

EFEITOS DA RESISTÊNCIA A MUDANÇA, AUTOEFICÁCIA E UTILIDADE PERCEBIDA NA INTENÇÃO DE USO DO CHATGPT EM PRÁTICAS DOCENTES

Área: Ensino-Aprendizagem, Pesquisa e Formação Didático-Pedagógica de Professores em Administração

Resumo:

Objetivo: Uma das tecnologias que vem chamando cada vez mais a atenção em todas as áreas, também na área de docência, é o ChatGPT, que devido ao seu potencial de realização de tarefas de forma autônoma, pode representar um desafio para a profissão docente, ou pode contribuir com ela, dependendo da ótica do profissional dessa área. Diante disso, este estudo tem como objetivo examinar os efeitos da resistência a mudança, autoeficácia e utilidade percebida, na intenção de uso do ChatGPT em práticas docentes de professores da administração e áreas afins que atuam no ensino superior.

Método: A coleta de dados, foi realizada utilizando-se de questionário disponibilizado na plataforma *google forms*, enviado para professores da administração e áreas afins, obtendo-se 116 respostas. O tratamento dos dados foi realizado por meio da técnica estatística PLS-SEM de modelagem de equações estruturais, que envolve análise do modelo de medição e análise do modelo estrutural para verificação dos resultados de *path coeficientes*.

Resultados: Os resultados demonstram que os professores investigados não demonstram resistência ao uso da ferramenta. Também foi constatado que professores auto eficazes percebem maior utilidade no uso da ferramenta, embora sua intenção de uso ainda seja modesta. Dentre os fatores estudados, a percepção de uso foi o que apresentou maior efeito sobre a intenção de uso do ChatGPT pelos professores em suas práticas docentes.

Contribuição: Os resultados da pesquisa contribuem para o direcionamento de fatores que podem ou não influenciar a percepção e a intenção de uso da inteligência artificial em práticas docentes.

Palavras-chave: ChatGPT; tecnologias no ensino aprendizagem; inovação na docência.

Abstract:

Objective: One of the technologies that has been increasingly attracting attention in all areas, including education, is ChatGPT. Due to its potential for autonomous task completion, it can either pose a challenge or be a valuable contribution to the teaching profession, depending on the perspective of the professional in this field. Therefore, this study aims to examine the effects of resistance to change, self-efficacy, and perceived usefulness on the intention to use ChatGPT in teaching practices of professors in the field of administration and related areas in higher education.

Method: Data collection was carried out using a questionnaire provided on the Google Forms platform, which was distributed to professors in the field of administration and related areas, obtaining 116 responses. Data analysis was conducted using the PLS-SEM technique for structural equation modeling, involving measurement model analysis and structural model analysis to verify the results of path coefficients.

Results: The results indicate that the investigated professors do not exhibit resistance to using the tool. It was also found that self-efficacious professors perceive greater usefulness in using the tool, although their intention to use it is still modest. Among the factors studied, the perception of usefulness had the greatest effect on the intention to use ChatGPT by professors in their teaching practices.

Contribution: The research results contribute to identifying factors that may or may not influence the perception and intention to use artificial intelligence in teaching practices.

Keywords: ChatGPT; technologies in teaching learning; innovation in teaching.

1 INTRODUÇÃO

Significativas mudanças vem ocorrendo nas práticas educacionais em instituições de ensino superior, principalmente nos últimos 20 anos, e grande parte delas são decorrentes aos avanços tecnológicos (GRATZ; LOONEY, 2020). A utilização de tecnologias na docência passou a ser um requisito fundamental e suas aplicações se dão não apenas nas práticas cotidianas de gestão das atividades do docente, mas principalmente tem afetado a experiência dos estudantes no processo de aprendizagem (BOND et al, 2020; ALGANI E GROSS, 2023).

O uso da inteligência artificial (IA), por sua vez, vem seguindo essa tendência. Apesar das opiniões críticas e até mesmo das proibições em determinadas comunidades e regiões, essa tecnologia é fundamental para inovações nas práticas educacionais (KASNECI, et al., 2023). As aplicações já bem disseminadas do uso de IA na educação são normalmente direcionadas para melhorar os serviços administrativos e o apoio acadêmico, como em sistemas de tutoria inteligentes (ITS) (LO, 2023).

De forma mais recente, considerando o progresso e a expansão no aprendizado de máquina, a IA passa, também, a ser potencialmente utilizada como uma tecnologia inovadora mais sofisticada para geração de conteúdo digital, como é o caso da inteligência artificial generativa (IA), que se trata de um aprendizado de máquina não supervisionado ou parcialmente supervisionado, que cria novos conteúdos a partir do conteúdo digital existente, como, entre outros, vídeo, imagens/gráficos, texto, áudio, aprendendo seus padrões e distribuição (HU, 2023).

Dentre as inteligências artificiais generativas mais conhecidas e, que já estão impactando a educação, o ChatGPT se destaca (KASNECI, et al., 2023), uma vez que foi treinado em um conjunto muito grande de dados, ou seja, textos de um *corpus web* muito grande, e demonstrou desempenho de última geração em uma ampla gama de tarefas de linguagem natural, variando da tradução a respostas, perguntas, redação de ensaios coerentes e programas de computador (KASNECI, et al., 2023).

O lançamento do ChatGPT ocorreu em 30 de novembro de 2022, e se tornou o aplicativo de usuário de crescimento mais rápido da história, atingindo 100 milhões de usuários ativos em janeiro de 2023, apenas dois meses após seu lançamento (Lo, 2023). Acompanhado desse sucesso, o ChatGPT trouxe tanto potenciais benefícios quanto novos desafios à educação, exigindo que os docentes e discentes desenvolvam conjuntos de competências e literacias necessárias para compreender a tecnologia, bem como as suas limitações e fragilidades (KASNECI, et al., 2023). Ainda de acordo com esses autores, quando adequadamente utilizado, o ChatGPT pode contribuir com as práticas docentes por meio da criação de conteúdo educacional, melhor envolvimento e interação dos alunos e personalização das experiências de aprendizagem.

A tecnologia melhora o ensino devido às possibilidades de personalização da aprendizagem e à maior flexibilidade em termos de tempo, ritmo e local (ESCAMILLA-Fajardo et al., 2021). No entanto, considerando que a maioria dos professores de ensino superior não são nativos digitais, a falta de literacia digital poderá se tornar um problema na aceitação dessa tecnologia, bem como, em sua intenção de utilizá-la, levando parte dos docentes a resistirem à mudança (BUENTELLO-MONTOYA et al., 2021). Por outro lado, fatores como a percepção de utilidade da tecnologia, bem como a autoeficácia do professor podem apresentar efeito positivo sobre a intenção de uso da inteligência artificial nas práticas docentes desses profissionais (MOURA et al., 2020)

Partindo desse entendimento e, utilizando alguns construtos do modelo proposto por Sánchez-Prieto, et.al., (2016) que é um complemento do modelo TAM proposto por Davis (1989) este estudo tem como propósito responder ao seguinte problema de pesquisa: ***quais os efeitos da resistência a mudança, autoeficácia e utilidade percebida, na intenção de uso do ChatGPT em práticas docentes de professores da administração e áreas afins que atuam no ensino superior?***

Para que isso seja possível, o objetivo do estudo é examinar os efeitos da resistência a mudança, autoeficácia e utilidade percebida, na intenção de uso do ChatGPT em práticas docentes de professores da administração e áreas afins que atuam no ensino superior.

Ao longo da última década, a digitalização moldou a estrutura do ensino aprendizagem em todo o mundo, trazendo mudanças significativas na educação e chamando a atenção de profissionais, investigadores e decisores políticos para o desenvolvimento educacional (QURESHI et al., 2021). Mesmo com todo o seu potencial, muitas instituições de ensino superior ainda não conseguem aproveitar as oportunidades proporcionadas pelas tecnologias devido à falta de conhecimento do que pode ser alcançado através da sua utilização (CALDWELL, 2018).

Desse modo, as aplicações de aprendizagem por aprimoramento de tecnologia tornaram-se uma área importante para estudo em instituições de ensino superior (TAWAFK et al., 2018), uma vez que a tecnologia avança a um ritmo cada vez maior, tornando-se um desafio incorporá-la às práticas de ensino aprendizagem (ESCAMILLA-FAJARDO et al., 2021).

Um dos principais desafios dessa aplicação diz respeito à mudança que grande parte dos docentes deve sofrer para se adaptar à essa nova forma de ensino, havendo a necessidade de aprender a ensinar com esses novos recursos. Compreender estes dispositivos é um desafio para formadores e educadores, que trabalham há muito tempo, levando-os a optar por seguir sistemas menos desenvolvidos, enquanto os alunos preferem as tecnologias em crescimento no modelo cooperativo (QURESHI et al., 2021).

Face ao exposto, este estudo se justifica por buscar identificar alguns fatores que podem produzir efeito sobre a intenção de uso de tecnologias na prática docentes de professores do ensino superior. Mais especificamente, a intenção de uso do ChatGPT. Espera-se que os resultados da pesquisa possam fornecer subsídios para identificação desses fatores, possibilitando que as IES que tenham intenção de implementar essa tecnologia em práticas docentes de seus professores, tenham um norte que favoreça a tomada de decisão acerca de ações que levem os professores a utilizarem essas tecnologias em suas atividades.

Esta pesquisa está estruturada da seguinte forma: no próximo tópico, serão apresentados o referencial teórico-empírico e as hipóteses de pesquisa; em seguida, será apresentada a metodologia aplicada ao longo do estudo; seguida da análise e discussão de resultados e, por fim, serão apresentadas as conclusões e sugestões de novos estudos.

2 REFERENCIAL TEÓRICO-EMPÍRICO E HIPÓTESES DE PESQUISA

2.1 Uso de Tecnologias na Docência

O ritmo acelerado da inovação tecnológica nos últimos anos criou uma necessidade de investigação educacional que possa ajudar-nos a compreender melhor como a aprendizagem está sendo mediada pelas tecnologias emergentes (OLIVEIRA, et al., 2019). Uma análise inicial do desenvolvimento histórico das

instituições educativas mostra que estas mudanças estão intimamente ligadas às fases distintas, iniciando com uma formação simples na educação clássica até à educação virtual, na medida em que o sistema reflete as necessidades educativas da aprendizagem tecnológica (TAWAFK et al., 2018).

Em um mundo pós-pandemia, no qual a inteligência artificial está mais acessível e sendo incorporada progressivamente nas práticas organizacionais e no cotidiano das pessoas, o uso de tecnologias na docência tornou-se urgente, uma necessidade inegável para o ensino superior e, conseqüentemente, tem afetado inerentemente todos os aspectos da experiência do aluno (PÚBLIO, 2018; Bond et al, 2020; BUENTELLO-MONTOYA et al., 2021; ALGANI & GROSS, 2023).

Nesse mundo moderno, onde indivíduos desde o ensino primário até ao ensino superior estão familiarizados com dispositivos digitais como smartphones, tablets e computadores portáteis, a tecnologia digital oferece uma oportunidade de proporcionar aos alunos uma aprendizagem adequada e sincronizada (QURESHI, 2021). Embora essa tecnologia possa ser grande aliada na prática docente, o uso de ferramentas apenas por usá-las ou somente para o professor demonstrar que está inovando em sua atividade docente, não é capaz de revelar o seu potencial. Os professores precisam não apenas saber como utilizar a ferramenta, mas também como ensinar por meio dela (OLIVEIRA ET AL, 2019; BUENTELLO-MONTOYA et al., 2021).

O uso de tecnologias na docência fomenta ambientes colaborativos de aprendizagem, uma vez que os alunos podem estar conectados com colegas e especialistas em todo o mundo, sem barreiras físicas, possibilitando a troca de ideias e experiências (BOND et al, 2020; CROMPTON et al., 2020; BUENTELLO-MONTOYA et al., 2021). Entretanto, um ambiente de ensino tecnológico requer uma mudança nos papéis e na responsabilidade pela aprendizagem, e conseguir isso torna-se um desafio para os professores (CALDWELL, 2018). Isso pode explicar algumas das diferentes barreiras pessoais, profissionais, institucionais e contextuais que levam alguns docentes universitários a não integrarem a tecnologia digital em suas atividades (ESCAMILLA-FAJARDO, et al., 2021), levando a necessidade da identificação de fatores que podem influenciar a intenção de uso da inteligência artificial por parte desses profissionais em suas práticas docentes.

2.2 Modelo e Hipóteses de Pesquisa

Uma das métricas empregadas para identificar a anuência das tecnologias no meio educacional é o Modelo de Aceitação da Tecnologia (TAM) proposto por Davis (1989) e que incorpora, dentre outras, as variáveis utilidade percebida e intenção comportamental de uso dos recursos tecnológicos, ambas utilizadas na realização deste estudo. Além dessas duas variáveis, esta pesquisa também utiliza as variáveis resistência a mudanças e autoeficácia propostas no modelo estendido TAM de Sánchez-Prieto et.al. (2016).

A literatura recente enfatiza que o nível de formação e habilidades dos professores não são suficientes, necessitando de aprimoramento, levando às novas tecnologias digitais relacionadas ao currículo educacional nas circunstâncias atuais, alinhando-se à necessidade de mudanças tecnológicas (QURESHI et al., 2021). No entanto, estudos preliminares reconhecem que tanto fatores externos quanto internos ao indivíduo influenciam as reações às mudanças (GRATZ; LOONEY, 2020). Parte dos estudos analisa os fatores situacionais (externos) como nível de apoio dentro das organizações, a compensação e a comunicação (OREG; VAKOLA, & ARMENAKIS, 2011); e outros que compreendem que os indivíduos vivenciam situações de formas

diferentes, experimentando assim a mudança com diferentes reações e respostas (OREG ET AL., 2011).

Mesmo quando a implementação da mudança se deve à necessidade de adaptação às condições ambientais voláteis para garantir sua sobrevivência e competitividade, alguns membros da organização reagem frequentemente de forma negativa aos esforços de mudança, negando sua necessidade e resistindo a ela (YILMAZ; KILICOGU, 2013).

Nessa linha, a resistência à mudança (RM) pode ser entendida como a dificuldade de quebrar com rotinas e o estresse emocional gerado ao enfrentar a expectativa das mesmas (SÁNCHEZ-PRIETO, et.al., 2016). A resistência à mudança é uma resistência à perda de algo que é valioso ou à perda do conhecido ao avançar para o desconhecido (YILMAZ, KILICOGU, 2013). Ela pode ser considerada como um dos principais problemas na implantação de tecnologias no contexto organizacional, uma vez que aceitação ou resistência na utilização de novos recursos por parte de seus usuários são definidas pela avaliação feita pelos impactos da mudança desses novos recursos em seu ambiente de trabalho (MOURA et al., 2020).

Nesse contexto, considerando que a resistência a mudanças pode impactar a percepção de utilidade e a intenção de uso das tecnologias pelos professores, anuncia-se as seguintes hipóteses de pesquisas:

H1: A resistência à mudança tem efeito negativo sobre a intenção de uso do ChatGPT pelos professores.

H2: A resistência à mudança tem efeito negativo sobre a utilidade percebida do ChatGPT pelos professores.

A literatura também aponta a autoeficácia (AE), que tem origem na Teoria Social Cognitiva (BANDURA, 1978), como um dos fatores que podem influenciar o comportamento dos indivíduos diante das inovações tecnológicas, pois ela considera que o pensamento e a ação humanos são produtos da interpelação entre o pessoal, influências comportamentais e ambientais (Moura et al., 2020). Assim, a autoeficácia também vem sendo relacionada ao estudo das atitudes dos professores nas práticas docentes. A “atitude”, nesse caso, é compreendida como a avaliação cognitiva e afetiva que uma pessoa faz de um comportamento específico, favorável ou desfavorável (AJZEN, 2012; YADA et al, 2022).

Considerando que a AE pode influenciar o ambiente em que o indivíduo está inserido, uma vez que a sua percepção sobre a capacidade de realizar determinado comportamento pode ser um fator determinante na concretização deste fato (MOURA et al., 2020); e que ela exerce influência positiva na facilidade de uso e na sua capacidade de usar corretamente de tecnologias por professores em suas práticas docentes (SANTOS, et al., (2019) declaramos as seguintes hipóteses de pesquisa:

H3: A autoeficácia tem efeito negativo na resistência à mudança dos professores em relação ao ChatGPT.

H4: A autoeficácia tem efeito positivo na utilidade percebida do ChatGPT pelos professores.

H5: A autoeficácia tem efeito positivo na intenção de uso do ChatGPT pelos professores.

Tal como ocorre no entendimento da autoeficácia e sua relação na intenção de uso de novas tecnologias na docência, o estudo da “atitude” desse grupo de indivíduos

também está relacionado ao “grau em que uma pessoa acredita que o uso de um sistema específico melhoraria seu desempenho no trabalho” (DAVIS, 1989, p. 320). Em outras palavras significa dizer que a atitude do indivíduo está condicionada pela utilidade percebida por ele na adoção do sistema de informação ou nova tecnologia (SÁNCHEZ-PRieto, et.al., 2016).

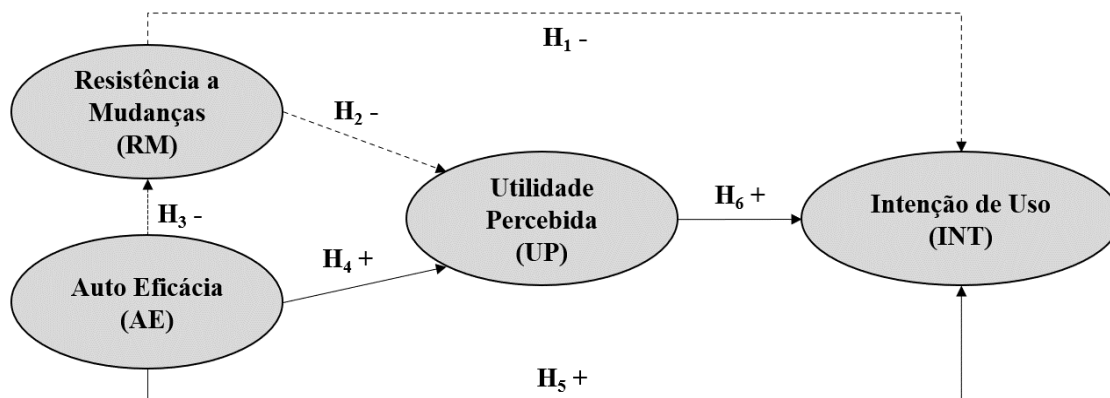
Isso implica que as expectativas dos usuários sobre os benefícios possibilitados por tecnologias no contexto organizacional tornam a intenção comportamental mais acentuada na medida em que tais expectativas de benefícios são mais positivas (MOURA et al., 2020). Tal relação já foi corroborada em estudos como de Santos, et al (2019) que confirmou haver uma relação positiva e significativa entre a utilidade percebida e a intenção de uso de ferramentas tecnológicas por docentes em sua atividade profissional.

Nesse contexto, considerando que a intenção dos professores em utilizar as tecnologias seja maior na medida em que elas facilitarão seu trabalho e aumentarão seu desempenho em relação a ele (MOURA et al., 2020) apresenta-se a seguinte hipótese de pesquisa:

H6: A utilidade percebida tem relação positiva com a intenção de uso do ChatGPT pelos professores.

Com base no contexto apresentado e nas relações estabelecidas, o modelo teórico utilizado nesta pesquisa foi construído utilizando quatro construtos do modelo proposto por Sánchez-Prieto et al. (2016). A figura 1 apresenta o modelo e as hipóteses de pesquisa descritas anteriormente.

Figura 1 - Modelo teórico de pesquisa



Fonte: Elaborado pelos autores (2023)

Conforme apresentado na figura 1, o modelo teórico de teste apresenta quatro variáveis entre dependentes e independentes. As relações apresentadas mostram a autoeficácia como variável independente que possui efeito sobre a resistência a mudanças, utilidade percebida e intenção de uso. Por sua vez, resistência a mudança apresenta-se como variável independente que possui efeito sobre a utilidade percebida e a intenção de uso. Já a utilidade percebida, esta também é apontada pela literatura como uma variável independente da intenção de uso dos professores em usar o ChatGPT em suas práticas docentes.

3. METODOLOGIA

A amostra desta pesquisa é composta de professores da administração e áreas correlatas que atuam em instituições de ensino superior brasileiras. Para a estimação do tamanho da amostra foi utilizado o *software G*Power 3.1.9.4*. O *software* foi

parametrizado com as seguintes informações: tamanho de efeito de 0,15, nível de significância do α de 0,05, poder do teste ($1-\beta$) de 0,95, e o maior número de preditores informados do modelo igual a 2 (HAIR Jr, et al., 2021). O resultado é uma amostra mínima de 110 respostas.

Os dados foram coletados por meio de questionário disponibilizado na *web* via *google forms*. Foi utilizada a escala proposta por Sánchez-Prieto et al. (2016) para os construtos do modelo desta pesquisa, além de perguntas sobre o perfil dos respondentes. Os contatos com os respondentes foram feitos por diferentes canais, como grupos de Whatsapp, e-mail e LinkedIn. O link para a coleta dos dados ficou disponível no período de 28/08/2023 a 14/09/2023. Obteve-se um retorno de 116 respostas.

A escala utilizada é do tipo *likert* de sete pontos, onde foi solicitado que os respondentes indicassem a intensidade de importância em cada uma das assertivas. Os construtos do modelo e a quantidade de assertivas de cada um, são apresentados na tabela 1:

Tabela 1 - Variáveis do instrumento de pesquisa

Construto	Nº de assertivas
Autoeficácia (AE)	3 assertivas
Intenção de uso (INTEN)	3 assertivas
Resistência a Mudanças (RM)	3 assertivas
Utilidade percebida (UP)	4 assertivas

Fonte: Elaborado pelos autores (2023)

Os dados foram tratados por meio da técnica de modelagem de equações estruturais de mínimos quadrados parciais PLS-SEM que estima estruturas de modelos parciais combinando análise de componentes principais com regressões de mínimos quadrados ordinários (HAIR Jr et al., 2019). Além disso, essa técnica fornece valores de coeficiente de determinação (R^2) e indica as relações significativas que existem entre os constructos que são capazes de denotar o desempenho do modelo (HANAFIAH, 2020). Esse método é útil para analisar inter-relações complexas entre variáveis observadas e latentes, e se mostra relevante quando o objetivo é prever variáveis-alvo no contexto de um modelo causal (HAIR Jr et al., 2021).

Um modelo de caminho PLS envolve uma abordagem de duas etapas, onde na primeira é realizada a estimativa do modelo de medição (modelo externo) e a segunda consiste na análise do modelo estrutural (modelo interno) (HANAFIAH, 2020). O modelo de medição deste estudo utiliza a abordagem reflexiva, cuja avaliação é feita por meio do exame dos parâmetros de (i) confiabilidade da consistência interna, (ii) confiabilidade do indicador, (iii) validade convergente e (iv) validade discriminante (HAIR Jr. et al., 2021). Esses parâmetros e suas recomendações podem ser observados na tabela 2:

Tabela 1 - Procedimento de avaliação do modelo de medição

Etapas	Critério	Métricas e limites
Etapa 1	Confiabilidade do indicador	Carregamentos do indicador > 0,708
Etapa 2	Confiabilidade de Consistência Interna	Confiabilidade composta > 0,70 Alfa de <i>Cronbach</i> > 0,70
Etapa 3	Validade convergente	Variância média extraída (AVE) > 0,50
Etapa 4	Validade discriminante - Critério de Fornell-Larcker	A AVE de cada construto deve ser maior que sua correlação quadrada com qualquer outro construto

Fonte: Adaptado de Hair Jr. et al. (2021)

Uma vez que os resultados dos testes da avaliação do modelo de mensuração apresentem níveis satisfatórios de confiabilidade e validade, prossegue-se com a avaliação do modelo estrutural (CHEAH et al., 2019) por meio da técnica de reamostragem *bootstrapping* (WONG, 2019) com 5.000 repetições para derivar estimativas de erro padrão dos parâmetros do modelo (HAIR Jr. et al., 2017), o que possibilita a verificação da relevância e significância dos caminhos estruturais (HAIR Jr. et al., 2021). Para tanto, os dados serão testados no *software Smart-Pls 4*, que possui as funções software Smart-Pls 4 que possui as funções Algoritmo PLS e *Bootstrapping*.

4 ANÁLISE E DISCUSSÃO DE RESULTADOS

4.1 Avaliação do Modelo de Mensuração

Para realizar os testes do modelo de mensuração, os dados foram carregados no *Smart-Pls* e executada a função Algoritmo PLS. Ao executar essa função, o *software* fornece um relatório onde são apresentadas tabelas com os resultados para cada critério dos procedimentos de avaliação do modelo de mensuração. O primeiro deles, é a confiabilidade do indicador, que é verificada por meio da matriz de cargas cruzadas. Esse critério indica quanto da variação de cada indicador é explicado por seu construto, sendo recomendados valores acima de 0,70 (HANAFIAH, 2020). A tabela 3 apresenta os pesos de cada indicador, os quais são destacados em negrito e sombreado:

Tabela 2 - Matriz de cargas cruzadas

Indicadores	AE_	INT_	RM_	UP_
AE_1	0,930	0,712	0,571	0,650
AE_2	0,931	0,633	0,509	0,586
AE_3	0,927	0,621	0,424	0,514
INT_1	0,711	0,950	0,719	0,813
INT_2	0,624	0,942	0,669	0,794
INT_3	0,691	0,971	0,694	0,835
RM_1	0,479	0,674	0,902	0,692
RM_2	0,449	0,661	0,928	0,687
RM_3	0,509	0,568	0,787	0,499
UP_1	0,658	0,820	0,692	0,942
UP_2	0,577	0,787	0,664	0,950
UP_3	0,511	0,760	0,669	0,941
UP_4	0,623	0,834	0,686	0,926

Fonte: Relatório de saída do *SmartPls*

Com base nos dados da tabela, observa-se que todos os indicadores dos construtos do modelo possuem pesos acima de 0,7. Isso significa que cada um dos construtos explica mais de 50% da variância de cada um de seus respectivos indicadores (HAIR Jr. et al., 2021). Com isso, seguiu-se com as próximas etapas da avaliação do modelo de mensuração.

As etapas dois e três de avaliação do modelo de mensuração implicam em examinar a confiabilidade da consistência interna e a validade convergente. A confiabilidade da consistência interna é examinada por meio da análise do *alfa de cronbach*, que representa o limite inferior da consistência, e da confiabilidade composta, que indica o limite superior (GHASEMY et al., 2020). Para que o construto

apresente consistência interna, ambos os critérios devem apresentar escores acima de 0,7 (GHASEMY et al., 2020; Hair Jr. et al., 2021).

Por sua vez, a validade convergente é a medida em que o construto converge para explicar a variância de seus indicadores, e a métrica utilizada para essa métrica é a variância média extraída (AVE) para todos os indicadores de cada construto (HAIR Jr. et al., 2021). Para que o construto apresente validade convergente, é preciso que apresente um valor de AVE mínimo de 0,5 (HANAFIAH, 2020; HAIR Jr. et al., 2021).

As métricas de consistência interna e validade discriminante e seus respectivos pesos podem ser observadas na tabela 4.

Tabela 3 – Consistência interna e validade convergente

Construto	Alfa de Cronbach	Confiabilidade Composta	Variância Média Extraída (AVE)
AE_	0,922	0,950	0,864
INT_	0,951	0,968	0,911
RM_	0,844	0,907	0,765
UP_	0,956	0,968	0,883

Fonte: Relatório de saída do *SmartPls*

Conforme apresentado na tabela, todos os construtos apresentaram *alfa de cronbach* e confiabilidade composta superior a 0,7, indicando que o modelo possui consistência interna. Os escores da AVE também foram superiores ao limite mínimo de 0,5, indicando que o modelo possui validade convergente. Desse modo, seguiu-se com os testes do modelo de mensuração.

A última etapa de avaliação do modelo de mensuração é a análise da validade discriminante. Essa métrica mede até que ponto um construto é empiricamente distinto estatisticamente de outros construtos no modelo estrutural (FLEUREN et al., 2018; Hair Jr. et al., 2021). A abordagem clássica para avaliar a validade discriminante baseia-se no exame do critério de Fornell-Larcker (WONG, 2019) que postula que a raiz quadrada da AVE de um construto deve ser maior do que todas as suas correlações ao quadrado com outros construtos (FLEUREN et al., 2018). Os dados para análise da validade discriminante são apresentados na tabela 5.

Tabela 4 - Validade discriminante

Construto	AE_	INT_	RM_	UP_
AE_	0,930			
INT_	0,708	0,954		
RM_	0,545	0,728	0,875	
UP_	0,633	0,853	0,722	0,940

Fonte: Relatório de saída do *SmartPls*

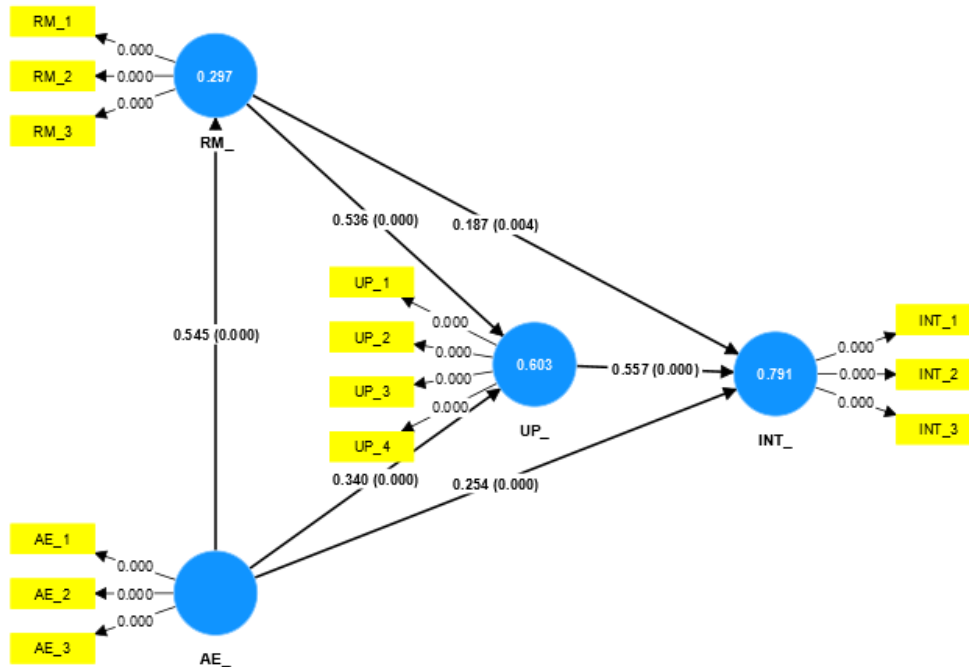
Os valores em negrito apresentados na tabela 5 indicam a raiz quadrada da AVE para cada um dos construtos do modelo. Conforme mostrado na tabela, a raiz quadrada da AVE para cada dos construtos apresentou valor maior que suas correlações com os outros construtos. Diante disso, confirmou-se que o modelo de mensuração apresenta todos os critérios necessários para sua validação, permitindo prosseguir com a análise do modelo estrutural.

4.2 Avaliação do Modelo de Estrutural

Na avaliação do modelo estrutural, verifica-se o poder explicativo do modelo por meio do R^2 e a significância das relações entre os construtos. O R^2 representa a variância explicada em cada um dos construtos endógenos que é explicada por outros

construtos endógenos, e é uma medida do poder explicativo do modelo (HAIR Jr. et al., 2021). Na figura 2 é possível observar o R² e as relações estruturais dos construtos do modelo.

Figura 2 - Modelo estrutural



Fonte: *Outputs do SmartPLS*

De acordo com Hair Jr. et al. (2021), valores de R² de 0,75, 0,50 e 0,25 podem ser considerados substanciais, moderados e fracos, respectivamente. Conforme mostrado na figura 2, a AE explica 29,7% da RM (fraco poder explicativo); a UP é explicada em 60,3% por RM e AE (poder explicativo moderado); e a AE, RM e UP juntas explicam 79,1% da INT (poder explicativo substancial).

Após a verificação do poder explicativo do modelo, procede-se com a análise da significância das relações entre os construtos. Um coeficiente de caminho é considerado significativo no nível de 5% se o valor zero não cair no intervalo de confiança de 95% (HAIR Jr. et al., 2021) sendo necessário usar a função *bootstrap* para calcular o p-valor (HAIR Jr e ALAMER, 2022). Na tabela 5 estão dispostas relações entre os construtos, o tamanho do efeito, t-valor e p-valor.

Tabela 5 - Resultados dos Path Coeficiente

Hipótese	Relação	Efeito	T valor	P valor	Significância
H1	RM_ -> INT_	0,187	2,908	0,004	Significante
H2	RM_ -> UP_	0,536	7,084	0,000	Significante
H3	AE_ -> RM_	0,545	7,917	0,000	Significante
H4	AE_ -> UP_	0,340	3,876	0,000	Significante
H5	AE_ -> INT_	0,254	3,898	0,000	Significante
H6	UP_ -> INT_	0,557	7,479	0,000	Significante

Fonte: Relatório de saída do *SmartPLS*

As hipóteses H1 e H2 estabeleciam relações negativas entre RM > INT e RM > UP respectivamente. Com base nos dados da tabela 5, observa-se que essas relações, embora apresentem significância estatística, não se confirmaram, pois os efeitos apresentados são positivos. Isso significa que os professores participantes da

pesquisa não possuem características que os levem a manifestar resistência na sua percepção de utilidade e, tampouco, na intenção de usar o ChatGPT em suas práticas docentes. Dessa forma, ambas as hipóteses não foram corroboradas com a literatura.

A H3 estabelecia relação negativa entre a AE e RM, indicando que a AE poderia reduzir a RM dos professores em relação ao ChatGPT. Conforme mostrado na tabela, essa relação também não foi corroborada, pois o efeito encontrado foi positivo, o contrário do esperado.

As hipóteses H4 e H5 buscaram verificar se a AE possui efeito positivo sobre a UP e INT. Os resultados demonstram que essas relações são estatisticamente significantes ao nível de 1%. De acordo com Hair Jr e Alamer, (2022) os coeficientes de caminho (β) variando de 0 a 0,10, 0,11 a 0,30, 0,30 a 0,50 e $> 0,50$ são indicativos de tamanhos de efeito fraco, modesto, moderado e fortes. Diante disso, constata-se um efeito moderado da AE sobre a UP, indicando que os professores que são auto eficazes conseguem perceber que a inteligência artificial pode ser útil em suas práticas docentes. Já o efeito da AE sobre a INT é considerado modesto, indicando que mesmo sendo auto eficazes os professores ainda não se sentem totalmente seguros para usar a inteligência artificial em suas práticas docentes sem contar com ajuda de terceiros.

Em relação à H6, esperava-se encontrar efeito positivo da UP sobre a INT. Essa relação foi corroborada e apontou um efeito forte, maior que 0,50. Isso significa que quando os professores percebem que o ChatGPT pode ser útil em suas atividades, essa percepção aumenta a sua intenção de usar a ferramenta em suas práticas docentes. Desse modo, pode-se inferir que a percepção de utilidade dessa tecnologia é o fator que tem maior potencial de impulsionar o uso da ferramenta pelos professores.

5 CONCLUSÕES E SUGESTÕES

Este estudo tem como objetivo examinar os efeitos da resistência a mudança, autoeficácia e utilidade percebida, na intenção de uso do ChatGPT em práticas docentes de professores da administração e áreas afins que atuam no ensino superior. Os resultados demonstraram que os professores inqueridos não possuem propensão à resistência no uso da inteligência artificial em suas práticas docentes. Por outro lado, o estudo confirmou que a autoeficácia eleva a percepção dos docentes sobre o potencial de uso da tecnologia em suas funções, podendo inferir que os professores auto eficazes conseguem perceber o quanto o ChatGPT pode ajudar na realização de suas atividades. Também se confirmou o efeito da autoeficácia sobre a intenção de uso, embora tenha sido constatado que, mesmo sendo auto eficazes, os professores ainda sentem certa insegurança em usar a tecnologia sem ajuda externa, uma vez que o efeito encontrado para essa relação é considerado modesto. Esse resultado indica a necessidade de as instituições de ensino investirem em treinamentos para que os professores possam se sentir mais confiantes no uso do recurso, o que impulsionará sua intenção em utilizá-lo. Por fim, o estudo evidenciou que a utilidade percebida dos professores em relação à tecnologia foi o fator que apresentou maior efeito sobre a intenção de uso desse recurso tecnológico. Isso demonstra que, para que os professores tenham maior propensão em usar o ChatGPT em suas práticas docentes, é necessário que seja demonstrado a eles as formas como esse recurso tecnológico pode ajudar no desenvolvimento de suas atividades.

Esta pesquisa contribui com a literatura sobre a adoção de novas tecnologias, além de fornecer insights sobre fatores que podem afetar a intenção de uso de

inteligência artificial na docência. Os resultados deste estudo podem direcionar as IES de ensino superior sobre quais fatores devem ser trabalhados para garantir que os professores tenham maior propensão de uso da inteligência artificial em suas práticas docentes. Para futuras pesquisas, sugere-se que seja utilizado o modelo TAM original (Davis, 1989) ou outros modelos desenvolvidos com a intenção de estudo de intenção e uso de tecnologias.

6 REFERÊNCIAS

AJZEN, I. Attitudes and persuasion. In K. Deaux, & M. Snyder (Eds.), **The Oxford handbook of personality and social psychology** (pp. 367e393). Oxford University Press. (2012).

ALGANI, Y. M. A.; GROSS, Z. Avaliação por docentes sobre o papel dos avanços tecnológicos no ensino. *Texto Livre*, Belo Horizonte-MG, v. 16, p. e46036, 2023.

BANDURA, Albert. The self system in reciprocal determinism. **American psychologist**, v. 33, n. 4, p. 344, 1978.

BOND, Melissa et al. Mapping research in student engagement and educational technology in higher education: A systematic evidence map. **International journal of educational technology in higher education**, v. 17, n. 1, p. 1-30, 2020.

BUENTELLO-MONTOYA, David-Antonio; LOMELÍ-PLASCENCIA, M. G.; MEDINA-HERRERA, L. M. The role of reality enhancing technologies in teaching and learning of mathematics. **Computers & Electrical Engineering**, v. 94, p. 107287, 2021.

CALDWELL, Helen. Mobile technologies as a catalyst for pedagogic innovation within teacher education. **International Journal of Mobile and Blended Learning (IJMBL)**, v. 10, n. 2, p. 50-65, 2018.

CHEAH, Jun-Hwa et al. A comparison of five reflective–formative estimation approaches: reconsideration and recommendations for tourism research. **Quality & Quantity**, v. 53, p. 1421-1458, 2019.

CROMPTON, Helen; BERNACKI, Matthew; GREENE, Jeffrey A. Psychological foundations of emerging technologies for teaching and learning in higher education. **Current Opinion in Psychology**, v. 36, p. 101-105, 2020.

DAVIS, fred d. Perceived usefulness, perceived ease of use, and user acceptance of information technology. **Mis quarterly**, p. 319-340, 1989.

ESCAMILLA-FAJARDO, Paloma; ALGUACIL, Mario; LÓPEZ-CARRIL, Samuel. Incorporating TikTok in higher education: Pedagogical perspectives from a corporal expression sport sciences course. **Journal of Hospitality, Leisure, Sport & Tourism Education**, v. 28, p. 100302, 2021.

FLEUREN, Bram PI et al. Handling the reflective-formative measurement conundrum: a practical illustration based on sustainable employability. **Journal of clinical epidemiology**, v. 103, p. 71-81, 2018.

GHASEMY, Majid et al. This fast car can move faster: A review of PLS-SEM application in higher education research. **Higher education**, v. 80, n. 6, p. 1121-1152, 2020.

GRATZ, Erin; LOONEY, Lisa. Faculty resistance to change: An examination of motivators and barriers to teaching online in higher education. **International Journal of Online Pedagogy and Course Design (IJOPCD)**, v. 10, n. 1, p. 1-14, 2020.

HAIR JR, Joe F. et al. PLS-SEM or CB-SEM: updated guidelines on which method to use. **International Journal of Multivariate Data Analysis**, v. 1, n. 2, p. 107-123, 2017.

HAIR JR, Joseph F. et al. **Partial least squares structural equation modeling (PLS-SEM) using R: A workbook**. Springer Nature, 2021.

HAIR, Joseph F. et al. When to use and how to report the results of PLS-SEM. **European business review**, v. 31, n. 1, p. 2-24, 2019.

HAIR, Joseph; ALAMER, Abdullah. Partial Least Squares Structural Equation Modeling (PLS-SEM) in second language and education research: Guidelines using an applied example. **Research Methods in Applied Linguistics**, v. 1, n. 3, p. 100027, 2022.

HANAFIAH, Mohd Hafiz. Formative vs. reflective measurement model: Guidelines for structural equation modeling research. **International Journal of Analysis and Applications**, v. 18, n. 5, p. 876-889, 2020.

HU, L. Generative AI and Future. Retrieved on January 23 from <https://pub.towardsai.net/generative-ai-and-future-c3b1695876f2>. (2023)

KASNECI, Enkelejda et al. ChatGPT for good? On opportunities and challenges of large language models for education. **Learning and individual differences**, v. 103, p. 102274, 2023.

LO, Chung Kwan. What is the impact of ChatGPT on education? A rapid review of the literature. **Education Sciences**, v. 13, n. 4, p. 410, 2023.

MOURA, Ivanildo Viana et al. Predictor factors of intention to use technological resources: A multigroup study about the approach of Technology Acceptance Model. **Sage Open**, v. 10, n. 4, p. 2158244020967942, 2020.

OLIVEIRA, Alandeom et al. Emerging technologies as pedagogical tools for teaching and learning science: A literature review. **Human Behavior and Emerging Technologies**, v. 1, n. 2, p. 149-160, 2019.

OREG, Shaul; VAKOLA, Maria; ARMENAKIS, Achilles. Change recipients' reactions to organizational change: A 60-year review of quantitative studies. **The Journal of applied behavioral science**, v. 47, n. 4, p. 461-524, 2011.

PÚBLIO, Claudemir Júnior. O docente e o uso das tecnologias no processo de ensinar e aprender. **Revista Ibero-Americana de Estudos em Educação**, p. 1092-1105, 2018.

QURESHI, Muhammad Imran et al. Digital technologies in education 4.0. Does it enhance the effectiveness of learning?. 2021.

SÁNCHEZ-PRIETO, José Carlos; OLMOS-MIGUELÁÑEZ, Susana; GARCÍA-PEÑALVO, Francisco J. Informal tools in formal contexts: Development of a model to assess the acceptance of mobile technologies among teachers. *Computers in Human Behavior*, v. 55, p. 519-528, 2016.

SANTOS, Edicreia Andrade et al. Ferramentas informais em contextos formais: aplicação de um modelo para avaliar a aceitação de tecnologias móveis entre Professores Universitários. **Revista Gestão & Tecnologia**, v. 19, n. 4, p. 117-137, 2019.

SANTOS, Edicreia Andrade et al. Ferramentas informais em contextos formais: aplicação de um modelo para avaliar a aceitação de tecnologias móveis entre Professores Universitários. **Revista Gestão & Tecnologia**, v. 19, n. 4, p. 117-137, 2019.

TAWAFK, Ragad M. et al. Assessing the impact of technology learning and assessment method on academic performance. **EURASIA Journal of Mathematics, Science and Technology Education**, v. 14, n. 6, p. 2241-2254, 2018.

WONG, Ken Kwong-Kay. **Mastering partial least squares structural equation modeling (PLS-Sem) with Smartpls in 38 Hours**. IUniverse, 2019.

YADA, Akie et al. Meta-analysis of the relationship between teachers' self-efficacy and attitudes toward inclusive education. **Teaching and Teacher Education**, v. 109, p. 103521, 2022.

YILMAZ, Derya; KILIÇOĞLU, Gökhan. Resistance to change and ways of reducing resistance in educational organizations. **European journal of research on education**, v. 1, n. 1, p. 14-21, 2013.