

**ADOÇÃO DA INTELIGÊNCIA ARTIFICIAL POR PROFISSIONAIS DE  
EDUCAÇÃO: UMA ANÁLISE COM BASE NO MODELO DE ACEITAÇÃO DE  
TECNOLOGIA (TAM)**

**ARIANE MARIA MACHADO DE OLIVEIRA**

UNIVERSIDADE ESTADUAL DO PARANÁ (UNESPAR) - CAMPUS PARANAVAI

**CHAYNE DE LIMA PEREIRA MAHNIC**

UNIVERSIDADE ESTADUAL DO PARANÁ (UNESPAR)

**EDI CARLOS DE OLIVEIRA**

UNIVERSIDADE ESTADUAL DO PARANÁ (UNESPAR) - CAMPUS PARANAVAI

**MARCELO ROGER MENEGHATTI**

UNIVERSIDADE ESTADUAL DO OESTE DO PARANÁ (UNIOESTE)

# ADOÇÃO DA INTELIGÊNCIA ARTIFICIAL POR PROFISSIONAIS DE EDUCAÇÃO: UMA ANÁLISE COM BASE NO MODELO DE ACEITAÇÃO DE TECNOLOGIA (TAM)

## 1 INTRODUÇÃO

O avanço das tecnologias digitais e sua inserção progressiva nos ambientes educacionais têm provocado profundas transformações no desenvolvimento profissional e nos processos de ensino e aprendizagem. Esse movimento é complexo, já que envolve a formação dos profissionais de educação e as crenças e atitudes desses indivíduos diante da inovação tecnológica. No caso específico da Inteligência Artificial (IA), observa-se um aumento expressivo de sua adoção e a reconfiguração de práticas pedagógicas no contexto educacional.

O uso das tecnologias digitais nos ambientes educacionais forma fenômenos complexos, em áreas como: formação humana, desenvolvimento, atuação dos profissionais e processos de aprendizagem dos alunos. A atitude do uso das tecnologias impacta comportamentos específicos e crenças dos indivíduos (Lopes; Caracciolo; Herrero, 2018). Esta pesquisa é motivada pelo fenômeno de aceitação e uso da IA em ambientes educacionais, o que resulta em mudanças significativas na postura dos profissionais e novas práticas de atuação.

As reflexões sobre o uso de tecnologias em ambientes educacionais não é uma preocupação atual, o aumento da aceitação e do uso é que vem se destacando. Por isso, alguns critérios como: a atitude e intenção em usar, a facilidade, a utilidade percebida e o quanto realmente as tecnologias são utilizadas é que são discutidas. Para tanto, a partir desse problema de pesquisa, percebeu-se que Modelo de Aceitação de Tecnologia (*Technology Acceptance Model* – TAM) se mostra adequado para tal debate, visto que contempla todos estes critérios (Davis; Bagozzi; Warshaw, 1989).

A IA possui um campo de aplicação amplo e interdisciplinar, consolidando-se como uma ferramenta relevante devido à variedade de usos possíveis (Russell; Norvig, 2022). No contexto educacional, tem sido utilizada para apoiar práticas de ensino, aprendizagem e pesquisa (Henning *et al.*, 2023). No entanto, seu uso também desperta preocupações, especialmente quando aplicado de forma inadequada, gerando riscos à formação humana e levantando dilemas éticos e morais (Gatrell *et al.*, 2024).

Embora o debate sobre tecnologias na educação seja antigo, o avanço acelerado da IA tem intensificado tanto o interesse quanto os questionamentos sobre seu uso. Diante disso, torna-se fundamental investigar os fatores que influenciam sua aceitação e adoção pelos profissionais da educação, uma vez que suas atitudes em relação à IA afetam diretamente suas intenções, percepções e comportamentos no ambiente educacional (Lopes; Caracciolo; Herrero, 2018).

O Modelo TAM se apresenta como uma estrutura teórica sólida e amplamente validada, oferecendo bases consistentes para explicar o comportamento dos usuários frente à adoção de inovações tecnológicas. Sua aplicabilidade torna-se ainda mais relevante em contextos educacionais mediados por IA, nos quais atitudes, percepções e intenções de uso influenciam diretamente a integração efetiva dessa tecnologia. E embora já seja usado neste ambiente novas pesquisas ajudam a consolidar o conhecimento teórico e o uso das tecnologias (Scherer; Siddiq; Tondeur, 2019).

O objetivo desta pesquisa é investigar a aceitação e o uso da Inteligência Artificial na atuação dos profissionais de educação em diferentes ambientes educacionais. Para isso, foi utilizado o Modelo de Aceitação de Tecnologia, desenvolvido por Fred Davis, em 1989, que serviu de base para a compreensão das relações entre os constructos presentes nesta pesquisa.

Com uma amostra de 281 profissionais de ambientes educacionais, esta pesquisa quantitativa empregou análise fatorial confirmatória (AFC) e análise de variância (ANOVA)

para atingir seu objetivo. Sendo que seus principais resultados apontam para relações como a acessibilidade e a percepção de utilidade, e a influência da modalidade de ensino nas percepções e no uso das tecnologias. E a indicação de que o instrumento de pesquisa e o modelo usado são adequados para tal investigação.

Os resultados ainda evidenciam que a Utilidade Percebida (UP), aliadas à Facilidade de Uso Percebida (FUP) e à Atitude em Relação ao Uso (ATU), influenciam a Intenção de Uso (ITU) e o Uso Real do Sistema (URS), além de revelarem variações conforme idade, área de atuação e modalidade de ensino, oferecendo subsídios para estratégias mais contextualizadas sobre IA. Como contribuições, destacam-se a validação empírica do TAM no contexto educacional e a comprovação da relevância dos constructos UP, FUP, ATU, ITU e URS para explicar a aceitação e o uso da IA por profissionais da educação.

## 2 FUNDAMENTAÇÃO TEÓRICA

A IA deixou de ser uma possibilidade futurista para se tornar uma ferramenta concreta e presente em diversas esferas da atividade humana. Na educação, sua incorporação tem provocado mudanças significativas nos modos de ensinar, aprender e administrar o processo pedagógico. Essa inovação exige análises que considerem não apenas as potencialidades técnicas dessa tecnologia, mas também a forma como ela é percebida, aceita e utilizada pelos profissionais de educação.

A literatura tem apontado a importância de modelos teóricos que expliquem o comportamento dos usuários frente às inovações tecnológicas; e dentre esses modelos, destaca-se o TAM, que oferece um embasamento teórico para investigar a aceitação da IA pelos profissionais da educação (Davis; Bagozzi; Warshaw, 1989; Yousafzai; Foxall; Pallister, 2007; Scherer; Siddiq; Tondeur, 2019). A próxima seção contempla os fundamentos teóricos que sustentam esta pesquisa, com foco nas potencialidades, aplicações e desafios da aceitação e uso da IA no ambiente educacional.

### 2.1 A Inteligência Artificial no Ambiente Educacional: Potencialidades, Aplicações e Desafios

A IA constitui um campo interdisciplinar de abrangência global, que compreende uma ampla gama de subáreas, desde aspectos gerais – como aprendizagem e raciocínio – até aplicações específicas, como a demonstração de teoremas matemáticos ou a produção de textos poéticos. Em razão dessa diversidade de aplicações, a IA é considerada pertinente a qualquer atividade que envolva processos intelectuais (Russell; Norvig, 2022).

No ambiente educacional, a IA vem promovendo transformações significativas nas práticas de ensino, aprendizagem e pesquisa. Dentre suas principais aplicações, destacam-se a personalização da aprendizagem, o suporte ao ensino, a geração automatizada de *feedback*, a construção de trilhas de conhecimento personalizadas, dentre outras (Henning *et al.*, 2023).

Há diversas aplicações da IA no ambiente educacional, como o auxílio em processos avaliativos (elaboração de questões e correção automática), auxílio na previsão de possíveis evasões acadêmicas com base no desempenho dos estudantes, o suporte por meio de *softwares* de assistência, a implementação de sistemas tutoriais inteligentes (voltados à individualização da aprendizagem) e a gestão da aprendizagem, mediante o desenho de atividades pedagógicas e a análise de dados educacionais (Rodrigues, 2023).

Alguns exemplos concretos de sistemas de IA atualmente empregados no ambiente educacional são: *Wiley* e *Snapwiz*, que promovem o ensino adaptativo com base nos pontos fortes e nas necessidades dos estudantes; *Turnitin*, que oferece serviços pedagógicos

relacionados à originalidade textual e à prevenção de plágio; e ferramentas como *Galileu*, *Lyceum* e *Wpensar*, voltadas à gestão pedagógica e institucional, abordando aspectos financeiros, acadêmicos e administrativos (Mariz *et al.*, 2024). O *ChatGPT*, por sua vez, destaca-se como uma das ferramentas mais amplamente utilizadas. Essa ferramenta é capaz de gerar textos coerentes e bem estruturados, contribuindo para a ampliação da produção acadêmica (Peres, 2024). No entanto, ressalta-se a necessidade de atenção às implicações éticas relacionadas à originalidade dos trabalhos produzidos com auxílio da IA.

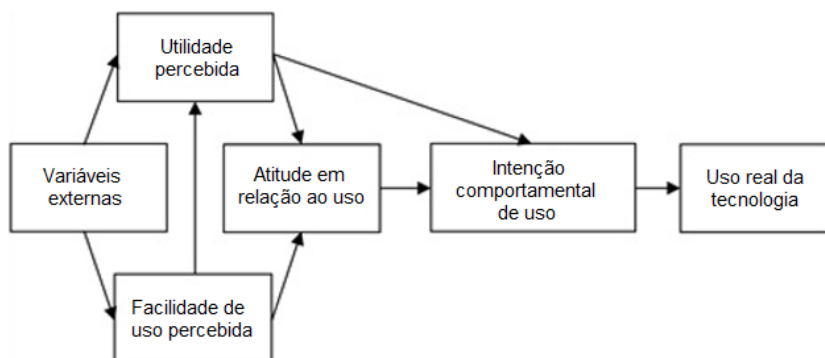
Apesar dos benefícios e das múltiplas possibilidades associadas ao uso da IA no ambiente educacional, diversos desafios persistem. Dentre eles destacam-se a necessidade de capacitação de professores e estudantes, as questões relacionadas à autoria e à ética, a privacidade dos dados, o risco de dependência tecnológica, a possibilidade de decisões equivocadas baseadas em algoritmos, a ocorrência de erros técnicos, a resistência de parte dos profissionais da educação ao uso dessas tecnologias e a carência de infraestrutura adequada por parte de muitas instituições de ensino (Henning *et al.*, 2023; Venkatesh *et al.*, 2003; Rodrigues, 2023; Mariz *et al.*, 2024).

## 2.2 Modelo TAM de Fred Davis

A partir da segunda metade da década de 1990, os estudos sobre aceitação da tecnologia passaram a ocupar uma posição de destaque na literatura científica (Yousafzai; Foxall; Pallister, 2007; Scherer; Siddiq; Tondeur, 2019). Diversos modelos teóricos foram desenvolvidos e aplicados ao longo dos anos; contudo, o Modelo de Aceitação de Tecnologia (TAM), proposto por Fred Davis, em 1989, consolidou-se como o mais amplamente difundido e adotado pelos pesquisadores da área.

Davis (1989) elaborou o TAM a partir da constatação da inexistência de instrumentos específicos para mensurar a aceitação do uso de tecnologias por parte dos usuários. O modelo constitui uma adaptação da Teoria da Ação Racional (TAR), uma teoria geral formulada com o objetivo de explicar o comportamento humano. Conforme a TAR, “a manifestação de um comportamento específico é governada pela intenção comportamental, a qual é determinada pela atitude que, por sua vez, é determinada pelas crenças do indivíduo” (Lopes; Caracciolo; Herrero, 2018, p. 196-197). Essa lógica conceitual foi incorporada ao modelo TAM. O TAM tem sido amplamente utilizado para investigar os fatores que influenciam a aceitação ou rejeição de tecnologias pelos indivíduos (Figura 1).

**Figura 1 – Modelo TAM**



Fonte: Davis, Bagozzi e Warshaw (1989).

A pesquisa original de Davis (1989) validou escalas para duas variáveis centrais – Utilidade Percebida (*perceived usefulness*) e Facilidade de Uso Percebida (*perceived ease of use*) – consideradas determinantes fundamentais da aceitação de sistemas tecnológicos. A UP

refere-se ao grau em que um indivíduo acredita que o uso de determinada tecnologia contribuirá para a melhoria de seu desempenho no trabalho. Contudo, mesmo que o sistema seja considerado útil, o usuário em potencial pode perceber sua utilização como complexa, o que comprometeria a relação custo-benefício do uso – a ATU. Nesse contexto, a FUP assume papel essencial. Observa-se também, que a UP possui correlação mais significativa com a ITU do que a FUP. Esta última, por sua vez, revela-se como um antecedente causal da UP, e não como um fator diretamente determinante da adoção da tecnologia – o URS (Davis, 1989).

### 3 METODOLOGIA

Esta pesquisa teve como objetivo investigar a aceitação e o uso da Inteligência Artificial por profissionais de educação em diferentes ambientes educacionais, utilizando o TAM, desenvolvido por Fred Davis, em 1989. Especificamente, buscou-se analisar as relações entre FUP, UP, ATU, ITU e URS em relação à IA no contexto educacional, adotando uma abordagem quantitativa (Prodanov; Freitas, 2013) e um delineamento descritivo (Triviños, 1987; Severino, 2007).

Optou-se pela abordagem quantitativa por permitir a mensuração das opiniões de profissionais de educação de diferentes áreas do conhecimento em relação à tecnologia em questão. A utilização de questionários estruturados (Oliveira *et al.*, 2016) viabilizou a obtenção de dados numéricos, possibilitando a aplicação de técnicas estatísticas para identificar padrões e correlações entre as variáveis investigadas. Ademais, essa abordagem favoreceu a replicação do estudo de Davis (1989) e a generalização dos resultados (Prodanov; Freitas, 2013).

O delineamento foi realizado com base no estudo de Gomes (2022), que apresentou variáveis relacionadas aos constructos do TAM e as utilizou para investigar a aceitação de ambientes virtuais de aprendizagem – especialmente o *Google Classroom* – por estudantes do ensino médio. Assim, foram adotadas as variáveis oriundas dessa escala validada, adaptando-as ao contexto da IA. O questionário foi composto por 30 questões, sendo: 7 sociodemográficas; 1 questão de controle para averiguar a atenção dos respondentes ao instrumento de coleta de dados; e 22 questões em escala *Likert*, adaptadas da pesquisa de Gomes (2022). A escala de cinco pontos foi de concordância, sendo de discordo totalmente até concordo totalmente.

Após a escolha do instrumento, este foi submetido à avaliação semântica por dois profissionais de educação com experiência no uso de IA. Posteriormente, com a validação do instrumento, iniciou-se a coleta de dados por meio da plataforma *Microsoft Forms*. Ao receberem o convite para participação, os(as) profissionais de educação tiveram autonomia para decidir se participariam voluntariamente da pesquisa.

A amostragem adotada foi probabilística/aleatória (Malhotra, 2012), e o público-alvo foi composto por profissionais de educação de diferentes áreas do conhecimento e de diferentes níveis de ensino, vinculados a instituições de ensino públicas e privadas, atuando nas modalidades presencial, a distância ou híbrida, em diversas unidades federativas do país. A coleta de dados ocorreu entre 12/06/2025 e 03/07/2025 e totalizou 281 participantes.

Considerando a natureza quantitativa do estudo, durante a análise dos questionários foram excluídos 4 respondentes que não atenderam ao critério de atenção estipulado pela questão de controle. Assim, foram considerados 277 questionários válidos para análise estatística, realizada com o auxílio do *software Jamovi*.

A utilização do *software* foi relevante para identificar as relações entre FUP, UP, ATU, ITU e URS vinculado à IA no contexto educacional. Foram aplicadas técnicas de estatística descritiva; teste de confiabilidade; análise fatorial confirmatória (AFC); pesos e covariâncias fatoriais; índices e medidas de ajustamento do modelo; diagrama de trajetórias; e, análise de variância (Hair Junior *et al.*, 2009), com a finalidade de assegurar a validade e a confiabilidade

dos instrumentos utilizados, avaliar a qualidade do ajuste do modelo teórico e compreender a intensidade e a direção das associações entre as variáveis analisadas.

#### 4 ANÁLISE DOS RESULTADOS

A análise descritiva considerou o total de 281 participantes. Observou-se que a faixa etária predominante entre os participantes é a de 35 a 44 anos, totalizando 92 respondentes. Em seguida, aparecem os grupos de 45 a 54 anos (86); 25 a 34 anos (49); 55 anos ou mais (39); e, por último, aqueles com 18 a 24 anos (15). Em relação aos participantes, 35% são do sexo masculino e 65% do sexo feminino. Majoritariamente, os participantes residem no Paraná (260) e os demais na Bahia, Ceará, Distrito Federal, Espírito Santo, Mato Grosso do Sul, Minas Gerais, Pará, Pernambuco, Rio Grande do Sul, Roraima e São Paulo.

Dentre os participantes, 74% trabalham em instituições públicas (federal, estadual ou municipal) e 26% em instituições privadas (particular). No que diz respeito às áreas de atuação dos profissionais de educação, a maioria atua na área de Ciências Sociais Aplicadas (31%), seguido das Ciências Humanas (20%), Linguística, Letras e Artes (13%), Ciências Exatas e da Terra (12%), Ciências da Saúde (10%), Ciências Biológicas (6%), Engenharias (5%) e Ciências Agrárias (2%). Em relação à modalidade de ensino em que os respondentes atuam, destaca-se 77% presencial, 14% híbrido e 9% à distância. Destes, 60% atuam no ensino superior (graduação e pós-graduação).

Para a análise estatística da presente pesquisa, considerou-se 277 participantes, tendo em vista que 4 participantes não atenderam ao critério de atenção estipulado pela questão de controle. Foi conduzida uma análise de confiabilidade utilizando o coeficiente *Alfa de Cronbach*, conforme os critérios estabelecidos por Hair Junior *et al.* (2009), que define valores entre 0.7 e 0.8 como adequados para indicar boa consistência interna. Na presente pesquisa, o coeficiente encontrado foi de 0.934, o que revela uma ótima consistência interna, indicando que os fatores estão mensurando o constructo de maneira confiável, reforçando a validade dos dados.

Na etapa seguinte, procedeu-se a AFC para verificar o quanto cada indicador representa o fator (dimensão teórica) ao qual está associado. Na AFC foram estimados os pesos fatoriais, as covariâncias entre os fatores e os índices de ajuste do modelo. Os resultados estão sintetizados na Tabela 1. As cargas fatoriais mostraram-se estatisticamente significativas ( $p < 0.001$ ), o que confirma que os indicadores utilizados representam de forma adequada os fatores teóricos propostos, assegurando a consistência e validade do constructo avaliado. Assim, a AFC demonstrou que o modelo é confiável e que os resultados obtidos apresentam validade e representatividade.

**Tabela 1 – Pesos Fatoriais**

Pesos fatoriais					
Fator	Indicador	Estimativas	Erro-padrão	Z	p
FUP – Facilidade de Uso Percebida	FUP1	0.826	0.0534	15.5	< .001
	FUP2	0.906	0.0550	16.5	< .001
	FUP3	0.920	0.0516	17.8	< .001
	FUP4	0.726	0.0562	12.9	< .001
	FUP5	0.733	0.0572	12.8	< .001
	FUP6	0.894	0.0500	17.9	< .001
UP – Utilidade Percebida	UP1	0.774	0.0449	17.2	< .001
	UP2	0.872	0.0495	17.6	< .001
	UP3	0.919	0.0487	18.9	< .001

	UP4	0.901	0.0483	18.7	< .001
	UP5	0.824	0.0488	16.9	< .001
	UP6	0.575	0.0398	14.4	< .001
ATU – Atitude em relação ao Uso	ATU1	0.768	0.0439	17.5	< .001
	ATU2	0.682	0.0423	16.2	< .001
	ATU3	0.843	0.0506	16.7	< .001
	ATU4	0.804	0.0450	17.9	< .001
ITU – Intenção de Uso	ITU1	0.921	0.0505	18.2	< .001
	ITU2	0.842	0.0501	16.8	< .001
	ITU3	0.642	0.0383	16.8	< .001
URS – Uso Real do Sistema	URS1	0.963	0.0642	15.0	< .001
	URS2	1.025	0.0562	18.2	< .001
	URS3	-0.907	0.0639	-14.2	< .001

Fonte: Dados da pesquisa (2025).

Dentre as variáveis observadas, o fator FUP é composto por seis indicadores, com cargas fatoriais variando de 0.726 a 0.920. As estimativas (pesos fatoriais) representam o grau de associação entre o indicador e o fator, sendo que a literatura revela que valores mais próximos de 1 indicam forte associação, demonstrando que o item representa bem o fator analisado. O erro-padrão também contribui, já que é uma medida de precisão da estimativa (quanto menor o erro-padrão, mais precisa é a estimativa).

O indicador FUP3 apresentou a maior carga fatorial (0.920), indica que a maneira de interação com as ferramentas de IA é clara e facilmente compreendida pelos profissionais de educação. Igualmente significativo é o FUP2 – eu sei facilmente como proceder com as ferramentas de IA para fazer o que eu quero (0.906), demonstrando que esse indicador também é fortemente sustentado. Esses resultados corroboram os estudos de Venkatesh *et al.* (2003), que destacam que a facilidade de uso percebida (FUP) influencia diretamente a aceitação da tecnologia.

O fator UP é composto por seis indicadores, com cargas fatoriais variando de 0.575 a 0.919. O indicador UP3 apresentou a maior carga fatorial (0.919), sugerindo que a produtividade dos profissionais de educação aumenta com o uso da IA. Merece destaque o UP4 – meu trabalho fica mais efetivo (eficiente e eficaz) usando a IA (0.901), demonstrando que esse indicador tem grande importância na explicação do constructo. Esses dados reforçam os achados de Davis (1989) sobre a importância da UP na aceitação da tecnologia, uma vez que ela é fundamental para a aceitação de sistemas tecnológicos.

O fator ATU é composto por quatro indicadores, com cargas fatoriais variando de 0.682 a 0.843. O indicador ATU3 apresentou a maior carga fatorial (0.843), demonstrando que os profissionais de educação acreditam ser muito melhor utilizar a IA no trabalho. Também relevante é o ATU2 – eu desejo utilizar a IA (0.682), sinalizando que esse indicador também apresenta boa consistência interna. Esses dados confirmam a afirmação de Lopes, Caracciolo e Herrero (2018), de que o uso da IA impacta diretamente as intenções, percepções e comportamentos dos usuários.

O fator ITU é composto por três indicadores, com cargas fatoriais variando de 0.642 a 0.921. O indicador ITU1 apresentou a maior carga fatorial (0.921), apontando que os profissionais de educação pretendem utilizar a IA sempre que possível. Outro indicador de destaque é o ITU2 – eu tenho a intenção de aumentar o uso da IA (0.842), demonstrando que esse indicador também possui uma boa carga fatorial e corrobora a afirmação de Davis (1989) de que o uso da IA possui correlação mais significativa com a ITU.

O fator URS é composto por três indicadores, com cargas fatoriais variando de -0.907 a 1.025. O indicador URS2 apresentou a maior carga fatorial (1.025), confirmando que os profissionais de educação usam a IA com frequência. Também se destaca o URS1 – uso a IA

diariamente (0.963), esse indicador também é fortemente sustentado. O item URS3 apresentou uma carga fatorial negativa (-0.907), indicando uma relação inversa com o fator URS. Esse resultado decorre de uma proposital formulação invertida do item, comum em escalas que buscam controlar a tendência de resposta, confirmando a consistência das mesmas, conforme preconizado pela literatura sobre o TAM.

Constata-se que as estimativas obtidas na AFC mostram que todos os indicadores apresentaram cargas fatoriais estatisticamente significativas ( $p < 0.001$ ), com valores superiores a 0.70. Esse resultado reforça a validade convergente dos constructos investigados (FUP, UP, ATU, ITU e URS). Além disso, os baixos valores dos erros-padrão e os altos valores  $z$  confirmam a precisão das estimativas, demonstrando a consistência interna dos indicadores em representar adequadamente os fatores propostos no modelo.

Com o objetivo de examinar as relações entre os fatores latentes do modelo, foi realizada a análise das covariâncias fatoriais (Tabela 2) para avaliar como os constructos teóricos estão correlacionados entre si e se essas correlações são estatisticamente significativas. Essa etapa é essencial para avaliar a validade discriminante, ou seja, a distinção entre os constructos teóricos.

As estimativas representam a covariância padronizada entre os fatores, sendo que quanto maior o valor (próximo de 1), mais forte é a relação entre os fatores; o erro-padrão mede a precisão da estimativa, sendo que valores baixos indicam mais confiabilidade; a estatística  $Z$  indica quantos desvios-padrão a estimativa está distante de zero (valor alto sugere relação forte e confiável); e a estatística  $p$  indica se a covariância é estatisticamente significativa (valores de  $p < 0.001$  significam que a correlação entre os fatores é muito significativa).

**Tabela 2 – Covariâncias fatoriais**

		<b>Estimativas</b>	<b>Erro-padrão</b>	<b>Z</b>	<b>p</b>
FUP	FUP	1.000 <sup>a</sup>			
	UP	0.535	0.0475	11.26	< 0.001
	ATU	0.459	0.0534	8.59	< 0.001
	ITU	0.372	0.0583	6.38	< 0.001
	URS	0.622	0.0443	14.05	< 0.001
UP	UP	1.000 <sup>a</sup>			
	ATU	0.896	0.0179	49.94	< 0.001
	ITU	0.806	0.0273	29.49	< 0.001
	URS	0.731	0.0354	20.64	< 0.001
ATU	ATU	1.000 <sup>a</sup>			
	ITU	0.958	0.0145	66.20	< 0.001
	URS	0.791	0.0318	24.84	< 0.001
ITU	ITU	1.000 <sup>a</sup>			
	URS	0.774	0.0342	22.60	< 0.001
URS	URS	1.000 <sup>a</sup>			

<sup>a</sup> parâmetro fixo

Fonte: Dados da pesquisa (2025).

As covariâncias estimadas entre os fatores mostraram-se estatisticamente significativas ( $p < 0.001$ ), indicando que os constructos estão relacionados entre si de maneira coerente com o modelo teórico adotado, sem que haja sobreposição excessiva entre eles.

A UP mostrou-se fortemente correlacionada com a Atitude (ATU,  $r = 0.896$ ) e com a Intenção de Uso (ITU,  $r = 0.806$ ), confirmando sua centralidade na estrutura preditiva do TAM. A Atitude, por sua vez, teve correlação quase perfeita com a Intenção de Uso ( $r = 0.958$ ), indicando forte alinhamento entre percepção positiva e predisposição comportamental. A FUP apresentou correlações moderadas com UP ( $r = 0.535$ ) e ATU ( $r = 0.459$ ), mas sua associação com a ITU foi relativamente mais baixa ( $r = 0.372$ ), reforçando sua influência indireta no

modelo. Por fim, o URS correlacionou-se fortemente com todos os demais fatores, especialmente com FUP ( $r = 0.622$ ), UP ( $r = 0.731$ ), ATU ( $r = 0.791$ ) e ITU ( $r = 0.774$ ), evidenciando a relevância da percepção e da intenção para a efetivação do uso. Esses resultados contribuem para a robustez do modelo, ao evidenciar conexões consistentes entre os fatores.

Ante o exposto, os dados revelam que o modelo está bem ajustado e os fatores estão relacionados como o TAM prevê. Ainda, é evidente que UP tem papel central, impactando tanto a ATU quanto a ITU e o URS. Como a ATU é altamente correlacionada com a ITU, a lógica do TAM é confirmada, conforme descrito por Davis (1989), de que atitudes incentivam ações concretas. Esses achados evidenciam que FUP e UP, somadas às ATU, contribuem diretamente para a ITU e URS; e no caso da presente pesquisa, ao uso real da IA em ambientes educacionais.

Com a finalidade de averiguar o ajuste global do modelo aos dados, realizou-se o teste qui-quadrado ( $\chi^2$ ) para avaliar a adequação do modelo teórico aos dados empíricos. O  $\chi^2$  compara a matriz de covariância observada com a matriz de covariância estimada pelo modelo. Especificamente, ele testa a hipótese nula de que a matriz de covariâncias observada é igual à matriz de covariâncias estimada pelo modelo. Para avaliar o grau de ajuste do modelo teórico aos dados empíricos, foi aplicado o teste do qui-quadrado ( $\chi^2$ ), demonstrado na Tabela 3.

**Tabela 3 – Teste Qui-quadrado –  $\chi^2$**

<b>Teste ao Ajustamento Exato</b>		
$\chi^2$	gl	p
558	199	< .001

Fonte: Dados da pesquisa (2025).

O teste qui-quadrado ( $\chi^2$ ) avalia o ajuste do modelo teórico que envolve os fatores FUP, UP, ATU, ITU e URS. O qui-quadrado ( $\chi^2$ ), portanto, reflete a consistência global do conjunto de relações entre os fatores do TAM aplicado à aceitação da IA. O teste qui-quadrado indicou um valor de  $\chi^2 (199) = 558$ ,  $p < 0.001$ , sugerindo que o modelo não apresenta ajuste perfeito aos dados. No entanto, essa estatística é sensível ao tamanho da amostra, o que pode resultar em rejeição da hipótese nula mesmo diante de discrepâncias triviais entre as matrizes observada e estimada.

Como a significância estatística do resultado do teste qui-quadrado ( $\chi^2$ ) não invalida o modelo, a literatura recomenda considerar os índices de ajuste adicionais (*Comparative Fit Index – CFI*, o *Tucker-Lewis Index – TLI* e o *Root Mean Square Error of Approximation – RMSEA*) para uma avaliação mais robusta da qualidade do modelo. Esses índices são amplamente recomendados na literatura por serem menos sensíveis ao tamanho da amostra e fornecerem uma avaliação mais precisa da adequação do modelo.

Assim, após a análise do teste qui-quadrado ( $\chi^2$ ), foram examinados os indicadores complementares de ajustamento do modelo (CFI, TLI e RMSEA), com o intuito de avaliar de forma mais robusta a qualidade do ajuste entre o modelo teórico proposto e os dados empíricos. A Tabela 4 apresenta os principais índices de ajuste incremental e de erro de aproximação: o CFI, o TLI e o RMSEA, acompanhados do intervalo de confiança de 90% para o RMSEA.

**Tabela 4 – Medidas de ajustamento**

CFI	TLI	RMSEA	IC 90% RMSEA	
			Lim. Inferior	Superior
0.932	0.921	0.0808	0.0729	0.0887

Fonte: Dados da pesquisa (2025).

Como o CFI compara o modelo ajustado com um modelo nulo (sem relações entre as variáveis), de modo que valores acima de 0.90 indicam um ajuste aceitável, e acima de 0.95, um ajuste muito bom. Portanto, o valor de 0.932 sugere que o modelo possui um bom ajuste

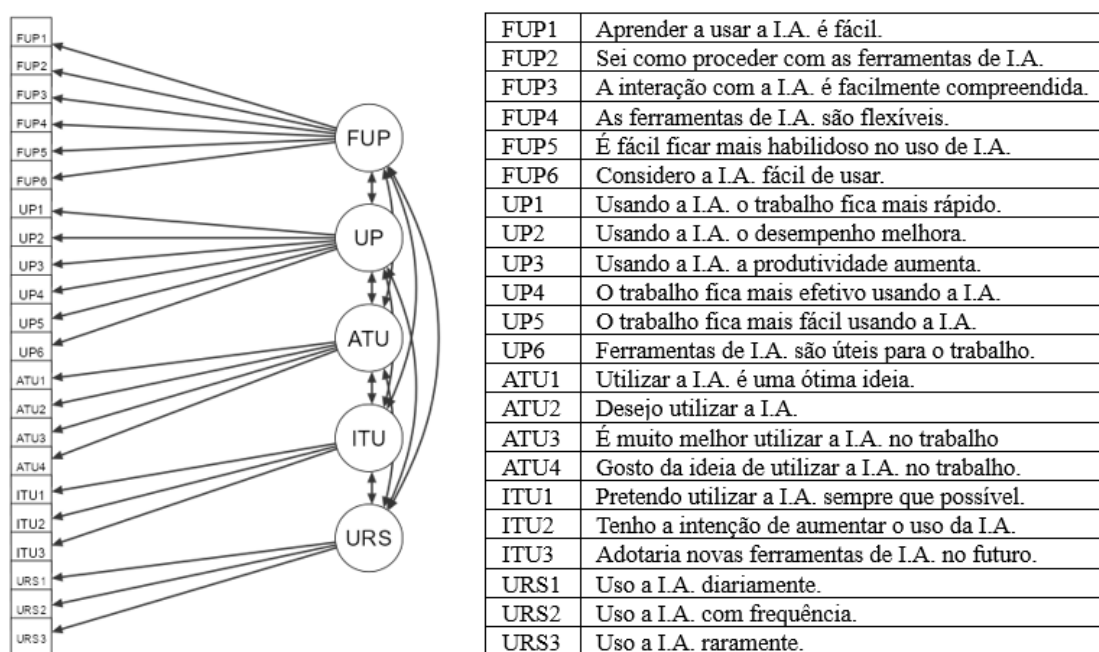
comparativo. O TLI é um índice que compara o modelo proposto ao modelo nulo, sendo que valores acima de 0.90 também indicam ajuste satisfatório. Logo, o TLI de 0.921 indica um bom ajuste, embora um pouco abaixo do ideal ( $> 0.95$ ).

E, quanto ao RMSEA, que avalia o erro de aproximação do modelo por grau de liberdade, constatou-se que o valor de 0.0808 apresenta limite próximo da zona crítica (aceitável entre 0.05 a 0.08; e excelente  $\leq 0.05$ ), indicando um ajuste razoável, mas no limite entre o aceitável e o fraco. Como o valor do RMSEA foi de 0.0808, com intervalo de confiança de 90% variando entre 0.0729 e 0.0887 – ele ainda se encontra dentro do limite de aceitação para modelos com estruturas complexas e amostras reais.

Considerando-se que o modelo apresentou um bom ajuste geral, com valores satisfatórios de CFI e TLI, e um RMSEA no limite do aceitável; e analisando todos os indicadores de forma conjunta, os resultados sustentam a adequação do modelo à estrutura dos dados, reforçando a validade da solução fatorial proposta. E como os demais testes (pesos fatoriais e covariâncias) foram favoráveis, o modelo pode ser validado com confiança.

Sequencialmente, a Figura 2 apresenta o diagrama de trajetória do modelo de mensuração proposto, construído com base no TAM, adaptado para o contexto do uso de ferramentas de IA. Conforme descrito anteriormente, esse modelo contempla cinco fatores latentes: FUP, UP, ATU, ITU e URS – cada um representado por um conjunto de indicadores observáveis. O diagrama tem por finalidade representar visualmente o modelo teórico testado, facilitando a compreensão da estrutura das relações entre os fatores latentes (constructos) e seus indicadores observáveis.

**Figura 2 – Diagrama de Trajetórias**



Fonte: Dados da pesquisa (2025).

As setas unidirecionais do diagrama indicam a associação entre os constructos latentes e seus respectivos itens, enquanto as setas curvas representam as correlações entre os fatores. O diagrama de trajetórias permite uma visualização da estrutura conceitual adotada na pesquisa e serve de base para as análises de validade e ajustamento do modelo.

A Figura 2 demonstra que o fator FUP é composto por seis indicadores (FUP1 a FUP6) que avaliam a percepção dos respondentes quanto à facilidade de aprender, compreender e operar ferramentas de IA, incluindo aspectos como flexibilidade, clareza e habilidade de uso.

Já o fator UP, também com seis indicadores (UP1 a UP6), capta os impactos positivos percebidos na produtividade, desempenho e eficácia do trabalho com o uso da IA, refletindo a percepção do usuário quanto ao valor funcional das ferramentas adotadas. A ATU é representada por quatro indicadores (ATU1 a ATU4), que expressam avaliações pessoais e julgamentos positivos sobre o uso da IA no ambiente de trabalho, como “utilizar a IA é uma ótima ideia” e “gosto da ideia de utilizar a IA”. O fator ITU é medido por três indicadores (ITU1 a ITU3), voltados à predisposição comportamental futura, como a intenção de continuar utilizando ou adotar novas ferramentas de IA. E, por fim, o fator URS, composto por três indicadores (URS1 a URS3), avalia a frequência e intensidade de uso das ferramentas de IA na prática. Observa-se, no entanto, que o indicador URS3 (“Uso a IA raramente”) é formulado de maneira inversa, o que explica a carga fatorial negativa identificada na AFC.

As relações entre os fatores latentes são representadas por setas bidirecionais, que indicam as covariâncias estimadas entre os fatores. Os dados empíricos demonstraram que todas as correlações fatoriais foram estatisticamente significativas ( $p < .001$ ) e teoricamente coerentes com o TAM, com destaque para a forte associação entre UP, ATU, ITU e URS. A FUP apresentou correlações moderadas com os demais fatores, o que reforça seu papel mais indireto na influência sobre o comportamento de uso, conforme proposto no modelo de Davis (1989).

Após a aplicação da AFC, optou-se por realizar uma Análise de Variância (ANOVA), com o objetivo de comparar as médias dos grupos e identificar possíveis diferenças estatisticamente significativas entre eles (Tabela 5 – idade, Tabela 6 – área de atuação e Tabela 7 – Modalidade de ensino que atua), já que a ANOVA é uma técnica estatística utilizada para examinar diferenças entre as médias de três ou mais grupos (Hair Junior *et al.*, 2009). O autor ressalta a importância desse método em pesquisas na área de Ciências Sociais, destacando que sua interpretação é baseada no valor de  $p$  – sendo que  $p < 0.05$  indica a presença de diferenças estatisticamente significativas entre os grupos avaliados.

**Tabela 5** – ANOVA a um fator – Idade

	<b>F</b>	<b>gl1</b>	<b>gl2</b>	<b>p value</b>
Média FUP – Facilidade de Uso Percebida	3.184	4	76.9	0.018
Média UP – Utilidade Percebida	1.281	4	74.6	0.285
Média ATU – Atitude em Relação ao Uso	0.581	4	75.1	0.677
Média ITU – Intenção de Uso	0.338	4	74.2	0.851
Média URS – Uso Real do Sistema	0.901	4	73.3	0.468

Fonte: Dados da pesquisa (2025).

A Tabela 5 apresenta os resultados da ANOVA, cujo objetivo foi verificar se existem diferenças estatisticamente significativas nas médias das variáveis estudadas (FUP, UP, ATU, ITU e URS) em função da idade dos participantes. Os resultados indicam que apenas a variável FUP apresentou diferença significativa entre os grupos etários, com valor de  $F = 3.184$  e  $p = 0.018$  ( $< 0.05$ ), sugerindo que a FUP varia conforme a faixa etária dos respondentes. Esse achado indica que a idade pode influenciar como os usuários percebem a facilidade de uso da tecnologia.

Por outro lado, as demais variáveis avaliadas – UP ( $p = 0,285$ ), ATU ( $p = 0.677$ ), ITU ( $p = 0.851$ ) e URS ( $p = 0.468$ ) – não apresentaram diferenças estatisticamente significativas entre as faixas etárias, uma vez que seus valores de  $p$  foram maiores que 0.05. Esse resultado indica que, independentemente da idade, os participantes possuem percepções/comportamentos semelhantes em relação à UP, ATU, ITU e URS. Desse modo, pode-se dizer que a idade dos usuários interfere na FUP, mas não impacta significativamente a UP, ATU, ITU e URS, apontando que a FUP pode ser um fator mais sensível às diferenças etárias.

**Tabela 6 – ANOVA a um fator – Área de atuação**

	F	gl1	gl2	<i>p value</i>
Média FUP – Facilidade de Uso Percebida	2.36	13	64.2	0.012
Média UP – Utilidade Percebida	4.61	13	65.0	<0.001
Média ATU – Atitude em Relação ao Uso	4.27	13	65.5	<0.001
Média ITU – Intenção de Uso	3.65	13	65.9	<0.001
Média URS – Uso Real do Sistema	2.13	13	64.7	0.024

Fonte: Dados da pesquisa (2025).

A Tabela 6 apresenta os resultados da ANOVA para o fator área de atuação, com o objetivo de identificar se existem diferenças significativas nas médias das variáveis analisadas conforme a área profissional dos participantes. A ANOVA revelou que todas as variáveis avaliadas apresentaram diferenças estatisticamente significativas entre as diferentes áreas profissionais dos participantes.

A FUP mostrou variação significativa com  $F = 2.36$  e  $p = 0.012$ , indicando que a FUP difere conforme a área de atuação. A UP apresentou uma diferença ainda mais robusta, com  $F = 4.61$  e  $p < 0.001$ , demonstrando que a UP varia de maneira significativa entre as áreas profissionais. ATU ( $F = 4.27$ ,  $p < 0.001$ ) e a ITU ( $F = 3.65$ ,  $p < 0.001$ ) também diferem significativamente conforme a área de atuação, sugerindo que o posicionamento e a disposição para utilizar o sistema são influenciados pelo contexto profissional. Finalmente, o URS também apresentou variação significativa entre as áreas ( $F = 2.13$ ,  $p = 0.024$ ), indicando que o comportamento efetivo de uso é impactado pelo setor de atuação.

Esses resultados indicam que a área profissional exerce influência relevante sobre as percepções e comportamentos dos usuários em relação ao sistema, destacando a importância de considerar as particularidades de cada segmento para promover uma melhor aceitação e utilização da tecnologia.

**Tabela 7 – ANOVA a um fator – Modalidade de ensino que atua**

	F	gl1	gl2	<i>p value</i>
Média FUP – Facilidade de Uso Percebida	5.58	5	46.9	<0.001
Média UP – Utilidade Percebida	6.13	5	48.6	<0.001
Média ATU – Atitude em Relação ao Uso	7.26	5	48.5	<0.001
Média ITU – Intenção de Uso	4.76	5	48.5	0.001
Média URS – Uso Real do Sistema	4.66	5	46.4	0.002

Fonte: Dados da pesquisa (2025).

A ANOVA apresentada na Tabela 7 em relação à modalidade de ensino que o profissional de educação atua revelou que todas as variáveis analisadas apresentaram diferenças estatisticamente significativas. A FUP demonstrou variação significativa com  $F = 5.58$  e  $p < 0.001$ , indicando que a FUP varia conforme a modalidade educacional. A UP também apresentou diferença significativa, com  $F = 6.13$  e  $p < 0.001$ , evidenciando que a mesma é influenciada pela modalidade de ensino. ATU ( $F = 7.26$ ,  $p < 0.001$ ) e a ITU ( $F = 4.76$ ,  $p = 0.001$ ) mostraram variações significativas, sugerindo que o posicionamento e a disposição para utilizar o sistema dependem da modalidade em que o profissional atua. Por fim, o URS apresentou diferenças relevantes entre as modalidades, com  $F = 4.66$  e  $p = 0.002$ , indicando que o comportamento efetivo de uso do sistema também é impactado pela modalidade de ensino.

Esses resultados evidenciam que a modalidade de ensino exerce influência significativa nas percepções e no uso do sistema, ressaltando a importância de adaptar estratégias de implementação conforme as especificidades de cada modalidade para otimizar a aceitação e o engajamento dos profissionais de educação.

## 5 CONCLUSÃO/CONTRIBUIÇÃO

Os achados da presente pesquisa reforçam a robustez teórica e empírica do TAM no contexto educacional, especialmente diante do avanço do uso de ferramentas baseadas em IA no cotidiano de profissionais da educação. A AFC validou os constructos clássicos do modelo (FUP, UP, ATU, ITU e URS), com cargas fatoriais altas e estatisticamente significativas (entre 0,642 e 1,025;  $p < 0,001$ ), reforçando a consistência dos indicadores adotados.

A correlação entre FUP e UP, confirma um dos princípios fundamentais do TAM proposto por Davis (1989): tecnologias percebidas como intuitivas tendem a ser vistas como úteis para o desempenho profissional. Essa relação foi evidenciada por um coeficiente de covariância de 0.535 (Tabela 2), indicando que a percepção de facilidade afeta indiretamente o comportamento de uso.

Da mesma forma, a elevada correlação entre UP, ATU e ITU evidencia que percepções positivas sobre os benefícios do uso da IA tendem a despertar atitudes favoráveis e maior intenção de continuidade. A atitude favorável, como indicam Venkatesh *et al.* (2003), constitui um mediador importante entre as crenças individuais e o comportamento de uso, o que foi confirmado pelos dados da Tabela 2, ao demonstrar a associação quase perfeita entre ATU e ITU (covariância de 0.958). Tais relações revelam forte coerência interna do modelo e sustentam sua validade estrutural.

Outro achado relevante diz respeito ao URS, que apresentou forte associação com os demais constructos do modelo, conforme mostrado na Tabela 2: FUP (0,622), UP (0,731), ATU (0,791) e ITU (0,774). Esses resultados indicam que a aceitação da tecnologia vai além da intenção declarada, concretizando-se em ações efetivas por parte dos profissionais da educação. Isso reforça a aplicabilidade prática do TAM no contexto educacional, demonstrando que o ciclo entre crença, atitude, intenção e comportamento está, de fato, presente na experiência cotidiana desses profissionais.

Essa dinâmica foi visualmente representada no diagrama de trajetórias (Figura 2), que contribuiu para a clareza e a coerência do modelo ao evidenciar os caminhos causais entre os constructos. A estrutura teórica proposta mostrou-se validada, com índices de ajuste dentro dos padrões recomendados pela literatura, como CFI (0,932), TLI (0,921) e RMSEA (0,0808), confirmando a qualidade do ajustamento do modelo aos dados empíricos e ampliando a compreensão sobre os fatores que impulsionam o uso da IA em ambientes educacionais.

As ANOVAS (Tabelas 5, 6 e 7) complementam esse cenário ao revelar que a aceitação da IA não é homogênea entre os profissionais da educação. Os dados sugerem que a FUP varia conforme a idade, o que aponta para a necessidade de ações específicas de capacitação voltadas a determinados grupos etários. Já as diferenças observadas entre áreas de atuação e modalidades de ensino evidenciam que o contexto profissional e institucional exerce influência direta nas percepções e comportamentos em relação à IA.

Dessa forma, considera-se que o objetivo principal desta pesquisa foi alcançado, ao investigar, com base no TAM, a aceitação e o uso da IA na atuação dos profissionais de educação em diferentes ambientes educacionais. A partir das análises quantitativas realizadas, foi possível compreender como os fatores de percepção, atitude, intenção e comportamento interagem entre si e influenciam o uso efetivo da IA no contexto educacional, oferecendo subsídios teóricos e práticos para futuras decisões sobre adoção e uso de tecnologias.

As políticas de formação devem considerar essas diferenças para serem mais eficazes. Por exemplo, profissionais da área de exatas ou que atuam na modalidade a distância podem ter experiências e expectativas distintas em relação ao uso da IA, quando comparados a profissionais da área de humanas ou da modalidade presencial. Essa diversidade de experiências pode ser um fator moderador relevante e merece ser investigada em estudos futuros. Ademais, essas nuances revelam que embora o TAM apresente um modelo geral de aceitação tecnológica,

sua aplicação prática demanda leitura sensível do contexto e personalização das estratégias de implementação. Ignorar essas especificidades pode comprometer o sucesso de iniciativas de inovação tecnológica no ambiente educacional.

Embora os resultados aqui apresentados sustentem a validade do modelo, é importante destacar que a realização de testes de hipótese em futuras análises pode contribuir para aprofundar ainda mais a compreensão sobre as relações causais entre os fatores, testando modelos alternativos ou mediadores/moderadores que ampliem o escopo explicativo da pesquisa em tela. Fica, portanto, a sugestão de continuidade da pesquisa por meio dessa abordagem, especialmente com vistas à elaboração de políticas institucionais e formativas mais assertivas no uso de tecnologias baseadas em IA na educação.

A principal contribuição desta pesquisa consiste na validação empírica do TAM aplicado ao contexto educacional, evidenciando a relevância dos constructos UP, FUP, ATU, ITU e URS para explicar a aceitação e o uso da IA por profissionais da educação. Os achados permitem compreender que a adoção efetiva da IA está diretamente ligada à UP e FUP, bem como à formação de ATU positivas e intencionais. Além disso, ao identificar variações significativas em função de fatores como idade, área de atuação e modalidade de ensino, a pesquisa oferece subsídios práticos para o desenvolvimento de estratégias formativas e institucionais mais alinhadas às realidades e necessidades dos profissionais de educação.

Reforça-se a relevância do Modelo TAM como estrutura explicativa para a aceitação e o uso da IA por profissionais da educação, destacando o papel central da UP e da FUP como catalisadores de ATU, ITU e do efetivo URS. Tais evidências empíricas indicam que a adoção da IA em contextos educacionais não ocorre de forma espontânea, mas depende da percepção de valor prático e da experiência de uso facilitada. Assim, recomenda-se que estudos futuros explorem a mediação de variáveis como formação continuada, suporte institucional e cultura organizacional no fortalecimento desses fatores, bem como realizem análises longitudinais ou estudos comparativos entre diferentes redes e níveis de ensino, a fim de aprofundar a compreensão sobre a sustentabilidade do uso da IA na educação ao longo do tempo.

## REFERÊNCIAS BIBLIOGRÁFICAS

DAVIS, F. D. Perceived Usefulness, Perceived Ease of Use, and User Acceptance of Information Technology. **MIS Quarterly**, v. 13, n. 3, p. 319-340, set. 1989.

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

GATRELL, C; MUZIO, D; POST, C.; WICKERT, C. Here, there and everywhere: on the responsible use of artificial intelligence (AI) in management research and the peer-review process. **Journal of Management Studies**, v. 61, n. 3, p. 739–751, 2024.

GOMES, R. S. **Aplicação do Modelo de Aceitação da Tecnologia (TAM) para analisar os fatores que afetam o uso do Google Classroom entre estudantes do ensino médio**. 2022. Monografia (Especialização em Informática na Educação) – Instituto Federal do Espírito Santo, Vitória, 2022.

HAIR JUNIOR, J.; BLACK, W.C.; BABIN, B.J.; ANDERSON, R.E.; TATHAM, R.L. **Análise Multivariada de Dados**. 6 ed. Porto Alegre: Bookman, 2009.

HENNING, M.; SANTOS, J. D. F.; CUNHA, C. J. C. A.; SILVA, S. M.; SOUZA, J. A. **Impactos da Inteligência Artificial na Educação Superior: uma revisão da literatura.** In: XXII Colóquio Internacional de Gestión Universitaria – Desafios y Futuro de la Educación Superior ante el impacto de la Intelligencia Artificial. Ciudad de Assunción – Paraguay, diciembre, 2023.

LOPES, E. R.; CARACCILO, L. L.; HERRERO, E. Aceitação do *Mobile Banking* no Brasil: uma Análise Por Meio do Modelo TAM Estendido. **Teoria e Prática em Administração**, v. 8, n.1, p. 190-221, 2018.

MALHOTRA, N. **Pesquisa de Marketing**. 6 ed. Porto Alegre: Bookman, 2012.

MARIZ, E. A. S. R.; COSTA, J. S.; BOTTENTUIT JÚNIOR, J. B.; ALBUQUERQUE, O. C. P. Inteligência artificial no ensino superior: uma revisão de literatura sobre desafios e possibilidades no contexto acadêmico. **Poliética – Revista de Ética e Filosofia Política**. São Paulo, v. 12, n. 3, p. 145-171, 2024.

OLIVEIRA, J. C. P.; OLIVEIRA, A. L.; MORAIS, F. A. M.; SILVA, G. M.; SILVA, C. N. M. **O questionário, o formulário e a entrevista como instrumentos de coleta de dados: vantagens e desvantagens do seu uso na pesquisa de campo em ciências humanas.** In: III Congresso Nacional de Educação, p. 1-13, 2016.

PERES, F. A literacia em saúde no ChatGPT: explorando o potencial de uso de inteligência artificial para a elaboração de textos acadêmicos. **Ciência & Saúde Coletiva**, v. 29, n. 1, p. 1-13, 2024.

PRODANOV, C. C.; FREITAS, E. C. **Metodologia do trabalho científico: métodos e técnicas da pesquisa e do trabalho acadêmico**. 2 ed. Novo Hamburgo: Feevale, 2013.

RODRIGUES, L. Pós-Humanismo e Educação: O Potencial da Inteligência Artificial na Inclusão no Ensino Superior. **Revista da UI\_IPSantarém**, v. 11, n. 4, p. 138-148, 2023.

RUSSEL, S.; NORVIG, P. **Artificial Intelligence: A Modern Approach**. 4th ed. Pearson Education Limited, 2022.

SCHERER, R.; SIDDIQ, F.; TONDEUR, J. The technology acceptance model (TAM): A meta-analytic structural equation modeling approach to explaining teachers' adoption of digital technology in education. **Computers & Education**, v. 128, p. 13–35, 2019.

SEVERINO, A. J. **Metodologia do trabalho científico**. 23 ed. São Paulo: Cortez, 2007.

TRIVIÑOS, A. N. S. **Introdução à pesquisa em ciências sociais: a pesquisa qualitativa em educação**. São Paulo: Atlas, 1987.

VENKATESH, V.; MORRIS, M. G.; DAVIS, G. B.; DAVIS, F. D. User Acceptance Of Information Technology: **Toward A Unified View**. **MIS Quarterly**, v. 27 n. 3, p. 425-478, 2003.

YOUSAFZAI, S. Y.; FOXALL, G. R.; PALLISTER, J. G. Technology acceptance: a meta-analysis of the TAM: Part 1. **Journal of Modelling in Management**, Bingley, v. 2, n. 3, p. 251–280, 2007. <https://doi.org/10.1108/17465660710834453>.