discordo ☐ Não concordo nem discordo ☐ Concordo ☐ Concordo totalmente	Adaptado de Dessilomba; Tanaamah, 2021
	23	A aceitação da inteligência artificial pelos meus colegas influencia minha disposição em utilizá-la na prática clínica.		Adaptado de Sitorus <i>et al.</i> , 2016
	24	Estou disposto(a) a aprender mais sobre o uso de IA na prática clínica.		Adaptado de Cornelissen <i>et al.</i> , 2022
	34	Eu considero integrar inteligência artificial na minha prática clínica diária.		Adaptado de Dessilomba; Tanaamah, 2021
4 Atitude em Relação ao Uso (ATU)	25	Acredito que a inteligência artificial poderia substituir meu trabalho.	☐ Não aplica ☐ Discordo totalmente ☐ Discordo ☐ Não concordo nem discordo ☐ Concordo ☐ Concordo totalmente	Adaptado de Oh <i>et al.</i> , 2019
	26	Concordo que o uso da inteligência artificial na medicina deve ser regulamentado por legislação específica.		Adaptado de Tamori <i>et al.</i> , 2022
	27	Sou favorável ao uso da inteligência artificial na medicina.		Adaptado de Tamori <i>et al.</i> , 2022
	28	Tenho receio de que o uso da inteligência artificial na medicina possa levar ao vazamento de dados sensíveis.		Adaptado de Tamori <i>et al.</i> , 2022

5 Uso Efetivo (AU)	30	Eu utilizo inteligência artificial para apoiar a tomada de decisões clínicas.	() Não aplica () Discordo totalmente () Discordo	Adaptado de Oh <i>et al.</i> , 2019
	31	Estou satisfeito(a) com a precisão da IA nas tarefas clínicas que realizo.	() Não concordo nem discordo () Concordo	Adaptado de Chen <i>et al.</i> , 2022
	32	Eu utilizo inteligência artificial para apoiar diagnósticos médicos.	() Concordo totalmente	Adaptado de Oh <i>et al.</i> , 2019
	33	Eu utilizo recomendações geradas pela inteligência artificial em minha prática clínica.		Adaptado de Oh <i>et al.</i> , 2019

Fonte: Elaborada pelo autor (2024) com base nos artigos citados na coluna de referência. Em relação às alternativas de respostas, as perguntas de 1 a 5 serão de múltipla escolha e o participante deverá escolher apenas uma das alternativas apresentadas. Em relação às alternativas de respostas das variáveis TAM (perguntas de 6 a 32), as opções de resposta serão 6 sendo a primeira como “Não se aplica” e as demais correspondentes às 5 alternativas de resposta de escala Likert de Concordância (1 - Discordo totalmente, 2 - Discordo, 3 - Não concordo nem discordo, 4 - Concordo, 5 - Concordo totalmente).