

**FUNDAÇÃO INSTITUTO DE ADMINISTRAÇÃO
FACULDADE FIA DE ADMINISTRAÇÃO E NEGÓCIOS
PROGRAMA DE MESTRADO PROFISSIONAL EM GESTÃO DE NEGÓCIOS**

EMERSON FELICIANO DA SILVA

**ADOÇÃO DE INTELIGÊNCIA ARTIFICIAL PARA AUTOMAÇÃO DE
PROCESSOS: UM ESTUDO EM SEGURADORAS DE AUTOMÓVEIS NO BRASIL**

São Paulo

2025

EMERSON FELICIANO DA SILVA

**ADOÇÃO DE INTELIGÊNCIA ARTIFICIAL PARA AUTOMAÇÃO DE
PROCESSOS: UM ESTUDO EM SEGURADORAS DE AUTOMÓVEIS NO BRASIL**

Dissertação apresentada à Banca Examinadora do Programa de Mestrado Profissional em Gestão de Negócios, mantida pela Fundação Instituto de Administração, como requisito para a obtenção do título de Mestre em Gestão de Negócios, sob a orientação do Prof. Dr. Cesar Akira Yokomizo.

São Paulo

2025

Ficha Catalográfica Elaborada pelo Bibliotecário Chefe
Kleber Zornoff Manrubia CRB-8 /7561

Silva, Emerson Feliciano da.

Adoção de inteligência artificial para automação de processos: um estudo em seguradoras de automóveis no Brasil. / Emerson Feliciano da Silva. São Paulo, [s.n.]: 2025.

109f.: il., tab.

Orientador: Prof. Dr. Cesar Akira Yokomizo.

Área de concentração: Sistemas de Informação.

Dissertação (Mestrado Profissional em Gestão de Negócios) – Faculdade FIA de Administração e Negócios, Programa de Pós-Graduação em Stricto Sensu, 2025.

1. Inteligência artificial.
 2. Adoção de tecnologia.
 3. Automação de processos.
 4. UTAUT.
 5. Seguradoras de automóveis - Brasil.
 6. IA - Setor de seguros - Agilidade organizacional.
- I. Yokomizo, Cesar Akira. II. Mestrado Profissional. III. Faculdade FIA de Administração e Negócios. IV. Fundação Instituto de Administração.

AGRADECIMENTOS

Ao finalizar mais essa etapa significativa de minha trajetória, percebo o quanto é essencial reconhecer e agradecer às pessoas e instituições que, direta ou indiretamente, contribuíram para que essa dissertação fosse concluída.

Primeiramente, meus sinceros agradecimentos aos meus pais, que sempre formaram a base sólida sobre a qual construí meus valores e minha dedicação ao conhecimento. Sem o apoio incondicional, o exemplo de resiliência e o incentivo permanente, eu não teria chegado até aqui.

À minha esposa, Milene, pelo apoio inestimável e pela paciência durante as longas horas de dedicação a esse trabalho. Seu amor e incentivo foram fundamentais para que eu pudesse superar os desafios e alcançar esse objetivo.

Ao meu orientador, Prof. Dr. Cesar Akira Yokomizo, agradeço pela orientação criteriosa, pelo apoio constante e pela confiança depositada em mim. Sua experiência, paciência e atenção aos detalhes foram indispensáveis para a construção desse estudo e para o meu crescimento como pesquisador.

Aos membros da banca, Prof. Dr. Luís Fernando Ascenção Guedes, Profa. Dra. Iara Yamamoto e Prof. Dr. Felipe Mendes Borini, registro minha gratidão pelas valiosas contribuições e sugestões. Suas análises críticas e perspectivas enriquecedoras elevaram a qualidade desse trabalho, e foi uma honra contar com suas reflexões.

À instituição de ensino, FIA Business School, e ao programa de Mestrado Profissional em Gestão de Negócios, que proporcionaram um ambiente de aprendizado e reflexão crítica. Aos professores e colegas de curso, com quem pude compartilhar experiências valiosas e enriquecedoras ao longo desta jornada acadêmica.

Um agradecimento especial aos participantes da pesquisa, peritos e analistas automotivos, que se dispuseram a contribuir com esse estudo. Sem o tempo e a atenção de vocês, essa pesquisa não teria sido possível.

Aos meus amigos, que sempre estiveram presentes com palavras de incentivo e compreensão, ainda que eu estivesse ausente em muitos momentos. Saibam que cada mensagem, cada gesto de apoio e cada conversa fizeram toda a diferença.

Por fim, agradeço a Deus pela força e determinação ao longo desta jornada. A cada desafio superado, ficou claro que o esforço e a fé são sempre recompensados.

A todos que, de alguma forma, contribuíram para esse momento, deixo aqui meu mais sincero muito obrigado!

“Ou você tem uma estratégia própria, ou então é parte da estratégia de alguém.”
- Alvin Tofler.

RESUMO

O avanço tecnológico tem transformado a dinâmica organizacional, incentivando empresas a adotarem soluções inovadoras para obter vantagem competitiva. Dentre essas soluções, a inteligência artificial (IA) destaca-se pela capacidade de oferecer respostas eficientes em tempo reduzido, tornando-se um foco de interesse crescente. Esta pesquisa objetiva identificar os fatores que mais influenciam a adoção da IA para automação de processos, a partir de um modelo teórico desenvolvido com base na teoria unificada de aceitação e uso da tecnologia (UTAUT). O modelo proposto foi refinado e operacionalizado por meio de um instrumento de coleta de dados validado, direcionado a profissionais de organizações que adotam ou consideram adotar a IA em seus processos. A pesquisa, de natureza quantitativa, utilizou modelagem de equações estruturais (SEM) para analisar as relações entre constructos preditores, moderadores e a intenção comportamental de adoção de IA. A coleta de dados envolveu 200 respondentes, e os dados foram analisados sem identificação de valores ausentes ou *outliers*, assegurando a robustez das análises. A validação do modelo de medição indicou altos índices de validade convergente, discriminante e confiabilidade dos constructos. Dentre os quatro modelos estruturais testados, o modelo estrutural 1, sem efeitos moderadores, mostrou-se o mais robusto, explicando 77,7% da variância da ‘intenção comportamental’. Os constructos ‘confiança na tecnologia’ ($\beta = 0,351$), ‘expectativa de desempenho’ ($\beta = 0,184$) e ‘inovatividade pessoal’ ($\beta = 0,182$) foram os principais preditores identificados. Os resultados contribuem para a compreensão aprofundada do fenômeno da adoção de IA, oferecendo subsídios para priorização de iniciativas estratégicas em organizações que buscam implementar essa tecnologia. Além disso, a pesquisa propõe um modelo teórico adaptado ao contexto da IA no Brasil, com um instrumento validado que pode ser replicado em estudos futuros. Limitações como a amostra focada no mercado segurador sugerem a ampliação do escopo em pesquisas subsequentes. Esse trabalho apresenta contribuições teóricas e práticas relevantes, auxiliando gestores a compreenderem os fatores determinantes da adoção de IA e a maximizar os benefícios dessa inovação tecnológica.

Palavras-chave: inteligência artificial; adoção de tecnologia; automação de processos; UTAUT; seguradoras de automóveis no Brasil.

ABSTRACT

Technological advancements have been transforming organizational dynamics, encouraging companies to adopt innovative solutions to gain competitive advantage. Among these solutions, artificial intelligence (AI) stands out for its ability to deliver efficient responses in a reduced timeframe, becoming a growing focus of interest. This research aims to identify and describe the factors that most influence the adoption of AI for process automation, based on a theoretical model developed from the Unified theory of acceptance and use of technology (UTAUT). The proposed model was refined and operationalized through a validated data collection instrument targeted at professionals in organizations that adopt or are considering adopting AI in their processes. This quantitative research employed Structural Equation Modeling (SEM) to analyze the relationships between predictor constructs, moderators, and the behavioral intention to adopt AI. The data collection involved 200 respondents, and data were analyzed without identifying missing values or *outliers*, ensuring the robustness of the analyses. The validation of the measurement model indicated high levels of convergent validity, discriminant validity, and construct reliability. Among the four structural models tested, model 1, without moderating effects, proved to be the most robust, explaining 77.7% of the variance in 'behavioral intention'. The constructs 'trust in Technology ($\beta = 0.351$)', performance expectancy ($\beta = 0.184$), and 'personal innovativeness' ($\beta = 0.182$) were identified as the main predictors. The results contribute to a deeper understanding of the phenomenon of AI adoption, offering insights into prioritizing strategic initiatives in organizations seeking to implement this technology. Furthermore, the research proposes a theoretical model adapted to the context of AI in Brazil, supported by a validated instrument that can be replicated in future studies. Limitations such as the sample focused on the insurance market suggest the need to expand the scope in subsequent research. This work presents relevant theoretical and practical contributions, aiding managers in understanding the key factors influencing AI adoption and maximizing the benefits of this technological innovation.

Keywords: artificial intelligence; technology adoption; process automation; UTAUT; automobile insurers in Brazil.

LISTA DE FIGURAS

Figura 1: O modelo conceitual UTAUT 1.....	24
Figura 2: O modelo conceitual UTAUT 2.....	25
Figura 3: O modelo conceitual UTAUT estendido 2016	26
Figura 4: O modelo conceitual UTAUT para adoção de IA	27
Figura 5: O modelo conceitual UTAUT estendido 2022	28
Figura 6: Modelo conceitual desta pesquisa.....	40
Figura 7: Cálculo de estimativa amostral.....	49
Figura 8: Modelo estrutural 1 – completo sem moderação	69
Figura 9: Modelo estrutural 2 – completo com todas as moderações	71
Figura 10: Modelo estrutural 3 – configuração seletiva.....	74
Figura 11: Modelo estrutural 4 – completo com uma moderadora específica	78
Figura 12: Modelo de adoção de IA para automação de processos	91

LISTA DE QUADROS

Quadro 1: Definição dos constructos do modelo conceitual	38
Quadro 2: Desenvolvimento das questões – Seção 1.....	42
Quadro 3: Desenvolvimento das questões – Seção 2.....	45
Quadro 4: Validação do questionário por especialistas	51
Quadro 5: Síntese das hipóteses testadas.....	87

LISTA DE TABELAS

Tabela 1: Análise das cargas fatoriais.....	62
Tabela 2: Validade discriminante entre os constructos do modelo.....	63
Tabela 3: Coerência interna e validade convergente dos constructos	65
Tabela 4: Coerência interna e validade convergente após reavaliação	67
Tabela 5: Coeficientes de caminho do modelo estrutural 1	70
Tabela 6: Coeficientes de caminho do modelo estrutural 2	72
Tabela 7: Coeficientes de caminho do modelo estrutural 3	75
Tabela 8: Coeficientes de caminho do modelo estrutural 4	79

SUMÁRIO

1 INTRODUÇÃO	16
1.1. Estrutura da dissertação	19
2 REFERENCIAL TEÓRICO.....	21
2.1. Adoção de tecnologia.....	21
2.1.1. Visão geral das principais teorias de 1975 a 2003	21
2.1.2. Desenvolvimento e evolução dos modelos da UTAUT – de 2003 a 2022	24
2.1.2.1. UTAUT 1 (2003)	24
2.1.2.2. UTAUT 2 (2012)	25
2.1.2.3. UTAUT extensão (2016)	26
2.1.2.4. UTAUT – Extensão para adoção de IA (2021)	27
2.1.2.5. UTAUT – Extensão para novos fatores independentes (2022)	28
2.2. Fatores de adoção de tecnologia IA em organizações	29
2.2.1. Fatores dependentes	30
2.2.1.1. Intenção comportamental	30
2.2.1.2. Comportamento de uso	30
2.2.2. Fatores independentes	31
2.2.2.1. Expectativa de desempenho	31
2.2.2.2. Expectativa de esforço	31
2.2.2.3. Influência social	32
2.2.2.4. Condições facilitadoras	32
2.2.2.5. Valor do preço	33
2.2.2.6. Custos	33
2.2.2.7. Compatibilidade	34
2.2.2.8. Inovatividade pessoal	34
2.2.2.9. Educação	35
2.2.2.10. Confiança na tecnologia	36
2.2.3. Fatores moderadores	37
2.2.3.1. Características individuais	37
2.2.3.2. Cultura	37
2.3. Modelo conceitual	38
2.3.1. Relação entre os fatores	39
3 PROCEDIMENTOS METODOLÓGICOS	41
3.1. Desenvolvimento e validação do questionário	41

3.1.1. Desenvolvimento das questões	41
3.1.1.1. Desenvolvimento das questões para fatores independentes.....	42
3.1.1.2. Escala de mensuração dos fatores independentes	44
3.1.1.3. Desenvolvimento das questões para fatores moderadores.....	45
3.2. Seleção da amostra.....	46
3.2.1. Definição dos critérios de seleção e amostragem	46
3.2.2. Tamanho da amostra e justificativa	47
3.2.2.1. Tamanho de efeito (f^2)	47
3.2.2.2. Nível de significância (α).....	48
3.2.2.3. Poder estatístico ($1-\beta$)	48
3.2.2.4. Integração dos parâmetros no cálculo amostral	49
3.3. Validação do questionário por especialistas (pré-teste).....	50
3.4. Coleta de dados piloto.....	55
3.4.1. Procedimentos e critérios de seleção dos profissionais	55
3.4.2. Ajustes no processo com base no <i>feedback</i> obtido	56
3.5. Coleta de dados em larga escala	57
3.6. Tratamento dos dados pré-análise por SEM	58
3.6.1. Detecção e manuseio dos dados faltantes	58
3.6.2. Detecção e manuseio de <i>outliers</i>	58
3.7. Análise dos dados por PLS-SEM.....	58
3.7.1. Validação do modelo de medição por análise fatorial confirmatória (AFC).....	59
3.7.1.1. Validade convergente por análise das cargas fatoriais	59
3.7.1.2. Validade discriminante por <i>Heterotrait-Monotrait Ratio</i> (HTMT).....	59
3.7.1.3. Confiabilidade dos constructos	59
3.7.2. Estimativas e teste do modelo estrutural.....	59
4 RESULTADOS E ANÁLISES	60
4.1 Validação do modelo de medição por análise fatorial confirmatória (AFC).....	61
4.1.1. Validação do modelo de medição	61
4.1.1.1. Validade convergente por análise das cargas fatoriais	61
4.1.1.2. Validade discriminante por <i>Heterotrait-Monotrait Ratio</i> (HTMT).....	63
4.1.1.3. Métricas de confiabilidade dos constructos	64
4.1.2. Preparação para o modelo estrutural	65
4.1.2.1. Exclusão das questões com baixa carga fatorial	66
4.1.2.2. Refinamento do modelo de medição	66
4.2. Estimativa e teste do modelo estrutural	68

4.2.1.1. Variância explicada (R^2) do modelo estrutural 1	69
4.2.1.2. Coeficientes de caminho do modelo estrutural 1	70
4.2.1.3. Critério de informação bayesiano (BIC) do modelo estrutural 1	71
4.2.2. Modelo estrutural 2 – configuração com moderações completas	71
4.2.2.1. Variância explicada (R^2) do modelo estrutural 2	72
4.2.2.2. Coeficientes de caminho do modelo estrutural 2	72
4.2.2.3. Critério de informação bayesiano (BIC) do modelo estrutural 2	73
4.2.2.4. Considerações sobre o modelo estrutural 2	73
4.2.3. Modelo estrutural 3 – configuração seletiva	74
4.2.3.1. Variância explicada (R^2) do modelo estrutural 3	75
4.2.3.2. Coeficientes de caminho do modelo estrutural 3	75
4.2.3.3. Critério de informação bayesiano (BIC) do modelo estrutural 3	76
4.2.3.4. Considerações sobre o modelo estrutural 3	76
4.2.4. Modelo estrutural 4: modelo completo com moderadora específica	77
4.2.4.1. Variância explicada (R^2) do modelo estrutural 4	78
4.2.4.2. Coeficientes de caminho do modelo estrutural 4	78
4.2.4.3. Critério de informação bayesiano (BIC) do modelo estrutural 4	80
4.2.4.4. Considerações sobre o modelo estrutural 4	80
4.3. Determinação do modelo estrutural mais adequado	81
4.4. Comparação dos achados do modelo estrutural 1 com as hipóteses teóricas	82
4.4.1. H1: ‘Expectativa de desempenho’	82
4.4.2. H2: ‘Expectativa de esforço’	82
4.4.3. H3: ‘Influência social’	83
4.4.4. H4: ‘Condições facilitadoras’	83
4.4.5. H5: ‘Valor do preço’	83
4.4.6. H6: ‘Custo percebido’	84
4.4.7. H7: ‘Compatibilidade’	84
4.4.8. H8: ‘Inovatividade pessoal’	85
4.4.9. H9: ‘Educação’	85
4.4.10. H10: ‘Confiança na tecnologia’	86
4.4.11. Síntese das hipóteses testadas	87
4.4.12. Lições aprendidas	87
4.4.12.1. Principais lições teóricas	87
4.4.12.2. Direções para pesquisas futuras	90
4.4.13. Modelo final de adoção de IA	90

5 CONSIDERAÇÕES FINAIS	92
REFERÊNCIAS	94
APÊNDICE A – Questionário sobre adoção de IA em organizações.	105
ANEXO 1 – Questionário UTAUT 1	108
ANEXO 2 – Questionário UTAUT 2	109

1 INTRODUÇÃO

Muitas organizações iniciaram ou aceleraram o processo de transformação digital nos anos recentes, em parte, por conta do rápido advento tecnológico e da crescente disponibilidade de infraestrutura. Essa pauta é considerada importante para competitividade, pois está frequentemente associada ao aumento da produtividade e à inovação (Chapuis *et al.*, 2024). Fitzgerald *et al.* (2013) argumentam que há três principais vantagens desse fenômeno para as organizações: (1) simplificar operações, (2) melhorar a experiência do cliente e (3) gerar novos modelos de negócios. Albertin e Albertin (2021) concordam que a aplicação de tecnologias digitais permite realizar operações de maneira nova, diferente e melhor, o que gera valor tanto para os clientes quanto para as empresas.

Estudos indicam que, desde a década de 1980, aproximadamente 50% de todos os novos investimentos nas organizações têm sido direcionados para tecnologia da informação (TI), e essa tendência continua a crescer, com projeções de que a transformação digital poderá potencialmente adicionar US\$13 trilhões à economia global até 2030 (Chapuis *et al.*, 2024). Uma pesquisa com 1.559 executivos revelou que 78% acreditam que esse processo transformacional será o principal foco para suas organizações (Fitzgerald *et al.*, 2013).

Nesse cenário, a inteligência artificial (IA) se destaca como peça importante na transformação digital. Impulsionada por investimentos globais que ultrapassaram US\$154 bilhões em 2023, o que representa um crescimento de 26% em relação ao ano anterior (Gartner, 2024), essa tecnologia tem provocado mudanças nos modelos de negócios e gerado novas oportunidades. Mais do que apenas aumentar a eficiência operacional, a IA se posiciona como um motor de desenvolvimento de soluções, permitindo a personalização em massa de serviços e o advento de soluções preditivas e automatizadas (Lee, 2019). Setores como saúde, varejo e finanças estão entre os mais impactados, com reformulação de processos para reduzir custos e melhorar a precisão das operações (Tegmark, 2019). Como resultado, a IA não apenas representa um salto tecnológico, mas impulsiona empresas para que estejam preparadas para lidar com seus impactos e explorar suas múltiplas possibilidades (Russell, 2021).

No entanto, o êxito da transformação digital e, particularmente, da obtenção dos resultados potenciais da IA depende da adoção dessa tecnologia por parte dos funcionários em suas atividades dentro das organizações. Esse processo pode ser desafiador devido à complexidade e à novidade dos sistemas baseados em IA (Venkatesh, 2021). A resistência à adoção de novas

tecnologias, muitas vezes causada pela falta de compreensão ou pela percepção de opacidade dos modelos de IA, pode resultar no fracasso de até 72% das iniciativas digitais (Chapuis *et al.*, 2024; Venkatesh, 2021). Por esse motivo, é oportuno compreender os fatores que influenciam a adoção de IA dentro das organizações.

Especificamente em relação à adoção da tecnologia, a Teoria Unificada de Aceitação e Uso de Tecnologia (UTAUT) consolida elementos de oito modelos anteriores e, portanto, apresenta contribuições teóricas e práticas significativamente melhores em relação aos modelos precedentes. Enquanto esses modelos anteriores explicavam entre 17% e 51% da variação na intenção de adoção e uso de tecnologia, a UTAUT consegue explicar até 70% dessa variação (Venkatesh *et al.*, 2003).

Embora a UTAUT seja amplamente utilizada para avaliar a adoção de diferentes tecnologias, sua aplicação específica para investigar a adoção de ferramentas de IA ainda é um campo em desenvolvimento. A complexidade dos algoritmos de IA, a opacidade dos modelos e a automatização de processos decisórios exigem uma adaptação da UTAUT para capturar melhor as particularidades dessa tecnologia (Venkatesh, 2021). Assim, a principal contribuição teórica desse trabalho é a adaptação da UTAUT para o contexto específico da IA com vistas à identificação dos fatores que mais influenciam a adoção dessa tecnologia para automação de processos.

Por sua vez, o setor de seguros emerge como um setor relevante para a aplicação da IA, dada sua complexidade operacional e alta dependência de processos decisórios automatizáveis. Mundialmente, esse setor movimentou aproximadamente EUR6,2 trilhões em prêmios (venda de apólices) em 2023, de acordo com Allianz Research (2024). O mesmo estudo mostra que economias maduras, como a da América do Norte, destacam-se nesse cenário, concentrando 54,2% do volume mundial de apólices emitidas em 2023. No Brasil, o setor de seguros arrecadou R\$209,58 bilhões no primeiro semestre de 2024, o que significa um crescimento de 15,3% em comparação com o mesmo período do ano anterior (SUSEP, 2024).

Dentre os diferentes ramos do setor segurador, o de automóveis destaca-se como um dos mais representativos, tanto em termos de volume de prêmios quanto na sua relevância para a operação das seguradoras. Em 2023, o mercado mundial de seguros de automóveis movimentou cerca de EUR2 trilhões. Nos Estados Unidos, esse tipo de seguro tem uma penetração elevada, refletindo 54,2% do volume total de prêmios (venda de apólices). No Brasil, em 2023, os

prêmios relacionados a seguros de automóveis representaram 48% dos prêmios totais no país, reforçando a importância desse tipo de cobertura (Allianz Research, 2024).

Segundo a Accenture (2023), 75% das seguradoras brasileiras estão em busca de soluções baseadas em IA para diversificar seus portfólios e aumentar a inovação. Além disso, 54% dos diretores de tecnologia desse setor estão priorizando investimentos em IA com foco em otimizar processos e melhorar a experiência do cliente (Gartner, 2024). No contexto específico do setor de seguros de automóveis, a IA tem sido progressivamente adotada. Porém, estudos recentes indicam que a maioria das pesquisas sobre IA em seguros se concentra em áreas como detecção de fraudes e precificação, o que abre possibilidade de investigações mais aprofundadas sobre os fatores que influenciam a adoção de IA para automação de processos críticos, como, por exemplo, o de gestão de sinistros (Barcelos e Santos, 2023). A IA promete transformar significativamente o setor de seguros, com estimativas sugerindo que, entre 10% e 55% dos processos, como subscrição e gestão de sinistros, serão automatizados até 2040, sendo a IA uma peça-chave nesse processo (Chapuis *et al.*, 2024).

Assim, a proposição da adaptação da UTAUT para a IA será aplicada, especificamente no processo de gestão de sinistros em seguradoras de automóveis no Brasil. Além disso, a partir da identificação dos fatores que mais influenciam a adoção dessa tecnologia, pretende-se contribuir com recomendações para que gestores possam priorizar iniciativas a fim de facilitar sua adoção dentro das organizações.

Nesse sentido, a questão de pesquisa que orienta esse estudo é: quais são os fatores que mais influenciam a adoção de inteligência artificial para automação do processo de gestão de sinistros em seguradoras de automóveis no Brasil?

Buscando responder a essa questão, o objetivo geral desse trabalho é: identificar os fatores que mais influenciam a adoção de inteligência artificial para automação do processo de gestão de sinistros em seguradoras de automóveis no Brasil.

Este objetivo geral foi desdobrado em três objetivos específicos:

OE1: Descrever, por meio da literatura, quais são os fatores (independentes, dependentes e moderadores) de adoção de IA para automação de processos em organizações;

OE2: Descrever, por meio da literatura, as relações entre os fatores (independentes, dependentes e moderadores) na adoção de IA para automação de processos em organizações; e

OE3: Propor um modelo conceitual e um instrumento de coleta de dados para identificar os fatores que mais influenciam a adoção de IA para automação de processos em organizações.

1.1. Estrutura da dissertação

Esta dissertação está estruturada de maneira a oferecer uma avaliação sobre adoção de IA para automação do processo de gestão de sinistros em seguradoras de automóveis no Brasil, e está dividida em capítulos que exploram desde os fundamentos teóricos até a aplicação empírica dos conceitos estudados.

O Capítulo 2, Referencial Teórico, apresenta uma revisão das teorias de adoção tecnológica, destacando o desenvolvimento e a evolução do modelo UTAUT. O capítulo explora a aplicabilidade desses modelos revisando a literatura para identificar como foram adaptados para diferentes contextos tecnológicos e setoriais. Além disso, apresenta uma análise dos constructos do modelo UTAUT, e as respectivas adaptações para abordar especificamente a adoção de IA. A partir dessa análise, um modelo conceitual é apresentado, integrando constructos e fatores mediadores identificados como críticos para o contexto de IA.

O Capítulo 3, Procedimentos Metodológicos, apresenta a metodologia empregada para testar o modelo conceitual proposto. Nele, são descritos o delineamento da pesquisa de campo, as estratégias de coleta de dados, os instrumentos de pesquisa utilizados e os métodos estatísticos aplicados para análise. Em particular, foi utilizada a Modelagem de Equações Estruturais com Mínimos Quadrados Parciais (PLS-SEM), uma abordagem robusta e amplamente recomendada para pesquisas exploratórias e modelos complexos. Além disso, o capítulo aborda os critérios de seleção da amostra, o cálculo amostral e o procedimento de coleta de dados, garantindo transparência e alinhamento às melhores práticas metodológicas.

Os resultados da pesquisa empírica e sua análise à luz do modelo conceitual desenvolvido são apresentados no Capítulo 4, Resultados e Análises. A análise inicia-se com a avaliação e refinamento do modelo de medição, utilizando o PLS-SEM, garantindo validade convergente, discriminante e confiabilidade dos constructos. Em seguida, são apresentados os resultados do modelo estrutural, incluindo os coeficientes de caminho (β), significância estatística e métricas de ajuste global, como R^2 e BIC. O capítulo discute como é que os achados se alinham ou divergem das teorias existentes, em particular a UTAUT e suas extensões. Por fim, são exploradas as implicações teóricas e práticas desses resultados, destacando como é que eles

podem orientar a adoção de IA em organizações e contribuir para avanços na literatura e nas estratégias corporativas.

O Capítulo 5, Considerações Finais, sintetiza os principais achados da pesquisa, destacando os fatores críticos que influenciam a adoção de IA no contexto organizacional. São discutidas as implicações teóricas, como o avanço no entendimento das relações entre os constructos analisados, e práticas, com recomendações para a aplicação dos resultados no setor de seguros e em outras indústrias. Além disso, o capítulo aborda as limitações metodológicas e contextuais do estudo, reconhecendo suas restrições e propondo direções para futuras pesquisas que possam aprofundar e expandir os *insights* apresentados.

As referências utilizadas são apresentadas ao final do texto. Anexos e apêndices compõem a parte final desta dissertação.

2 REFERENCIAL TEÓRICO

Este capítulo apresenta uma revisão das teorias de adoção de tecnologia, com destaque para o desenvolvimento da UTAUT, o que inclui diferentes contextos tecnológicos. Além disso, apresenta as adaptações necessárias para abordar especificamente a adoção de IA. A partir dessa base, é apresentado um modelo conceitual que integra constructos adaptados para o contexto da IA.

2.1. Adoção de tecnologia

A adoção tecnológica é um fenômeno multidisciplinar que se beneficia das contribuições das ciências da computação, psicologia, sociologia e administração, e reflete a complexidade e a diversidade dos fatores que influenciam a aceitação e o uso de novas tecnologias por parte do usuário (Venkatesh *et al.*, 2003). A apresentação da adoção de tecnologia será dividida em duas partes: na primeira, uma visão geral das principais teorias, de 1975 até 2003, com destaque para o surgimento da UTAUT; na segunda parte, a evolução e as várias versões da UTAUT, de 2003 até 2022, com adaptações do modelo às mudanças tecnológicas ao longo do tempo.

2.1.1. Visão geral das principais teorias de 1975 a 2003

Os estudos da adoção de tecnologia têm evoluído a partir de diferentes lentes teóricas ao longo das últimas décadas e, usualmente, adotam como ponto de partida os trabalhos de Fishbein e Ajzen em 1975, com a *Theory of Reasoned Action* (TRA). A TRA enfatiza que o comportamento do usuário diante da tecnologia é uma função direta da ‘intenção comportamental’, que, por sua vez, é influenciada pela ‘atitude’ em relação ao comportamento e pelas ‘normas subjetivas’ percebidas. A ‘atitude’ refere-se à avaliação, positiva ou negativa, do uso da tecnologia, enquanto a ‘norma subjetiva’ diz respeito à percepção das expectativas sociais. Essa teoria lançou as bases para estudos subsequentes sobre os fatores comportamentais na adoção de tecnologia, o que evidencia a importância das crenças, avaliações pessoais e sociais no processo de decisão (Venkatesh *et al.* 2003).

Em 1986, Bandura apresenta a *Social Cognitive Theory* (SCT), que foca no ‘aprendizado social’ e na ‘autoeficácia’ como fatores determinantes para a adoção de tecnologia. Há destaque para o ambiente social e a capacidade de aprender com a observação dos outros no processo de adoção tecnológica. A ‘autoeficácia’, ou a crença na própria capacidade de executar uma tarefa, é central para a SCT, pois influencia diretamente a confiança do usuário na adoção e uso eficaz da tecnologia. O autor argumenta que o comportamento humano é moldado por uma interação

recíproca contínua entre fatores cognitivos, comportamentais e ambientais. Essa teoria destaca o papel das expectativas de resultado e das influências sociais, o que sugere que as pessoas são mais propensas a adotar tecnologias se acreditarem que têm a capacidade de usá-las e se perceberem que haverá apoio social para essa adoção (Bobsin *et al.*, 2009).

Davis, em 1989, apresenta o *Technology Acceptance Model* (TAM), em que se destaca a importância da ‘utilidade percebida’ e da ‘facilidade de uso’ como determinantes da aceitação tecnológica. A ‘utilidade percebida’ refere-se ao grau em que uma pessoa acredita que o uso de uma tecnologia específica irá melhorar seu desempenho no trabalho, enquanto a ‘facilidade de uso’ é o grau em que uma pessoa acredita que usar uma tecnologia será livre de esforço. Esse modelo foi posteriormente expandido para contextos mais complexos, com inclusão de elementos de ‘experiência’ e ‘voluntariedade’. Ele tem sido amplamente utilizado em diferentes áreas, desde sistemas de informação a dispositivos móveis (Venkatesh *et al.*, 2003).

O *Model of PC Utilization* (MPCU), proposto por Thompson, Higgins e Howell, em 1991, traz uma perspectiva psicológica ao considerar a ‘experiência prévia’, as ‘consequências esperadas’, a ‘autoeficácia’ e a ‘ansiedade’ em relação à tecnologia. A teoria destaca que a utilização de computadores é influenciada não apenas pela percepção de facilidade e utilidade, mas também pela ‘ansiedade’ em relação ao uso da tecnologia e pela ‘autoeficácia do usuário’ (Venkatesh *et al.*, 2003).

A *Diffusion of Innovations Theory* (DOI), de Rogers, desenvolvida desde a década de 1960, explora como soluções se disseminam entre indivíduos e organizações. Moore e Benbasat (1991) refinaram essa teoria para estudar a aceitação individual de tecnologias, identificando constructos centrais como ‘vantagem relativa’, que mede o grau em que uma solução é percebida como superior à anterior; ‘facilidade de uso’, que avalia o quanto simples é o uso da tecnologia; ‘imagem’, que reflete como a adoção da inovação pode melhorar o status social do usuário; ‘visibilidade’, que considera a facilidade com que outros podem observar o uso da tecnologia; ‘compatibilidade’, que avalia a consistência com valores e experiências anteriores; ‘demonstração de resultados’, que indica a tangibilidade dos benefícios do uso da inovação; e ‘voluntariedade de uso’, que mede a percepção de uso voluntário da tecnologia. Esses constructos ajudam a compreender os fatores que influenciam a aceitação individual de novas soluções tecnológicas, enfatizando tanto características da inovação quanto os processos sociais associados à sua adoção. (Venkatesh *et al.*, 2003).

Ajzen, também em 1991, expande a TRA ao incluir a ‘percepção de controle’ com a *Theory of Planned Behavior* (TPB), que se refere à percepção do usuário sobre a facilidade ou dificuldade de adotar a tecnologia, considerando tanto fatores internos quanto externos. O autor argumenta que, além da ‘atitude’ e da ‘norma subjetiva’, a ‘percepção de controle’ sobre o comportamento desempenha um papel determinante na formação da ‘intenção comportamental’ e, finalmente, no comportamento real (Venkatesh *et al.*, 2003).

O *Combined TAM-TPB Model* (C-TAM-TPB), desenvolvido por Taylor e Todd, em 1995, combinou elementos do TAM e da TPB ao integrar percepções de ‘utilidade’, ‘facilidade de uso’ e ‘controle comportamental’, o que proporciona uma visão holística dos fatores que influenciam a intenção de usar tecnologia. Como resultado, essa combinação permite uma previsão mais precisa das intenções comportamentais em comparação aos modelos individuais (Bobsin *et al.*, 2009).

Vallerand, em 1997, foca na ‘motivação intrínseca e extrínseca’ com o *Motivational Model* (MM). Tanto impulsos internos quanto externos influenciam a decisão de adotar novas tecnologias. A ‘motivação intrínseca’ refere-se ao prazer e satisfação derivados do uso da tecnologia em si, enquanto a ‘motivação extrínseca’ envolve recompensas externas, como reconhecimento e benefícios tangíveis. O autor sugere que a ‘motivação intrínseca’ pode levar a um uso mais persistente e aprofundado da tecnologia, enquanto a ‘motivação extrínseca’ pode impulsionar com mais ênfase a adoção inicial (Venkatesh *et al.*, 2003).

Finalmente, em 2003, Venkatesh *et al.* (2003) propõem a *Unified Theory of Acceptance and Use of Technology* (UTAUT), que consolidou elementos de oito modelos anteriores em um modelo unificado. A UTAUT integra quatro principais determinantes: (a) ‘expectativa de desempenho’, (b) ‘expectativa de esforço’, (c) ‘influência social’ e (d) ‘condições facilitadoras’, além de considerar moderadores como ‘gênero’, ‘idade’, ‘experiência’ e ‘voluntariedade’. As atualizações subsequentes da UTAUT incluíram novos constructos e fatores mediadores, tornando-a basilar para uma explicação mais robusta e abrangente dos fatores que influenciam a adoção de tecnologia (Blut *et al.*, 2022).

2.1.2. Desenvolvimento e evolução dos modelos da UTAUT – de 2003 a 2022

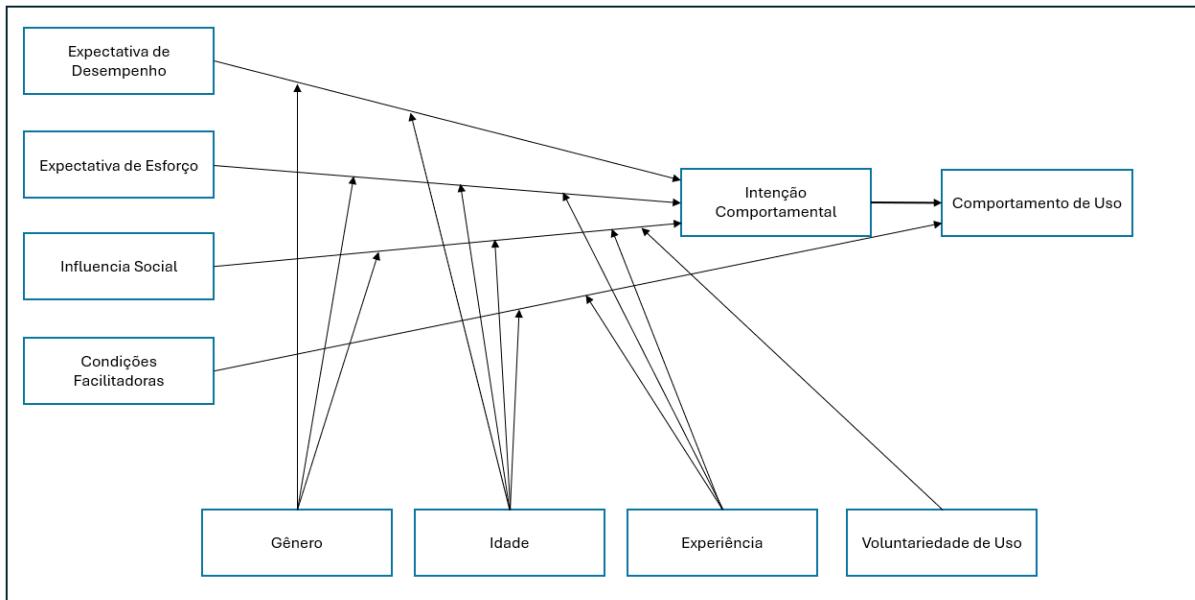
Este subcapítulo descreve a evolução da UTAUT de 2003 a 2022, detalhando como é que o modelo foi expandido e refinado para abordar as novas dinâmicas tecnológicas e contextuais.

2.1.2.1. UTAUT 1 (2003)

Ao implantar uma metodologia longitudinal em quatro organizações ao longo de seis meses, Venkatesh *et al.* (2003) compararam empiricamente oito modelos de adoção de tecnologia, em que os resultados iniciais explicaram entre 17% e 51% da variância de intenção de adoção e uso de tecnologia dos usuários. Com essas descobertas, os autores desenvolveram a UTAUT 1, que sintetizou os elementos-chave desses modelos e aumentou a capacidade explicativa para até 70%, o que a habilita a um modelo melhor em relação aos existentes (Venkatesh *et al.*, 2003).

A UTAUT 1 define quatro determinantes principais de adoção de tecnologia: (a) ‘expectativa de desempenho’, (b) ‘expectativa de esforço’, (c) ‘influência social’ e (d) ‘condições facilitadoras’. Além disso, o modelo considera moderadores como (e) ‘idade’, (f) ‘gênero’, (g) ‘experiência’ e (h) ‘voluntariedade de uso’, que podem influenciar a força das relações entre os determinantes e as intenções e/ou uso da tecnologia, conforme Figura 1, a seguir (Venkatesh *et al.*, 2003).

Figura 1: O modelo conceitual UTAUT 1

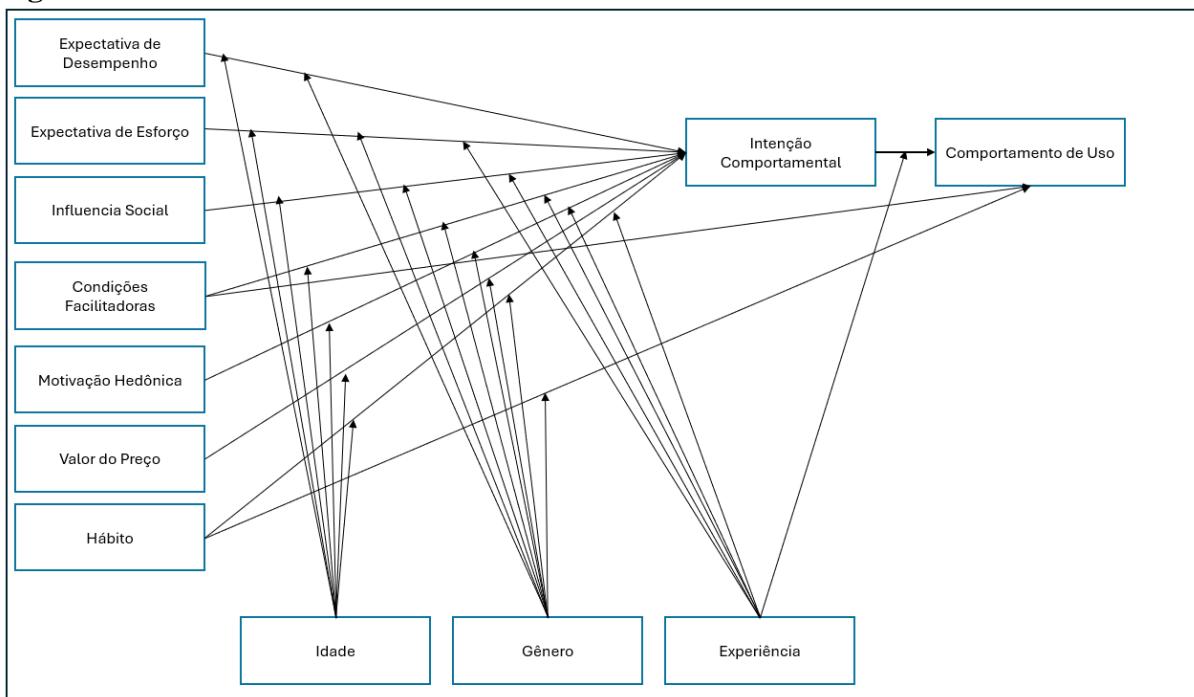


Fonte: Venkatesh *et al.* (2003).

2.1.2.2. UTAUT 2 (2012)

Venkatesh, Thong e Xu (2012) apresentam a UTAUT 2, uma adaptação desenvolvida especificamente para a esfera do consumidor e que representa um avanço significativo ao modelo UTAUT 1. Os autores identificaram que, enquanto a UTAUT 1 era robusta em contextos organizacionais, a adaptação para o contexto do consumidor exigia que, além dos 4 constructos originais da UTAUT 1 – (a) ‘expectativa de desempenho’, (b) ‘expectativa de esforço’, (c) ‘influência social’ e (d) ‘condições facilitadoras’ – fossem incorporados fatores diretamente relevantes para experiências pessoais e diárias dos usuários: (e) a ‘motivação hedônica’, definida como o prazer derivado do uso de tecnologia; (f) o ‘valor do preço’, que considera os benefícios em relação aos ‘custos’; e (g) o ‘hábito’, que descreve o uso automático da tecnologia. Os moderadores (h) ‘idade’, (i) ‘gênero’ e (j) ‘experiência’ foram mantidos, enquanto o moderador ‘voluntariedade de uso’ foi removido nessa versão, pois, considerando que o usuário final adquire a solução tecnológica por vontade própria, a ‘voluntariedade de uso’ já está implícita (Venkatesh, Thong e Xu, 2012). O estudo longitudinal realizado para testar a UTAUT 2, envolvendo consumidores de internet móvel, mostrou que essas adições permitiram ao modelo explicar até 74% da variação na ‘intenção comportamental’, destacando a relevância dos novos constructos, especialmente a ‘motivação hedônica’, em contextos de consumo em que a satisfação pessoal desempenha um papel crítico.

Figura 2: O modelo conceitual UTAUT 2



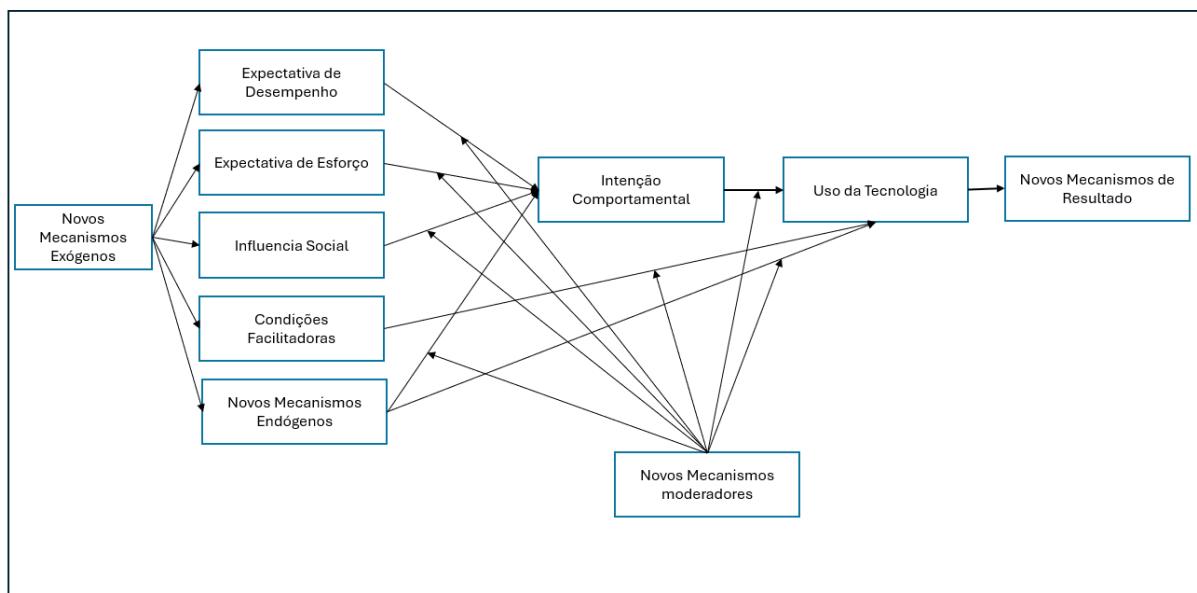
Fonte: Venkatesh, Thong e Xu (2012).

Vale destacar que a UTAUT 2 foi desenvolvida com o objetivo de avaliar a adoção de tecnologia por parte do consumidor final, em contraste com a UTAUT 1, que foca na adoção de tecnologias por funcionários em ambientes organizacionais. Por essa razão, todas as extensões apresentadas a seguir derivam da UTAUT 1 e não representam uma continuidade da UTAUT 2, como poderia ser comumente assumido.

2.1.2.3. UTAUT extensão (2016)

Nessa extensão, Venkatesh, Thong e Xu (2016) se voltam novamente para o fenômeno da adoção tecnológica em organizações (e não por parte do consumidor final). Por meio de uma revisão sistemática de literatura, os autores revisitam e expandem a UTAUT 1, incorporando análises críticas e apontando direções para futuras pesquisas. A análise teórica revelou três limitações principais na literatura da UTAUT: (1) a predominância de aplicações que não testam completamente os efeitos moderadores propostos, (2) a falta de exploração de novos mecanismos endógenos e exógenos e (3) uma insuficiente incorporação de fatores culturais e contextuais. Assim, além dos 4 constructos originais da UTAUT 1 – (a) ‘expectativa de desempenho’, (b) ‘expectativa de esforço’, (c) ‘influência social’ e (d) ‘condições facilitadoras’ – os autores orientam que (e) novos mecanismos exógenos e endógenos, e (f) moderadores, sejam incorporados. Caberá a cada pesquisador identificar os constructos mais adequados ao fenômeno que deseja avaliar. E assim, apresentaram um modelo conceitual estendido, conforme Figura 3, a seguir. (Venkatesh, Thong, e Xu, 2016).

Figura 3: O modelo conceitual UTAUT estendido 2016



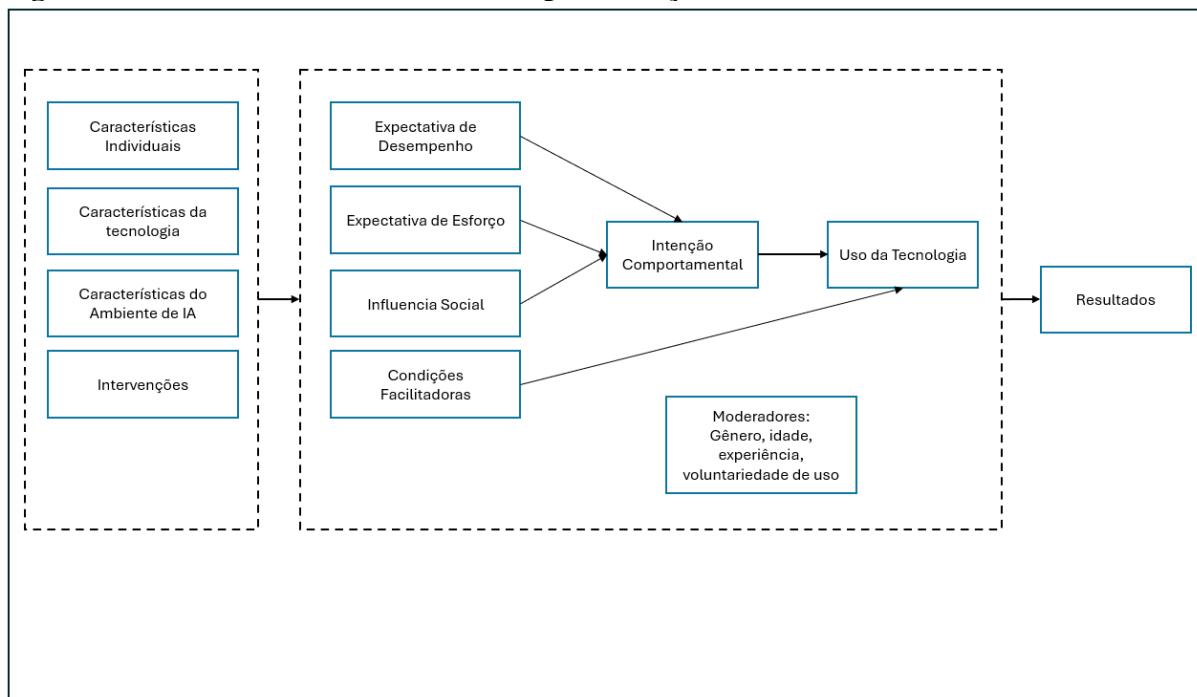
Fonte: Venkatesh, Thong e Xu (2016).

2.1.2.4. UTAUT – Extensão para adoção de IA (2021)

Em 2021, Venkatesh (2021) explorou como a UTAUT 1 poderia contribuir para o estudo de adoção de ferramentas de IA dentro das organizações, com destaque para fatores específicos ao contexto dessa tecnologia. Além dos 4 constructos originais, são propostos fatores que podem influenciar negativamente sua adoção por parte dos funcionários, como (e) ‘características individuais’, (f) ‘características tecnológicas’, (g) ‘características ambientais’ e (h) ‘intervenções’. Dentre os obstáculos identificados, estão (a) a opacidade dos modelos de IA (também referenciado como caixa-preta), que pode reduzir a confiança dos usuários e (b) o potencial para erros significativos do modelo, como mostra a Figura 4, a seguir.

Dado o papel central que a ‘confiança na tecnologia’ desempenha na superação desses desafios, esse estudo irá se aprofundar nesse constructo, reconhecendo-a como um fator essencial para mitigar os impactos negativos da opacidade e de erros iniciais percebidos. A análise desse constructo será importante para compreender como é que os aspectos tecnológicos, humanos e organizacionais interagem na adoção de tecnologias de IA, contribuindo para um modelo teórico mais robusto e aplicável ao contexto corporativo.

Figura 4: O modelo conceitual UTAUT para adoção de IA

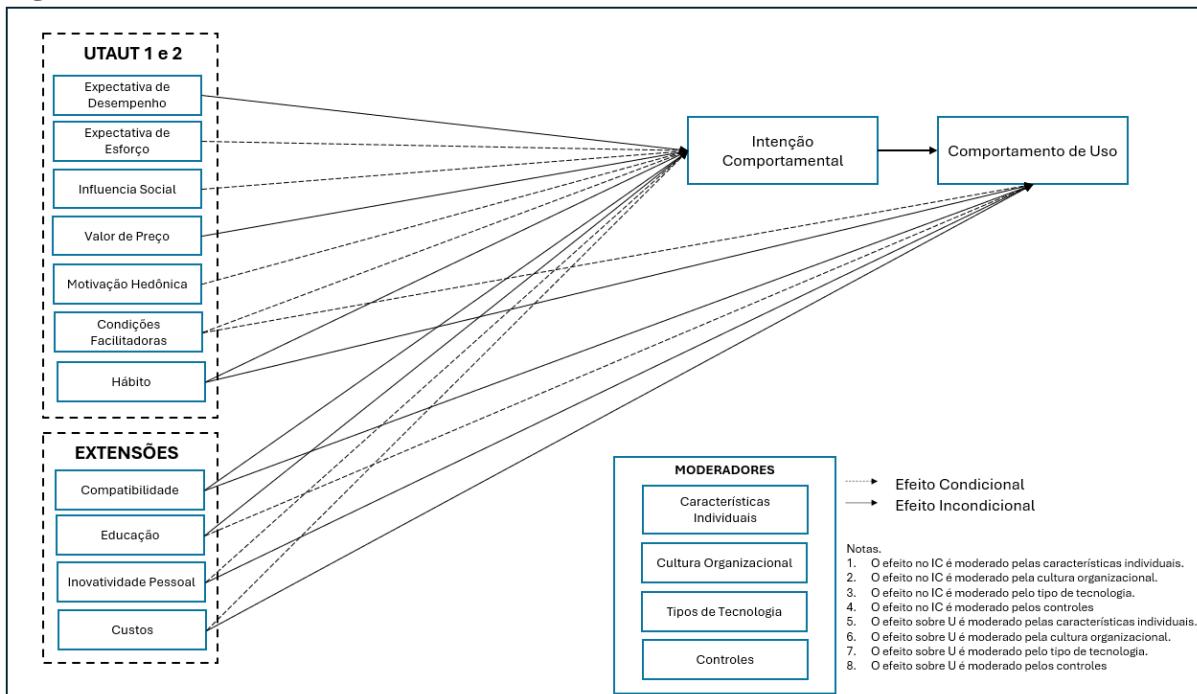


Fonte: Venkatesh (2021).

2.1.2.5. UTAUT – Extensão para novos fatores independentes (2022)

Em 2022, Blut *et al.* (2022), conduziram uma meta-análise abrangente, revisando 25.619 tamanhos de efeito (medida estatística usada para quantificar a magnitude de uma relação entre variáveis) reportados por 737.112 usuários em 1.935 amostras independentes. O estudo sugere que, apesar da popularidade da UTAUT, existem lacunas significativas que precisam ser abordadas para manter o modelo relevante em contextos tecnológicos e culturais em evolução. Dentre as propostas, os autores sugerem a inclusão de novos fatores independentes, como (a) ‘compatibilidade’ tecnológica, (b) ‘inovatividade pessoal’, (c) ‘educação’ do usuário e (d) ‘custos’ da tecnologia, além de considerar novos moderadores como (e) ‘tipos de tecnologia’, (f) ‘cultura’ e (g) ‘controles’, como mostra a Figura 5, a seguir. Essas extensões visam aprimorar o potencial de generalização e a precisão do modelo em diferentes cenários.

Figura 5: O modelo conceitual UTAUT estendido 2022



Fonte: Blut *et al.* (2022).

2.2. Fatores de adoção de tecnologia IA em organizações

Este subcapítulo examina os principais fatores que influenciam a adoção de IA para automação de processos em organizações. A seleção desses fatores foi baseada na evolução do modelo UTAUT e suas extensões ao longo dos anos, sendo amplamente fundamentada no modelo conceitual estendido de Blut *et al.* (2022), com as adaptações necessárias para o contexto específico da adoção de IA.

Os constructos fundamentais da UTAUT, (a) ‘expectativa de desempenho’, (b) ‘expectativa de esforço’, (c) ‘influência social’ e (d) ‘condições facilitadoras’, foram mantidos por constituírem a base teórica consolidada para estudos de adoção tecnológica. Além disso, foram incorporados fatores adicionais identificados nas extensões do modelo, como (e) ‘valor do preço’, (f) ‘custos’, (g) ‘compatibilidade’, (h) ‘inovatividade pessoal’ e (i) ‘educação’, todos apontados por Blut *et al.* (2022) como relevantes para a adoção de tecnologia em ambientes organizacionais.

Um fator de destaque nesse estudo é (j) ‘confiança na tecnologia’, identificado por Venkatesh *et al.* (2021) como um dos principais determinantes na aceitação de IA. Esse constructo, ausente no modelo estendido de Blut *et al.* (2022), foi incluído nesta pesquisa como uma contribuição original, considerando seu impacto específico na adoção de tecnologias baseadas em inteligência artificial.

A adaptação ao contexto organizacional também levou à exclusão de fatores como ‘motivação hedônica’ e ‘hábito’, que são mais pertinentes ao uso de tecnologia pelo consumidor final e apresentam menor aplicabilidade em cenários corporativos. Além disso, dois moderadores, ‘características individuais’ e ‘cultura’, serão analisados para avaliar sua influência sobre a relação entre os fatores independentes e a intenção de adotar IA. No entanto, como essa pesquisa possui caráter exploratório, o foco principal será nos fatores independentes, que desempenham um papel central na formação da ‘intenção comportamental’. A análise da moderação será complementar, uma vez que, no contexto estudado, o uso do *software* de IA é obrigatório, o que pode minimizar o impacto desses moderadores.

Dessa forma, esse subcapítulo discute a interconexão entre esses fatores e sua influência na ‘intenção comportamental’ de adotar tecnologias de IA para automação de processos em organizações.

2.2.1. Fatores dependentes

Este subcapítulo apresenta os fatores dependentes, que representam os constructos influenciados pelos fatores independentes e fatores moderadores.

2.2.1.1. Intenção comportamental

A ‘intenção comportamental’ é a força que impulsiona o usuário a adotar e usar uma tecnologia, sendo o preditor-chave da aceitação tecnológica (Venkatesh *et al.*, 2003). Segundo Bharti *et al.* (2023), a intenção de clientes bancários na Índia de adotar IA é fortemente influenciada pela percepção de benefícios tangíveis e eficácia. No setor educacional, Lee e Kim (2022) mostram que a intenção dos educadores de usar plataformas de realidade virtual é moldada pela percepção de ‘utilidade’ e ‘facilidade de uso’. Em saúde, Fan *et al.* (2020) destacam que a confiança nas capacidades da IA e o suporte institucional são determinantes para a adoção de sistemas de suporte à decisão médica. Hasija e Esper (2022) revelam que, em logística hospitalar, além dos benefícios percebidos, a ‘cultura organizacional’ e o apoio à inovação fortalecem a intenção de adotar IA. Assim, a ‘intenção comportamental’ é essencial para prever a adoção e uso de tecnologia, sendo um dos principais fatores para organizações que buscam integrar novas soluções em suas operações.

2.2.1.2. Comportamento de uso

O ‘comportamento de uso’ refere-se à forma como um indivíduo utiliza a tecnologia na prática e é o resultado das influências descritas no modelo UTAUT (Venkatesh *et al.*, 2003), sendo uma métrica singular para avaliar o sucesso da integração de novas tecnologias, indicando não apenas aceitação, mas também a adoção efetiva nas operações cotidianas. Segundo Maruping *et al.* (2017), o ‘comportamento de uso’ não se limita ao início do uso de uma tecnologia, mas também à sua utilização contínua e eficaz ao longo do tempo, sendo o suporte e capacitação essenciais para essa manutenção. Sujati, Yudoko e Okdinawati (2023) mostram que, no setor de mineração, o uso contínuo de aplicativos móveis é sustentado por atualizações regulares e suporte técnico.

O ‘comportamento de uso’ é frequentemente medido em pesquisas longitudinais, que acompanham o uso ao longo de diferentes períodos para capturar dinâmicas de aceitação e manutenção tecnológica. Como esse trabalho adota um delineamento transversal, que coleta dados em um único momento no tempo, o principal preditor de aceitação tecnológica será a ‘intenção comportamental’.

2.2.2. Fatores independentes

Este subcapítulo apresenta os fatores independentes, que exercem influência sobre os fatores dependentes no modelo conceitual.

2.2.2.1. Expectativa de desempenho

A ‘expectativa de desempenho’, refere-se à crença de que o uso de uma tecnologia resultará em melhoria no desempenho do trabalho (Venkatesh *et al.*, 2003). Segundo Almagrashi *et al.* (2016), pequenas e médias empresas na Malásia veem o *social commerce* como uma ferramenta para melhorar o desempenho nos negócios, enquanto Alwaishi e Snásel (2013) mostram que a expectativa de ganhos em produtividade e eficiência é fundamental para a adoção de tecnologia. No contexto da IA, Fan *et al.* (2020) destacam que profissionais de saúde esperam que a IA melhore a precisão dos diagnósticos, e Alneyadi *et al.* (2022) afirmam que a adoção de sistemas de cibersegurança baseados em IA nos Emirados Árabes é influenciada pela percepção de melhoria na detecção e prevenção de ameaças digitais.

H1: A ‘expectativa de desempenho’ influencia positivamente a ‘intenção comportamental’ de usar tecnologias de IA.

2.2.2.2. Expectativa de esforço

A ‘expectativa de esforço’ refere-se à facilidade percebida no uso de uma tecnologia específica. Ela é determinante para avaliar como os usuários potenciais enxergam a adoção de novas tecnologias em termos de complexidade e facilidade de aprendizado (Venkatesh *et al.*, 2003). Segundo Alves e Hamza (2019), na adoção de serviços de *streaming* de vídeo, uma interface intuitiva e facilidade de navegação são fatores determinantes que influenciam a ‘expectativa de esforço’ e, consequentemente, a aceitação do serviço. Da mesma forma, Chen e Zhao (2023) observam que, no setor financeiro, a simplicidade no uso de serviços inteligentes afeta diretamente a intenção de uso pelos consumidores. Bharti *et al.* (2023) apontam que, para clientes bancários na Índia, a simplicidade percebida na utilização da tecnologia é um fator determinante para sua adoção. No contexto de tecnologias de IA, Alneyadi *et al.* (2022) ressaltam que uma interface clara e suporte adequado são fundamentais para reduzir a ‘expectativa de esforço’ e promover a adoção de IA no ambiente de trabalho.

H2: A ‘expectativa de esforço’ influencia positivamente a ‘intenção comportamental’ de usar tecnologias de IA.

2.2.2.3. Influência social

A ‘influência social’ refere-se à forma como a opinião de pessoas importantes para um indivíduo afeta sua intenção de adotar uma nova tecnologia (Venkatesh *et al.*, 2003). Segundo Almagrashi *et al.* (2016), a influência de colegas e superiores pode impactar significativamente a adoção do *social commerce* em pequenas e médias empresas. Alwaishi e Snásel (2013) destacam que a influência de colegas e da comunidade *online* afeta a disposição para adotar tecnologias de comunicação e informação. Alneyadi *et al.* (2022) afirmam que a opinião de colegas sobre a utilidade e segurança dos sistemas de IA influencia sua adoção no ambiente corporativo dos Emirados Árabes, enquanto Fan *et al.* (2020) identificam que a ‘influência social’ impacta na adoção de sistemas de suporte à decisão médica baseados em IA, especialmente quando endossados por figuras de autoridade. Portanto, a ‘influência social’ é oportuna na adoção de tecnologias, especialmente em contextos inovadores e complexos, como a IA.

H3: A ‘influência social’ influencia positivamente a ‘intenção comportamental’ de usar tecnologias de IA.

2.2.2.4. Condições facilitadoras

O constructo de ‘condições facilitadoras’ refere-se à percepção dos indivíduos sobre a existência de suporte organizacional e infraestrutura que auxiliam o uso de uma tecnologia (Venkatesh *et al.*, 2003). Essa percepção é essencial para que os usuários se sintam capacitados a utilizar a tecnologia, com acesso aos recursos e conhecimentos necessários. Alwaishi e Snásel (2013) apontam que o suporte técnico e a disponibilidade de recursos são determinantes para incentivar a adoção de tecnologias de comunicação e informação. Almagrashi *et al.* (2016) destacam a importância do suporte organizacional na adoção do *social commerce* por pequenas e médias empresas na Malásia. Alneyadi *et al.* (2022) ressaltam que uma estrutura de suporte eficiente, incluindo capacitação e suporte técnico contínuo, é vital para a adoção de sistemas baseados em IA no ambiente empresarial. Fan *et al.* (2020) também enfatizam que a disposição dos profissionais de saúde para adotar sistemas de suporte à decisão médica baseados em IA depende do acesso a suporte técnico adequado. Assim, as ‘condições facilitadoras’ são essenciais para garantir que as tecnologias de IA sejam integradas com sucesso nas práticas organizacionais e efetivamente utilizadas pelos funcionários.

H4: As ‘condições facilitadoras’ influenciam positivamente a ‘intenção comportamental’ de usar tecnologias de IA.

2.2.2.5. Valor do preço

O ‘valor do preço’ refere-se à percepção do usuário sobre o custo-benefício ao adotar uma nova tecnologia (Venkatesh, Thong e Xu, 2012). Esse constructo ajuda a entender como é que os usuários avaliam a acessibilidade financeira de uma tecnologia em relação aos benefícios percebidos. Kim, Giroux e Lee (2021) demonstraram que a transparência e a percepção de justiça nos preços influenciam a confiança e aceitação de recomendações feitas por IA no varejo *online*. No contexto empresarial, Xie *et al.* (2021) apontam o valor de preço como um fator determinante para a adoção de plataformas de *fintech* por instituições financeiras, acelerando sua aceitação com base na eficiência custo-benefício percebida. No setor de saúde, Fan *et al.* (2020) observaram que o custo das tecnologias de IA, em relação aos benefícios em precisão diagnóstica e eficiência operacional, é uma consideração vital para sua adoção. A percepção de um bom ‘valor do preço’ é determinante para a adoção e uso continuado das tecnologias.

H5: O ‘valor do preço’ influencia negativamente a ‘intenção comportamental’ de usar tecnologias de IA.

2.2.2.6. Custos

Os ‘custos’ estão associados à avaliação negativa de um indivíduo sobre os recursos financeiros, esforço e tempo exigidos ao usar uma tecnologia (Venkatesh, Thong, e Xu, 2016). Identificar esses ‘custos’ é essencial para identificar as barreiras econômicas e de esforço que podem influenciar a decisão de adotar novas tecnologias (Blut *et al.*, 2022). Sánchez e Ramos (2019) mostram que os custos iniciais de implantação e os custos operacionais contínuos podem ser fatores limitantes para a adoção de tecnologias de análise de grandes dados, especialmente em pequenas e médias empresas com recursos limitados. No setor de saúde, Pan *et al.* (2022) destacam que os custos de integração de sistemas de IA no recrutamento de funcionários podem afetar negativamente a decisão de adoção, principalmente quando os benefícios percebidos não superam os custos de forma evidente. No setor de mineração, Sujati, Yudoko e Okdinawati (2023) mostram que, apesar dos benefícios em eficiência operacional, os custos iniciais e de manutenção podem desencorajar a rápida adoção de aplicativos móveis digitais. Compreender esses ‘custos’ pode ajudar as organizações a planejarem melhor suas estratégias de investimento tecnológico e maximizar o retorno sobre o investimento (Blut *et al.*, 2022).

H6: O fator ‘custos’ influencia negativamente a ‘intenção comportamental’ de usar tecnologias de IA.

2.2.2.7. Compatibilidade

A ‘compatibilidade’ avalia o quanto uma solução é percebida como consistente com os valores, experiências passadas e necessidades dos potenciais adotantes (Venkatesh, Thong, e Xu, 2016). Segundo Fan *et al.* (2020), a percepção de ‘compatibilidade’ dos sistemas de suporte à decisão médica baseados em IA com as práticas clínicas existentes é determinante para sua adoção por profissionais de saúde, pois, quando esses sistemas estão alinhados com os métodos de trabalho e objetivos clínicos dos médicos, a probabilidade de adoção aumenta. Lee e Kim (2022) também apontam que a ‘compatibilidade’ entre as experiências virtuais oferecidas pelo Metaverso e as preferências dos usuários afeta diretamente sua disposição para engajar com essa nova plataforma. Marques, Behr e Malanovicz (2020) reforçam essa ideia ao mostrar que a ‘compatibilidade’ dos sistemas ERP com os processos contábeis existentes em um departamento contábil é fundamental para sua aceitação e uso efetivo. A ‘compatibilidade’ não só influencia a decisão inicial de adotar tecnologias, mas também desempenha importante papel na integração e uso contínuo dessas soluções em diversos contextos.

H7: A ‘compatibilidade’ da tecnologia de IA com os sistemas existentes influencia positivamente a ‘intenção comportamental’.

2.2.2.8. Inovatividade pessoal

A ‘inovatividade pessoal’ é definida como a tendência de um indivíduo adotar novas tecnologias antes dos outros em um grupo social (Venkatesh, Thong, e Xu, 2016). Indivíduos com alta ‘inovatividade pessoal’ tendem a adotar novas tecnologias precocemente, influenciando o comportamento de adoção em seu círculo social ou organizacional (Blut *et al.*, 2022). Sujati, Yudoko e Okdinawati (2023) destacam que, no setor de mineração de carvão na Indonésia, indivíduos com alta propensão à inovação são mais predispostos a adotar aplicativos móveis que oferecem soluções avançadas para questões operacionais, o que melhora eficiência e segurança. No contexto educacional, Lee e Kim (2022) mostram que a ‘inovatividade pessoal’ dos educadores está fortemente relacionada com a disposição para integrar ambientes de aprendizagem virtuais no Metaverso em suas práticas pedagógicas. Em saúde, Hasija e Esper (2022) observam que gerentes com alta inclinação à inovação são mais propensos a implantar soluções de IA na logística hospitalar para melhorar a eficiência das cadeias de suprimentos.

No setor financeiro, Pandey e Rajeswari (2023) revelam que profissionais com alta ‘inovatividade pessoal’ são mais inclinados a adotar práticas e produtos que alinham sustentabilidade e inovação tecnológica. A ‘inovatividade pessoal’ é um determinante significativo na adoção de novas tecnologias, e cultivá-la pode ser uma estratégia chave para empresas e instituições que buscam implantar tecnologias de maneira eficaz e sustentável.

H8: A ‘inovatividade pessoal’ dos funcionários influencia positivamente a ‘intenção comportamental’ de usar tecnologias de IA.

2.2.2.9. Educação

A ‘educação’, definida como o nível de conhecimento específico que um indivíduo possui sobre o uso da tecnologia, tem uma grande contribuição na adoção de novas ferramentas (Blut *et al.*, 2022), especialmente em contextos que exigem compreensão técnica e capacidade analítica, como é o caso da IA. Usuários com maior conhecimento e/ou capacitação específicos tendem a adotar novas tecnologias com mais facilidade, pois possuem as habilidades necessárias para utilizá-las efetivamente (Blut *et al.*, 2022). Hardingham *et al.* (2018) destacam que a ‘educação’ é essencial para preparar a força de trabalho para maximizar o uso de tecnologias automatizadas, facilitando a transição para funções que exigem interação com novas ferramentas tecnológicas. No setor de saúde, Fan *et al.* (2020) identificam que a formação contínua em novas tecnologias médicas é fundamental para que profissionais da saúde adotem sistemas de suporte à decisão baseados em IA, melhorando a compreensão e confiança nessas ferramentas. No campo das tecnologias financeiras, Xie *et al.* (2021) mostram que a ‘educação’ financeira dos usuários influencia significativamente sua disposição para adotar plataformas *fintech* ao permitir melhor compreensão dos benefícios e riscos. Em tecnologias sustentáveis, Pandey e Rajeswari (2023) discutem como a ‘educação’ sobre sustentabilidade e tecnologia motiva os consumidores a adotarem produtos sustentáveis. A ‘educação’ não só capacita os indivíduos a operarem novas tecnologias, mas também aumenta sua confiança e capacidade de adaptação, o que promove integração mais eficaz e sustentada das soluções tecnológicas nas práticas diárias.

H9: O nível de ‘educação’ dos funcionários influencia positivamente a ‘intenção comportamental’.

2.2.2.10. Confiança na tecnologia

A ‘confiança na tecnologia’ desporta como um dos principais determinantes para a adoção de tecnologias avançadas, especialmente em contextos que envolvem IA e automação de processos. Em contraste com outros constructos amplamente estudados, como ‘expectativa de desempenho’ e ‘esforço’, a ‘confiança na tecnologia’ destaca-se pela sua capacidade de mitigar os desafios específicos associados à complexidade e opacidade de sistemas autônomos, tornando-se um elemento central na aceitação e no uso eficaz da IA (Venkatesh, 2021).

Ao incorporar esse constructo como uma contribuição original ao modelo teórico, esse estudo reafirma sua relevância ao demonstrar que ele complementa as abordagens existentes, incluindo o modelo estendido de Blut *et al.* (2022). Além disso, evidencia sua importância prática ao atender às demandas específicas de contextos organizacionais, nos quais decisões críticas estão em forte tendência de começarem a ser delegadas para tecnologias avançadas.

Hasiija e Esper (2022) argumentam que a confiança é essencial em ambientes em que a tecnologia desempenha funções críticas sem intervenção humana direta. A ‘confiança na tecnologia’ está intrinsecamente ligada à percepção de risco, especialmente quando os usuários se confrontam com tecnologias que operam além de sua compreensão direta. Venkatesh (2021) sugere que a confiança mitiga o medo e a incerteza que frequentemente acompanham a introdução de novas tecnologias, facilitando uma atitude mais receptiva. Em contextos de IA, em que as decisões podem ser pouco transparentes e os processos não são facilmente auditáveis, a confiança torna-se um fator ainda mais crítico, como aponta Venkatesh (2021), destacando que maior transparência nos algoritmos pode reforçar a confiança dos usuários. Kosmas *et al.* (2023) demonstram que a ‘confiança na tecnologia’ é influenciada tanto pela experiência anterior do usuário com tecnologias semelhantes quanto pelo grau de familiaridade com a tecnologia em questão. Maruping *et al.* (2017) observam que, uma vez estabelecida, a ‘confiança na tecnologia’ pode levar a um compromisso de longo prazo com a tecnologia, com usuários mais propensos a explorar e utilizar plenamente as capacidades da IA.

A confiança não apenas facilita a aceitação inicial, mas também incentiva a exploração contínua e o uso eficaz das tecnologias ao longo do tempo, garantindo que os investimentos em IA gerem o retorno máximo possível.

H10: A ‘confiança na tecnologia’ de IA influencia positivamente a ‘intenção comportamental’ de usar tecnologias de IA.

2.2.3. Fatores moderadores

Em ambientes organizacionais onde o uso de tecnologias frequentemente pode ser obrigatório devido a políticas institucionais ou demandas operacionais, os fatores moderadores podem exercer um impacto reduzido na relação entre os fatores independentes e dependentes. No entanto, essa influência não deve ser subestimada, especialmente em contextos nos quais a adesão à tecnologia depende não apenas de normas institucionais, mas também da percepção e das experiências individuais dos usuários (Blut *et al.*, 2022). Este capítulo aborda os fatores moderadores que, segundo a literatura, têm o potencial de alterar a força ou a direção das relações entre os constructos do modelo proposto, destacando seu papel em moldar a intenção comportamental.

2.2.3.1. Características individuais

A UTAUT sugere que características do usuário, como ‘idade’, ‘gênero’ e ‘experiência’, atuam como moderadores nas relações entre crenças dos usuários (como ‘expectativa de desempenho’ e ‘expectativa de esforço’) e suas ‘intenções comportamentais’ e uso efetivo da tecnologia (Venkatesh *et al.*, 2003). Esses moderadores influenciam a força dessas relações, com a ‘idade’ interagindo com todos os preditores da UTAUT, por exemplo. Em contextos de consumidores, os preditores da UTAUT têm fortes efeitos, mas em ambientes organizacionais, em que o uso de tecnologias pode ser obrigatório, as características individuais podem ter impacto menor na moderação dos fatores independentes (Venkatesh *et al.*, 2012).

2.2.3.2. Cultura

A extensão UTAUT sugerida por Blut *et al.* (2022) propõe que a ‘cultura’ seja um moderador significativo nas relações de aceitação e uso da tecnologia, refletindo a programação coletiva da mente que distingue diferentes grupos humanos. Segundo esses autores, quatro dimensões culturais – (1) ‘distância do poder’, (2) ‘individualismo *versus* coletivismo’, (3) ‘evitação da incerteza’ e (4) ‘masculinidade *versus* feminilidade’ – influenciam diretamente em como as pessoas interagem com novas tecnologias. Em culturas com alta distância do poder, por exemplo, espera-se que os membros mais poderosos cuidem dos menos poderosos, o que pode alterar a percepção da ‘influência social’ e das ‘condições facilitadoras’ na aceitação da tecnologia. O ‘individualismo *versus* coletivismo’ afeta a prioridade dos objetivos pessoais em relação aos do grupo, influenciando a relevância de constructos como a ‘expectativa de desempenho’. A dimensão da ‘masculinidade *versus* feminilidade’ afeta a importância dada à

‘expectativa de desempenho’ em culturas masculinas e à ‘expectativa de esforço’ e ‘influência social’ em culturas femininas. Já a ‘evitação da incerteza’ impacta a aceitação de tecnologias novas ou arriscadas, sendo mais influente em culturas que evitam incertezas. Esses moderadores culturais podem contribuir para entender as variações na aceitação e uso da tecnologia, destacando a importância de considerar o contexto cultural ao aplicar o modelo UTAUT em estudos internacionais (Blut *et al.*, 2022).

2.3. Modelo conceitual

O Quadro 1, a seguir, apresenta as variáveis do modelo conceitual, suas definições e referências, categorizados em fatores dependentes, independentes e moderadores, conforme sugere Forza (2002).

Quadro 1: Definição dos constructos do modelo conceitual

Categoría	Constructo	Definição	Referência
Fatores Dependentes	IC - ‘Intenção Comportamental’	A força que impulsiona o usuário a realizar um comportamento específico, como a adoção e uso de uma tecnologia.	Blut <i>et al.</i> (2022).
	COU - ‘Comportamento de Uso’	A forma como um indivíduo usa a tecnologia na prática.	Blut <i>et al.</i> (2022).
Fatores Independentes	ED - ‘Expectativa de Desempenho’	O grau em que um indivíduo acredita que o uso de uma determinada tecnologia melhorará seu desempenho no trabalho.	Blut <i>et al.</i> (2022).
	EE - ‘Expectativa de Esforço’	O grau de facilidade associado ao uso da tecnologia.	Blut <i>et al.</i> (2022).
	IS - ‘Influência Social’	O grau em que um indivíduo percebe que pessoas importantes para ele acreditam que ele deve usar a nova tecnologia.	Blut <i>et al.</i> (2022).
	CF - ‘Condições Facilitadoras’	O grau em que um indivíduo acredita que uma infraestrutura, organizacional e técnica, existe para apoiar o uso da tecnologia.	Blut <i>et al.</i> (2022).

	VP – ‘Valor do Preço’	A percepção cognitiva do custo-benefício do usuário ao adotar uma nova tecnologia.	Blut <i>et al.</i> (2022)
	CS – ‘Custo’	Avaliação negativa de um indivíduo sobre os recursos financeiros gastos ao usar a tecnologia.	Blut <i>et al.</i> (2022)
	CO - ‘Compatibilidade’	O grau em que uma solução é percebida como consistente com os valores existentes, experiências passadas e necessidades dos potenciais adotantes.	Blut <i>et al.</i> (2022)
	IP - ‘Inovatividade Pessoal’	A tendência de um indivíduo adotar novas tecnologias antes dos outros em um grupo social.	Blut <i>et al.</i> (2022)
	EDUC - ‘Educação’	Nível de conhecimento específico que um indivíduo possui, relevante para o uso da tecnologia.	Blut <i>et al.</i> (2022)
	CT – ‘Confiança na Tecnologia’	O grau em que um indivíduo acredita na integridade, competência e confiabilidade da tecnologia.	Venkatesh (2021)
	CI - ‘Características Individuais’	Moderadores como idade, gênero e experiência que influenciam a relação entre os constructos e a ‘intenção comportamental’.	Blut <i>et al.</i> (2022).
Fatores Moderadores	CO - ‘Cultura’ Organizacional	A programação coletiva da mente que distingue os membros de diferentes grupos humanos e influencia a aceitação e uso da tecnologia.	Blut <i>et al.</i> (2022)

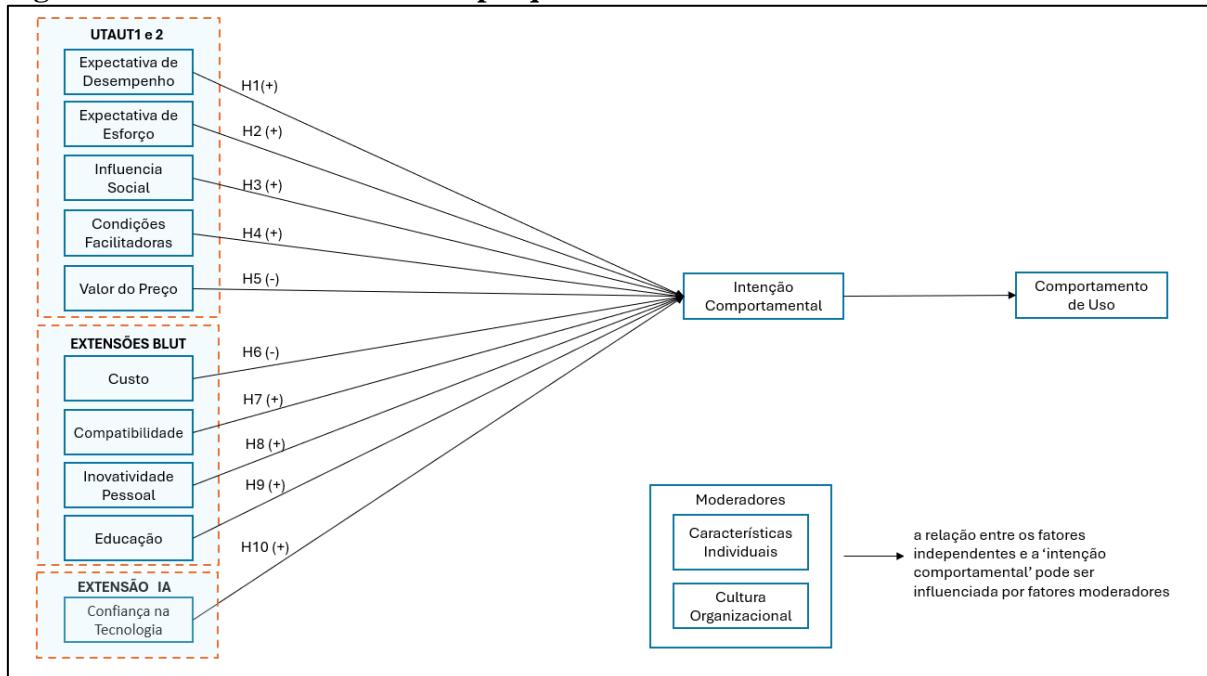
Fonte: elaborado pelo autor (2024).

2.3.1. Relação entre os fatores

O modelo conceitual apresentado na Figura 6, a seguir, ilustra as relações entre fatores dependentes, independentes e moderadores, conjecturando como é que essas interações podem impactar a ‘intenção comportamental’ de adotar a tecnologia. Essas relações foram delineadas

para testar as hipóteses apresentadas, fornecendo um caminho para a verificação empírica dos pressupostos teóricos.

Figura 6: Modelo conceitual desta pesquisa



Fonte: elaborado pelo autor (2024), com base em Blut *et al.* (2022).

3 PROCEDIMENTOS METODOLÓGICOS

Este capítulo apresenta os procedimentos metodológicos adotados na pesquisa, de natureza quantitativa e com caráter exploratório-descritivo. Para investigar as relações entre os fatores que influenciam a adoção de IA na gestão de sinistros em seguradoras, foi utilizada a modelagem de equações estruturais com mínimos quadrados parciais (PLS-SEM). O desenvolvimento seguiu as etapas recomendadas por Hair *et al.* (2009, 2014, 2017) e Forza (2002), abrangendo: (3.1) desenvolvimento e validação do questionário: formulação das perguntas com base em questionários da UTAUT validados, validação com especialistas, ajustes e adaptação ao contexto do estudo, (3.2) seleção da amostra: definição dos critérios de inclusão e exclusão, de modo a garantir a representatividade do público-alvo, (3.3) validação do questionário por especialistas (pré-teste), (3.4) coleta de dados em pequena escala: realização de um teste piloto para ajustes operacionais e metodológicos da pesquisa de campo, (3.5) coleta de dados em larga escala: condução da pesquisa em uma amostra transversal, considerando a representatividade do público-alvo, (3.6) tratamento dos dados pré-análise: detecção e tratamento dos dados faltantes e dos *outliers* e (3.7) análise dos dados por SEM: teste das relações entre os construtos e avaliação do modelo estrutural e confiabilidade dos resultados. A seguir, cada uma dessas etapas será detalhada.

3.1. Desenvolvimento e validação do questionário

O questionário foi desenvolvido seguindo as diretrizes de Forza (2002), que sugere que o instrumento de coleta de dados deve estar diretamente alinhado aos objetivos de pesquisa e aos constructos teóricos, além de garantir a relevância e clareza das questões para o público-alvo. Vieira (2010) recomenda que o questionário seja construído de forma a minimizar ambiguidades e facilitar a compreensão dos respondentes, enquanto Hair *et al.* (2009) destacam a importância de utilizar questões e escalas validadas na literatura, adaptando-as ao contexto específico do estudo.

3.1.1. Desenvolvimento das questões

As questões foram adaptadas a partir dos instrumentos desenvolvidos e aplicados na literatura da UTAUT, amplamente utilizados em estudos que aplicaram esse arcabouço. Forza (2002) enfatiza a importância de adaptar instrumentos validados para contextos específicos preservando a integridade teórica das questões originais. O questionário foi organizado em duas seções: (1) questões relacionadas aos fatores independentes e (2) questões voltadas aos fatores

moderadores e demográficos. Essa estrutura foi projetada para facilitar a análise das relações entre os constructos e assegurar que os dados capturados refletem as experiências práticas dos profissionais do setor.

3.1.1.1. Desenvolvimento das questões para fatores independentes

O Quadro 2, a seguir, (a) apresenta os constructos associados a cada questão, (b) identifica a versão ou extensão da UTAUT de onde a questão foi originada, (c) exibe o texto das questões originais, (d) apresenta as questões adaptadas para esse estudo e (e) vincula essas questões às respectivas hipóteses.

Quadro 2: Desenvolvimento das questões – Seção 1

Constructo	Questões originais dos questionários UTAUT (Apêndices)	Questões adaptadas para IA e processo de gestão de sinistros em seguradoras de automóveis	Hipótese
ED1 – ‘Expectativa de Desempenho’	Considero que o sistema seria útil no meu trabalho. UTAUT 1 - Venkatesh <i>et al.</i> (2003)	Considero que o sistema com IA é, ou será, útil para realizar orçamentos de sinistros.	H1 (+)
ED2 – ‘Expectativa de Desempenho’	Usar o sistema me permite realizar tarefas mais rapidamente. UTAUT 1 - Venkatesh <i>et al.</i> (2003)	Usar o sistema com IA me permite ou me permitirá realizar orçamentos de sinistros mais rapidamente.	H1 (+)
ED3 – ‘Expectativa de Desempenho’	Usar o sistema aumenta minha produtividade. UTAUT 1 - Venkatesh <i>et al.</i> (2003)	Usar o sistema com IA aumenta ou aumentará minha produtividade.	H1 (+)
EE1 – ‘Expectativa de Esforço’	Considero que o sistema será fácil de usar. UTAUT 1 - Venkatesh <i>et al.</i> (2003)	Considero que o sistema com IA é, ou será, fácil de usar.	H2 (+)
EE2 – ‘Expectativa de Esforço’	Aprender a operar o sistema é fácil para mim. UTAUT 1 - Venkatesh <i>et al.</i> (2003)	Aprender a operar o sistema com IA é, ou será, fácil para mim.	H2 (+)
IS1 – ‘Influência Social’	As pessoas que influenciam meu comportamento acham que eu deveria usar o sistema. UTAUT 1 - Venkatesh <i>et al.</i> (2003)	As pessoas que influenciam meu comportamento acham que eu devo ou deverei usar o sistema com IA para realizar orçamentos de sinistros.	H3 (+)
IS2 – ‘Influência Social’	As pessoas importantes para mim acham que eu deveria usar o sistema. UTAUT 1 - Venkatesh <i>et al.</i> (2003)	As pessoas importantes para mim acham que eu devo ou deverei usar o sistema com IA para realizar orçamentos de sinistros.	H3 (+)

IS3 – ‘Influência Social’	A organização tem apoiado o uso do sistema. UTAUT 1 - Venkatesh <i>et al.</i> (2003)	A organização me apoia ou apoiará a utilização do sistema com IA.	H3 (+)
CF1 – ‘Condições Facilitadoras’	Eu tenho os recursos necessários para usar o sistema. UTAUT 1 - Venkatesh <i>et al.</i> (2003)	Eu tenho ou terei os recursos necessários para usar o sistema com IA.	H4 (+)
CF2 – ‘Condições Facilitadoras’	Existe uma pessoa específica ou grupo disponível para assistência com dificuldades no sistema. UTAUT 1 - Venkatesh <i>et al.</i> (2003)	Existe ou existirá uma pessoa específica ou grupo disponível para assistência com dificuldades no sistema com IA.	H4 (+)
VP1 – ‘Valor do Preço’	O sistema tem um preço razoável. UTAUT 2 - Venkatesh, Thong e Xu (2012)	O sistema com IA tem ou terá um preço razoável.	H5 (-)
VP2 – ‘Valor do Preço’	O sistema agrega um valor superior ao preço que possui. UTAUT 2 - Venkatesh, Thong e Xu (2012)	O sistema com IA agrega ou agregará um valor superior ao preço que possui.	H5 (-)
CS1 – ‘Custos’	Os custos associados ao uso do sistema são justificáveis. Extensão - Blut <i>et al.</i> (2022)	Os custos associados ao uso do sistema com IA são justificáveis.	H6 (-)
CS2 – ‘Custos’	Os custos de implantação e manutenção do sistema são uma preocupação. Extensão - Blut <i>et al.</i> (2022)	Os custos de implantação e manutenção do sistema com IA são uma preocupação.	H6 (-)
CS3 – ‘Custos’	A relação custo-benefício do sistema é vantajosa. Extensão - Blut <i>et al.</i> (2022)	A relação custo-benefício do sistema com IA é vantajosa.	H6 (-)
CO1 – ‘Compatibilidade’	O sistema é compatível com as ferramentas e processos que já utilizei. Extensão - Blut <i>et al.</i> (2022)	O sistema com IA é compatível com as ferramentas e processos que já utilizei.	H7 (+)
CO2 – ‘Compatibilidade’	Integra-se facilmente com outras tecnologias usadas na minha empresa. Extensão - Blut <i>et al.</i> (2022)	O sistema com IA integra-se facilmente com outras tecnologias usadas na minha empresa.	H7 (+)
CO3 – ‘Compatibilidade’	O sistema se alinha bem com os objetivos estratégicos da minha empresa. Extensão - Blut <i>et al.</i> (2022)	O sistema com IA se alinha bem com os objetivos estratégicos da minha empresa.	H7 (+)
IP1 – ‘Inovatividade Pessoal’	Gosto de experimentar novas tecnologias antes dos outros. Extensão - Blut <i>et al.</i> (2022)	Gosto de experimentar novas tecnologias antes dos outros.	H8 (+)

IP2 – ‘Inovatividade Pessoal’	Estou sempre buscando soluções tecnológicas inovadoras para melhorar meu desempenho. Extensão - Blut <i>et al.</i> (2022)	Estou sempre buscando soluções tecnológicas inovadoras para melhorar meu desempenho.	H8 (+)
IP3 – ‘Inovatividade Pessoal’	Estou disposto a mudar a maneira como trabalho para incorporar novas tecnologias como o Sistema. Extensão Blut <i>et al.</i> (2022)	Estou disposto a mudar a maneira como trabalho para incorporar novas tecnologias, como o sistema com IA.	H8 (+)
EDUC1 – ‘Educação’	Meu nível de ‘educação’ me ajuda a entender e utilizar novas tecnologias. Extensão - Blut <i>et al.</i> (2022)	Meu nível de capacitação me ajuda a entender e utilizar novas tecnologias.	H9 (+)
EDUC2 – ‘Educação’	Recebi treinamento suficiente para usar eficientemente o sistema. Extensão - Blut <i>et al.</i> (2022)	Recebi ou receberei capacitação suficiente para usar eficientemente o sistema com IA.	H9 (+)
EDUC3 – ‘Educação’	A ‘educação’ que recebi me prepara para enfrentar desafios técnicos ao usar novas tecnologias. Extensão - Blut <i>et al.</i> (2022)	A formação que recebi me prepara para enfrentar desafios técnicos ao usar novas tecnologias.	H9 (+)
CT1 – ‘Confiança na Tecnologia’	Confio que o sistema funcionará como esperado sem falhas significativas. Extensão IA - Venkatesh (2021)	Confio que o sistema com IA funciona ou funcionará como esperado sem falhas significativas.	H10 (+)
CT2 – ‘Confiança na Tecnologia’	Sinto-me seguro ao usar o sistema devido às suas medidas de segurança. Extensão IA - Venkatesh (2021)	Sinto-me seguro ao usar o sistema com IA, devido às suas medidas de segurança.	H10 (+)
CT3 – ‘Confiança na Tecnologia’	A estabilidade e a confiabilidade do sistema reforçam minha confiança em sua utilização diária. Extensão IA - Venkatesh (2021)	A estabilidade e a confiabilidade do sistema com IA reforçam minha confiança em sua utilização diária.	H10 (+)

Fonte: elaborado pelo autor (2024)

3.1.1.2. Escala de mensuração dos fatores independentes

As questões foram estruturadas em uma escala *Likert* adaptada de 7 pontos, variando de 1 (“discordo totalmente”) a 7 (“concordo totalmente”), conforme preconizado por Venkatesh *et al.* (2003). Essa escala foi escolhida por sua eficácia na medição de percepções e atitudes, permitindo uma análise quantitativa detalhada e garantindo comparabilidade com outros estudos que utilizam o mesmo arcabouço.

3.1.1.3. Desenvolvimento das questões para fatores moderadores

O Quadro 3, a seguir, (a) apresenta as dimensões relacionadas aos fatores moderadores, (b) identifica o constructo moderador associado a cada questão, (c) exibe o texto original ou recomendação sobre como elaborar a questão com base em Venkatesh *et al.* (2003) e Blut *et al.* (2022) e (d) apresenta a adaptação feita para esse estudo, incluindo a (e) codificação das respostas.

Quadro 3: Desenvolvimento das questões – Seção 2

Dimensão	Constructo moderador	Questões originais ou recomendações teóricas para formulação da questão.	Questões adaptadas para IA e processo de gestão de sinistros em seguradoras de automóveis
‘Características individuais’	Idade	<p>Idade deve ser codificada em faixas etárias, como uma variável contínua.</p> <p>UTAUT1 - Venkatesh <i>et al.</i> (2003)</p> <p>Critério:</p> <p>Menos de 20 anos, geração Z; 21-27 anos, <i>millennials</i>; 28-43 anos, geração X; 44-59 anos, baby boomers); Mais de 60 anos, geração silenciosa.</p>	<p>Por favor, indique sua faixa etária:</p> <p><input type="checkbox"/> Menos de 20 anos</p> <p><input type="checkbox"/> 21-27 anos</p> <p><input type="checkbox"/> 28-43 anos</p> <p><input type="checkbox"/> 44-59 anos</p> <p><input type="checkbox"/> Mais de 60 anos</p>
‘Características individuais’	Gênero	<p>Gênero deve ser classificado de forma binária (masculino e feminino).</p> <p>Recomenda-se ser operacionalizada como uma variável <i>dummy</i>*.</p> <p>UTAUT 1 - Venkatesh <i>et al.</i> (2003)</p>	<p>Por favor, selecione seu gênero:</p> <p><input type="checkbox"/> Masculino</p> <p><input type="checkbox"/> Feminino</p> <p><input type="checkbox"/> Prefiro não dizer</p>
‘Características individuais’	Experiência com Tecnologia	<p>Recomenda-se ser operacionalizada como uma variável <i>dummy</i>, em que a experiência acumulada com tecnologia deve ser quantificada em anos.</p> <p>UTAUT 1 - Venkatesh <i>et al.</i> (2003)</p>	<p>Quantos anos de experiência você tem usando sistemas de gestão de sinistros de automóveis?</p> <p><input type="checkbox"/> Menos de 1 ano</p> <p><input type="checkbox"/> 1 a 5 anos</p> <p><input type="checkbox"/> Mais de 5 anos</p>
‘Cultura’ organizacional	Distância do Poder	A distância do poder deve ser relacionado à percepção dos funcionários sobre a centralização das decisões na organização.	De acordo com a cultura da empresa em que trabalho, pessoas em posições de autoridade tendem a tomar decisões sem consultar os

		Recomenda-se ser operacionalizada como uma variável <i>dummy</i> . Extensão - Blut <i>et al.</i> (2022)	subordinados. <input type="checkbox"/> Sim <input type="checkbox"/> Não
‘Cultura’ organizacional	Individualismo vs. Coletivismo	O ‘individualismo vs. coletivismo’ deve ser relacionado à orientação da importância do bem-estar do grupo comparado aos interesses individuais. Recomenda-se ser operacionalizada como uma variável <i>dummy</i> . Extensão - Blut <i>et al.</i> (2022)	De acordo com a cultura da empresa em que trabalho, o bem-estar do grupo é considerado mais importante do que os interesses individuais. <input type="checkbox"/> Sim <input type="checkbox"/> Não
‘Cultura’ organizacional	Masculinidade vs. Feminilidade	A ‘masculinidade vs. feminilidade’ deve ser relacionado à orientação para o sucesso competitivo (masculinidade) ou colaborativo (feminilidade) na organização, com base nas percepções dos funcionários sobre a cultura empresarial. Recomenda-se ser operacionalizada como uma variável <i>dummy</i> . Extensão - Blut <i>et al.</i> (2022)	De acordo com a cultura da empresa em que trabalho, o sucesso é mais associado à: <input type="checkbox"/> Competição <input type="checkbox"/> Cooperação

Fonte: elaborado pelo autor (2024)

*De acordo com Hair *et al.* (2009), uma variável *dummy* é uma forma de representar variáveis categóricas em modelos estatísticos, permitindo a inclusão de informações qualitativas em análises quantitativas. No caso de categorizar gênero, por exemplo, a variável *dummy* assume o valor 1 para uma categoria (por exemplo, masculino) e 0 para outra (feminino). Em situações com mais de duas categorias, são criadas múltiplas variáveis *dummy*, cada uma representando uma categoria, enquanto uma delas é omitida para servir como base de comparação. Isso possibilita a modelagem de efeitos de variáveis qualitativas, como gênero, em modelos de regressão, facilitando a interpretação e a análise dos dados.

3.2. Seleção da amostra

A seguir, são detalhados os critérios para determinar a seleção da amostra para esse estudo, seguindo as recomendações de Hair *et al.* (2009).

3.2.1. Definição dos critérios de seleção e amostragem

Este estudo adota uma estratégia de amostragem intencional (não probabilística), focada nos profissionais que trabalham em seguradoras de automóveis no Brasil e que utilizam *software* de gestão de sinistros, com ou sem automação por IA. Os critérios específicos de inclusão abrangeram:

- i. As oito maiores seguradoras de automóveis atuando no Brasil, classificadas com base no ranking SUSEP (Superintendência de Seguros Privados), de acordo com o faturamento (prêmio emitido);
- ii. Empresas que utilizam ou estão em processo de adoção de tecnologias IA em gestão de sinistros; e
- iii. Profissionais que utilizam *software* de gestão de sinistros, com ou sem automação por IA.

3.2.2. Tamanho da amostra e justificativa

A definição do tamanho da amostra em PLS-SEM é uma etapa essencial para garantir a validade estatística e a robustez dos resultados, especialmente em pesquisas exploratórias como é o caso desse estudo. De acordo com Hair *et al.* (2017), existem duas abordagens principais para estimar o tamanho da amostra em modelos PLS-SEM: (1) a abordagem mais simples e amplamente utilizada é a regra de ouro, que sugere um tamanho mínimo de amostra equivalente a dez vezes o número de caminhos (setas) que convergem para o constructo mais complexo do modelo. No entanto, essa abordagem não considera aspectos como o tamanho de efeito (f^2), o nível de significância estatística (α) e o poder estatístico desejado, que são fundamentais para estimativas mais precisas e cientificamente embasadas (Hair *et al.*, 2017). Optou-se, portanto, pela (2) abordagem mais robusta e precisa, baseada em mínimos quadrados, utilizando o *software G*Power* para o cálculo do tamanho da amostra. Essa metodologia leva em conta parâmetros-chave como o número de variáveis preditoras, tamanho de efeito, nível de significância e poder estatístico, que foram definidos com base nas melhores práticas da literatura, conforme será apresentado a seguir.

3.2.2.1. Tamanho de efeito (f^2)

De acordo com Cohen (2013), o tamanho de efeito (f^2) é uma métrica fundamental para estimar a amostra necessária em estudos empíricos. Ele reflete a magnitude da relação entre variáveis independentes e dependentes no modelo e é classificado como pequeno (0,02), médio (0,15) ou grande (0,35). Em pesquisas exploratórias, como nesse estudo, o uso de um f^2 pequeno é amplamente recomendado para garantir sensibilidade suficiente na identificação de relações teóricas, mesmo que sutis. Hair *et al.* (2017) reforçam que adotar um f^2 pequeno em estudos iniciais assegura que até mesmo efeitos de baixa magnitude, mas teoricamente relevantes, possam ser detectados. Para esse estudo, que investiga fatores relacionados à adoção de IA em contextos corporativos, foi adotado $f^2 = 0,08$, classificado como pequeno. Essa decisão reflete

uma abordagem conservadora e alinhada às diretrizes metodológicas, assegurando que o cálculo do tamanho da amostra seja sensível a potenciais relações sutis entre variáveis.

3.2.2.2. Nível de significância (α)

O nível de significância (α) é o parâmetro que define a probabilidade de rejeitar incorretamente uma hipótese nula verdadeira, ou seja, cometer um erro do tipo I.

No cálculo do tamanho da amostra, foi utilizado $\alpha=0,01$, um critério mais rigoroso do que o tradicional $\alpha=0,05$. Essa escolha teve como objetivo garantir uma amostra suficientemente robusta para detectar efeitos estatísticos reais, reduzindo a probabilidade de erro tipo I já na fase de planejamento do estudo. Hair *et al.* (2017) enfatizam que, em modelos SEM, onde múltiplas relações são analisadas simultaneamente, um ‘ α ’ mais conservador no cálculo amostral contribui para a estabilidade das estimativas e mitiga a propagação do erro estatístico. Cohen (2013) reforça que a adoção de um ‘ α ’ menor nessa etapa fortalece a confiabilidade dos achados e melhora sua replicabilidade em estudos futuros.

Já na etapa de modelagem estrutural PLS-SEM, como será detalhado posteriormente, optou-se por utilizar $\alpha=0,05$, seguindo as recomendações de Hair *et al.* (2017) e Cohen (2013) para testes de hipóteses nesse tipo de análise.

Assim, a adoção de $\alpha=0,01$ no cálculo do tamanho da amostra e $\alpha=0,05$ na modelagem estrutural reflete um equilíbrio metodológico entre rigor estatístico e viabilidade analítica, garantindo a robustez da amostra sem comprometer a interpretação dos resultados na modelagem PLS-SEM.

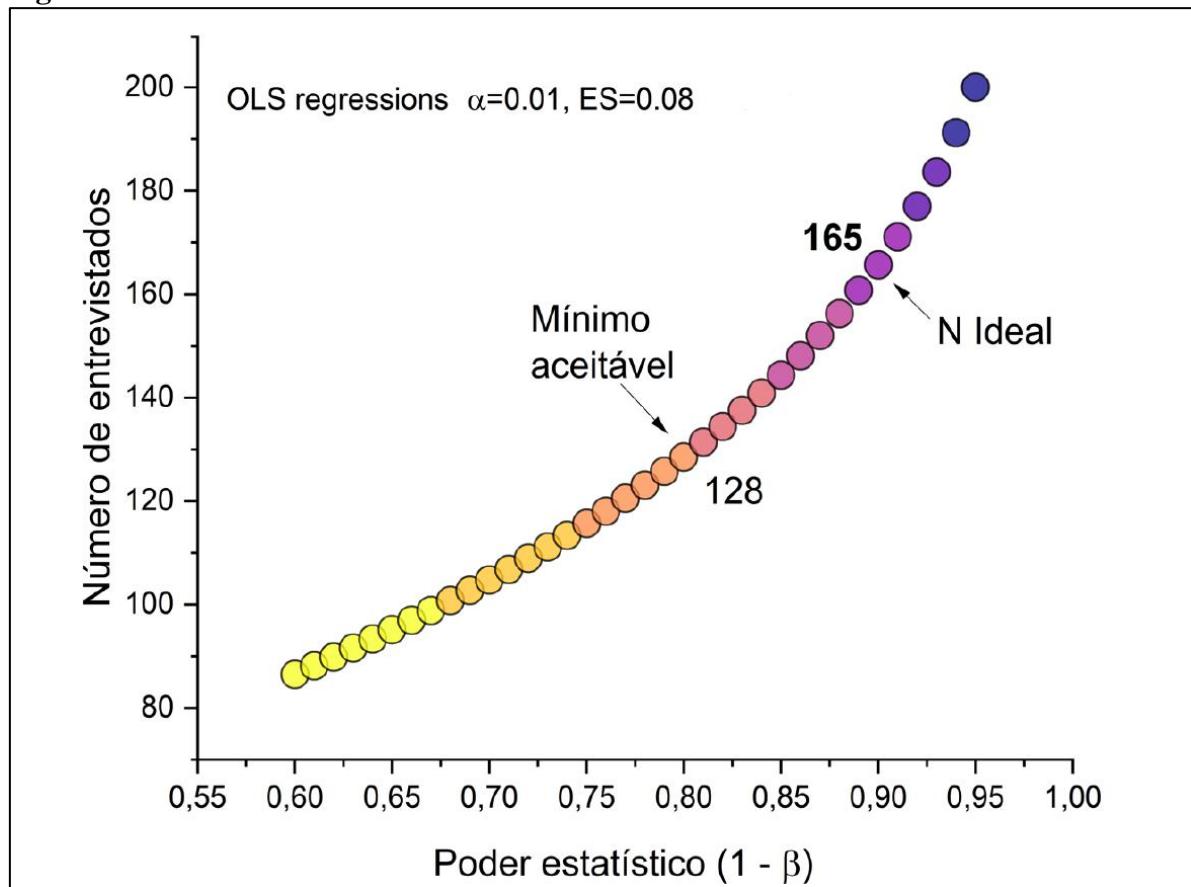
3.2.2.3. Poder estatístico (1- β)

O poder estatístico (1- β) é a probabilidade de identificar corretamente um efeito verdadeiro, evitando um erro do tipo II. Para esse estudo, foi adotado um poder estatístico de 90% (1- β = 0,90), superando o limite mínimo de 80% recomendado por Cohen (2013) para garantir análises estatisticamente significativas. Hair *et al.* (2017) destacam que um poder estatístico elevado é oportuno em estudos exploratórios e modelos SEM, especialmente em cenários com efeitos pequenos, como o adotado nesse estudo ($f^2 = 0,08$). O uso de 1- β = 0,90 reflete uma abordagem conservadora, assegurando que até mesmo relações sutis sejam identificadas. Essa escolha foi particularmente relevante no contexto desse estudo, que envolve um modelo conceitual complexo. O poder estatístico foi considerado no cálculo amostral realizado no *G*Power*, confirmado que o número de respondentes proposto atenderia às exigências metodológicas.

3.2.2.4. Integração dos parâmetros no cálculo amostral

Com base nos parâmetros estabelecidos ($f^2 = 0,08$, $\alpha = 0,01$ e $1-\beta = 0,90$), o software *G*Power* foi utilizado para calcular o tamanho mínimo necessário da amostra, considerando uma análise de regressão múltipla (*OLS regressions*). Os resultados indicaram que o número mínimo de respondentes seria de 128, enquanto a amostra ideal seria composta por 165 participantes. Para garantir uma margem de segurança metodológica e reforçar a robustez estatística, decidiu-se ampliar o tamanho da amostra para 200 casos. Essa decisão foi estratégica, especialmente considerando a complexidade do modelo conceitual, que apresenta 10 caminhos para o constructo dependente principal. Com 200 casos, o estudo excede a exigência da regra de ouro, que estabelece um mínimo de 10 casos por caminho (Hair *et al.*, 2017). Os dados apresentados na Figura 7, a seguir, evidenciam que a amostra definida não apenas atende, mas supera os requisitos mínimos, garantindo a adequação do estudo e aumentando a confiabilidade dos resultados.

Figura 7: Cálculo de estimativa amostral



Fonte: o autor, a partir dos resultados obtidos no software *G*Power* (2024).

A robustez da amostra definida é evidenciada pelos resultados apresentados nesse estudo, detalhados no Capítulo 4, que validam as métricas utilizadas e confirmam a adequação estatística do modelo. O modelo estrutural apresentou um coeficiente de determinação elevado ($R^2 = 0,777$ para a intenção comportamental), indicando uma forte capacidade explicativa dos constructos analisados. Além disso, as métricas de consistência interna (como o *alfa de Cronbach* e a confiabilidade composta) e de validade convergente e discriminante (como o AVE) atenderam aos critérios recomendados pela literatura, assegurando a qualidade das medições. O uso de *bootstrapping* com 5.000 randomizações reforça a robustez estatística dos resultados, garantindo maior confiabilidade nas inferências realizadas. Esses achados destacam que a amostra de 200 respondentes não apenas cumpre os requisitos teóricos e metodológicos, mas também oferece uma base sólida para o desenvolvimento de um modelo teórico relevante e aplicável ao contexto corporativo analisado.

3.3. Validação do questionário por especialistas (pré-teste)

De acordo com Forza (2002), o pré-teste de um questionário pode envolver três grupos: (1) colegas pesquisadores, que verificam se o questionário está alinhado aos objetivos da pesquisa (2) especialistas do setor, que identificam possíveis questões desnecessárias ou mal formuladas, e, (3) respondentes-alvo, que avaliam o instrumento quanto à clareza, relevância e adequação ao propósito do estudo.

Neste estudo, o pré-teste foi realizado com a participação de nove profissionais, divididos em 3 grupos: (1) colegas pesquisadores: selecionados três pesquisadores com experiência em estudos quantitativos e na aplicação de pesquisas em administração, (2) especialistas do setor de seguros automotivos: três especialistas do setor, escolhidos com base em sua experiência mínima de cinco anos no setor de seguros automotivos e no envolvimento direto com projetos de tecnologia, assegurando que o *feedback* reflita uma visão ampla das práticas de mercado e, (3) respondentes-alvo: escolhidos três profissionais que atuam diretamente com manuseio de *software* de gestão de sinistros, refletindo o público-alvo final da pesquisa, garantindo que suas percepções sejam relevantes para o contexto estudado.

O processo de validação do questionário foi documentado por meio de entrevistas com protocolo semiestruturado conduzidas com os 3 grupos, conforme recomendado por Forza (2002). Durante o pré-teste, os participantes responderam ao questionário sob a supervisão do pesquisador, permitindo a identificação e o ajuste de ambiguidades ou dificuldades de

entendimento. Após o preenchimento, os participantes foram entrevistados para fornecer *feedback* detalhado sobre pontos específicos, tais como as questões abaixo recomendadas por Forza (2002):

- As instruções estavam claras?
- As perguntas estavam claras?
- Houve alguma dificuldade em entender o tipo de resposta esperado ou em fornecer essas respostas?
- Há alguma questão que você considera desnecessária ou repetitiva, que deva ser retirada do questionário?
- Existe alguma pergunta que você incluiria?

De acordo com a recomendação de Forza (2002) o pesquisador registrou o processo de resposta ao questionário para garantir *insights* sobre a clareza das perguntas e a eficácia do *design* do questionário no contexto prático da pesquisa, conforme Quadro 4, a seguir.

3.3.1 Resultado da validação do questionário por especialistas

O Quadro 4, a seguir, sintetiza as contribuições recebidas, categorizadas por área de atuação dos avaliadores, e destaca as alterações implantadas, a partir dos comentários e observações.

Quadro 4: Validação do questionário por especialistas

Categoria	Relevância	As instruções estavam claras?	As perguntas estavam claras?	Dificuldade em entender o tipo de resposta esperado?	Questões desnecessárias ou repetitivas?	Perguntas que você incluiria?	Sugestões Implantadas
Colega Pesquisador A	Prof. Dr. Especialista em mercados e geração de valor, com 10 anos de experiência em pesquisas acadêmicas e profissionais. Nota: informações coletadas no currículo Lattes, que tem natureza pública.	Sim.	Sim.	Nenhuma dificuldade.	Não identificou.	Incluir pergunta sobre barreiras e dificuldades no uso da IA.	Adicionada pergunta sobre barreiras e dificuldades.
Colega Pesquisador B	Prof. Ms. Especialista em desenvolvimento	Sim.	Sim, mas recomendou simplificar,	Não houve dificuldade, mas achou o	Comentou que a repetição da escala em cada	Não sugeriu novas perguntas.	Não houve implementação das sugestões.

	<p>corporativo, Doutorando, com 5 anos de experiência em pesquisas acadêmicas e profissionais.</p> <p>Nota: informações coletadas no currículo Lattes, que tem natureza pública.</p>		<p>removendo o termo "sistema de IA" das perguntas.</p>	<p>processo demorado pela repetição da escala de respostas.</p>	<p>pergunta torna o processo mais demorado e desnecessário.</p>		<p>No processo de piloto, verificou-se que as sugestões não impactavam o preenchimento.</p>
Colega Pesquisador C	<p>Prof. Dr. Especialista em métodos quantitativos com mais de 8 anos de experiência em pesquisas acadêmicas e profissionais.</p> <p>Nota: informações coletadas no currículo Lattes, que tem natureza pública.</p>	<p>Sim, mas comentou que o termo "é ou será" pode gerar confusão e sugeriu ajustes.</p>	<p>Sim, mas sugeriu retirar o termo "sistema de IA" das perguntas e colocar na introdução do questionário.</p>	<p>Nenhuma dificuldade.</p>	<p>Repetição da escala torna o questionário longo.</p>	<p>Não sugeriu novas perguntas, mas recomendou alterar o formato das perguntas para acelerar o processo.</p>	<p>Ajuste no questionário, utilizando apenas o termo "será".</p>
Especialista do Setor A	<p>Especialista do Setor com cargo de gerência e vasta experiência no desenvolvimento de software baseado em IA.</p>	<p>Sim, as instruções estavam claras.</p>	<p>Algumas perguntas ficaram confusas, especialmente sobre capacitação.</p>	<p>Sim, houve dificuldade com perguntas sobre treinamento, que pareceram ambíguas.</p>	<p>Sentiu ambiguidade na pergunta sobre capacitação (formação acadêmica vs treinamento).</p>	<p>Sugere incluir mais contexto sobre a empresa fornecendo o treinamento e a clareza de instrução sobre capacitação.</p>	<p>Inclusão de mais detalhes no contexto sobre capacitação e ajustes na redação das perguntas sobre treinamento.</p>
Especialista do Setor B	<p>Especialista do Setor com cargo de gerência e vasta experiência na no processo de gestão de sinistro de automóveis.</p>	<p>Sim, as instruções estavam claras.</p>	<p>Sim, as perguntas estavam claras, exceto por uma com viés negativo que pode confundir o respondente.</p>	<p>Não, exceto por uma pergunta com viés negativo que pode repetitivas devido ao viés afirmativo e uma negativa no meio do questionário.</p>	<p>Comentou que algumas perguntas sobre se a IA é vista como ameaça ao emprego.</p>	<p>Sugere incluir uma pergunta sobre a percepção da IA como ameaça ao emprego.</p>	<p>Inclusão de pergunta sobre percepção da IA como ameaça ao emprego.</p>

						utilização de I.A.	
Especialista do Setor C	Especialista do Setor com cargo de gerência e vasta experiência no desenvolvimento de <i>software</i> baseado em IA.	Sim, mas sugere adicionar sinônimos para termos como "adesão" para facilitar a compreensão.	Comentou que o range de alternativas para resposta (discordo totalmente, concordo, etc.) poderia ser simplificado.	Sim, comentou que a granularidade das respostas das respostas torna o questionário confuso para o público-alvo.	Acha que o questionário ficou longo e com perguntas parecidas, o que pode levar o respondente a respostas enviesadas. Na pergunta sobre custo-benefício acredita que o respondente não saberá mensurar. As perguntas sobre o nível de capacitação não estão claras se é treinamento ou nível educacional.	Sugere perguntas mais diretas sobre a percepção dos benefícios da IA e a adesão de empresas ao uso de IA. Incluir uma questão sobre se o usuário já teve algum contato com algum tipo de inteligência artificial.	Inclusão de uma questão sobre se o usuário já teve algum contato com algum tipo de inteligência artificial. Revisão da redação das perguntas que exploram o nível de capacitação.
Respondente Alvo A	Respondente Alvo com mais de 20 anos em utilização de <i>software</i> de gestão de sinistros.	Não, achou que as instruções poderiam ser mais claras.	Algumas perguntas podem gerar dúvida, especialmente entre "concordo" e "concordo totalmente", pois a tecnologia IA é muito nova para ele o respondente assinalar o "concordo totalmente"	Sim, indicou que o receio de perda de emprego pode influenciar a resposta.	Não identificou questões repetitivas, mas comentou sobre a relevância de simplificar as alternativas de resposta.	Sugeriu incluir perguntas sobre receio de perda de emprego em função da IA.	Inclusão de pergunta sobre o receio de perda de emprego causado pela IA.

Respondente Alvo B	Respondente Alvo com mais de 15 anos em utilização de <i>software</i> de gestão de sinistros.	Sim, as instruções estavam claras.	Sim, mas condicionou algumas respostas ao conhecimento prévio sobre qual papel a I.A irá desempenhar dentro do workflow, pois não está claro.	Algumas perguntas dependem do conhecimento sobre qual papel a I.A irá desempenhar dentro do workflow, o que pode dificultar a resposta.	Comentou que algumas perguntas pareciam repetitivas, especialmente aquelas que falam sobre preço e custo.	Sugere incluir uma pergunta sobre a experiência prévia do usuário em utilização de I.A.	Inclusão de orientações sobre qual papel a I.A irá desempenhar dentro do workflow. Inclusão de uma questão sobre a experiência prévia do usuário com IA.
Respondente Alvo C	Respondente Alvo com mais de 15 anos em utilização de <i>software</i> de gestão de sinistros.	Sim, as instruções estavam claras.	Sim, mas observou que algumas perguntas pareciam similares.	Não houve dificuldade com o tipo de resposta, mas sugeriu incluir campo para justificar respostas parciais. Na pergunta sobre custo-benefício acredita que o respondente não saberá mensurar.	Comentou que algumas perguntas pareciam repetitivas, especialmente sobre custo-benefício e compatibilidade.	Sugeriu incluir um campo para justificar respostas parciais, como "concordo parcialmente". Incluir uma questão sobre se o usuário já teve algum contato com algum tipo de inteligência artificial.	Inclusão de uma questão sobre a experiência prévia do usuário com IA. Inclusão de uma pergunta sobre se a IA é vista como ameaça ao emprego.

Fonte: elaborado pelo autor (2024)

Com base nos resultados da validação do questionário por especialistas, apresentados no Quadro 4, foram incorporadas três perguntas adicionais ao questionário, compondo o moderador ‘características individuais’. Essas inclusões foram realizadas em caráter exploratório, considerando a recorrência de dois temas centrais identificados: (1) o impacto da experiência prévia com IA na aceitação de novos sistemas e (2) a preocupação quanto ao impacto da IA na estabilidade do emprego.

A literatura sobre adoção de tecnologia destaca que fatores contextuais, como a percepção de risco e familiaridade com a tecnologia, podem influenciar a aceitação de novos sistemas (Venkatesh *et al.*, 2003; Moore e Benbasat, 1991). Além disso, Venkatesh (2021) aponta que a opacidade dos sistemas de IA pode gerar resistência, tornando essencial considerar aspectos psicológicos no processo de adoção. Dessa forma, essa inclusão permite explorar possíveis lacunas teóricas e metodológicas relacionadas à adoção da IA no ambiente corporativo.

Diante desse contexto, foram adicionadas as seguintes perguntas ao questionário:

- **CI4** - Eu utilizei ou já utilizei algum tipo de inteligência artificial em minhas atividades profissionais.
- **CI5** - Eu utilizei ou já utilizei algum tipo de inteligência artificial para lazer, estudos ou outras atividades.
- **CI6** - Eu acredito que o uso de Inteligência Artificial em sistemas de orçamentação representa uma ameaça ao meu emprego ou à minha função atual.

As escalas de resposta para essas questões foram operacionalizadas como variáveis *dummy* ('Sim' ou 'Não'), assegurando a padronização com outras perguntas do questionário.

A versão revisada e aprimorada do questionário está disponível na seção de apêndices.

3.4. Coleta de dados piloto

Complementando o pré-teste, a fase de coleta de dados piloto foi realizada com o objetivo de testar a operacionalização do questionário em campo, com vistas à sua dinâmica e viabilidade para uma aplicação em larga escala. Essa etapa permitiu avaliar aspectos práticos como (a) o tempo de resposta, (b) a facilidade de acesso ao questionário, (c) o fluxo de naveabilidade e (d) a experiência geral dos respondentes. Esses elementos asseguram a aderência do processo às necessidades da pesquisa, conforme recomendado por Hair *et al.* (2009).

3.4.1. Procedimentos e critérios de seleção dos profissionais

O piloto foi conduzido com um grupo de 10 profissionais com experiência no manuseio de *software* de gestão de sinistros. O critério de seleção para os participantes incluíram:

- i. Experiência mínima de 1 ano no uso de sistemas de gestão de sinistros.
- ii. Cargo ou atividade atual como analista ou gestor de sinistros (atuando diretamente na tomada de decisões relacionadas a orçamentos de reparo); e

- iii. Representatividade geográfica dentro das seguradoras, assegurando diversidade regional e operacional.

Os participantes foram selecionados para refletir características similares ao público-alvo da pesquisa. Esse cuidado na amostra piloto é importante para antecipar desafios operacionais e ajustar o processo de coleta, conforme ressaltado por Vieira (2010) e Forza (2002). A diversidade dos participantes proporcionou *insights* abrangentes e alinhados às condições reais de aplicação do questionário.

3.4.2. Ajustes no processo com base no *feedback* obtido

A coleta de dados piloto ocorreu entre 01 e 11 de outubro de 2024 e contribuiu para a validação do questionário em um ambiente prático. Os resultados obtidos estão descritos a seguir:

- i. **Tempo de resposta:** O tempo médio de preenchimento variou entre 5 e 8 minutos, considerado adequado para o público-alvo. Quando perguntados sobre a percepção de duração, nenhum respondente indicou achar o tempo excessivo, evidenciando que o questionário está bem ajustado nesse aspecto.
- ii. **Facilidade de acesso:** Todos os participantes relataram conforto ao acessar o *link* enviado, sem qualquer dificuldade técnica significativa. Isso demonstra que a interface e os métodos de distribuição são intuitivos e acessíveis, em linha com as recomendações de Vieira (2010).
- iii. **Fluxo de naveabilidade:** A naveabilidade foi avaliada como fluida, com os respondentes relatando facilidade em seguir as instruções e responder às questões. Quando questionados diretamente, todos afirmaram que o fluxo era claro e intuitivo.
- iv. **Engajamento e finalização:** Todos os participantes completaram o questionário e relataram uma experiência tranquila e fácil. A taxa de finalização de 100% reflete um elevado nível de engajamento, um indicativo positivo para a aplicação em larga escala.
- v. **Opção “não sei ou não tenho como opinar”:** Inicialmente, para todas as perguntas da seção 1 do questionário, havia uma opção de resposta “não sei ou não tenho como opinar” destinada a casos em que o respondente não tivesse informações suficientes para responder. No entanto, essa opção foi removida após a coleta piloto, pois nenhum respondente a utilizou em qualquer questão. Quando indagados, os participantes explicaram que, por possuírem experiência no uso de *software* de orçamentação, não encontraram necessidade de utilizá-la. A remoção dessa opção contribuiu para

simplificar e tornar o questionário mais direto, sem comprometer a qualidade ou integridade dos dados coletados.

3.5. Coleta de dados em larga escala

A coleta de dados em larga escala foi realizada entre os meses de outubro e novembro de 2024. Conforme destacado por Hair *et al.* (2009), a precisão das estimativas e a capacidade de generalização dos resultados dependem diretamente da qualidade e da quantidade dos dados coletados.

A estratégia adotada para a coleta envolveu o envio do *link* de acesso ao questionário *online* por meio de *e-mails* e ferramentas de mídias sociais, como *WhatsApp* e *LinkedIn*. O foco foi direcionado a profissionais envolvidos em operações que estão em fase de adoção de IA na gestão de sinistros. Os contatos dos respondentes foram obtidos com o apoio dos gestores das seguradoras, garantindo a diversidade e a representatividade da amostra. Esses gestores, pertencentes a rede de contatos do pesquisador, foram previamente envolvidos no estudo por meio de reuniões individuais, nas quais o escopo do projeto foi apresentado e sua colaboração foi solicitada para incentivar a participação e maximizar o engajamento dos respondentes.

A participação foi inteiramente voluntária, e os respondentes foram informados de que o tempo estimado para o preenchimento do questionário seria de aproximadamente 7 minutos, o que foi confirmado durante a coleta como adequado e bem aceito.

Para maximizar a taxa de participação, lembretes automatizados foram enviados a cada três dias para os participantes que ainda não haviam respondido o questionário. Adicionalmente, foi realizado contato direto com os participantes, sempre respeitando a ética e o consentimento prévio, para reforçar a importância da pesquisa e incentivar sua finalização. A estrutura do questionário foi projetada para garantir a completude dos dados, não permitindo que o respondente avançasse ou finalizasse sem responder a todas as questões. Essa abordagem assegurou que 100% dos participantes concluíssem o questionário com todas as perguntas respondidas, eliminando lacunas de dados e garantindo a consistência necessária para análises subsequentes.

O uso de lembretes automatizados e o contato direto demonstraram-se eficazes para elevar a taxa de resposta, enquanto estratégias de engajamento, como a oferta de relatórios de

benchmarking e acesso antecipado aos resultados, aumentaram o interesse dos respondentes, alinhando-se às sugestões de Vieira (2010) e Hair *et al.* (2009).

3.6. Tratamento dos dados pré-análise por SEM

Para assegurar a qualidade e consistência do conjunto de dados, foi realizada uma etapa de revisão e preparação antes das análises pelo método SEM (Hair *et al.*, 2009). Como se trata de uma pesquisa de natureza exploratória, a confiabilidade do conjunto de dados foi avaliada cuidadosamente, de modo a identificar e corrigir eventuais problemas.

3.6.1. Detecção e manuseio dos dados faltantes

Não foram identificados dados faltantes no conjunto de respostas coletado. Esse resultado reflete o *design* do questionário, que foi configurado para que os respondentes não pudessem avançar sem responder a todas as questões. Assim, o conjunto de dados foi considerado completo e adequado para as etapas subsequentes de análise, eliminando a necessidade de imputação ou exclusão de casos, conforme práticas recomendadas por Hair *et al.* (2009).

3.6.2. Detecção e manuseio de *outliers*

Durante a revisão preliminar dos dados, não foram identificados *outliers* que comprometessem a análise subsequente. Como o método PLS-SEM não assume normalidade dos dados, não foi aplicada uma técnica convencional de remoção de *outliers* baseada em pressupostos paramétricos. No entanto, para garantir a qualidade das estimativas, foi realizada uma análise exploratória das respostas, avaliando a distribuição dos indicadores, a presença de valores extremos e possíveis influências desproporcionais nos coeficientes do modelo. O conjunto de dados foi considerado adequado para os procedimentos de modelagem estrutural subsequentes, conforme os critérios de qualidade recomendados para PLS-SEM (Hair *et al.*, 2017).

3.7. Análise dos dados por PLS-SEM

A análise dos dados por PLS-SEM foi realizada para avaliar as relações propostas no modelo conceitual, com base nas diretrizes de Hair *et al.* (2017). Por se tratar de uma pesquisa exploratória, os resultados das análises serão apresentados detalhadamente no Capítulo 4, no qual as métricas de validade, confiabilidade e ajuste do modelo estrutural são discutidas.

3.7.1. Validação do modelo de medição por análise fatorial confirmatória (AFC)

A validação do modelo de medição foi conduzida utilizando a Análise Fatorial Confirmatória (AFC), com foco na verificação de três aspectos principais: (1) validade convergente, (2) validade discriminante e (3) confiabilidade dos constructos. Esses critérios garantem que os indicadores reflitam adequadamente os constructos teóricos e que as métricas apresentadas estejam em conformidade com os padrões estabelecidos na literatura.

3.7.1.1. Validação convergente por análise das cargas fatoriais

A validade convergente foi avaliada com base nas cargas fatoriais das questões que compõem os constructos, assegurando que cada questão represente adequadamente o conceito que se pretende medir. De acordo com Hair *et al.* (2009), cargas superiores a 0,70 são ideais, enquanto valores acima de 0,50 para o *Average Variance Extracted* (AVE) indicam boa representatividade do constructo.

3.7.1.2. Validação discriminante por *Heterotrait-Monotrait Ratio* (HTMT)

A validade discriminante foi analisada utilizando o critério HTMT (*Heterotrait-Monotrait Ratio*), considerado robusto para identificar a distinção entre constructos. Os valores encontrados foram inferiores a 0,90 confirmando que os constructos são conceitualmente distintos, eliminando problemas de sobreposição.

3.7.1.3. Confiabilidade dos constructos

A confiabilidade dos constructos foi avaliada por meio da *Composite Reliability* (CR) e do *Alfa de Cronbach*, sendo ambos superiores a 0,70 para todos os constructos, o que assegura a consistência interna dos dados coletados.

3.7.2. Estimativas e teste do modelo estrutural

Após a validação do modelo de medição, a análise prosseguiu com o teste do modelo estrutural, que examina as relações causais entre os constructos. Um dos principais indicadores utilizados foi o coeficiente de determinação (R^2), que mede a proporção da variância da variável dependente explicada pelas variáveis independentes no modelo. Em termos simples, o R^2 avalia o quanto o modelo é capaz de prever ou explicar os resultados observados. Além disso, métricas de ajuste global, como o Critério de Informação Bayesiano (BIC), foram analisadas para avaliar a qualidade geral do modelo.

4 RESULTADOS E ANÁLISES

Este capítulo apresenta e analisa os resultados obtidos a partir da pesquisa de campo, explorando as relações entre os constructos propostos no modelo conceitual e validando as hipóteses levantadas no estudo. O processo de análise teve início com a realização de (1) uma análise fatorial confirmatória (AFC), que permitiu verificar a validade e confiabilidade dos constructos, seguida pela (2) identificação e exclusão de questões com baixas cargas fatoriais, assegurando a coerência interna do modelo.

A partir desse refinamento, (3) foram desenvolvidos e testados quatro modelos estruturais, derivados do modelo conceitual, seguindo diretrizes metodológicas para a avaliação progressiva da robustez do modelo teórico e da influência de variáveis moderadoras. De acordo com Hair *et al.* (2017), em modelagens de equações estruturais, recomenda-se iniciar as análises com um modelo mais simples, sem moderações ou interações complexas, e gradualmente testar configurações mais elaboradas, permitindo uma avaliação incremental do impacto das variáveis no fenômeno estudado. Seguindo essa abordagem, esta pesquisa desenvolveu quatro variações de modelos estruturais, buscando comparar a robustez do modelo conceitual sob diferentes níveis de complexidade. Essa abordagem possibilitou explorar desde uma estrutura básica, baseada apenas em relações diretas entre os constructos, até configurações mais abrangentes, que incorporam moderações identificadas na literatura e nos achados empíricos da pesquisa.

Os modelos testados foram definidos da seguinte forma:

- **Modelo estrutural 1:** Representa a estrutura básica do modelo conceitual sem a inclusão de efeitos de moderação, servindo como referência inicial para avaliar as relações diretas entre os constructos.
- **Modelo estrutural 2:** Inclui todas as variáveis moderadoras propostas, permitindo testar a influência dessas interações e identificar potenciais efeitos condicionais sobre a intenção de adoção de IA.
- **Modelo estrutural 3:** Restringe a análise a um subconjunto específico de variáveis preditoras e moderadoras, buscando uma configuração mais parcimoniosa, baseada na significância estatística observada nos modelos anteriores.

- **Modelo estrutural 4:** Introduz a moderadora específica ‘CI6 - Confiança’, identificada durante o processo de validação do questionário por especialistas, como uma variável potencialmente relevante para a adoção de IA. A moderadora ‘CI6 - Confiança’ foi operacionalizada por meio da seguinte pergunta, apresentada no subcapítulo 3.3.1 – Resultados da Validação por Especialistas: ‘*Eu acredito que o uso de Inteligência Artificial em sistemas de orçamentação representa uma ameaça ao meu emprego ou à minha função atual*’.

Essas etapas foram conduzidas utilizando o *software Smart-PLS 4.0* e técnicas de modelagem de equações estruturais com mínimos quadrados parciais (PLS-SEM), permitindo a comparação sistemática entre os modelos, com 5000 randomizações via *bootstrapping* para inferência da significância dos parâmetros e um nível de significância (α) de 5%. Esse processo permitiu a comparação sistemática entre os modelos, levando em consideração métricas de ajuste global, como variância explicada (R^2) e critério de informação bayesiano (BIC), além dos coeficientes de caminho (β) e seus respectivos valores de significância (p). Os próximos subcapítulos apresentam os detalhes e os principais achados das análises realizadas.

4.1 Validação do modelo de medição por análise fatorial confirmatória (AFC)

O objetivo da análise fatorial confirmatória foi verificar a estrutura de constructos do modelo conceitual, testando sua coerência interna. O processo de AFC foi dividido em duas etapas principais, conforme recomendado por Hair *et al.* (2017) sendo (1) validação do modelo de medição e (2) preparação para o modelo estrutural.

4.1.1. Validação do modelo de medição

4.1.1.1. Validez convergente por análise das cargas fatoriais

As cargas fatoriais indicam a relação entre as questões do questionário e seus constructos, sendo fundamentais para avaliar a validez convergente do modelo. De acordo com Hair *et al.* (2017), o valor ideal para cargas fatoriais é superior a **0,708**, pois indica que a questão explica pelo menos 50% da variância do constructo ($R^2 > 0,5$). Valores entre **0,4** e **0,7** são considerados minimamente aceitáveis em estudos exploratórios, desde que sua inclusão não comprometa a coerência interna dos constructos, e valores abaixo de **0,4** devem ser eliminados.

Tabela 1: Análise das cargas fatoriais

Relação	Outer loadings (cargas fatoriais)
CF1 <- Condições Facilitadoras	0.600
CF2 <- Condições Facilitadoras	0.739
CO1 <- Compatibilidade	0.757
CO2 <- Compatibilidade	0.703
CO3 <- Compatibilidade	0.892
CS1 <- Custo	0.820
CS2 <- Custo	0.110
CS3 <- Custo	0.888
CT1 <- Confiança na Tecnologia	0.759
CT2 <- Confiança na Tecnologia	0.877
CT3 <- Confiança na Tecnologia	0.915
ED1 <- Expectativa de Desempenho	0.943
ED2 <- Expectativa de Desempenho	0.883
ED3 <- Expectativa de Desempenho	0.920
EDUC1 <- Educação	0.535
EDUC2 <- Educação	0.910
EDUC3 <- Educação	0.470
EE1 <- Expectativa de Esforço	0.735
EE2 <- Expectativa de Esforço	0.757
IC1 <- Intenção Comportamental	0.918
IC2 <- Intenção Comportamental	0.779
IC3 <- Intenção Comportamental	0.922
IP1 <- Inovatividade Pessoal	0.757
IP2 <- Inovatividade Pessoal	0.661
IP3 <- Inovatividade Pessoal	0.922
IS1 <- Influência Social	0.822
IS2 <- Influência Social	0.879
IS3 <- Influência Social	0.771
VP1 <- Valor do Preço	0.598
VP2 <- Valor do Preço	0.694

Fonte: elaborado pelo autor (2024).

Nessa fase, a questão **CS2** foi excluída devido à sua carga fatorial significativamente baixa, abaixo do limite mínimo recomendado. Outras questões com cargas moderadas, como **EDUC3** (0,470), foram mantidas nesta etapa, pois estão dentro do limite aceitável. Essas questões só

devem ser eliminadas se sua exclusão demonstrar uma melhora na coerência interna do constructo, em conformidade com as recomendações de Hair *et al.* (2017).

4.1.1.2. Validação discriminante por *Heterotrait-Monotrait Ratio* (HTMT)

A validade discriminante verifica se os constructos de um modelo são distintos entre si, garantindo que cada constructo capture um conceito único, sem sobreposição de significado (Hair *et al.*, 2017). Neste estudo, utilizou-se o critério HTMT (*Heterotrait-Monotrait Ratio*), considerado mais robusto que o método de *Fornell-Larcker*. Ao contrário do critério de *Fornell-Larcker*, o HTMT não depende da AVE e fornece um teste mais rigoroso, especialmente quando os constructos têm correlações altas e podem estar capturando o mesmo conceito. Por isso, ele é mais sensível para identificar problemas de validade discriminante (Henseler *et al.*, 2009). O HTMT mede a razão entre as correlações médias de itens de constructos diferentes e de um mesmo constructo. Valores abaixo de 0,9 indicam validade discriminante adequada.

Tabela 2: Validação discriminante entre os constructos do modelo.

	<i>Heterotrait-monotrait ratio (HTMT)</i>
Condições Facilitadoras <-> Compatibilidade	0.563
Confiança na Tecnologia <-> Compatibilidade	0.829
Confiança na Tecnologia <-> Condições Facilitadoras	0.618
Custo <-> Compatibilidade	0.853
Custo <-> Condições Facilitadoras	0.420
Custo <-> Confiança na Tecnologia	0.774
Educação <-> Compatibilidade	0.549
Educação <-> Condições Facilitadoras	0.433
Educação <-> Confiança na Tecnologia	0.602
Educação <-> Custo	0.360
Expectativa de Desempenho <-> Compatibilidade	0.768
Expectativa de Desempenho <-> Condições Facilitadoras	0.403
Expectativa de Desempenho <-> Confiança na Tecnologia	0.718
Expectativa de Desempenho <-> Custo	0.837
Expectativa de Desempenho <-> Educação	0.300
Expectativa de Esforço <-> Compatibilidade	0.858
Expectativa de Esforço <-> Condições Facilitadoras	0.470
Expectativa de Esforço <-> Confiança na Tecnologia	0.829
Expectativa de Esforço <-> Custo	0.795
Expectativa de Esforço <-> Educação	0.590
Expectativa de Esforço <-> Expectativa de Desempenho	0.770
Influência Social <-> Compatibilidade	0.662
Influência Social <-> Condições Facilitadoras	0.395
Influência Social <-> Confiança na Tecnologia	0.659
Influência Social <-> Custo	0.707

Influência Social <-> Educação	0.304
Influência Social <-> Expectativa de Desempenho	0.722
Influência Social <-> Expectativa de Esforço	0.775
Inovatividade Pessoal <-> Compatibilidade	0.670
Inovatividade Pessoal <-> Condições Facilitadoras	0.454
Inovatividade Pessoal <-> Confiança na Tecnologia	0.692
Inovatividade Pessoal <-> Custo	0.526
Inovatividade Pessoal <-> Educação	0.490
Inovatividade Pessoal <-> Expectativa de Desempenho	0.569
Inovatividade Pessoal <-> Expectativa de Esforço	0.716
Inovatividade Pessoal <-> Influência Social	0.614
Intenção Comportamental <-> Compatibilidade	0.834
Intenção Comportamental <-> Condições Facilitadoras	0.477
Intenção Comportamental <-> Confiança na Tecnologia	0.885
Intenção Comportamental <-> Custo	0.824
Intenção Comportamental <-> Educação	0.475
Intenção Comportamental <-> Expectativa de Desempenho	0.802
Intenção Comportamental <-> Expectativa de Esforço	0.869
Intenção Comportamental <-> Influência Social	0.731
Intenção Comportamental <-> Inovatividade Pessoal	0.752
Valor do Preço <-> Compatibilidade	0.478
Valor do Preço <-> Condições Facilitadoras	0.366
Valor do Preço <-> Confiança na Tecnologia	0.473
Valor do Preço <-> Custo	0.514
Valor do Preço <-> Educação	0.261
Valor do Preço <-> Expectativa de Desempenho	0.470
Valor do Preço <-> Expectativa de Esforço	0.456
Valor do Preço <-> Influência Social	0.426
Valor do Preço <-> Inovatividade Pessoal	0.413
Valor do Preço <-> Intenção Comportamental	0.450

Fonte: elaborado pelo autor (2024).

No modelo avaliado, todas as relações entre os constructos apresentaram valores de HTMT inferiores a 0,9, conforme apresentado na Tabela 2, confirmando que os constructos medidos possuem distinção clara e são conceitualmente únicos. Essa distinção é essencial para garantir que as hipóteses testadas no modelo estrutural sejam baseadas em constructos bem definidos e independentes.

4.1.1.3. Métricas de confiabilidade dos constructos

A análise das métricas de confiabilidade dos constructos é essencial para garantir a consistência interna e validade do modelo de medição. Nesta etapa, foram analisadas três métricas principais: (1) o *alpha de Cronbach*, que mede a coerência interna entre as questões que

compõem um constructo; (2) a confiabilidade composta (Rho_c) que avalia a confiabilidade geral considerando os pesos das questões; e (3) a variância média extraída (AVE), que verifica a quantidade de variância explicada pelos itens em relação ao erro. Essas métricas, conforme orientações de Hair *et al.* (2017), asseguram a robustez do modelo para a próxima etapa de análise.

Tabela 3: Coerência interna e validade convergente dos constructos

Constructos	<i>Cronbach's alpha</i> (standardized)	<i>Cronbach's alpha</i>	<i>Composite reliability (rho_c)</i>	<i>Average variance extracted (AVE)</i>
Compatibilidade	0.831	0.841	0.830	0.621
Condições Facilitadoras	0.614	0.631	0.621	0.453
Confiança na Tecnologia	0.886	0.895	0.888	0.727
Custo	0.552	0.845	0.684	0.491
Educação	0.701	0.774	0.688	0.445
Expectativa de Desempenho	0.940	0.941	0.940	0.839
Expectativa de Esforço	0.715	0.715	0.715	0.557
Influência Social	0.862	0.868	0.865	0.681
Inatividade Pessoal	0.830	0.848	0.828	0.620
Intenção Comportamental	0.905	0.914	0.908	0.767
Valor do Preço	0.587	0.595	0.590	0.420

Fonte: elaborado pelo autor (2024).

De acordo com Hair *et al.* (2017), os valores recomendados para o *alpha de Cronbach* e a confiabilidade composta (Rho_c) situam-se entre 0,7 e 0,95, enquanto a variância média extraída (AVE) deve ser superior a 0,5 para indicar validade convergente adequada. Assim, conforme apresentado na Tabela 3, quatro constructos preditores apresentaram métricas abaixo do ideal: ‘condições facilitadoras’, ‘custo’, ‘educação’ e ‘valor do preço’. As cargas fatoriais de cada questão associada a esses constructos serão reavaliadas, passando por um processo de refinamento que visa assegurar a consistência interna e a validade do modelo de medição. Esse processo será detalhado no próximo subcapítulo, onde as questões com cargas fatoriais inadequadas serão analisadas e, se necessário, excluídas, a fim de garantir um modelo teoricamente consistente e estatisticamente robusto.

4.1.2. Preparação para o modelo estrutural

A preparação para o modelo estrutural envolveu duas etapas: (1) a exclusão das questões com baixa carga fatorial relacionadas aos constructos indicados anteriormente – ‘condições

facilitadoras', 'custo', 'educação' e 'valor do preço' – e, (2) o refinamento do modelo de medição. A seguir, são detalhados os critérios e os resultados de cada etapa.

4.1.2.1. Exclusão das questões com baixa carga fatorial

A exclusão de questões com baixa carga fatorial foi fundamentada nos critérios estabelecidos por Hair *et al.* (2017).

4.1.2.1.1. Critérios adotados

- **Cargas fatoriais ideais:** Valores superiores a 0,708, indicando que a variável explica pelo menos 50% da variância do constructo.
- **Limite inferior aceitável:** Cargas fatoriais entre 0,4 e 0,7 foram aceitas em caráter exploratório, se não impactassem negativamente as métricas de confiabilidade do constructo.
- **Exclusão:** Variáveis com cargas fatoriais inferiores a 0,4 foram removidas.

4.1.2.1.2. Processo de análise

Foram analisadas as cargas fatoriais apresentadas na Tabela 1. Identificou-se que algumas questões apresentaram cargas significativamente baixas, como CS2 (0,110), EDUC1 (0,535), EDUC3 (0,470) e VP1 (0,598). Essas questões foram excluídas devido à sua baixa contribuição para os respectivos constructos.

4.1.2.2. Refinamento do modelo de medição

Após a exclusão das questões com baixa carga fatorial, foi realizado o refinamento do modelo de medição. Essa etapa teve como objetivo verificar os impactos das alterações e assegurar que o modelo permanecesse estatisticamente robusto e teoricamente consistente.

4.1.2.2.1. Reavaliação das métricas

As métricas recalculadas para o modelo refinado foram apresentadas na Tabela 4, a seguir. Os resultados indicaram que:

- **Alpha de Cronbach:** Os valores variaram entre 0,715 e 0,940, atendendo ao intervalo recomendado de 0,7 a 0,95.
- **Confiabilidade composta (pc):** Todos os constructos apresentaram valores superiores a 0,7, indicando boa consistência interna.

- **Variância média extraída (AVE):** Os valores oscilaram entre 0,557 e 0,839, todos acima do limite de 0,5.

Tabela 4: Coerência interna e validade convergente após reavaliação

	<i>Cronbach's alpha (standardized)</i>	<i>Cronbach's alpha)</i>	<i>Composite reliability (rho_c)</i>	<i>Average variance extracted (AVE)</i>
Compatibilidade	0.831	0.841	0.830	0.621
Condições Facilitadoras	0.886	0.895	0.888	0.727
Confiança na Tecnologia	0.847	0.851	0.849	0.737
Custo	0.940	0.941	0.940	0.839
Educação	0.715	0.715	0.715	0.557
Expectativa de Desempenho	0.862	0.868	0.865	0.681
Expectativa de Esforço	0.830	0.848	0.828	0.620
Influência Social	0.905	0.914	0.908	0.767
Inatividade Pessoal	0.831	0.841	0.830	0.621
Intenção Comportamental	0.886	0.895	0.888	0.727
Valor do Preço	0.847	0.851	0.849	0.737

Fonte: elaborado pelo autor (2024).

Com o refinamento do modelo de medição concluído e a reavaliação das métricas apresentando resultados alinhados às recomendações da literatura (Hair *et al.*, 2017), verifica-se que o modelo atingiu um nível satisfatório de robustez estatística e consistência teórica. O *alpha de Cronbach*, a confiabilidade composta (pc) e a variância média extraída (AVE) indicam que os constructos possuem coerência interna e validade convergente adequadas, garantindo a confiabilidade dos dados coletados. Assim, o modelo de medição está devidamente validado e pronto para dar suporte à próxima etapa da análise, permitindo que o modelo estrutural seja testado com confiança na sua capacidade de capturar as relações causais propostas.

Outro ponto a ser observado é que, de forma prática, com o refinamento do modelo de medição e a validação das métricas estatísticas, por meio da exclusão de questões com baixa carga factorial, chegou-se a uma versão validada do questionário, que assegura confiabilidade e aplicabilidade. Esse processo metodológico robusto não apenas garante a adequação do instrumento às necessidades desse estudo, mas também oferece uma ferramenta replicável para futuros trabalhos acadêmicos e organizacionais, especialmente no campo da adoção de tecnologias de IA. O questionário final, após todas as etapas de validação e refinamento, encontra-se no Apêndice A.

4.2. Estimativa e teste do modelo estrutural

O objetivo desse subcapítulo é apresentar a análise detalhada do modelo estrutural, considerando diferentes configurações teóricas previamente discutidas na introdução desse capítulo. Seguindo as diretrizes metodológicas de Hair *et al.* (2017), que recomendam iniciar a modelagem estrutural com um modelo mais simples e gradualmente incorporar complexidade para avaliar a robustez das relações testadas, foram analisadas quatro variações do modelo estrutural. Essas variações contemplam diferentes combinações de variáveis independentes, dependentes e moderadoras, sendo, em resumo: (a) o modelo estrutural 1, que representa a estrutura completa sem efeitos de moderação; (b) o modelo estrutural 2, que incorpora todas as variáveis moderadoras propostas; (c) o modelo estrutural 3, que reduz a análise a um subconjunto específico de variáveis preditoras e moderadoras; e (d) o modelo estrutural 4, que adiciona uma moderadora específica – ‘CI6 _ Confiança’, identificada como relevante no processo de validação do questionário.

Cada modelo foi submetido a análises utilizando métricas consagradas de ajuste global, como **R²** e **BIC**, além da avaliação dos coeficientes de caminho (β) e da significância estatística (**p-valor**).

Durante as análises, foram identificados desafios metodológicos, como problemas técnicos no cálculo de p-valores para o modelo estrutural 2, relacionados à singularidade da matriz de covariância. Esse fator destaca a necessidade de cautela na interpretação dos resultados desse modelo e reforça a importância de comparar os modelos de forma sistemática. Para isso, o critério de informação bayesiano, BIC, de Schwarz (1978), foi utilizado para avaliar a parcimônia e adequação de cada modelo, complementando a análise estatística.

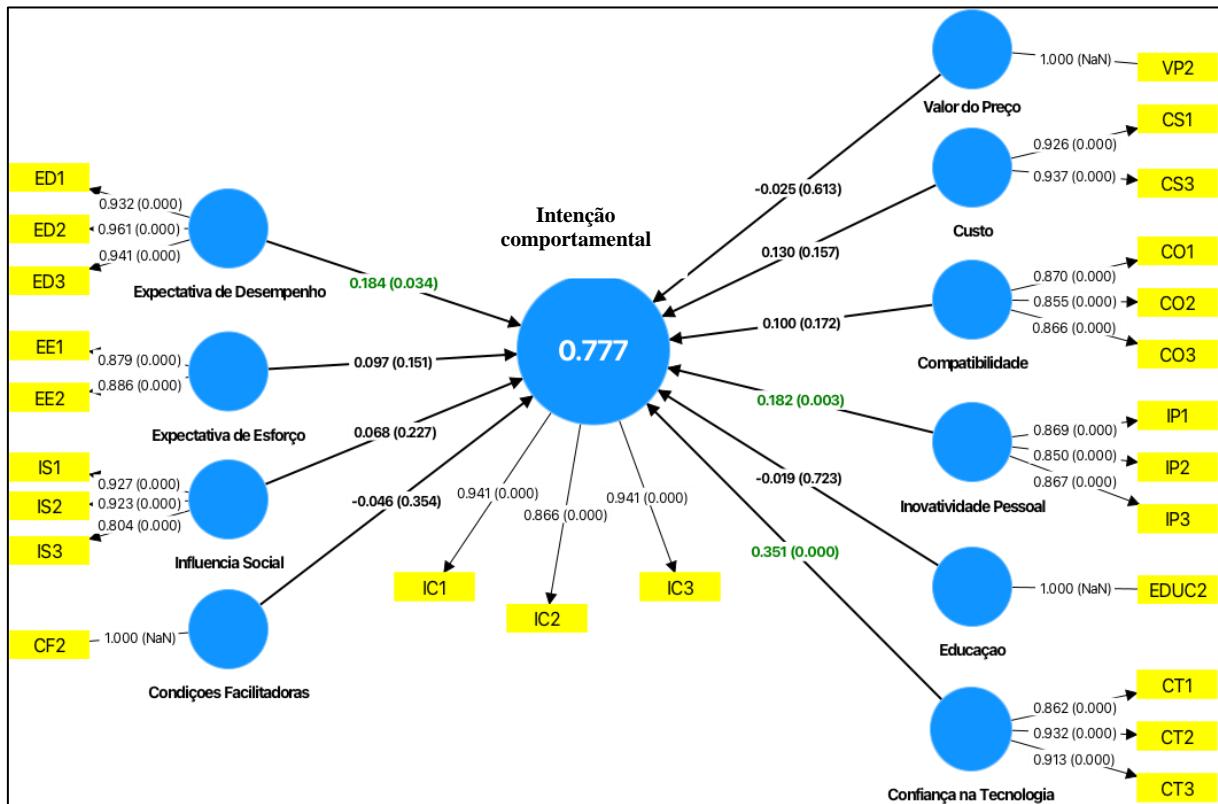
Ao longo do capítulo, serão apresentados (1) os resultados de cada variação do modelo estrutural, seguidos de (2) uma comparação crítica entre eles, com base em seus ajustes e relevância teórica. Essa abordagem permitirá (3) identificar o modelo mais adequado para responder à questão de pesquisa: “quais são os fatores que mais influenciam a adoção de inteligência artificial para automação do processo de gestão de sinistros em seguradoras de automóveis no Brasil?”.

4.2.1. Modelo estrutural 1 – estrutura completa sem moderação

O modelo estrutural 1 representa a configuração inicial para avaliar as relações estruturais entre os constructos, sem a inclusão de variáveis moderadoras. Esse modelo busca verificar a força

das associações diretas entre as variáveis independentes e a variável dependente, oferecendo uma base para comparações posteriores com configurações mais complexas. Hair *et al.* (2017) destacam que, em modelagens estruturais, é recomendável iniciar com um modelo o mais simplificado possível para avaliar o padrão geral das relações e a qualidade das métricas antes de adicionar complexidade, como efeitos moderadores.

Figura 8: Modelo estrutural 1 – completo sem moderação



Fonte: elaborado pelo autor (2024).

4.2.1.1. Variância explicada (R^2) do modelo estrutural 1

O modelo estrutural 1, explica 77,7% da variância da variável dependente ‘intenção de comportamental’ ($R^2 = 0.777$). Esse resultado demonstra uma contribuição substancial dos constructos independentes, indicando que as relações diretas capturadas nesse modelo possuem boa capacidade explicativa no contexto analisado. Segundo Hair *et al.* (2017), valores elevados de R^2 indicam forte adequação do modelo aos dados observados, especialmente em estudos com múltiplas variáveis latentes. Para fins de comparação, a UTAUT 1 e UTAUT 2 apresentam resultados de variância de 70% e 74% respectivamente.

4.2.1.2. Coeficientes de caminho do modelo estrutural 1

A Tabela 5, a seguir, apresenta os coeficientes de caminho (β) e seus respectivos valores de significância (p-valor) do modelo estrutural 1. Três constructos apresentaram significância estatística no nível de confiança de 95% ($p < 0.05$): ‘confiança na tecnologia’, ‘expectativa de desempenho’ e ‘inovatividade pessoal’.

Tabela 5: Coeficientes de caminho do modelo estrutural 1

Constructo	β	p-valor
Compatibilidade	0.100	0.172
Confiança na Tecnologia	0.351	0.000
Condições Facilitadoras	-0.045	0.354
Custo	0.130	0.157
Educação	-0.019	0.723
Expectativa de Desempenho	0.184	0.034
Expectativa de Esforço	0.097	0.151
Influência Social	0.068	0.227
Inovatividade Pessoal	0.182	0.003
Valor do Preço	-0.025	0.613

Fonte: elaborado pelo autor (2024).

‘Confiança na tecnologia’ apresentou o coeficiente mais elevado ($\beta = 0.351$, $p < 0.001$), reforçando sua relevância como fator determinante para a intenção de adoção. Esse resultado está alinhado com a literatura, que destaca a confiança como fundamental para a aceitação da inteligência artificial. (Venkatesh *et al.*, 2021).

‘Expectativa de desempenho’ demonstrou significância estatística ($\beta = 0.184$, $p = 0.034$), indicando que percepções de melhoria no desempenho influenciam positivamente a intenção de adoção. Este achado é consistente com o modelo UTAUT (Venkatesh *et al.*, 2003).

‘Inovatividade pessoal’ apresentou efeito positivo e significativo ($\beta = 0.182$, $p = 0.003$), evidenciando que indivíduos mais inclinados à inovação estão mais propensos a adotar novas tecnologias (Agarwal e Prasad, 1998).

Outros constructos, como ‘compatibilidade’, ‘custo’, ‘condições facilitadoras’ e ‘influência social’, não demonstraram significância estatística ($p > 0.05$), sugerindo que seus impactos diretos na variável dependente são limitados no contexto analisado.

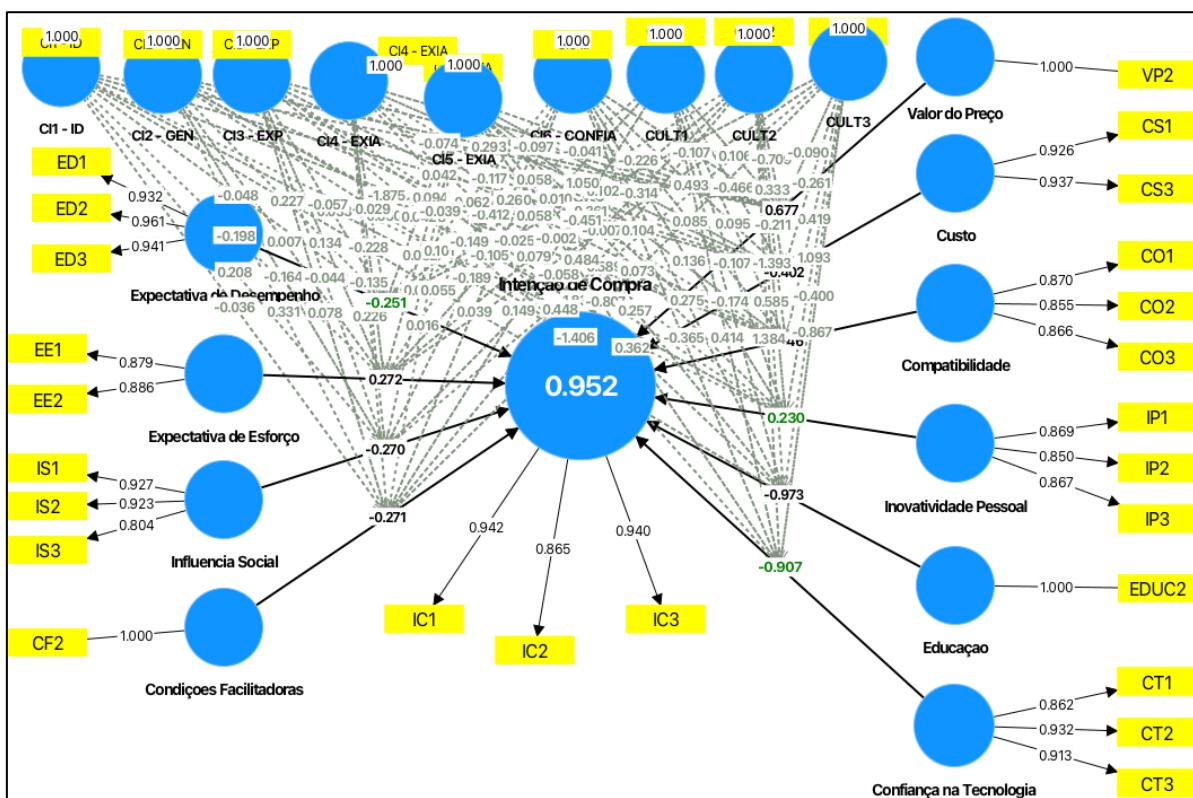
4.2.1.3. Critério de informação bayesiano (BIC) do modelo estrutural 1

O BIC do modelo estrutural 1 é de -206.259, o que indica um excelente ajuste do modelo, destacando sua capacidade de explicar a variância (R^2) de forma eficiente. Segundo Schwarz (1978), valores mais baixos de BIC refletem melhor equilíbrio entre ajuste do modelo e complexidade. Esse resultado posiciona o modelo estrutural 1 como uma referência robusta para a avaliação comparativa dos modelos subsequentes.

4.2.2. Modelo estrutural 2 – configuração com moderações completas

O modelo estrutural 2 expande a análise realizada no modelo estrutural 1 ao incorporar todas as variáveis moderadoras propostas no estudo. Essa configuração busca avaliar o impacto das interações entre constructos no comportamento da variável dependente, fornecendo uma análise mais detalhada e robusta. Porém, apesar do potencial para maior explicação de variância, o modelo estrutural 2 apresentou problemas técnicos relacionados à ausência de p-valores calculados, limitando a análise estatística de significância.

Figura 9: Modelo estrutural 2 – completo com todas as moderações



Fonte: elaborado pelo autor (2024).

4.2.2.1. Variância explicada (R^2) do modelo estrutural 2

O modelo estrutural 2 apresentou uma variância explicada de 95,2% ($R^2 = 0.952$), indicando que ele captura uma proporção substancial da variância da variável dependente ‘intenção de comportamental’. No entanto, esse aumento em relação ao modelo estrutural 1 ($R^2 = 0.777$) foi obtido ao custo de uma complexidade significativamente maior, com 90 novos coeficientes adicionados ao modelo. Esse aumento na complexidade gera muitas limitações interpretativas e práticas, conforme apontado por Hair *et al.* (2017), que destacam que modelos mais complexos não necessariamente resultam em melhorias substanciais em explicação teórica.

4.2.2.2. Coeficientes de caminho do modelo estrutural 2

Embora o modelo estrutural 2 tenha introduzido moderações para os caminhos de correlação, os coeficientes de caminho (β) obtidos carecem de significância estatística, pois o *software* SmartPLS não conseguiu calcular os p-valores para esse modelo. Tal problema técnico ocorreu devido à singularidade das matrizes de variância e covariância geradas após a inclusão das variáveis moderadoras, tornando-as não invertíveis e inviabilizando a computação completa do modelo.

Tabela 6: Coeficientes de caminho do modelo estrutural 2

Constructo	β	p-valor
Compatibilidade	0.546	n/g
Condições Facilitadoras	-0.271	n/g
Confiança na Tecnologia	-0.907	n/g
Custo	-0.402	n/g
Educação	-0.973	n/g
Expectativa de Desempenho	-0.251	n/g
Expectativa de Esforço	0.272	n/g
Influência Social	-0.270	n/g
Inovatividade Pessoal	0.230	n/g
Valor do Preço	0.677	n/g

Fonte: elaborado pelo autor (2024).

A ausência de p-valores impossibilita qualquer inferência estatística robusta sobre a significância das relações observadas. Apesar disso, algumas tendências nos coeficientes são notáveis: ‘confiança na tecnologia’ ($\beta = -0.907$) apresenta uma inversão no sinal em comparação ao modelo estrutural 1 ($\beta = 0.351$), sugerindo que a introdução de moderações pode

ter distorcido as relações previamente positivas. ‘Compatibilidade’ ($\beta = 0.546$) aparece como um potencial preditor positivo, mas sua significância não pode ser avaliada, o que limita conclusões. A inclusão de variáveis moderadoras parece ter introduzido inconsistências nos coeficientes de constructos, como ‘educação’ ($\beta = -0.973$) e ‘custo’ ($\beta = -0.402$), que não demonstraram impacto negativo relevante no modelo estrutural 1. Devido a essas limitações, o modelo estrutural 2 é incapaz de oferecer resultados confiáveis e interpretáveis para os constructos e relações moderadas.

4.2.2.3. Critério de informação bayesiano (BIC) do modelo estrutural 2

O BIC do modelo estrutural 2 é de -106.182, um valor substancialmente superior ao do modelo estrutural 1 (-206.259). Segundo Schwarz (1978), valores mais baixos de BIC indicam modelos mais teoricamente adequados. O aumento significativo no BIC reflete a penalização pela complexidade adicional introduzida no modelo estrutural 2 sem ganhos proporcionais em explicação teórica ou predição.

4.2.2.4. Considerações sobre o modelo estrutural 2

Embora o modelo estrutural 2 tenha apresentado um R^2 elevado, sua eficácia é seriamente limitada por problemas técnicos e interpretativos: (1) complexidade excessiva: a inclusão de múltiplas variáveis moderadoras introduziu complexidade desnecessária, dificultando a interpretação e o cálculo estatístico, (2) problemas técnicos: a singularidade das matrizes de variância e covariância tornou o cálculo de p-valores impossível, inviabilizando a validação das relações moderadas e (3) BIC elevado: o valor do BIC reflete que o modelo é menos eficiente que o modelo estrutural 1. Conforme ressaltado por Hair *et al.* (2017), um modelo altamente complexo sem interpretação prática contradiz o objetivo da modelagem estrutural, que é simplificar fenômenos complexos sem comprometer a validade teórica.

Os dados mostram que o modelo estrutural 2 é inferior ao modelo estrutural 1 em termos de parcimônia, robustez estatística e confiabilidade. Embora apresente um R^2 mais elevado, sua complexidade adicional e os problemas técnicos o tornam inadequado para a análise. O modelo estrutural 1 permanece como o melhor modelo até o momento, fornecendo uma estrutura direta, confiável e teoricamente robusta.

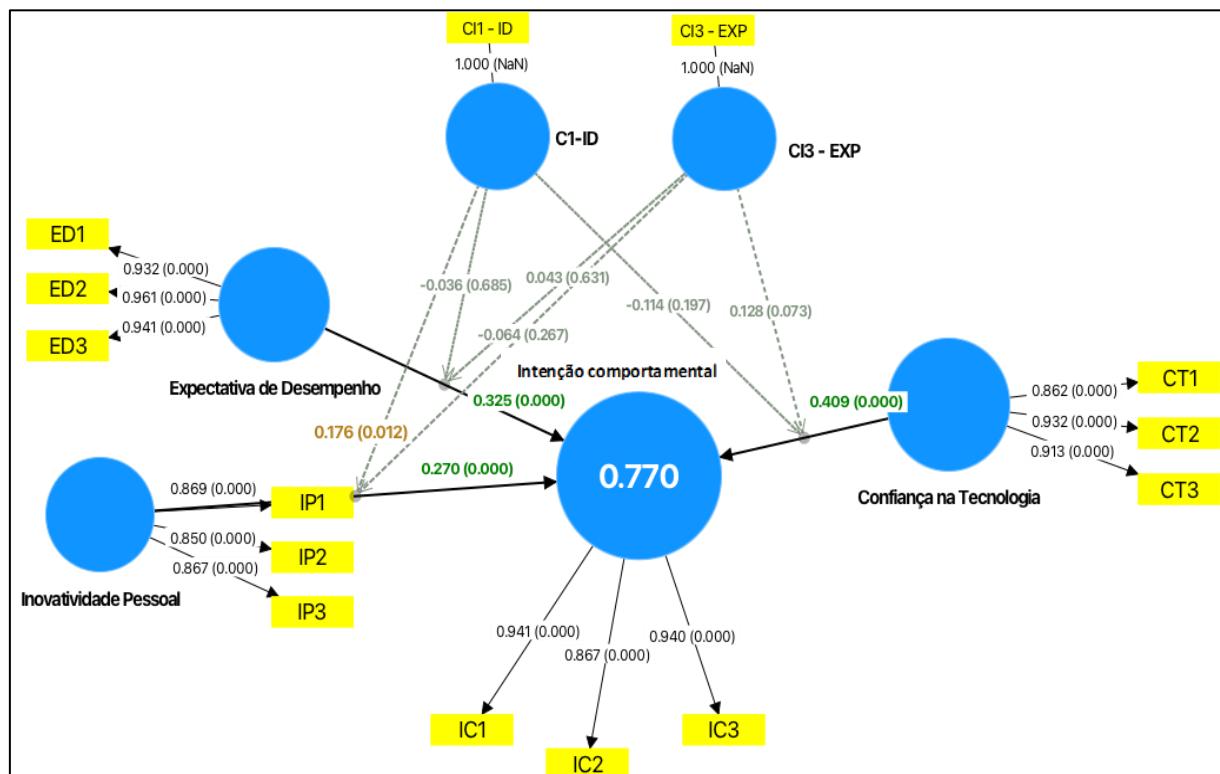
4.2.3. Modelo estrutural 3 – configuração seletiva

O modelo estrutural 3 foi desenvolvido como uma configuração seletiva, priorizando três variáveis independentes e duas variáveis moderadoras. As variáveis independentes foram selecionadas com base em sua significância estatística evidenciada no modelo estrutural 1, conforme avaliado anteriormente, indicando sua robustez e impacto direto na ‘intenção comportamental’. Essa abordagem alinha-se às recomendações metodológicas de Hair *et al.* (2017), que destacam a importância de concentrar a análise em constructos com significância empírica comprovada, para maximizar a relevância teórica e a parcimônia do modelo.

As duas variáveis moderadoras foram definidas por sua ampla aplicação e reconhecimento na literatura da UTAUT 1, conforme estabelecido por Venkatesh *et al.* (2003). Essas variáveis têm sido consistentemente utilizadas em estudos sobre adoção tecnológica, dada sua capacidade de capturar nuances contextuais e influências específicas nas relações entre constructos.

Essa estratégia reflete uma escolha intencional de foco em relações significativas e reconhecidas pela literatura, permitindo explorar em maior profundidade os fatores-chave que influenciam a adoção de tecnologias, com atenção especial à sua relevância prática e teórica.

Figura 10: Modelo estrutural 3 – configuração seletiva



Fonte: elaborado pelo autor (2024).

4.2.3.1. Variância explicada (R^2) do modelo estrutural 3

O modelo estrutural 3 apresentou um R^2 de 0.770, explicando 77% da variância da variável dependente. Esse valor é ligeiramente inferior ao do modelo estrutural 1 ($R^2 = 0.777$), sugerindo que a seleção de apenas constructos com alta significância e a inclusão de variáveis moderadoras nesse modelo não trouxe ganhos expressivos na explicação do fenômeno em estudo.

4.2.3.2. Coeficientes de caminho do modelo estrutural 3

Os coeficientes de caminho no modelo estrutural 3 incluem tanto os efeitos principais quanto os efeitos moderados, conforme apresentados na Tabela 7, a seguir:

Tabela 7: Coeficientes de caminho do modelo estrutural 3

Efeito Principal/Moderado	β	p-valor
CI3 - EXP → Intenção Comportamental	-0.003	0.956
Confiança na Tecnologia → Intenção Comportamental	0.409	0.000
Expectativa de Desempenho → Intenção Comportamental	0.325	0.000
Inovatividade Pessoal → Intenção Comportamental	0.270	0.000
C1-ID x Expectativa de Desempenho → Intenção Comportamental	-0.036	0.685
C1-ID x Inovatividade Pessoal → Intenção Comportamental	0.176	0.012
C1-ID x Confiança na Tecnologia → Intenção Comportamental	-0.114	0.197
CI3 - EXP x Expectativa de Desempenho → Intenção Comportamental	0.043	0.631
CI3 - EXP x Inovatividade Pessoal → Intenção Comportamental	-0.064	0.267
CI3 - EXP x Confiança na Tecnologia → Intenção Comportamental	0.128	0.073

Fonte: elaborado pelo autor (2024).

‘Confiança na tecnologia’ ($\beta = 0.409$; $p < 0.001$): principal fator determinante da ‘intenção comportamental’, consistente com os resultados do modelo estrutural 1 e reforçando sua importância central. ‘Expectativa de desempenho’ ($\beta = 0.325$; $p < 0.001$): confirma sua relevância como um dos principais preditores da adoção tecnológica. ‘Inovatividade pessoal’ ($\beta = 0.270$; $p < 0.001$): mantém-se significativa, indicando que características individuais têm papel relevante na adoção de novas tecnologias.

A única moderação significativa foi C1-ID x ‘Inovatividade pessoal’ → Intenção comportamental ($\beta = 0.176$; $p = 0.012$). Apesar disso, o coeficiente é pequeno, limitando sua relevância prática. Outros efeitos moderados, como CI3-EXP x ‘Confiança na tecnologia’ ($\beta =$

0.128; $p = 0.073$), ficaram próximos à significância, mas ainda insuficientes para justificar sua inclusão.

4.2.3.3. Critério de informação bayesiano (BIC) do modelo estrutural 3

O BIC do modelo estrutural 3 foi de -121.182, sendo maior, em termos absolutos, do que o do modelo estrutural 1 (-206.259) e menor do que o do modelo estrutural 2 (-106.182). Conforme destacado por Schwarz (1978), valores menores de BIC indicam melhor ajuste em modelos comparáveis. Isso evidencia que, apesar da redução na complexidade em relação ao modelo estrutural 2, o modelo estrutural 3 ainda não supera o modelo estrutural 1 em adequação teórica e parcimônia. A comparação dos BICs reforça que o modelo estrutural 1 permanece a escolha mais robusta, combinando ‘simplicidade’ estrutural com elevado poder explicativo.

4.2.3.4. Considerações sobre o modelo estrutural 3

A análise do modelo estrutural 3 confirma a relevância de ‘confiança na tecnologia’, ‘expectativa de desempenho’ e ‘inovatividade pessoal’ como preditores centrais da ‘intenção comportamental’. No entanto, os efeitos moderados se mostraram amplamente insignificantes, com exceção de um coeficiente de baixa magnitude. Quando comparado ao modelo estrutural 1, o modelo estrutural 3 adiciona complexidade sem ganhos expressivos, o que é refletido em um BIC mais elevado. Além disso, em relação ao modelo estrutural 2, o modelo estrutural 3 é mais funcional devido à computação bem-sucedida dos p-valores e maior estabilidade nos coeficientes de caminho. Apesar disso, não supera o modelo estrutural 1 em termos de simplicidade e robustez. Assim, até o momento, o modelo estrutural 1 permanece como a configuração mais adequada para explicar a adoção de inteligência artificial no contexto estudado.

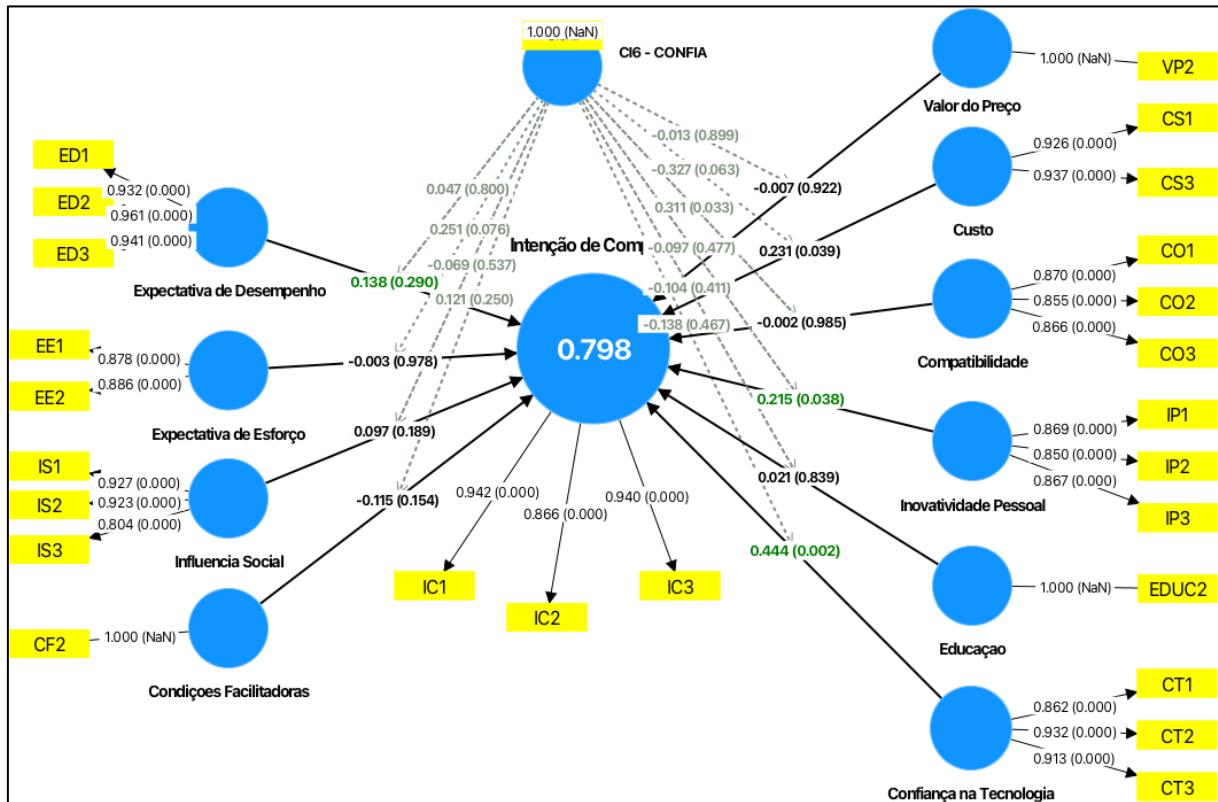
4.2.4. Modelo estrutural 4: modelo completo com moderadora específica

Este subcapítulo apresenta a análise do modelo estrutural 4, que inclui uma moderadora específica, a variável CI6, associada à percepção de ameaça no contexto de adoção de tecnologias. Essa variável equivale à pergunta: *"Eu acredito que o uso de inteligência artificial em sistemas de orçamentação representa uma ameaça ao meu emprego ou à minha função atual"*. A inclusão da variável CI6 foi motivada pela alta frequência com que essa preocupação surgiu durante o processo de validação com especialistas e o teste piloto do instrumento de coleta de dados, reforçando a necessidade de abordar questões relacionadas à aceitação tecnológica e suas implicações no ambiente organizacional. Segundo Venkatesh *et al.* (2003) e Moore e Benbasat (1991), a percepção de risco ou ameaça pode influenciar significativamente a adoção de novas tecnologias, especialmente em contextos profissionais em que mudanças tecnológicas podem impactar funções e atividades.

O modelo estrutural 4 propõe adicionar complexidade ao modelo estrutural 1, utilizando as mesmas variáveis independentes e a variável dependente ‘intenção comportamental’, mas incluindo a variável moderadora CI6. Essa abordagem permite investigar se a percepção de ameaça (representada pela CI6) modifica a intensidade ou direção das relações entre as variáveis preditoras e a intenção de adoção de IA. Conforme Schwarz (1978), a introdução de elementos adicionais no modelo deve ser avaliada quanto à sua capacidade de melhorar o ajuste e a explicação do fenômeno, sem comprometer a parcimônia.

Ao explorar a interação entre os constructos principais e a variável moderadora, o modelo estrutural 4 busca fornecer uma visão mais rica e detalhada das dinâmicas que influenciam a aceitação da IA, destacando como fatores contextuais específicos podem amplificar ou atenuar essas relações. Esse desenho metodológico alinha-se às recomendações de Hair *et al.* (2017), que destacam a importância de construir modelos iterativos para capturar efeitos moderadores e enriquecer a compreensão teórica de fenômenos complexos.

Figura 11: Modelo estrutural 4 – completo com uma moderadora específica



Fonte: elaborado pelo autor (2024).

4.2.4.1. Variância explicada (R^2) do modelo estrutural 4

O modelo estrutural 4 apresentou um R^2 de 0.798, indicando que a variância explicada pela variável dependente 'Intenção Comportamental' é ligeiramente superior ao Modelo estrutural 1 ($R^2 = 0.777$) e ao modelo estrutural 3 ($R^2 = 0.770$). Entretanto, conforme destaca Hair *et al.* (2017), a adição de complexidade em um modelo deve ser justificada por melhorias substanciais no poder explicativo. Neste caso, a proximidade dos valores de R^2 entre os modelos indica que o aumento observado no modelo estrutural 4 não é suficiente para justificar sua adoção, principalmente frente ao modelo estrutural 1, que apresenta maior parcimônia.

4.2.4.2. Coeficientes de caminho do modelo estrutural 4

Os coeficientes de caminho (β) e seus respectivos p-valores no modelo estrutural 4 são apresentados na Tabela 8, a seguir:

Tabela 8: Coeficientes de caminho do modelo estrutural 4

Constructo/Efeito Moderado	β	p-valor
CI6 - CONFIA → Intenção Comportamental	-0.022	0.809
Compatibilidade → Intenção Comportamental	-0.002	0.985
Condições Facilitadoras → Intenção Comportamental	-0.115	0.154
Confiança na Tecnologia → Intenção Comportamental	0.444	0.002
Custo → Intenção Comportamental	0.231	0.039
Educação → Intenção Comportamental	0.021	0.839
Expectativa de Desempenho → Intenção Comportamental	0.138	0.290
Expectativa de Esforço → Intenção Comportamental	-0.003	0.978
Influência Social → Intenção Comportamental	0.097	0.189
Inovatividade Pessoal → Intenção Comportamental	0.215	0.038
Valor do Preço → Intenção Comportamental	-0.007	0.922
CI6 - CONFIA x Inovatividade Pessoal → Intenção Comportamental	-0.097	0.477
CI6 - CONFIA x Compatibilidade → Intenção Comportamental	0.311	0.033
CI6 - CONFIA x Valor do Preço → Intenção Comportamental	-0.013	0.899
CI6 - CONFIA x Expectativa de Esforço → Intenção Comportamental	0.251	0.076
CI6 - CONFIA x Custo → Intenção Comportamental	-0.327	0.063
CI6 - CONFIA x Confiança na Tecnologia → Intenção Comportamental	-0.138	0.467
CI6 - CONFIA x Expectativa de Desempenho → Intenção Comportamental	0.047	0.800
CI6 - CONFIA x Educação → Intenção Comportamental	-0.104	0.411
CI6 - CONFIA x Condições Facilitadoras → Intenção Comportamental	0.121	0.250
CI6 - CONFIA x Influência Social → Intenção Comportamental	-0.069	0.537

Fonte: elaborado pelo autor (2024).

‘Confiança na tecnologia’ ($\beta = 0.444$; $p = 0.002$) confirma sua relevância como principal preditor, alinhados com os resultados dos modelos anteriores. ‘Inovatividade pessoal’ ($\beta = 0.215$; $p = 0.038$) mantém-se significativa, reforçando o impacto das características individuais

na intenção de adoção. Como ressaltam Hair *et al.* (2014), coeficientes com significância estatística devem ser priorizados na análise, pois representam efeitos robustos e confiáveis.

A única moderação com p-valor significativo foi CI6 - CONFIA x Compatibilidade ($\beta = 0.311$; $p = 0.033$). Entretanto, como alertado por Hair *et al.* (2017), a significância de uma moderação precisa ser avaliada dentro do contexto da significância do efeito principal. No presente caso, a relação principal Compatibilidade → Intenção Comportamental foi insignificante ($p = 0.985$), tornando o efeito moderador irrelevante na prática.

Os demais efeitos moderadores apresentaram p-valores elevados, indicando ausência de influência significativa.

4.2.4.3. Critério de informação bayesiano (BIC) do modelo estrutural 4

O valor do BIC para o modelo estrutural 4 foi -281.853, inferior ao BIC do modelo estrutural 1 (-206.259), ao modelo estrutural 2 (-106.182) e ao modelo estrutural 3 (-121.182). Se o objetivo fosse apenas otimizar o ajuste global, o modelo estrutural 4 seria tecnicamente o ‘melhor’ devido ao BIC mais baixo. No entanto, considerando a falta de significância estatística dos efeitos de moderação, o modelo estrutural 1 ainda é o mais apropriado, pois é mais simples e apresenta resultados mais diretos e interpretáveis.

4.2.4.4. Considerações sobre o modelo estrutural 4

A análise do modelo estrutural 4 confirma que a tentativa de incluir a moderação específica não gerou ganhos significativos no poder explicativo do modelo. A única moderação considerada estatisticamente significativa, ‘CI6 - CONFIA x Compatibilidade’, carece de relevância prática, uma vez que a relação principal não apresenta significância. Os principais resultados do modelo estrutural 4 permanecem consistentes com os achados do modelo estrutural 1: ‘confiança na tecnologia’ ($\beta = 0.444$), ‘custo’ ($\beta = 0.231$) e ‘inovatividade pessoal’ ($\beta = 0.215$) são os únicos constructos com efeitos estatisticamente significativos.

Do ponto de vista metodológico, Hair *et al.* (2017) destacam que a simplicidade e a parcimônia devem ser priorizadas em modelagem de equações estruturais. Neste sentido o modelo estrutural 1 se mantém como o mais adequado, pois apresenta (1) resultados estatísticos claros e robustos e, (2) ausência de complexidade desnecessária.

Portanto, o modelo estrutural 4, assim como os modelos estruturais 2 e 3, demonstra que a introdução de moderadores não contribuiu para o refinamento do modelo. A tentativa de

capturar efeitos de moderação resultou em complexidade adicional e interpretações inconsistentes, reforçando a superioridade do modelo estrutural 1 em desempenho e parcimônia.

4.3. Determinação do modelo estrutural mais adequado

Após a avaliação dos quatro modelos estruturais desenvolvidos, o modelo estrutural 1 foi escolhido como a configuração mais adequada para responder à pergunta de pesquisa e objetivos ao identificar e explicar “*quais são os fatores que mais influenciam a adoção de Inteligência Artificial (IA) para automação do processo de gestão de sinistros em seguradoras de automóveis no Brasil*”. Esse modelo destacou-se pela combinação de simplicidade estrutural, robustez estatística e elevada capacidade explicativa, conforme evidenciado por seu R^2 de 0.777 e o valor de critério de informação bayesiano (BIC) de -206.259. Esses resultados, alinhados às recomendações metodológicas de Schwarz (1978) e Hair *et al.* (2017), reforçam a parcimônia como um critério essencial para a modelagem de equações estruturais.

A escolha do modelo estrutural 1 reflete a eficácia das relações diretas entre as variáveis independentes ‘confiança na tecnologia’, ‘expectativa de desempenho’ e ‘inovatividade pessoal’ na explicação da intenção de adoção. Esses constructos apresentaram coeficientes estatisticamente significativos ($p < 0.05$), corroborando sua relevância teórica e prática. Em contrapartida, os modelos 2, 3 e 4, apesar de introduzirem maior complexidade com variáveis moderadoras, não resultaram em melhorias substanciais no ajuste global ou no poder explicativo.

A análise comparativa também destacou que a inclusão de variáveis moderadoras nos modelos 3 e 4 não proporcionou ganhos significativos na explicação da variância da intenção comportamental. Embora a variável moderadora CI6 no modelo estrutural 4 tenha introduzido nuances importantes relacionadas à percepção de ameaça, sua contribuição prática foi limitada devido à ausência de efeitos consistentes e significativos em interações chave. Assim, o modelo estrutural 1 representa a solução mais robusta, oferecendo uma visão clara e direta dos principais fatores que influenciam a adoção de IA, sem comprometer a simplicidade analítica ou a validade teórica.

4.4. Comparação dos achados do modelo estrutural 1 com as hipóteses teóricas

O presente subcapítulo analisa os resultados obtidos no modelo estrutural 1 em relação às hipóteses propostas no modelo conceitual.

4.4.1. H1: ‘Expectativa de desempenho’

Hipótese: A ‘expectativa de desempenho’ influencia positivamente a ‘intenção comportamental’ de usar tecnologias de IA.

Resultado no modelo estrutural 1: Hipótese aceita. A ‘expectativa de desempenho’ apresentou um coeficiente significativo e positivo ($\beta = 0.184$; $p = 0.034$), confirmando sua influência positiva na intenção de adoção de IA.

Alinhamento com o referencial teórico: A ‘expectativa de desempenho’ foi identificada como um dos três constructos mais representativos nesse estudo, reforçando sua relevância como fator determinante na ‘intenção comportamental’. Esse resultado está diretamente alinhado à UTAUT, que posiciona a ‘expectativa de desempenho’ como o constructo mais influente na intenção de uso em contextos tecnológicos. A percepção de que uma tecnologia melhora o desempenho no trabalho é um preditor robusto da sua aceitação e uso. Assim, os achados desse estudo não apenas corroboram os fundamentos da UTAUT, mas também reafirmam a aplicabilidade desse constructo no contexto específico da adoção de IA para automação de processos. Estudos prévios, como os de Almagrashi *et al.* (2016) e Fan *et al.* (2020), também reforçam a centralidade da ‘expectativa de desempenho’, destacando que tecnologias são mais rapidamente adotadas quando os usuários percebem ganhos claros em produtividade, eficiência e qualidade do trabalho.

Assim, esses achados indicam que estratégias para impulsionar a adoção de IA devem comunicar claramente os benefícios tangíveis da tecnologia, destacando como ela pode impactar positivamente o desempenho organizacional e individual.

4.4.2. H2: ‘Expectativa de esforço’

Hipótese: A ‘expectativa de esforço’ influencia positivamente a ‘intenção comportamental’ de usar tecnologias de IA.

Resultado no modelo estrutural 1: Hipótese rejeitada. A ‘expectativa de esforço’ apresentou um coeficiente positivo, porém não significativo ($\beta = 0.097$; $p = 0.151$).

Alinhamento com o referencial teórico: Embora a ‘expectativa de esforço’ seja considerada um fator relevante na UTAUT (Venkatesh *et al.*, 2003), o resultado sugere que, no contexto específico de IA para gestão de sinistros, a facilidade de uso não se mostrou um determinante significativo. Alneyadi *et al.* (2022) afirmam que, em contextos corporativos, o suporte organizacional pode atenuar a percepção de esforço.

4.4.3. H3: ‘Influência social’

Hipótese: A ‘influência social’ afeta positivamente a ‘intenção comportamental’ de usar tecnologias de IA.

Resultado no modelo estrutural 1: Hipótese rejeitada. A ‘influência social’ apresentou coeficiente positivo, mas não significativo ($\beta = 0.068$; $p = 0.227$).

Alinhamento com o referencial teórico: Apesar de ‘influência social’ ser destacada em estudos como Alneyadi *et al.* (2022) e Fan *et al.* (2020), os resultados indicam que, no contexto analisado, a opinião de colegas e superiores não influenciou significativamente a intenção de adoção de IA. Esse resultado pode refletir a maturidade tecnológica do setor ou a ausência de um endosso ativo por lideranças, alinhando-se à UTAUT, que sugere que a ‘influência social’ é mais relevante em contextos de baixa familiaridade tecnológica (Venkatesh *et al.*, 2003).

4.4.4. H4: ‘Condições facilitadoras’

Hipótese: As ‘condições facilitadoras’ influenciam positivamente a ‘intenção comportamental’ de usar tecnologias de IA.

Resultado no modelo estrutural 1: Hipótese rejeitada. O coeficiente foi negativo e não significativo ($\beta = -0.045$; $p = 0.354$).

Alinhamento com o referencial teórico: O suporte organizacional, infraestrutura e recursos necessários, que são fatores importantes na UTAUT, não foram considerados relevantes. Almagrashi *et al.* (2016) destacam que a percepção das ‘condições facilitadoras’ pode ser mitigada pela experiência prévia dos usuários ou pela cultura organizacional, tornando-se menos impactante.

4.4.5. H5: ‘Valor do preço’

Hipótese: O ‘valor do preço’ influencia negativamente a ‘intenção comportamental’ de usar tecnologias de IA.

Resultado no modelo estrutural 1: Hipótese rejeitada. O ‘valor do preço’ apresentou um coeficiente negativo, mas não significativo ($\beta = -0.025$; $p = 0.613$).

Alinhamento com o referencial teórico: Embora a UTAUT 2 (Venkatesh, Thong e Xu, 2012) destaque o ‘valor do preço’ como relevante, no presente estudo o fator não demonstrou impacto significativo. Kim, Giroux e Lee (2021) sugerem que, em contextos de adoção corporativa, a percepção de custo-benefício pode ser menos relevante quando os benefícios intangíveis, como eficiência e precisão, superam os custos percebidos.

4.4.6. H6: ‘Custo percebido’

Hipótese: O ‘custo percebido’ influencia negativamente a ‘intenção comportamental’ de usar tecnologias de IA.

Resultado no modelo estrutural 1: Hipótese rejeitada. O custo apresentou um coeficiente positivo e não significativo ($\beta = 0.130$; $p = 0.157$).

Alinhamento com o referencial teórico: Embora a literatura sugira que o ‘custo percebido’ pode atuar como uma barreira para a adoção de tecnologias (Kim *et al.*, 2021), o resultado indica que esse fator não teve impacto relevante no estudo. Isso pode ocorrer devido ao contexto organizacional, onde os benefícios percebidos da IA, como eficiência e economia de tempo, superam a preocupação com os custos diretos. Almagrashi *et al.* (2016) sugerem que o foco em resultados estratégicos pode minimizar a percepção de custos.

4.4.7. H7: ‘Compatibilidade’

Hipótese: A ‘compatibilidade’ influencia positivamente a ‘intenção comportamental’ de usar tecnologias de IA.

Resultado no modelo estrutural 1: Hipótese rejeitada. O coeficiente foi positivo, mas não significativo ($\beta = 0.100$; $p = 0.172$).

Alinhamento com o referencial teórico: A ‘compatibilidade’ refere-se ao grau de alinhamento entre a tecnologia e as práticas, valores ou necessidades existentes (Blut *et al.*, 2022). No entanto, nesse contexto, os resultados sugerem que a percepção de compatibilidade não influencia de forma relevante a intenção de adoção. Isso pode ocorrer em setores onde a implementação da IA ainda é percebida como uma solução disruptiva e independente dos processos atuais. Estudos como os de Blut *et al.* (2022) indicam que, em estágios iniciais de adoção, a ‘compatibilidade’ tende a ter menor impacto.

4.4.8. H8: ‘Inovatividade pessoal’

Hipótese: A ‘inovatividade pessoal’ influencia positivamente a ‘intenção comportamental’ de usar tecnologias de IA.

Resultado no modelo estrutural 1: Hipótese aceita. O coeficiente foi positivo e significativo ($\beta = 0.182$; $p = 0.003$).

Alinhamento com o referencial teórico: A ‘inovatividade pessoal’ foi identificada como um dos três constructos mais representativos nesse estudo, destacando sua relevância no processo de adoção de tecnologias emergentes, como a IA. Esse constructo reflete a predisposição dos indivíduos a experimentar e adotar novas tecnologias antes de outros membros de seu grupo social, conforme definido por Agarwal e Prasad (1998). O resultado ($\beta = 0.182$; $p = 0.003$) evidencia que indivíduos com maior tendência à inovação percebem a IA não apenas como uma ferramenta, mas como uma oportunidade capaz de gerar valor e transformação no ambiente organizacional. Estudos prévios, como os de Pandey e Rajeswari (2023), corroboram a importância da ‘inovatividade pessoal’ como um forte preditor de intenção de uso em contextos de tecnologias emergentes. Esses autores destacam que indivíduos inovadores são mais propensos a superar barreiras de incerteza e risco, explorando o potencial de novas tecnologias de maneira mais assertiva. No presente estudo, a relevância desse constructo se torna ainda mais evidente no contexto organizacional, onde a adoção de IA para automação de processos exige habilidades como curiosidade tecnológica, abertura para mudanças e confiança na experimentação de sistemas complexos.

Esse achado reforça que estratégias organizacionais devam considerar não apenas aspectos técnicos, mas também características individuais dos usuários, incentivando a formação de perfis inovadores por meio de treinamentos e iniciativas que promovam a curiosidade e a experimentação tecnológica. Dessa forma, a ‘inovatividade pessoal’ contribui não apenas para a aceitação inicial, mas também para a exploração contínua das capacidades da IA, maximizando os benefícios organizacionais e individuais.

4.4.9. H9: ‘Educação’

Hipótese: O nível educacional influencia positivamente a ‘intenção comportamental’ de usar tecnologias de IA.

Resultado no modelo estrutural 1: Hipótese rejeitada. O coeficiente foi negativo e não significativo ($\beta = -0.019$; $p = 0.723$).

Alinhamento com o referencial teórico: Os resultados sugerem que o nível educacional não influencia diretamente a intenção de adoção da IA. Isso pode ocorrer porque, em contextos corporativos, a capacitação e o treinamento fornecidos internamente são mais relevantes para a percepção de adoção tecnológica do que o nível educacional formal dos indivíduos. Estudos como os de Blut *et al.* (2022) indicam que a educação pode ter um papel indireto, mediado por fatores como experiência prática e suporte organizacional.

4.4.10. H10: ‘Confiança na tecnologia’

Hipótese: A ‘confiança na tecnologia’ influencia positivamente a ‘intenção comportamental’ de usar tecnologias de IA.

Resultado no modelo estrutural 1: Hipótese aceita. A ‘confiança na tecnologia’ apresentou coeficiente positivo e altamente significativo ($\beta = 0.351$; $p < 0.001$).

Alinhamento com o referencial teórico: A ‘confiança na tecnologia’ desporta como um dos principais determinantes para a adoção de tecnologias avançadas, especialmente em contextos que envolvem inteligência artificial (IA) e automação de processos. Em contraste com outros constructos amplamente estudados, como ‘expectativa de desempenho’ e ‘expectativa de esforço’, a ‘confiança na tecnologia’ destaca-se por sua capacidade de mitigar os desafios específicos associados à complexidade e opacidade de sistemas autônomos, tornando-se um elemento central para a aceitação e uso eficaz da IA.

Esse resultado confirma a importância da ‘confiança na tecnologia’ como fator determinante na adoção de tecnologias, corroborando com o estudo de Venkatesh (2021) sobre adoção de IA. A ‘confiança na tecnologia’ reflete a percepção de segurança, confiabilidade e competência do sistema, sendo fundamental para superar barreiras de resistência, especialmente em soluções baseadas em IA. A transparência e previsibilidade dos algoritmos, bem como a experiência prévia dos usuários com tecnologias semelhantes, desempenham papel importante no fortalecimento dessa confiança, conforme apontado por Kosmas *et al.* (2023).

Ao introduzir a ‘confiança na tecnologia’ como uma contribuição original ao modelo adaptado, esse estudo reafirma sua relevância ao evidenciar que ele não apenas preenche lacunas teóricas presentes em modelos estendidos, como o proposto por Blut *et al.* (2022), mas também se alinha às necessidades práticas de contextos organizacionais. Diferentemente de constructos como ‘hábito’ ou ‘motivação hedônica’, que são menos relevantes em ambientes corporativos, a

‘confiança na tecnologia’ é especialmente crítica em cenários onde decisões fundamentais são delegadas a tecnologias, como a automação de sinistros.

O coeficiente significativo e robusto observado nesse estudo ($\beta = 0.351$) reforça a relevância desse constructo no contexto corporativo brasileiro, demonstrando que a confiança não apenas facilita a aceitação inicial da IA, mas também incentiva seu uso contínuo e a exploração total de suas capacidades. Dessa forma, esse estudo destaca a ‘confiança na tecnologia’ como um pilar essencial para a adoção bem-sucedida da IA, tanto do ponto de vista teórico quanto prático, proporcionando insights valiosos para gestores que buscam implantar tecnologias de automação em suas organizações.

4.4.11. Síntese das hipóteses testadas

A tabela a seguir apresenta uma síntese das hipóteses testadas nesse estudo.

Quadro 5: Síntese das hipóteses testadas

Hipótese	Resultado
H1: Expectativa de desempenho	Aceita
H2: Expectativa de esforço	Rejeitada
H3: Influência social	Rejeitada
H4: Condições facilitadoras	Rejeitada
H5: Valor do preço	Rejeitada
H6: Custo percebido	Rejeitada
H7: Compatibilidade	Rejeitada
H8: Inovatividade pessoal	Aceita
H9: Educação	Rejeitada
H10: Confiança na tecnologia	Aceita

Fonte: elaborado pelo autor (2024).

4.4.12. Lições aprendidas

Com base nas análises realizadas nesse capítulo, foi possível extrair importantes lições sobre os fatores que influenciam a adoção de inteligência artificial para automação de processos em seguradoras.

4.4.12.1. Principais lições teóricas

(a) A confiança na tecnologia é o fator mais relevante

Entre os constructos analisados, ‘confiança na tecnologia’ destacou-se como o principal fator determinante da intenção de adoção de IA. Este achado reforça estudos prévios que apontam a confiança como elemento essencial para a aceitação de tecnologias emergentes (Venkatesh *et al.*, 2021; Kosmas *et al.*, 2023), mas também sugere uma particularidade do contexto

corporativo. Diferente de outras tecnologias estudadas sob o modelo UTAUT, que frequentemente enfatizam fatores como ‘expectativa de esforço’ e ‘condições facilitadoras’, a adoção da IA parece depender mais da redução da percepção de risco e da previsibilidade dos sistemas. Estudos como o de Venkatesh (2021) indicam que tecnologias baseadas em aprendizado de máquina exigem maior transparência e previsibilidade para superar barreiras de aceitação, o que pode explicar a centralidade da confiança identificada nesse estudo.

Esse resultado levanta uma hipótese relevante para futuras pesquisas: em que medida a opacidade dos algoritmos de IA influencia a necessidade de ‘confiança na tecnologia’ como fator central para adoção?

(b) Adoção de IA está fortemente associada à percepção de benefícios

A relação positiva entre ‘expectativa de desempenho’ e ‘inovatividade pessoal’ com a intenção de adoção reforça que usuários corporativos tomam suas decisões com base na percepção de valor da tecnologia. Em outras palavras, quando os benefícios da IA são tangíveis – como ganho de produtividade e eficiência operacional – a aceitação tende a ser maior.

Esse achado se alinha com estudos que mostram que a adoção de IA no ambiente corporativo segue uma lógica pragmática, baseada em ROI percebido e impacto no desempenho organizacional (Grover *et al.*, 2022). Contudo, contrasta com modelos mais tradicionais de adoção, nos quais fatores sociais e estruturais costumam ter papel mais relevante (Venkatesh *et al.*, 2003).

Uma possível explicação para essa diferença reside no grau de controle dos usuários sobre a decisão de adoção. Em tecnologias voltadas ao consumo final, elementos como ‘influência social’ e ‘facilidade de uso’ são mais relevantes porque os indivíduos escolhem se querem ou não utilizar determinado sistema (Venkatesh *et al.*, 2012). No entanto, no ambiente corporativo, essa escolha é muitas vezes institucional e baseada no impacto que a tecnologia pode gerar no desempenho da empresa, o que pode justificar o menor peso de fatores como ‘influência social’ e ‘expectativa de esforço’.

(c) Fatores tradicionalmente relevantes em modelos de adoção foram irrelevantes no contexto estudado

Uma das descobertas que mais significativas desse estudo foi a irrelevância estatística de constructos como ‘expectativa de esforço’, ‘influência social’, ‘condições facilitadoras’ e

‘compatibilidade’ para a intenção de adoção de IA. Esses fatores, amplamente discutidos em modelos de aceitação tecnológica como UTAUT e TAM (Venkatesh *et al.*, 2003; Davis, 1989;), costumam ser determinantes na adoção de novas ferramentas digitais.

No entanto, no presente estudo, sua ausência como preditores significativos sugere que a IA pode seguir um padrão de aceitação distinto de outras tecnologias organizacionais. Uma possível explicação é que, diferentemente de sistemas tradicionais, a IA não exige um aprendizado individual intenso para ser utilizada, pois muitas vezes opera em segundo plano, realizando tarefas de maneira automatizada sem demandar uma interação direta e constante do usuário.

Esse achado levanta a seguinte hipótese para futuras investigações: o grau de autonomia de uma tecnologia influencia a relevância dos fatores tradicionais de adoção? Tecnologias que operam de forma mais autônoma e exigem menos esforço de aprendizado poderiam apresentar padrões distintos de aceitação, com menor dependência de constructos como expectativa de esforço e compatibilidade.

(d) O papel dos moderadores é limitado

Outro achado relevante foi a baixa influência das variáveis moderadoras na explicação do fenômeno estudado. Mesmo a variável percepção de ameaça da IA ao emprego, identificada no pré-teste como uma preocupação recorrente dos participantes, não alterou as relações principais do modelo.

Isso sugere que, no contexto corporativo, a decisão de adoção da IA pode estar menos associada a fatores individuais e mais vinculada a diretrizes organizacionais. Ou seja, enquanto no nível individual o medo de substituição pode gerar resistência inicial, a introdução da IA nas empresas ocorre principalmente por meio de decisões estratégicas dos gestores, reduzindo o impacto de variáveis moderadoras no comportamento dos usuários.

Esse achado reforça a necessidade de investigações futuras sobre a interação entre decisão organizacional e aceitação individual da IA. Essa dinâmica pode explicar por que as moderações não desempenharam um papel significativo no modelo estrutural testado.

4.4.12.2. Direções para pesquisas futuras

A partir dos achados desse estudo, algumas questões emergem como oportunidades para futuras pesquisas:

- i. O papel da transparência na construção da confiança em IA – Em que medida a explicabilidade dos algoritmos influencia a aceitação de tecnologias baseadas em IA?
- ii. Diferenças entre aceitação ativa e passiva de IA – Como os fatores que influenciam a adoção variam entre tecnologias de uso voluntário e aquelas implementadas diretamente pelas organizações?
- iii. Impacto da decisão organizacional na aceitação individual – Em que medida a obrigatoriedade do uso da IA afeta a percepção dos usuários e sua aceitação da tecnologia?
- iv. A autonomia da tecnologia como moderador da adoção – Tecnologias mais autônomas exigem menor esforço de aprendizado, tornando fatores tradicionais de adoção menos relevantes?

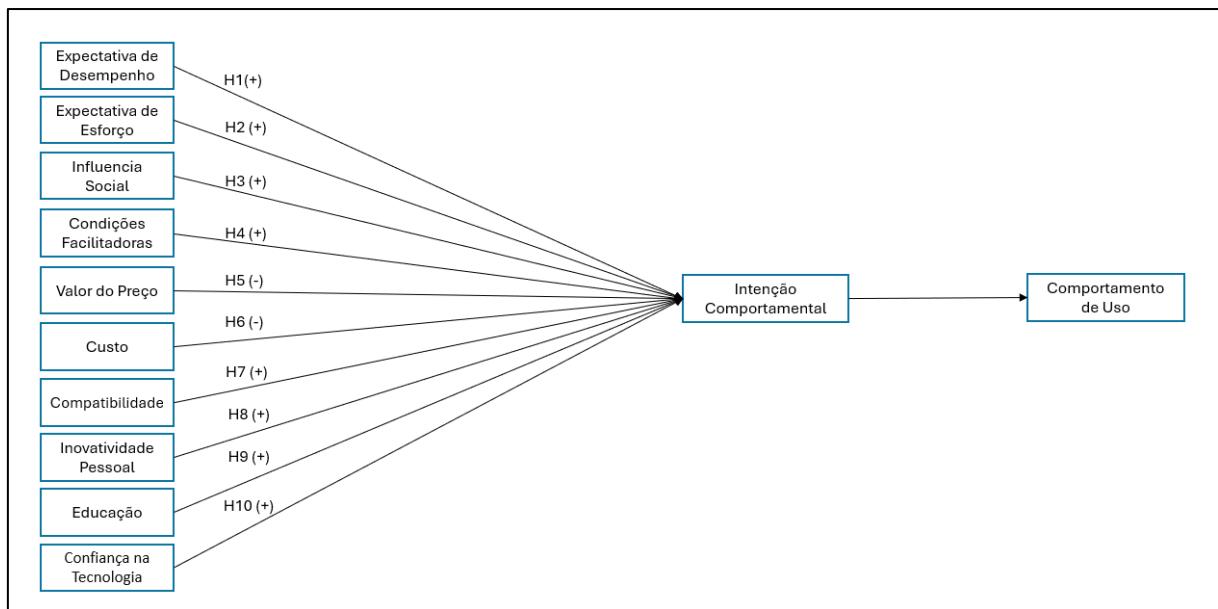
Essas questões reforçam a necessidade de ampliar a pesquisa sobre adoção de IA, considerando suas particularidades em relação a modelos tradicionais de aceitação tecnológica. Ao avançar nesse debate, futuras investigações poderão contribuir para um entendimento mais refinado sobre os desafios e oportunidades da integração da IA no ambiente corporativo.

4.4.13. Modelo final de adoção de IA

Com base nos achados, o modelo estrutural 1 foi validado como o mais adequado, consolidando-se como o modelo de adoção de IA para automação de processos. Esse modelo enfatiza a centralidade da confiança na tecnologia, da expectativa de desempenho e da inovatividade pessoal, ao mesmo tempo em que descarta a necessidade de fatores tradicionais que não demonstraram impacto significativo.

A Figura 12, a seguir, apresenta a versão final do modelo conceitual, refinado a partir dos resultados empíricos:

Figura 12: Modelo de adoção de IA para automação de processos



Fonte: elaborado pelo autor (2024).

5 CONSIDERAÇÕES FINAIS

Esse estudo teve como objetivo identificar os principais fatores que influenciam a adoção da inteligência artificial (IA) para automação de processos no setor de seguros de automóveis no Brasil. Com base em um modelo teórico fundamentado na UTAUT e suas extensões, a pesquisa revelou *insights* para acadêmicos e gestores sobre os desafios e oportunidades da incorporação dessa tecnologia no setor.

Os achados demonstraram que a ‘confiança na tecnologia’, a ‘expectativa de desempenho’ e a ‘inovatividade pessoal’ são os fatores mais determinantes para a ‘intenção comportamental’ de adoção da IA. Ao mesmo tempo, fatores como ‘custo’, ‘compatibilidade’ e ‘condições facilitadoras’ não apresentaram impacto significativo, sugerindo que, no contexto corporativo estudado, a percepção de valor agregado é mais influente do que barreiras financeiras ou estruturais. Essa constatação reforça a necessidade de estratégias que priorizem o aumento da confiança dos usuários em sistemas baseados em IA, garantindo transparência, segurança e explicação acessível dos algoritmos utilizados.

A contribuição teórica desta pesquisa reside na adaptação e validação da UTAUT para o contexto específico da IA em automação de processos, oferecendo um modelo analítico robusto que pode ser replicado e expandido em estudos futuros. Além disso, a investigação amplia o entendimento sobre o papel da ‘confiança na tecnologia’ como um fator crítico para a adoção de IA, o que é particularmente relevante em um cenário em que a automação de decisões é cada vez mais presente.

Do ponto de vista prático, os resultados fornecem diretrizes valiosas para gestores do setor de seguros e de outras indústrias que buscam implementar IA em seus processos. A pesquisa destaca que a aceitação da IA não depende apenas de sua eficácia operacional, mas também da forma como os usuários percebem sua confiabilidade e impacto no dia a dia. Assim, estratégias de implantação devem priorizar a construção de uma cultura organizacional voltada à inovação, além de investimentos em capacitação e comunicação clara dos benefícios da tecnologia.

Além das contribuições teóricas e empíricas, o modelo desenvolvido nesta pesquisa pode ser utilizado como um arcabouço aplicável tanto no meio acadêmico quanto na prática organizacional. Do ponto de vista metodológico, esse estudo pode ser utilizado como uma referência para pesquisadores interessados na construção e validação de questionários para mensuração da adoção de tecnologia a partir da UTAUT. O processo seguido, desde a

formulação das hipóteses até a modelagem estatística via PLS-SEM, demonstra um passo a passo rigoroso para quem deseja conduzir estudos futuros nesse campo. Ao integrar rigor estatístico com relevância prática, a pesquisa oferece um modelo replicável, que pode ser adaptado para diferentes contextos organizacionais que enfrentam desafios semelhantes na implementação de IA.

No entanto, como qualquer estudo acadêmico, essa pesquisa apresenta limitações. A amostra foi composta predominantemente por peritos e analistas do setor de seguros, o que pode restringir a generalização dos resultados para outros segmentos. Ademais, o delineamento transversal impossibilita a análise da evolução da percepção dos usuários ao longo do tempo. Para futuras pesquisas, recomenda-se a ampliação do escopo amostral, a incorporação de análises longitudinais e a investigação de variáveis mediadoras e moderadoras que possam enriquecer ainda mais a compreensão do fenômeno estudado.

Com isso, os objetivos estabelecidos foram plenamente atingidos. A pesquisa não apenas identificou os fatores determinantes para a adoção de IA no setor de seguros, como também consolidou um modelo explicativo robusto e metodologicamente fundamentado. Ao unir teoria e prática, esse estudo amplia a compreensão sobre o fenômeno da adoção tecnológica e fornece um referencial valioso para gestores, pesquisadores e formuladores de políticas que buscam otimizar a implementação da inteligência artificial em suas respectivas áreas de atuação.

Em um mundo em que a digitalização e a automação são imperativos estratégicos, compreender os fatores que impulsionam ou dificultam a adoção de IA é essencial para o sucesso organizacional. Esse estudo contribui para esse debate, fornecendo um alicerce sólido para decisores e pesquisadores que buscam transformar desafios tecnológicos em vantagens competitivas sustentáveis.

REFERÊNCIAS

- ACCENTURE. **Tendências na indústria de seguros.** [S.l.: s.n.], 2023.
- ADAM, A.; JIZAT, J. E. M.; NOOR, M. A. M. **A Review of Factors That Influenced the Intention of Acceptance and Use of Social Commerce among Small Medium-Sized Enterprises in Malaysia.** Advances in Business-Related Scientific Research Journal, [s. l.], v. 7, n. 2, p. 15–26, 2016.
- ALBERTIN, A.; ALBERTIN, R. **Transformação digital: gerando valor para o “novo futuro”.** GVexecutivo, v. 20, n. 1, p. 27-29, jan./mar. 2021.
- ALLIANZ RESEARCH. **Global Insurance Report 2024.** Allianz, 2024.
- ALMAGRASHI, A., ALSHORMANI, N., BINRASHED, A., e ALZAMEL, N. **Factors determining internal auditors’ behavioral intention to use computer-assisted auditing techniques: an extension of the UTAUT model and an empirical study.** Future Business Journal, [s. l.], v. 9, n. 1, p. 1–19, 2023.
- ALNEYADI, M. R. M. A. H.; MD KASSIM, N.; TEH SIN YIN. **Conceptual Framework on the Factors Influencing Users’ Intention to Adopt AI-Based Cybersecurity Systems at Workplaces in the UAE.** Global Business e Management Research, [s. l.], v. 14, p. 1053–1064, 2022.
- ALVES, G.; MIADAIRA HAMZA, K. **Comportamento Do Consumidor De Streaming De Vídeo Sob a Ótica Da Extensão Da Teoria Unificada De Aceitação E Uso Da Tecnologia.** Revista Interdisciplinar de Marketing (RIMAR), [s. l.], v. 9, n. 1, p. 46–61, 2019.
- ALWAHAISHI, S.; SNÁŠEL, V. **Consumers’ Acceptance and Use of Information and Communications Technology: A UTAUT and Flow Based Theoretical Model.** Journal of Technology Management e Innovation, [s. l.], v. 8, n. 2, p. 61–73, 2013.
- ASIR.T, R. G.; MANOHAR, H. L. **Variations on Internet of Things adoption factors between India and the USA.** South African Journal of Business Management, [s. l.], v. 54, n. 1, p. 1–13, 2023.

- BANDYOPADHYAY, K.; FRACCASTORO, K. A. **The Effect of Culture on User Acceptance of Information Technology**. Communications of the Association for Information Systems, [s. l.], v. 19, p. 522–543, 2007.
- BANERJEE, A.; KABADI, S.; KARIMOV, D. **The Transformative Power of Ai: Projected Impacts on the Global Economy by 2030**. Review of Artificial Intelligence in Education, [s. l.], n. 4, p. 1–11, 2023.
- BARCELOS, V.; SANTOS, A. **Transformação digital e seguro: uma revisão sistemática da literatura**. *Revista Gestão e Secretariado (GeSec)*, São Paulo, SP, v. 14, n. 6, p. 8849-8874, 2023.
- BHARTI, S., AWASTHI, P., CHAUDHARY, H., e MAHAJAN, R. **Prioritisation of Factors for Artificial Intelligence-Based Technology Adoption by Banking Customers in India: Evidence Using the Dematel Approach**. Applied Finance Letters, [s. l.], v. 12, n. 2, p. 2–22, 2023.
- BHATTACHARYA, S.; KUMAR, V.; NISHAD, S. N. **Technology Readiness Level: An Assessment of the Usefulness of this Scale for Translational Research**. Productivity, [s. l.], v. 62, n. 2, p. 106–118, 2021.
- BLAGOV, E. **UTAUT validity testing in Russian companies' corporate Web 2.0 adoption**. Proceedings of ISPIM Conferences, [s. l.], n. 24, p. 1–8, 2012.
- BLAGOV, E.; BOGOLYUBOV, P. **Corporate Web 2.0 Systems Adoption in Russian Companies: Testing the UTAUT Validity**. Proceedings of the European Conference on Innovation e Entrepreneurship, [s. l.], p. 37–45, 2013.
- BLUT, M. *et al.* **Meta-Analysis of the Unified Theory of Acceptance and Use of Technology (UTAUT): Challenging its Validity and Charting a Research Agenda in the Red Ocean**. Journal of the Association for Information Systems, [s. l.], v. 23, n. 1, p. 13–95, 2022.
- BOBSIN, D.; VISENTINI, M. S.; RECH, I. **Em Busca Do Estado Da Arte Do UTAUT: Ampliando as Considerações Sobre O Uso Da Tecnologia**. Revista de Administração e Inovação (RAI), [s. l.], v. 6, n. 2, p. 99–118, 2009.

- BOUSTANI, N. M.; CHAMMAA, C. **Youth Adoption of Innovative Digital Marketing and Cross-cultural Disparities**. *Administrative Sciences* (2076-3387), [s. l.], v. 13, n. 6, p. 151, 2023.
- BROWN, S. A.; DENNIS, A. R.; VENKATESH, V. **Predicting Collaboration Technology Use: Integrating Technology Adoption and Collaboration Research**. *Journal of Management Information Systems*, [s. l.], v. 27, n. 2, p. 9–53, 2010.
- CABRERA-SÁNCHEZ, J.-P.; VILLAREJO-RAMOS, Á. F. **Factors Affecting the Adoption of Big Data Analytics in Companies**. *RAE: Revista de Administração de Empresas*, [s. l.], v. 59, n. 6, p. 415–429, 2019.
- CHAPUIS, R.; MELNIKOV, L.; SANDRI, N. **The journey toward AI-enabled railway companies**. *McKinsey Insights*, [s. l.], p. N.PAG, 2024.
- CHEN, H.; ZHAO, X. **Use intention of green financial security intelligence service based on UTAUT**. *Environment, Development e Sustainability*, [s. l.], v. 25, n. 10, p. 10709–10742, 2023.
- CHIAN-SON YU. **Factors Affecting Individuals to Adopt Mobile Banking: Empirical Evidence from the Utaut Model**. *Journal of Electronic Commerce Research*, [s. l.], v. 13, n. 2, p. 104–121, 2012.
- COHEN, Jacob. **Statistical power analysis for the behavioral sciences**. routledge, 2013.
- COOPER, DONALD R.; SCHINDLER, PAMELA S. **Métodos de Pesquisa em Administração-12ª edição**. McGraw Hill Brasil, 2016.
- CRESWELL, J. W. **Métodos qualitativo, quantitativo e misto – 2.ed.** – Porto Alegre: Artmed, 2007 Projeto de, 2007.
- DE ANDRÉS-SÁNCHEZ, J.; GENÉ-ALBESA, J. **Explaining Policyholders' Chatbot Acceptance with an Unified Technology Acceptance and Use of Technology-Based Model**. *Journal of Theoretical e Applied Electronic Commerce Research*, [s. l.], v. 18, n. 3, p. 1217–1237, 2023.

DE MATOS SILVA, J. V.; APARECIDO RODELLO, I. **Fatores determinantes para a elaboração de estratégias com vistas à aceitação e uso da Realidade Aumentada em cenários de negócio.** Universitas. Gestão e Tecnologia, [s. l.], v. 7, n. 1/2, p. 117–125, 2017.

DULLOO, R.; PURI, M. M. **A Study on Investigating Utaut Model with Respect to Various Domains. International Conference on Ongoing Research in Management e IT**, [s. l.], p. 591–602, 2019.

EFTIMOV, L.; KITANOVIKJ, B. **Unlocking the Path to AI Adoption: Antecedents to Behavioral Intentions in Utilizing AI for Effective Job (Re)Design.** Journal of HRM, [s. l.], v. 26, n. 2, p. 122–134, 2023.

EISENHARDT, K. M. **Building theories from case study research.** Academy of management review, v. 14, n. 4, p. 532-550, 1989.

EKKA, S.; SINGH, P. **Predicting HR Professionals' Adoption of HR Analytics: An Extension of UTAUT Model.** Organizacija, [s. l.], v. 55, n. 1, p. 77–93, 2022.

FAHIM, SYED MUHAMMAD; BANO, S.; AHMED, S.; MUNAWAR, S.; SALEEM M. **Journal of Organisational Studies e Innovation. Autumn2023**, Vol. 10 Issue 3, p17-36. 20p.

FAN, W. *et al.* **Investigating the impacting factors for the healthcare professionals to adopt artificial intelligence-based medical diagnosis support system (AIMDSS).** Annals of Operations Research, [s. l.], v. 294, n. 1/2, p. 567–592, 2020.

FERNANDES, P. M.; SANTOS, F. C.; LOPES, M. **Norms for beneficial A.I.: A computational analysis of the societal value alignment problem.** AI Communications, [s. l.], v. 33, n. 5/6, p. 155–171, 2020.

FERRATT, T. W.; PRASAD, J.; DUNNE, E. J. **Fast and Slow Processes Underlying Theories of Information Technology Use.** Journal of the Association for Information Systems, [s. l.], v. 19, n. 1, p. 1–22, 2018.

FITZGERALD, M.; KRUSCHWITZ, N.; BONNET, D.; e WELCH, M. (2013). **Embracing Digital Technology: A New Strategic Imperative.** MIT Sloan Management Review. Massachusetts Institute of Technology.

FILLION, G.; BRAHAM, H.; EKIONEA, J.-P. B. **Testing Utaut on the Use of Erp Systems by Middle Managers and End-Users of Medium- to Large-Sized Canadian Enterprises.** Academy of Information e Management Sciences Journal, [s. l.], v. 15, n. 2, p. 1–28, 2012.

FORZA, C. **Survey research in operations management: a process-based perspective,** International Journal of Operations e Production Management, Vol. 22 No. 2, pp. 152-194, 2022.

FRANK, D.; CHRYSOCHOU, P.; MITKIDIS, P. **The paradox of technology: Negativity bias in consumer adoption of innovative technologies.** Psychology e Marketing, [s. l.], v. 40, n. 3, p. 554–566, 2023.

GARTNER, Inc. **CIO Agenda 2024: Adopt Franchise Best Practices to Improve Digital Delivery.** 2024.

GARTNER. *The State of AI and AI Investments.* 2024.

GIL, A.C. **Métodos e técnicas de pesquisa social.** 6. ed. Editora Atlas SA, 2008.

GROVER, P.; KAR, A. K.; DWIVEDI, Y. K. **Understanding artificial intelligence adoption in operations management: insights from the review of academic literature and social media discussions.** Annals of Operations Research, [s. l.], v. 308, n. 1/2, p. 177–213, 2022.

HARDINGHAM, E. *et al.* **Will Cognitive Technology-Driven Automation Lead to Economic Growth?** Journal of Self-Governance e Management Economics, [s. l.], v. 6, n. 4, p. 13–18, 2018.

HARDY, S.; BROUGHAM, D. **Intelligent automation in New Zealand: Adoption scale, impacts, barriers and enablers.** New Zealand Journal of Human Resources Management, [s. l.], v. 22, n. 1, p. 15–31, 2022.

HAIR, J. F. *et al.* **Análise multivariada de dados.** Bookman editora, 2009.

HAIR, J. F., HULT, G. T. M., RINGLE, C.M., AND SARSTEDT, M. (2014). **A primer on partial least squares structural equation modeling (PLS-SEM).** Sage Publications.

HAIR, J. F. *et al.* (2017). **A Primer on Partial Least Squares Structural Equation Modeling (PLS-SEM),** 2nd Ed., Sage: Thousand Oaks.

HASIJA, A.; ESPER, T. L. **In artificial intelligence (AI) we trust: A qualitative investigation of AI technology acceptance.** Journal of Business Logistics, [s. l.], v. 43, n. 3, p. 388–412, 2022. DOI 10.1111/jbl.12301.

HEINONEN, M.; OJANEN, V.; HANNOLA, L. **Adoption of VR and AR technologies in the enterprise. Proceedings of ISPIM Conferences**, [s. l.], p. 1–10, 2018.

HENSELER, J.; RINGLE, C. M.; SINKOVICS, R. R. **The use of partial least squares path modeling in international marketing.** In: SINKOVICS, Rudolf R.; GHAURI, Pervez N. (Eds.). Advances in International Marketing. Bingley: Emerald Group Publishing Limited, 2009. p. 277–320. modeling in international marketing. Advances in International Marketing, 20, 277-320.

HMOUD, B. **The Adoption of Artificial Intelligence in Human Resource Management.** Forum Scientiae Oeconomia, [s. l.], v. 9, n. 1, p. 105–118, 2021.

IVASHCHENKO, T.; CHORNODID, I.; IVASHCHENKO, A. **The Business Assistant Service as One of the Promising Areas for the Adoption of Ai Technologies in the Enterprise.** Business: Theory e Practice, [s. l.], v. 21, n. 2, p. 588–597, 2020.

JAMES E. ANDREWS, HEATHER WARD, JUNGWON YOON. **UTAUT as a Model for Understanding Intention to Adopt AI and Related Technologies among Librarians**, The Journal of Academic Librarianship, Volume 47, Issue 6, 2021.

KEN FUJIHARA, R.; MONTEZANO, L.; ALFINITO, S. **Theories, Models, and Frameworks for the Use and Acceptance of Information and Communication Technologies.** Revista Gestão e Tecnologia, [s. l.], v. 22, n. 3, p. 145–173, 2022.

KIM, J.; GIROUX, M.; LEE, J. C. **When do you trust AI? The effect of number presentation detail on consumer trust and acceptance of AI recommendations.** Psychology e Marketing, [s. l.], v. 38, n. 7, p. 1140–1155, 2021.

KOSMAS, I. *et al.* **The Use of Artificial Neural Networks in the Public Sector.** *Fintech*, [s. l.], v. 2, n. 1, p. 138–152, 2023.

KWARTENG, M. A. *et al.* **Extending the Utaut Model to Understand the Barriers Towards Sme Digitalization.** Serbian Journal of Management, [s. l.], v. 17, n. 2, p. 403–424, 2022.

- LEE, K. Inteligência Artificial: **Como os Robôs estão mudando o Mundo, a Forma como Amamos, nos Relacionamos, Trabalhamos e Vivemos**. Rio de Janeiro: Editora Globo, 2019.
- LEE, U.K.; KIM, H. **UTAUT in Metaverse: An “Ifland” Case**. Journal of Theoretical e Applied Electronic Commerce Research, [s. l.], v. 17, n. 2, p. 613–635, 2022.
- LÖBLER, M. L. *et al.* **As Influências Na Intenção De Uso Dos Sistemas De Informação: Uma Abordagem Entre a Teoria De Estilos Cognitivos De Kirton E a Teoria Unificada De Aceitação E Uso Da Tecnologia**. Revista de Administração e Inovação (RAI), [s. l.], v. 8, n. 2, p. 55–81, 2011.
- LUTFI, A. **Factors Influencing the Continuance Intention to Use Accounting Information System in Jordanian SMEs from the Perspectives of UTAUT: Top Management Support and Self-Efficacy as Predictor Factors**. Economies, [s. l.], v. 10, n. 4, p. 75, 2022.
- MARUPING, L. M. *et al.* **Going beyond intention: Integrating behavioral expectation into the unified theory of acceptance and use of technology**. Journal of the Association for Information Science e Technology, [s. l.], v. 68, n. 3, p. 623–637, 2017.
- MIGUEL MARTINS, N. L.; DUARTE, P.; M. R. PINHO, J. C. **Análise Dos Fatores Que Condicionam a Adoção De Mobile Health (Mhealth)**. RAE: Revista de Administração de Empresas, [s. l.], v. 61, n. 4, p. 1–17, 2021.
- NWANKWO, W. *et al.* **The Adoption of AI and IoT Technologies: Socio-Psychological Implications in the Production Environment**. IUP Journal of Knowledge Management, [s. l.], v. 19, n. 1, p. 50–75, 2021.
- OZMEN O. *et al.* **Six Human-Centered Artificial Intelligence Grand Challenges**. International Journal of Human-Computer Interaction, [s. l.], v. 39, n. 3, p. 391–437, 2023.
- PAN, Y. *et al.* **The adoption of artificial intelligence in employee recruitment: The influence of contextual factors**. International Journal of Human Resource Management, [s. l.], v. 33, n. 6, p. 1125–1147, 2022.
- PANDEY, A. *et al.* **Strategic Technology Adoption of social media in Indian SMEs**. International Management Review, [s. l.], v. 19, n. 1, p. 44–52, 2023.

- PANDEY, R.; RAJESWARI, M. **Sustainable Technologies and Sustainable Products**. Environmental e Social Management Journal / Revista de Gestão Social e Ambiental, [s. l.], v. 17, n. 4, p. 1–13, 2023.
- PERNA, G.; TURNER, B. E. W. **Navigating the “Wild West” of AI adoption in healthcare**. Modern Healthcare, [s. l.], v. 52, n. 24, p. 14, 2022.
- QUEIROZ, M. M.; FARIAS PEREIRA, S. C. **Intention to Adopt Big Data in Supply Chain Management: A Brazilian Perspective**. RAE: Revista de Administração de Empresas, [s. l.], v. 59, n. 6, p. 389–401, 2019.
- RAMO, R. M.; ALSHAHER, A. A.; AL-FAKHRY, N. A. **The Effect of Using Artificial Intelligence on Learning Performance in Iraq: The Dual Factor Theory Perspective**. Ingénierie des Systèmes d’Information, [s. l.], v. 27, n. 2, p. 255–265, 2022.
- RANA, N. P. *et al.* **Theories and Theoretical Models for Examining the Adoption of E-Government Services**. e-Service Journal, [s. l.], v. 8, n. 2, p. 26–56, 2012.
- ROCHA I.F, KISSIMOTO K.O. **Artificial intelligence and internet of things adoption in operations management: Barriers and benefits**. RAM, Rev Adm Mackenzie. 2022.
- RONAGHI, M. H. **The influence of artificial intelligence adoption on circular economy practices in manufacturing industries**. Environment, Development e Sustainability, [s. l.], v. 25, n. 12, p. 14355–14380, 2023.
- RUSSELL, S. **Inteligência Artificial a Nossa Favor**: Como Manter o Controle sobre a Tecnologia. Tradução Berilo Vargas. 1. ed. São Paulo: Companhia das Letras, 2021.
- SADEGHEIN, R.; HASHEMI, M. **Assessing the Role of Technology Readiness and Technological Attributes on Technology Usage**. AMA Summer Academic Conference Proceedings, [s. l.], v. 27, p. F-5-F-6, 2016.
- SCHMIDT, E; ROSENBERG, J. **Como o Google Funciona**. 1. ed. Rio de Janeiro: Elsevier, 2014.
- SCHNEIDER, S.; LEYER, M. **Me or information technology? Adoption of artificial intelligence in the delegation of personal strategic decisions**. Managerial e Decision Economics, [s. l.], v. 40, n. 3, p. 223–231, 2019.

SCHWARZ, G. **Estimating the dimension of a model.** *The Annals of Statistics*, v. 6, n. 2, p. 461–464, 1978.

SUPERINTENDÊNCIA DE SEGUROS PRIVADOS (SUSEP). **Síntese Mensal Junho de 2024.** SUSEP, 2024.

SWEENEY, DENNIS J.; WILLIAMS, THOMAS A.; ANDERSON, David R. **Estatística aplicada à administração e economia.** São Paulo: Cengage Learning, 2013.

SYJATI, R. K. **Exploring Antecedents of Peoples' Intentions to Use Smart Services in a Smart City Environment: An Extended UTAUT Model.** *Journal of Information Systems*, [s. l.], v. 36, n. 1, p. 133–149, 2022.

SYKES, T. A.; VENKATESH, V.; GOSAIN, S. **Model of Acceptance with Peer Support: A Social Network Perspective to Understand Employees' System Use.** *MIS Quarterly*, [s. l.], v. 33, n. 2, p. 371–393, 2009.

TANANTONG T, WONGRAS P. **A UTAUT-Based Framework for Analyzing Users' Intention to Adopt Artificial Intelligence in Human Resource Recruitment: A Case Study of Thailand.** *Systems*. 2024; 12(1):28.

TEGMARK, M. *Life 3.0: O Ser Humano na Era da Inteligência Artificial.* 1. ed. São Paulo: Companhia das Letras, 2019.

TERRES, M. da S. *et al.* **O Papel Da Confiança Na Marca Na Intenção De Adoção De Novas Tecnologias.** *Revista de Administração e Inovação (RAI)*, [s. l.], v. 7, n. 4, p. 162–185, 2010.

UPTA, S.; ABBAS, A. F.; SRIVASTAVA, R. **Technology Acceptance Model (TAM): A Bibliometric Analysis from Inception.** *Journal of Telecommunications e the Digital Economy*, [s. l.], v. 10, n. 3, p. 77–106, 2022.

VALENZUELA, L.; MARTÍNEZ, C. **Influencia de la adopción de tecnologías de información en el desempeño organizacional.** *Estudios de Administración*, [s. l.], v. 19, n. 1, p. 65–88, 2012.

VENKATESH, V. **Adoption and use of AI tools: a research agenda grounded in UTAUT.** *Annals of Operations Research*, [s. l.], v. 308, n. 1/2, p. 641–652, 2022.

- VENKATESH, V. *et al.* **User Acceptance of Information Technology: Toward a Unified View.** MIS Quarterly, [s. l.], v. 27, n. 3, p. 425–478, 2003.
- VENKATESH, V.; L. THONG, J. Y.; XU, X. **Consumer Acceptance and Use of Information Technology: Extending the Unified Theory of Acceptance and Use of Technology.** MIS Quarterly, [s. l.], v. 36, n. 1, p. 157–178, 2012.
- VENKATESH, V.; THONG, J. Y. L.; XIN XU. **Unified Theory of Acceptance and Use of Technology: A Synthesis and the Road Ahead.** Journal of the Association for Information Systems, [s. l.], v. 17, n. 5, p. 328–376, 2016.
- VIEIRA, S. **Como elaborar questionários.** In: Como elaborar questionários. 2009. p. 159–159.
- XIE *et al.* **Understanding Fintech Platform Adoption: Impacts of Perceived Value and Perceived Risk.** Journal of Theoretical e Applied Electronic Commerce Research, [s. l.], v. 16, n. 5, p. 1893–1911, 2021.
- WACH, K. *et al.* **The dark side of generative artificial intelligence: A critical analysis of controversies and risks of ChatGPT.** Entrepreneurial Business e Economics Review, [s. l.], v. 11, n. 2, p. 7–30, 2023.
- WANG, T. *et al.* **Exploring determinants of adoption intentions towards Enterprise 2.0 applications: an empirical study.** Behaviour e Information Technology, [s. l.], v. 33, n. 10, p. 1048–1064, 2014.
- WIWIN S; GATOT Y; LIANE, M. **Systematic Literature Review of Utaut Model to Understand Adopter's Perception of Digital Mobile App Applications in the Indonesian Coal Mining Industry.** Journal of Indonesian Applied Economics (JIAE), [s. l.], v. 11, n. 2, p. 1–19, 2023.
- WON-JUN, L; SEUNGJAE, S; HAN SUK, M. **An Empirical Study of Consumer Adoption of IoT Services.** Allied Academies International Conference: Proceedings of the Academy of Management Information e Decision Sciences (AIMDS), [s. l.], v. 21, n. 1, p. 28, 2017.
- YOKOMIZO, C. **The relations between innovation and internationalization, and between innovation and business performance: evidence from companies operating in Brazil.** 2014. 331 p. Tese (Doutorado) – Universidade de São Paulo, São Paulo, 2014.

YOUNG, S.; PRIHANTO, J. J. N.; UTOMO, P. **Unraveling the Influence of Factors on Micro Small and Medium-Sized Enterprises' Adoption of Social Media Marketing and Its Business Impact.** Journal Return, [s. l.], v. 2, n. 12, p. 1228–1239, 2023.

ZAIN, M. R. M. *et al.* **ERP Post-Implementation Phase: Deployment of the Unified Theory of Acceptance and Use of Technology (UTAUT) Model on User Acceptance.** Asia-Pacific Management Accounting Journal, [s. l.], v. 18, n. 1, p. 85–129, 2023.

ZANCAN MARQUES, K.; BEHR, A.; VIEIRA MALANOVICZ, A. **Avaliação Da Aceitação De Um Erp No Departamento Contábil De Uma Empresa Pública Segundo O Modelo Utaut.** Revista de Gestão, Finanças E Contabilidade, [s. l.], v. 10, n. 1, p. 82–104, 2020.

APÊNDICE A – Questionário sobre adoção de IA em organizações.

Prezado(a) Respondente,

Esta pesquisa tem como objetivo compreender os fatores que podem impactar o uso da inteligência artificial (IA) em *softwares* de orçamentação de sinistros como Audatex e Cilia.

Instruções:

- O questionário é dividido em duas partes e o tempo médio de resposta é de 5 minutos.
- Considere sempre que o papel da IA será de analisar as fotos dos danos e criar um pré-orçamento.
- Leia cada uma das questões e assinale a resposta que melhor represente o seu grau de concordância.
- Obs: Todos os dados coletados serão tratados de forma confidencial. Agradecemos seu tempo e colaboração.

Constructo	Questões afirmativas	Escala Lickert: 1 – Discordo Totalmente 7 – Concordo Totalmente
ED1 - Expectativa de Desempenho	Considero que o sistema com IA será útil para realizar orçamentos de sinistros.	<p>1 2 3 4 5 6 7</p> <p>Discordo Totalmente <input type="radio"/> Concordo Totalmente <input type="radio"/> Não sei ou não tenho como opinar</p>
ED2 - Expectativa de Desempenho	Usar o sistema com IA me permitirá realizar orçamentos de sinistros mais rapidamente.	<p>1 2 3 4 5 6 7</p> <p>Discordo Totalmente <input type="radio"/> Concordo Totalmente <input type="radio"/> Não sei ou não tenho como opinar</p>
ED3 - Expectativa de Desempenho	Usar o sistema com IA aumentará minha produtividade.	<p>1 2 3 4 5 6 7</p> <p>Discordo Totalmente <input type="radio"/> Concordo Totalmente <input type="radio"/> Não sei ou não tenho como opinar</p>
EE1 - Expectativa de Esforço	Considero que o sistema com IA será fácil de usar.	<p>1 2 3 4 5 6 7</p> <p>Discordo Totalmente <input type="radio"/> Concordo Totalmente <input type="radio"/> Não sei ou não tenho como opinar</p>
EE2 - Expectativa de Esforço	Aprender a operar o sistema com IA será fácil para mim.	<p>1 2 3 4 5 6 7</p> <p>Discordo Totalmente <input type="radio"/> Concordo Totalmente <input type="radio"/> Não sei ou não tenho como opinar</p>
IS1 - Influência Social	As pessoas que influenciam meu comportamento acham que eu deveria usar um sistema de orçamentação com IA.	<p>1 2 3 4 5 6 7</p> <p>Discordo Totalmente <input type="radio"/> Concordo Totalmente <input type="radio"/> Não sei ou não tenho como opinar</p>
IS2 - Influência Social	As pessoas importantes para mim acreditam que eu deveria usar um sistema de orçamentação com IA.	<p>1 2 3 4 5 6 7</p> <p>Discordo Totalmente <input type="radio"/> Concordo Totalmente <input type="radio"/> Não sei ou não tenho como opinar</p>
IS3 - Influência Social	A organização tem apoiado o uso de um sistema de orçamentação com IA.	<p>1 2 3 4 5 6 7</p> <p>Discordo Totalmente <input type="radio"/> Concordo Totalmente <input type="radio"/> Não sei ou não tenho como opinar</p>
CF1 - Condições Facilitadoras	Eu tenho os recursos necessários para usar um sistema de orçamentação com IA.	<p>1 2 3 4 5 6 7</p> <p>Discordo Totalmente <input type="radio"/> Concordo Totalmente <input type="radio"/> Não sei ou não tenho como opinar</p>

CF2 - Condições Facilitadoras	Considero que existirá uma equipe de suporte disponível caso eu tenha dificuldades com o sistema de orçamentação com IA.	<p>1 2 3 4 5 6 7</p> <p>Discreto Totalmente <input type="radio"/> Concorde Totalmente <input type="radio"/> Não sei ou não tenho como opinar</p>
VP1 – Valor do Preço	Considero que um sistema de orçamentação com IA agrega valor superior ao preço que possui.	<p>1 2 3 4 5 6 7</p> <p>Discreto Totalmente <input type="radio"/> Concorde Totalmente <input type="radio"/> Não sei ou não tenho como opinar</p>
CS1 – Custos	Os custos associados ao uso de um sistema de orçamentação com IA são justificáveis.	<p>1 2 3 4 5 6 7</p> <p>Discreto Totalmente <input type="radio"/> Concorde Totalmente <input type="radio"/> Não sei ou não tenho como opinar</p>
CS2 – Custos	A relação custo-benefício de um sistema de orçamentação com IA é ou será vantajosa.	<p>1 2 3 4 5 6 7</p> <p>Discreto Totalmente <input type="radio"/> Concorde Totalmente <input type="radio"/> Não sei ou não tenho como opinar</p>
CO1 - Compatibilidade	Um sistema de orçamentação com IA será compatível com as ferramentas e processos que já utilizo.	<p>1 2 3 4 5 6 7</p> <p>Discreto Totalmente <input type="radio"/> Concorde Totalmente <input type="radio"/> Não sei ou não tenho como opinar</p>
CO2 - Compatibilidade	Um sistema de orçamentação com IA irá se integrar facilmente com outras tecnologias usadas na minha empresa.	<p>1 2 3 4 5 6 7</p> <p>Discreto Totalmente <input type="radio"/> Concorde Totalmente <input type="radio"/> Não sei ou não tenho como opinar</p>
CO3 - Compatibilidade	Um sistema de orçamentação com IA, se alinha bem com os objetivos estratégicos da minha empresa.	<p>1 2 3 4 5 6 7</p> <p>Discreto Totalmente <input type="radio"/> Concorde Totalmente <input type="radio"/> Não sei ou não tenho como opinar</p>
IP1 - Inovatividade Pessoal	Gosto de experimentar novas tecnologias antes dos outros.	<p>1 2 3 4 5 6 7</p> <p>Discreto Totalmente <input type="radio"/> Concorde Totalmente <input type="radio"/> Não sei ou não tenho como opinar</p>
IP2 - Inovatividade Pessoal	Estou sempre buscando soluções tecnológicas inovadoras para melhorar meu desempenho.	<p>1 2 3 4 5 6 7</p> <p>Discreto Totalmente <input type="radio"/> Concorde Totalmente <input type="radio"/> Não sei ou não tenho como opinar</p>
IP3 - Inovatividade Pessoal	Estou disposto a mudar a maneira como trabalho para incorporar novas tecnologias, como um sistema de orçamentação com IA.	<p>1 2 3 4 5 6 7</p> <p>Discreto Totalmente <input type="radio"/> Concorde Totalmente <input type="radio"/> Não sei ou não tenho como opinar</p>
EDUC1 - Educação	Receberei treinamento suficiente para aprender a usar eficientemente um sistema de orçamentação com IA.	<p>1 2 3 4 5 6 7</p> <p>Discreto Totalmente <input type="radio"/> Concorde Totalmente <input type="radio"/> Não sei ou não tenho como opinar</p>
CT1 - Confiança na Tecnologia	Confio que um sistema de orçamentação com IA funcionará como o esperado, sem falhas significativas.	<p>1 2 3 4 5 6 7</p> <p>Discreto Totalmente <input type="radio"/> Concorde Totalmente <input type="radio"/> Não sei ou não tenho como opinar</p>
CT2 - Confiança na Tecnologia	Me sentirei seguro para usar um sistema de orçamentação com IA devido às suas medidas de segurança da informação.	<p>1 2 3 4 5 6 7</p> <p>Discreto Totalmente <input type="radio"/> Concorde Totalmente <input type="radio"/> Não sei ou não tenho como opinar</p>
CT3 - Confiança na Tecnologia	A estabilidade e a confiabilidade de um sistema de orçamentação com IA irão reforçar a minha confiança durante o uso diário.	<p>1 2 3 4 5 6 7</p> <p>Discreto Totalmente <input type="radio"/> Concorde Totalmente <input type="radio"/> Não sei ou não tenho como opinar</p>

Instruções Seção 2:

- Leia atentamente cada afirmativa e selecione a opção que descreve suas ‘características individuais’ e ‘experiência’.

Constructo	Questões	Respostas
CI1 – ID: Características Individuais 1 - Idade	Por favor, indique sua faixa etária:	<input type="checkbox"/> Menos de 20 anos <input type="checkbox"/> 21-27 anos <input type="checkbox"/> 28-43 anos <input type="checkbox"/> 44-59 anos <input type="checkbox"/> Mais de 60 anos
CI2 – GEN: Características Individuais 2 - Gênero	Por favor, selecione seu gênero:	<input type="checkbox"/> Masculino <input type="checkbox"/> Feminino <input type="checkbox"/> Prefiro não responder
CI3 – EXP: Características Individuais 3 - Experiência com Tecnologia	Selecione o tempo de experiência você tem utilizando sistemas de orçamentação.	<input type="checkbox"/> Menos de 1 ano <input type="checkbox"/> 1 a 5 anos <input type="checkbox"/> Mais de 5 anos
CULT1: Cultura - Distância do Poder	De acordo com a cultura da empresa em que trabalho, pessoas em posições de autoridade tendem a tomar decisões sem consultar os subordinados.	<input type="checkbox"/> Sim <input type="checkbox"/> Não
CULT2: Cultura - Individualismo <i>vs.</i> Coletivismo	De acordo com a cultura da empresa em que trabalho, o bem-estar do grupo é considerado mais importante do que os interesses individuais.	<input type="checkbox"/> Sim <input type="checkbox"/> Não
CULT3: Cultura 3 - Masculinidade <i>vs.</i> Feminilidade:	De acordo com a cultura da empresa em que trabalho, o sucesso é mais associado à:	<input type="checkbox"/> Competição <input type="checkbox"/> Cooperação
CI4 – EXIA: Características Individuais 4 - Experiência com IA	Eu utilizei ou já utilizei algum tipo de inteligência artificial em minhas atividades profissionais.	<input type="checkbox"/> Sim <input type="checkbox"/> Não
CI5 – EXIA:- Características Individuais 5 - Experiência com IA	Eu utilizei ou já utilizei algum tipo de inteligência artificial para lazer, estudos ou outras atividades.	<input type="checkbox"/> Sim <input type="checkbox"/> Não
CI6 – CONFIA: Características Individuais 6 – Confiança na IA	Eu acredito que o uso de Inteligência Artificial em sistemas de orçamentação representa uma ameaça ao meu emprego ou à minha função atual.	<input type="checkbox"/> Sim <input type="checkbox"/> Não

ANEXO 1 – Questionário UTAUT 1

Table 16. Items Used in Estimating UTAUT

Performance expectancy

- U6: I would find the system useful in my job.
- RA1: Using the system enables me to accomplish tasks more quickly.
- RA5: Using the system increases my productivity.
- OE7: If I use the system, I will increase my chances of getting a raise.

Effort expectancy

- EOU3: My interaction with the system would be clear and understandable.
- EOU5: It would be easy for me to become skillful at using the system.
- EOU6: I would find the system easy to use.
- EU4: Learning to operate the system is easy for me.

Attitude toward using technology

- A1: Using the system is a bad/good idea.
- AF1: The system makes work more interesting.
- AF2: Working with the system is fun.
- Affect1: I like working with the system.

Social influence

- SN1: People who influence my behavior think that I should use the system.
- SN2: People who are important to me think that I should use the system.
- SF2: The senior management of this business has been helpful in the use of the system.
- SF4: In general, the organization has supported the use of the system.

Facilitating conditions

- PBC2: I have the resources necessary to use the system.
- PBC3: I have the knowledge necessary to use the system.
- PBC5: The system is not compatible with other systems I use.
- FC3: A specific person (or group) is available for assistance with system difficulties.

Self-efficacy

- I could complete a job or task using the system...
- SE1: If there was no one around to tell me what to do as I go.
- SE4: If I could call someone for help if I got stuck.
- SE6: If I had a lot of time to complete the job for which the software was provided.
- SE7: If I had just the built-in help facility for assistance.

Anxiety

- ANX1: I feel apprehensive about using the system.
- ANX2: It scares me to think that I could lose a lot of information using the system by hitting the wrong key.
- ANX3: I hesitate to use the system for fear of making mistakes I cannot correct.
- ANX4: The system is somewhat intimidating to me.

Behavioral intention to use the system

- BI1: I intend to use the system in the next <n> months.
- BI2: I predict I would use the system in the next <n> months.
- BI3: I plan to use the system in the next <n> months.

Fonte: Venkatesh *et. al.*, (2003).

ANEXO 2 – Questionário UTAUT 2

Survey Items	
<p>Performance Expectancy</p> <p>PE1. I find mobile Internet useful in my daily life. PE2. Using mobile Internet increases my chances of achieving things that are important to me. (dropped) PE3. Using mobile Internet helps me accomplish things more quickly. PE4. Using mobile Internet increases my productivity.</p> <p>Effort Expectancy</p> <p>EE1. Learning how to use mobile Internet is easy for me. EE2. My interaction with mobile Internet is clear and understandable. EE3. I find mobile Internet easy to use. EE4. It is easy for me to become skillful at using mobile Internet.</p> <p>Social Influence</p> <p>SI1. People who are important to me think that I should use mobile Internet. SI2. People who influence my behavior think that I should use mobile Internet. SI3. People whose opinions that I value prefer that I use mobile Internet.</p> <p>Facilitating Conditions</p> <p>FC1. I have the resources necessary to use mobile Internet. FC2. I have the knowledge necessary to use mobile Internet. FC3. Mobile Internet is compatible with other technologies I use. FC4. I can get help from others when I have difficulties using mobile Internet.</p> <p>Hedonic Motivation</p> <p>HM1. Using mobile Internet is fun. HM2. Using mobile Internet is enjoyable. HM3. Using mobile Internet is very entertaining.</p>	<p>Price Value</p> <p>PV1. Mobile Internet is reasonably priced. PV2. Mobile Internet is a good value for the money. PV3. At the current price, mobile Internet provides a good value.</p> <p>Habit</p> <p>HT1. The use of mobile Internet has become a habit for me. HT2. I am addicted to using mobile Internet. HT3. I must use mobile Internet. HT4. Using mobile Internet has become natural to me. (dropped)</p> <p>Behavioral Intention</p> <p>BI1. I intend to continue using mobile Internet in the future. BI2. I will always try to use mobile Internet in my daily life. BI3. I plan to continue to use mobile Internet frequently.</p> <p>Use</p> <p>Please choose your usage frequency for each of the following:</p> <p>a) SMS b) MMS c) Ringtone and logo download d) Java games e) Browse websites f) Mobile e-mail</p> <p>Note: Frequency ranged from "never" to "many times per day."</p>

Fonte: Venkatesh, Thong e Xu (2016)