

Adoção e Utilização de Inteligência Artificial Generativa em Uma Universidade Federal

THAÍSA SILVA HONORATO
UNIVERSIDADE FEDERAL DE VIÇOSA (UFV)

GILBERTO VENÂNCIO LUIZ
UNIVERSIDADE FEDERAL DE VIÇOSA (UFV)

Agradecimento à órgão de fomento:

Agradeço à Universidade Federal de Viçosa (UFV) e ao CNPq pelo financiamento desta pesquisa, por meio do Programa de Bolsa de Iniciação Científica (PIBIC/UFV/CNPq).

ADOÇÃO E UTILIZAÇÃO DE INTELIGÊNCIA ARTIFICIAL GENERATIVA EM UMA UNIVERSIDADE FEDERAL

1 INTRODUÇÃO

A Inteligência Artificial Generativa (IAG) tem avançado rapidamente, despertando atenção significativa nos últimos anos. Trata-se de um conjunto de tecnologias capazes de criar novos conteúdos, como textos, imagens, sons e códigos, por meio de algoritmos de aprendizado profundo (Silva et al., 2021). Do ponto de vista científico, a IA constitui um domínio interdisciplinar que investiga como computadores podem realizar tarefas tipicamente associadas à cognição humana, incluindo aprendizado, criatividade e resolução de problemas.

Entre as diversas aplicações, destaca-se seu potencial de transformação no setor público. A IAG permite automatizar processos, gerar documentos e melhorar fluxos de trabalho, ampliando a eficiência administrativa e a qualidade dos serviços ofertados à população. Além disso, a adoção de IA nos serviços governamentais aumenta a eficácia e a capacidade de resposta estatal, embora requeira atenção aos desafios éticos, de privacidade e de confiança pública (Hamirul et al., 2023).

Segundo Nurjaman (2022), a IAG pode impactar positivamente a gestão pública ao otimizar tarefas burocráticas, melhorar decisões e potencializar o trabalho dos servidores. Contudo, Toletto e Mendonça (2022) alertam que a implementação enfrenta barreiras como a falta de aceitação por parte dos profissionais, seja por receio de substituição, desconhecimento ou dificuldade de adaptação aos novos sistemas. Hamirul et al. (2023) apontam essa resistência como um obstáculo crítico para a adoção eficaz de IA no setor público.

Ruvalcaba-Gomez (2023) identifica que servidores públicos interpretam as capacidades da IA a partir de duas dimensões principais: fatores sistemáticos, relacionados à análise de dados, e fatores axiológicos, vinculados a valores e ética. Miyazaki (2023) complementa, ao afirmar que funcionários associam IA a tarefas e aplicativos conhecidos, mais do que a algoritmos e técnicas subjacentes. Apesar do interesse crescente, Ruvalcaba-Gomez e Cifuentes-Faura (2023) destacam a lacuna de conhecimento sobre suas aplicações no setor público, ressaltando a necessidade de formação contínua.

Nesse contexto, a presente pesquisa busca responder: Quais fatores contribuem para a adoção da Inteligência Artificial Generativa na realização de tarefas diárias de servidores públicos? O estudo fundamenta-se na Teoria da Difusão da Inovação (Rogers, 1983; Moore & Benbasat, 1991), que postula que percepções sobre características como vantagem relativa, compatibilidade, complexidade, experimentação e observabilidade influenciam o processo de adoção tecnológica.

O objetivo deste artigo foi analisar os fatores que contribuem para a adoção e utilização de sistemas de IAG no setor público, considerando as percepções dos servidores. Devido à amplitude de servidores públicos no Brasil, em nível municipal, estadual e federal, o *locus* de pesquisa será uma Universidade Federal do Interior de Minas Gerais. As IES federais são centros de excelência acadêmica e pesquisa, onde há recursos e expertise para investigar questões complexas e inovadoras. Adicionalmente, o contexto das universidades federais muitas vezes reflete o ambiente do setor público, tornando-as um local relevante para estudar a implementação da IA generativa.

A crescente utilização de Inteligência Artificial Generativa (IAG) no setor público, especialmente em universidades federais, evidencia seu potencial para automatizar tarefas administrativas, subsidiar decisões estratégicas e otimizar processos acadêmicos e gerenciais (Coelho; Silva, 2024; Domingo-Alejo, 2024). Diante disso, justifica-se este estudo por sua

relevância em compreender os fatores que influenciam a adoção e utilização da IAG no contexto de uma Universidade Federal do Interior de Minas Gerais, contribuindo para o avanço do conhecimento acadêmico sobre inovação tecnológica no setor público e para a formulação de estratégias que promovam sua implementação de forma eficaz e alinhada às demandas institucionais.

2 REVISÃO DE LITERATURA

2.1 Inteligência Artificial Generativa no Setor Público

A Inteligência Artificial Generativa (IAG) é um campo em rápido crescimento dentro da inteligência artificial (IA), caracterizado pela capacidade de criar novos conteúdos em diversos formatos, como texto, imagens, música e vídeos. Essa tecnologia utiliza algoritmos avançados, incluindo Autoencoders Variacionais (VAEs) e Redes Generativas Adversariais (GANs), que têm possibilitado a criação de mídias realistas e inovadoras (Rios-Campos et al., 2023).

De acordo com Lv (2023), a IAG difere dos métodos tradicionais de IA por gerar dados originais com base nos padrões aprendidos em grandes conjuntos de dados, redefinindo os limites da criatividade computacional. Kar et al. (2023) e (Liu et al, 2023) complementam ao conceituá-la como um subcampo da IA dedicado à criação de resultados criativos por meio de técnicas de aprendizado profundo, com potencial para produção autônoma de conteúdos, o que suscita discussões sobre autoria e responsabilidade.

Essa tecnologia tem promovido avanços expressivos em diversas áreas, incluindo educação, saúde e administração pública. No setor público, a IAG pode automatizar tarefas repetitivas, aprimorar processos decisórios e gerar soluções inovadoras para desafios complexos (Hamirul et al., 2023). Conforme Lu et al. (2022), seu uso contribui para a resolução de problemas administrativos de forma inteligente, enquanto Kouziokas (2017) destaca sua aplicação no gerenciamento de transportes e segurança pública por meio de redes neurais para identificação de áreas de risco.

No ambiente educacional, Zhenxing Ge et al. (2020) apontam que a IA possibilita melhorias na gestão acadêmica, construção do corpo docente e administração do ensino, otimizando processos e elevando a qualidade institucional. Popescu et al. (2023) observam que universidades internacionais têm utilizado IA para aprimorar comunicações internas e reduzir tarefas administrativas, permitindo que professores dediquem mais tempo ao ensino e orientação. Ahmad et al. (2022) ressaltam sua utilidade em Learning Analytics, realidade virtual, admissões e avaliações. Complementarmente, Alnaggar e Abdulkader (2023) associam essas aplicações à melhoria da inovação organizacional e qualidade de vida dos servidores, enquanto Tarisayi (2023) destaca a adoção de chatbots para otimização de serviços.

Apesar de seus benefícios, a implementação da IAG suscita preocupações éticas e legais, como integridade da pesquisa, autoria e direitos autorais (Park, 2023; Kar et al., 2023). Bartlett e Bartlett (2024) enfatiza que, embora a IA amplie as capacidades humanas, seu uso deve ser equilibrado com habilidades e competências individuais para mitigar suas limitações. Aguilera e Barrera (2016) acrescentam que essas tecnologias impactam diretamente o ambiente de trabalho e social, exigindo adaptação e reflexão sobre suas implicações. Além disso, Souza et al. (2019) destacam que a escolha estratégica das técnicas de IA mais adequadas às necessidades dos serviços públicos é essencial para garantir previsões, alertas, análises e aprendizados que agreguem valor às funções governamentais e aprimorem sua capacidade de resposta às demandas sociais.

1.1. Teoria da Difusão da Inovação

A Teoria da Difusão da Inovação, desenvolvida por Rogers (1983), descreve como novas ideias, produtos ou práticas se espalham por uma população ou mercado ao longo do tempo, sendo amplamente aplicada em áreas como marketing, economia, ciência da computação e formulação de políticas públicas (Moore; Benbasat, 1991). Essa teoria considera que a adoção de inovações não ocorre de forma homogênea, mas envolve diferentes perfis de adotantes e múltiplos fatores individuais, sociais e contextuais.

Dearing (2008) destaca a centralidade do adotante como tomador de decisão, enfatizando o papel dos fatores pessoais e dos canais de comunicação persuasivos no processo de adoção. Complementarmente, Vargo et al. (2020) descrevem a difusão da inovação como um fenômeno unidirecional, do desenvolvimento tecnológico ao mercado, influenciado por contextos sociais e econômicos. Garcia-Aviles (2020) reforça essa visão ao salientar a importância de identificar práticas eficazes de disseminação de inovações, aprendendo com experiências bem-sucedidas para maximizar impactos sociais.

Scheuer et al. (2021) acrescentam que a teoria classifica os adotantes conforme seu grau de conhecimento, interesse, avaliação, teste e adoção, permitindo estratégias direcionadas de promoção conforme cada perfil. Zacharias et al. (2021) definem inovação como qualquer ideia, prática ou objeto percebido como novo, sendo a percepção dos indivíduos sobre suas características determinante para sua aceitação.

Rogers (1983) delimitou cinco características fundamentais das inovações que foram consistentemente identificados como influenciadores da adoção, conforme evidenciado por uma gama de estudos de difusão por ele revisados. Esses atributos foram conceituados da seguinte maneira: (a) Vantagem Relativa: O nível percebido em que uma inovação é considerada superior à sua antecessora em termos de eficácia, eficiência ou benefício geral; (b) Compatibilidade: O grau em que uma inovação é percebida como harmoniosa com os valores, necessidades e experiências prévias dos potenciais adotantes, facilitando sua incorporação nas práticas existentes, (c) Complexidade: O grau percebido de dificuldade associado à compreensão e implementação de uma inovação, influenciando a disposição dos adotantes em aceitá-la; (d) Observabilidade: O grau em que os resultados tangíveis de uma inovação são facilmente discerníveis e observáveis por outros, o que pode influenciar a imitação e a adoção e (e) Experimentabilidade: O grau em que os indivíduos têm a oportunidade de experimentar ou testar uma inovação antes de tomar uma decisão final de adoção, permitindo uma avaliação preliminar de seus benefícios e adequação. Esses atributos oferecem uma estrutura conceitual para entender os processos pelos quais as inovações são adotadas e difundidas em uma população.

Com base em uma revisão sistemática de vários estudos, Kapoor et al. (2011) destacam a importância da percepção dos usuários em relação a uma nova tecnologia. A compatibilidade da inovação com as normas profissionais ou organizacionais, estilos de trabalho e valores pode afetar sua assimilação. Além disso, a observabilidade dos benefícios que a inovação oferece aos usuários pode acelerar sua adoção. Outros fatores como a relativa vantagem da inovação, sua complexidade, experimentabilidade e comunicabilidade também desempenham papéis importantes na aceitação e adoção de novas tecnologias.

Tomando por base as proposições de Rogers (1983), Moore e Benbasat (1991) conceberam uma ferramenta abrangente destinada a avaliar as múltiplas percepções que os indivíduos podem ter em relação às características de utilização de uma inovação. Além dos cinco atributos das inovações, Moore e Benbasat (1991) apresentaram mais três atributos inovadores: imagem, voluntariedade de uso e demonstração de resultados.

A Imagem refere-se à percepção que os usuários têm da inovação em termos de sua reputação, status e prestígio associados ao uso dessa inovação. Uma imagem positiva pode influenciar positivamente a adoção da inovação. O Uso Voluntário diz respeito à liberdade e

autonomia dos usuários em escolher usar a inovação de forma voluntária, sem pressões externas. A percepção de que o uso é uma escolha pessoal pode impactar a aceitação da inovação. A Demonstração de Resultado refere-se à capacidade da inovação em demonstrar resultados tangíveis e mensuráveis para os usuários, mostrando claramente os benefícios e impactos positivos que ela pode trazer. Uma demonstração eficaz dos resultados pode aumentar a probabilidade de adoção da inovação (Moore; Benbasat, 1991).

Ademais, Moore e Benbasat (1991) ajustaram os atributos originais de complexidade e observabilidade ao seu cenário de pesquisa, renomeando-os como facilidade de uso e visibilidade, respectivamente. Facilidade de Uso, é um atributo que se refere à percepção que os usuários têm sobre o quão fácil é utilizar um determinado sistema, produto ou serviço. A Visibilidade diz respeito à facilidade com que os indivíduos podem ver, observar ou ter conhecimento sobre a inovação. Dessa forma, tomando por base o modelo de Moore e Benbasat (1991) são apresentadas as características que servirão de base para este estudo.

Quadro 1: Fatores influenciadores da adoção de inovação

| | |
|------------------------------------|---|
| Vantagem Relativa | O nível em que uma inovação é percebida como sendo melhor do que seu antecessor. |
| Compatibilidade | O nível em que uma inovação é percebida como consistente com os valores existentes, necessidades e experiências passadas dos adotantes potenciais. |
| Testabilidade/Experimentação | O nível em que uma inovação pode ser experimentada antes de ser adotada. |
| Complexibilidade/Facilidade de uso | O grau em que uma inovação é percebida como sendo difícil de usar. |
| Visibilidade | O nível em que os resultados de uma inovação são observáveis por outros. |
| Imagem | O nível de percepção que os usuários têm da inovação em termos de sua reputação, status e prestígio associados ao seu uso. |
| Uso Voluntário | O nível de Liberdade e autonomia dos usuários em escolher usar a inovação de forma voluntária, sem pressões externas. |
| Demonstração de Resultado | O nível da capacidade da inovação em demonstrar resultados tangíveis e mensuráveis para os usuários, mostrando claramente os benefícios e impactos positivos que ela pode trazer. |

Fonte: Moore e Benbasat (1991)

Com base nesse modelo de características que influenciam a adoção e o uso de uma inovação tecnológica e conforme descrito por Zacharias et al (2021) que pela Teoria da Difusão da Inovação (TDI), a adoção e o uso de uma inovação dependem diretamente da forma como ela é percebida por seus adotantes; e além disso, conforme relatam Perez e Zwicker (2010), que as percepções dos usuários sobre as características de uma inovação influenciam a adoção dessa inovação, na intenção de aumentar o uso e que essa adoção pode ter impactos significativos nos serviços oferecidos, nos processos organizacionais, no ensino e na aprendizagem, bem como nas inovações administrativas

1.2. Fatores que influenciam o uso de IAG

Os fatores que influenciam o uso da Inteligência Artificial Generativa (IAG) podem ser analisados em múltiplas dimensões, destacando-se inicialmente a compatibilidade, definida como o grau em que a tecnologia se ajusta aos valores, experiências e necessidades dos usuários ou organizações. Quando percebida como compatível com objetivos educacionais – como o aprimoramento do ensino, da aprendizagem e da literacia em IA – sua adoção é facilitada (Jin

et al., 2024). No setor empresarial, a compatibilidade com sistemas legados reduz resistências, demonstrando efeito estatisticamente significativo na adoção da IA (Paiva et al., 2024).

Outro fator determinante é a vantagem relativa, referente à percepção de superioridade da tecnologia frente às alternativas existentes. Essa percepção impulsiona a aceitação da IAG, seja pela melhoria da eficiência, da tomada de decisões ou pela promoção de inovação organizacional (Alamri, 2025; Maestro & Rana, 2024). Em contextos corporativos, a vantagem relativa apresentou o maior impacto entre os fatores analisados, sugerindo que os benefícios percebidos superam os custos associados à mudança tecnológica (Paiva et al., 2024).

Por sua vez, a complexidade, entendida como a dificuldade percebida de uso, não demonstrou impacto significativo na adoção da IAG em estudos recentes (Alamri, 2025; Paiva et al., 2024). Esse resultado indica que a tecnologia é vista como acessível e de fácil implementação, possivelmente reflexo da evolução das interfaces. Ainda assim, permanece como dimensão teórica relevante, especialmente para análises futuras sobre limitações de modelos tradicionais como o TAM (Maestro & Rana, 2024).

A experimentabilidade, que envolve a possibilidade de testar a tecnologia antes de sua adoção, contribui para reduzir incertezas e desenvolver confiança (Alamri, 2025). No contexto educacional, o uso experimental da IAG tem sido incentivado para promover reflexão crítica e perspectivas humanocêntricas (Jin et al., 2024). Já a observabilidade, ou a visibilidade dos benefícios gerados, favorece a difusão da tecnologia por meio da influência social e evidências práticas de sucesso (Alamri, 2025). Universidades que monitoram sistematicamente os impactos da IAG destacam-se pelo fortalecimento de sua legitimidade e colaboração interna (Jin et al., 2024).

Os benefícios da IAG vão desde a automação de tarefas e melhorias na tomada de decisão até ganhos de competitividade (Maestro & Rana, 2024). Na esfera corporativa, contribui para maior eficiência operacional e agilidade frente às mudanças (Paiva et al., 2024). No setor educacional, promove o desenvolvimento de habilidades digitais e literacia em IA (Jin et al., 2024). Entre os fatores organizacionais, o apoio da gestão e a prontidão organizacional são essenciais. O suporte da liderança facilita alocação de recursos e engajamento dos colaboradores (Paiva et al., 2024), enquanto a prontidão – disponibilidade de recursos financeiros, tecnológicos e humanos – tem demonstrado impacto significativo (Paiva et al., 2024). Adicionalmente, uma cultura voltada à inovação, clareza de papéis e gestão eficaz de mudanças minimizam resistências e fortalecem a integração da IA (Jin et al., 2024; Maestro & Rana, 2024).

Dessa forma, os fatores humanos, como autoeficácia e prontidão da força de trabalho, influenciam diretamente a disposição individual para uso da tecnologia. A autoeficácia mostrou impacto positivo na adoção por estudantes, sendo até mais relevante do que o conhecimento técnico prévio (Alamri, 2025). No ambiente organizacional, programas de qualificação contínua e aprendizagem prática fortalecem a prontidão para os desafios da IA (Maestro & Rana, 2024).

A análise integrada dessas dimensões tecnológicas, organizacionais e humanas é fundamental para compreender os processos de adoção da IAG no setor público, orientando estratégias para maximizar seus benefícios e garantir sua implementação ética e eficaz.

2. PROCEDIMENTOS METODOLÓGICOS

Este estudo caracteriza-se por uma abordagem quantitativa e, quanto ao objetivo, é classificado como descritivo (Gil, 2002). Será conduzido por meio de uma abordagem sistemática para coletar e analisar dados, visando descrever características de um fenômeno específico, além de quantificar e verificar relações entre variáveis e testar hipóteses de pesquisa.

2.1. População e Amostra

A população alvo deste estudo é composta por técnicos-administrativos e professores de uma Universidade Federal no interior de Minas Gerais, que tem hoje um total de 3742 servidores (Brasil, 2024). A amostra foi do tipo não-probabilística, devido ao fato de não ter como identificar quantos funcionários da IES faziam uso de IAG. O número total de participantes foi de 187, que responderam ao questionário durante o período em que ficou disponível para acesso, entre o mês de novembro de 2024 e o mês de março de 2025.

2.2. Coleta de Dados

Os dados foram coletados por meio de um questionário online, que foi enviado por meio do sistema de mensagens da instituição pesquisada. Durante o período de coleta de dados foram realizados quatro envios do instrumento. O questionário foi composto por questões sobre: perfil Sociodemográfico: Esta seção incluirá questões relacionadas ao perfil dos participantes, como idade, gênero e nível de escolaridade; perfil de uso de IAG: Setor que trabalho, cargo exercido, tempo de trabalho na Instituição, se usa IAG em suas tarefas, Tipo de IAG mais utilizada e quais melhorias foram verificadas em caso de uso da IAG; nível de uso e resultado do uso (Quadro 2) e fatores que influenciam a adoção de sistemas de IAG (Quadro 3) baseados na adaptação do questionário desenvolvido por Moore e Benbasat (1991), que investiga características influenciadoras na adoção de inovações.

Quadro 2: Variáveis nível uso e resultado do uso

| Nível de Uso - NUSO | |
|--------------------------------|---|
| X1 | Considero-me usuário intensivo de IAG. |
| X2 | Assim que possível pretendo usar mais intensamente a IA. |
| Resultado do uso - RUSO | |
| X30 | O uso da IAG possibilita a criação de novos serviços ou processos. |
| X31 | O uso da IAG permite melhorar a forma de realizar serviços ou processos atuais. |
| X32 | O uso da IAG permite a criação de serviços ou processos diferenciados. |
| X33 | O uso da IAG possibilita inovar a forma de executar minhas funções administrativas. |
| X34 | O uso da IAG permite ter acesso a novos conhecimentos. |
| X35 | O uso da IAG propicia novas alternativas para o método de ensino. |

Fonte: Adaptado de Perez e Zwicker (2010) e Zacharias et al, (2021)

Quadro 2: Fatores de Adoção de Inovação de sistemas de IAG

| Compatibilidade - COMP | |
|---|--|
| X3 | Entendo que a IAG ajusta-se bem a forma que gosto de trabalhar. |
| X4 | O uso da IAG ajusta-se ao meu estilo de trabalho. |
| X5 | O uso da IAG é compatível com todos os aspectos do meu trabalho. |
| Demonstração de resultado - DRES | |
| X6 | Acredito que posso comunicar aos outros as consequências do uso da IAG. |
| X7 | Os resultados do uso da IAG são aparentes pra mim. |
| X8 | Não tenho dificuldade para explicar porque o uso da IAG pode ou não ser benefício. |
| X9 | Não tive dificuldades para dizer aos outros sobre os benefícios da IAG. |
| Testabilidade - TEST | |
| X10 | Tive várias oportunidades de experimentar aplicações para a IAG. |
| X11 | Antes de decidir a usar a IAG, pude experimentá-lo corretamente |
| X12 | Foi-me permitido usar a IAG a título de teste, com tempo suficiente para entender o que poderia fazer. |
| Facilidade de Uso - FUSO | |

| | |
|---------------------------------|---|
| X13 | Acredito que é fácil utilizar a IAG para fazer o que preciso fazer. |
| X14 | Minha interação com a da IAG é clara e de fácil compreensão. |
| X15 | No geral, acredito que a IAG é fácil de ser utilizada. |
| X16 | Aprender a usar a IAG é fácil para mim. |
| Imagem - IMAG | |
| X17 | As pessoas da minha instituição que usam a IAG têm um perfil diferenciado. |
| X18 | As pessoas da minha instituição que usam a IAG têm maior prestígio do que aquelas que não usam. |
| X19 | Usar a IAG é um símbolo de status em minha instituição. |
| Vantagem Relativa - VREL | |
| X20 | Usando a IAG, posso realizar minhas tarefas mais rapidamente. |
| X21 | O uso da IAG torna mais fácil a realização do meu trabalho. |
| X22 | O uso da IAG me possibilita um maior controle do meu trabalho. |
| X23 | O uso da IAG eletrônico melhora a qualidade do meu trabalho. |
| X24 | O uso da IAG melhora minha efetividade no trabalho. |
| Visibilidade - VISI | |
| X25 | O uso da IAG não é percebido em minha instituição. |
| X26 | É fácil observar outras pessoas utilizando a IAG em minha instituição. |
| X27 | Na minha instituição, pode-se encontrar a IAG em vários computadores. |
| Uso Voluntário - UVOL | |
| X28 | Meus superiores não me obrigam a utilizar a IAG. |
| X29 | Embora seja útil, usar a IAG não é obrigatório em meu trabalho. |

Fonte: Adaptado de Moore e Benbasat (1991)

Para mensuração das questões relacionadas ao modelo de Moore e Benbasat (1991), ao uso atual de IAG e impactos nos serviços e processos organizacionais será utilizado o modelo de sete pontos, onde para cada item o respondente avaliará o quanto discorda ou concorda com as afirmações propostas, sendo a variação entre 1 – Discordo Totalmente e 7 – Concordo Totalmente. A escolha desse modelo se deve as proposições de Costa (2011) que indica a escala de 7 pontos por ser mais consistentes que outras. Para definição dos fatores usados na análise foi feito a média das variáveis relacionadas a cada fator.

2.3. Análise dos Dados

Os dados foram analisados utilizando análise de contingência (qui-quadrado), Análise Fatorial Confirmatória para verificar a consistência dos fatores de inovação e regressão linear simples e múltipla usando o modelo Stepwise, para verificar o efeito dos fatores de inovação sobre o nível de uso e no resultado do uso. Na regressão foram estimados modelos nulos como referência, seguidos pela inclusão progressiva dos preditores para verificar incrementos no R² e avaliar a significância estatística dos modelos, utilizando valores de $p < 0.05$ como critério de significância. Foram também analisados os coeficientes padronizados (β) para interpretação da magnitude dos efeitos, bem como o fator de inflação de variância (VIF) para avaliação de multicolinearidade. Todas as análises foram realizadas no software JASP 0.19.3.

3.4 Questões Éticas

Esta pesquisa foi aprovada pelo Comitê de Ética em Pesquisa com Seres Humanos (CEP) da UFV, com CAAE nº 83343924.6.0000.5153. Os participantes receberam um Termo de Consentimento Livre e Esclarecido (TCLE) antes de responder ao questionário, garantindo transparência e sigilo dos dados. Durante a preparação deste trabalho, os autores utilizaram o ChatGPT 4o para melhorar o texto, corrigindo erros ortográficos e gramaticais. Após o uso

desta ferramenta os autores revisaram e editaram o conteúdo em conformidade com o método científico e assumem total responsabilidade pelo conteúdo da publicação.

3. RESULTADOS E DISCUSSÕES

4.1 Caracterização da Amostra

O estudo contou com a participação de 187 servidores públicos, dos quais 58,8% se identificaram com o gênero masculino e 41,2% com o gênero feminino. A idade média dos respondentes foi de 45,4 anos (DP = 8,45), com variação entre 25 e 67 anos. No que diz respeito ao tempo de serviço na instituição, a média foi de 13,5 anos (DP = 7,9), com um tempo mínimo de 3 meses e máximo de 46 anos.

Com relação à escolaridade, observou-se um alto nível de qualificação entre os participantes: 54% possuíam doutorado, 10,7% mestrado e 27,8% pós-graduação lato sensu. Apenas 7,5% apresentavam até o nível superior completo ou incompleto. Isso reflete o perfil técnico-científico exigido para o exercício das funções no setor público federal, especialmente no ambiente universitário.

Quanto à distribuição por campus, a maioria dos respondentes era do campus de Viçosa, sendo 111 pessoas (59,35%), seguido pelo campus Rio Paranaíba com 43 participantes (23%) e Florestal com 33 (17,64%). Em relação à função exercida, destaca-se a predominância de docentes do ensino superior (50,8%), seguida por técnicos administrativos em diversas especialidades, como informática, laboratório, contabilidade e educação.

4.2 Perfil de Uso de IAG

Os dados apontam uma percepção moderada de competência para o uso de Inteligência Artificial Generativa (IAG). A maior parte dos participantes se classificou como "moderadamente competente" (27,3%) ou "pouco competente" (34,8%). Apenas 3,2% se consideraram "muito competentes", enquanto 16,6% relataram não ter nenhuma competência. Esses dados evidenciam um cenário ainda incipiente de domínio técnico sobre o uso da IAG no setor público, mesmo entre profissionais altamente qualificados.

Quanto às finalidades atribuídas à IAG, os usos mais frequentes foram: automação de tarefas repetitivas (28,87%), suporte na tomada de decisões (13,9%) e geração de relatórios e análises (19,25%). Outros usos citados incluíram comunicação com usuários/estudantes, revisão textual, geração de ideias e elaboração de conteúdos avaliativos. Apenas um participante afirmou utilizar todas as opções disponíveis, enquanto dois responderam que não utilizam a tecnologia.

Para verificar se há associação entre gênero e competência percebida no uso da IAG, foi realizada uma análise de contingência. Os resultados não indicaram associação estatisticamente significativa entre as variáveis. Homens e mulheres apresentaram distribuições semelhantes nos níveis de competência, com ligeira predominância masculina entre os que se declararam "competentes" ou "muito competentes", mas sem evidência suficiente para afirmar que o gênero influencia a autopercepção de competência.

A análise de contingência entre escolaridade e competência percebida revelou uma tendência interessante: indivíduos com maior grau de escolaridade (especialmente doutorado) tenderam a relatar níveis mais baixos de competência no uso de IAG, enquanto aqueles com pós-graduação lato sensu ou apenas graduação relataram níveis ligeiramente mais altos de autopercepção de competência. Embora o resultado sugira uma possível dissociação entre titulação acadêmica e domínio prático da tecnologia, a associação também não foi

estatisticamente significativa, indicando que o grau formal de escolaridade não determina diretamente a familiaridade ou segurança no uso de tecnologias emergentes como a IAG.

4.3 Análise Fatorial Confirmatória e Confiabilidade

A estrutura fatorial do instrumento foi avaliada por meio de análise fatorial confirmatória. As cargas fatoriais revelaram-se estatisticamente significativas ($p < .001$) para todos os indicadores, com exceção do item X25 do fator Visibilidade (VISI), cuja estimação ($\lambda = 0.005$; $p = .972$) indicou ausência de validade convergente; por esse motivo o indicador foi excluído das análises. O fator Uso Voluntário (UVOL) apresentou cargas significativas, mas coeficientes de confiabilidade moderada ($\omega = 0.691$; $\alpha = 0.624$). Todavia, optou-se por manter UVOL no modelo em razão de sua pertinência teórica para a Teoria da Difusão da Inovação e pela evidência empírica de seu papel complementar na explicação do comportamento de adoção.

Quanto à consistência interna, os fatores exibiram níveis satisfatórios ou excelentes: Vantagem Relativa (VREL) alcançou os maiores índices ($\omega = 0.913$; $\alpha = 0.912$), seguido de Compatibilidade (COMP) e Facilidade de Uso (FUSO), ambos com valores superiores a 0.85, assegurando robustez psicométrica. Disposição para Experimentação (TEST) e Demonstração de Resultados (DRES) também apresentaram confiabilidade adequada ($\omega \geq 0.80$). A Imagem (IMAG) registrou valores moderados ($\omega = 0.751$; $\alpha = 0.712$), aceitáveis em instrumentos com número reduzido de itens. Já o coeficiente global do questionário foi elevado ($\omega = 0.917$; $\alpha = 0.930$), atestando a consistência interna do instrumento como um todo e sustentando sua adequação para mensuração dos fatores que influenciam a adoção e o uso de Inteligência Artificial Generativa.

4.4 Influência dos fatores de adoção de tecnologia na Percepção do Resultado do Uso

Foi realizada uma análise de regressão linear múltipla pelo método Stepwise (Tabela 1) para verificar o efeito dos fatores de adoção de inovação sobre a os benefícios do resultado do uso (RUSO) de IAG no trabalho. Inicialmente, estimou-se o modelo nulo (M_0), que inclui apenas o intercepto, apresentando R^2 igual a zero, indicando que nenhuma variância do desfecho é explicada por esse modelo de referência. O erro médio quadrático (RMSE) do modelo nulo foi de 1.378. Em seguida, foi testado o modelo 1 (M_1), que incluiu o fator vantagem relativa (VREL) como preditor, resultando em R^2 de 0.443 e R^2 ajustado de 0.440. Isso demonstra que aproximadamente 44% da variância da variável dependente foi explicada por VREL. Além disso, observou-se uma redução no RMSE para 1.031, indicando melhora no ajuste do modelo em relação ao modelo nulo.

No modelo 2 (M_2), foi adicionada o fator uso voluntário (UVOL) ao modelo anterior, o que resultou em aumento no R^2 para 0.475 e R^2 ajustado de 0.470, com redução do RMSE para 1.004. O incremento de R^2 foi de 0.032, estatisticamente significativo ($p = 0.001$), indicando que UVOL contribuiu para a explicação adicional da variância do modelo. No modelo 3 (M_3), foi adicionada o fator compatibilidade (COMP), resultando em um R^2 de 0.494 e R^2 ajustado de 0.486, com RMSE de 0.988. O aumento de R^2 em relação ao modelo anterior foi de 0.019, também estatisticamente significativo ($p = 0.010$), indicando que o fator compatibilidade (COMP) contribuiu adicionalmente, ainda que de forma menor em magnitude.

Tabela 1: Indicadores dos Modelos de Regressão - Fatores de adoção de tecnologia e Resultado do Uso

| Modelo | R | R ² | R ² ajustado | RMSE | AIC | BIC | ΔR^2 | df ₁ | df ₂ | p |
|--------|-------|----------------|-------------------------|-------|--------|--------|--------------|-----------------|-----------------|---|
| M_0 | 0.000 | 0.000 | 0.000 | 1.378 | 653.61 | 660.07 | – | 0 | 186 | – |

| Modelo | R | R ² | R ² ajustado | RMSE | AIC | BIC | ΔR^2 | df ₁ | df ₂ | p |
|----------------|-------|----------------|-------------------------|-------|--------|--------|--------------|-----------------|-----------------|-------|
| M ₁ | 0.666 | 0.443 | 0.440 | 1.031 | 546.02 | 555.71 | 0.443 | 1 | 185 | 0.001 |
| M ₂ | 0.689 | 0.475 | 0.470 | 1.004 | 537.03 | 549.95 | 0.032 | 1 | 184 | 0.001 |
| M ₃ | 0.703 | 0.494 | 0.486 | 0.988 | 532.19 | 548.34 | 0.019 | 1 | 183 | 0.010 |

Fonte: Dados da Pesquisa

Os resultados da análise de variância (ANOVA) confirmaram a significância global dos modelos testados, com valores de F elevados e $p < 0.001$ em todos os modelos, demonstrando que as variáveis preditoras explicam variância do desfecho de maneira significativa em relação ao modelo nulo.

Tabela 2: Coeficiente de Regressão dos Modelos – Resultado do Uso

| Modelo | Variável | B | SE | β | t | p | Tolerance | VIF |
|----------------|------------|-------|-------|---------|--------|--------|-----------|-------|
| M ₀ | Intercepto | 5.089 | 0.101 | – | 50.498 | < .001 | – | – |
| M ₁ | Intercepto | 2.722 | 0.209 | – | 13.027 | < .001 | – | – |
| | VREL | 0.568 | 0.047 | 0.666 | 12.141 | < .001 | 1.000 | 1.000 |
| M ₂ | Intercepto | 1.329 | 0.464 | – | 2.861 | .005 | – | – |
| | VREL | 0.533 | 0.047 | 0.625 | 11.395 | < .001 | 0.949 | 1.054 |
| | UVOL | 0.239 | 0.072 | 0.183 | 3.338 | .001 | 0.949 | 1.054 |
| M ₃ | Intercepto | 1.186 | 0.461 | – | 2.574 | .011 | – | – |
| | VREL | 0.404 | 0.068 | 0.473 | 5.973 | < .001 | 0.441 | 2.270 |
| | UVOL | 0.244 | 0.070 | 0.187 | 3.464 | < .001 | 0.948 | 1.055 |
| | COMP | 0.164 | 0.063 | 0.204 | 2.611 | .010 | 0.454 | 2.203 |

Fonte: Dados da Pesquisa

No que se refere aos coeficientes estimados no modelo final (Tabela 2), o intercepto apresentou valor de 1.186 ($p = 0.011$), indicando o valor estimado do desfecho quando todas as variáveis independentes são zero. O coeficiente de VREL foi de 0.404 ($p < 0.001$), o que significa que, controladas as demais variáveis, cada aumento de uma unidade em VREL está associado a um aumento médio de 0.404 unidades na percepção dos melhoria do resultado do uso de IAG no trabalho. O coeficiente padronizado (β) de VREL foi de 0.473, sendo o maior entre os preditores, indicando maior magnitude de efeito. O fator UVOL apresentou coeficiente de 0.244 ($p < 0.001$), indicando que cada aumento de uma unidade em UVOL está associado a um aumento médio de 0.244 unidades na variável dependente, controladas as demais variáveis, com coeficiente padronizado (β) de 0.187. Já o fator COMP apresentou coeficiente de 0.164 ($p = 0.010$), sugerindo que cada unidade adicional em COMP resulta em aumento médio de 0.164 unidades no desfecho, com β de 0.204.

Os valores dos fatores de inflação de variância (VIF) variaram entre 1.055 e 2.270, não indicando problemas de multicolinearidade. Os resultados indicam que as variáveis VREL, UVOL e COMP contribuem de maneira significativa para a explicação da variável dependente, sendo que VREL apresentou o maior efeito no modelo final.

4.5 Influência dos Fatores de Adoção de Inovação no Nível de Uso de IAG

Outra análise realizada, foi a verificação do efeito dos fatores de adoção de inovação sobre a variável dependente nível de uso (NUSO) de IAG. Inicialmente, foi estimado o modelo nulo (Tabela 3), contendo apenas o intercepto, que apresentou um R² igual a zero, indicando que nenhuma variância da variável dependente foi explicada por esse modelo de referência. O erro médio quadrático (RMSE) do modelo nulo foi de 1.569.

No modelo 1 (M_1), incluiu-se o fator compatibilidade (COMP) como preditor, resultando em um R^2 de 0.608 e R^2 ajustado de 0.606. Esses valores indicam que aproximadamente 60,6% da variância da variável dependente (NUSO) foi explicada por COMP. Além disso, houve redução no RMSE para 0.985, evidenciando melhora no ajuste do modelo em relação ao modelo nulo. O valor de p foi menor que 0.001, confirmando a significância estatística do modelo.

No modelo 2 (M_2), foi adicionado ao modelo anterior o fator testabilidade (TEST), isto é, o nível em que uma inovação pode ser experimentada antes de ser adotada. O R^2 aumentou para 0.637 e o R^2 ajustado para 0.633, com redução adicional do RMSE para 0.950. O incremento de R^2 em relação ao modelo 1 foi de 0.029, sendo estatisticamente significativo ($p < 0.001$), demonstrando que TEST contribuiu para a explicação adicional da variância do modelo.

Tabela 3: Indicadores dos Modelos de Regressão - Fatores de Adoção de Inovação no Nível de Uso de IAG

| Modelo | R | R^2 | R^2 ajustado | RMSE | AIC | BIC | ΔR^2 | df ₁ | df ₂ | p |
|--------|------|-------|----------------|-------|--------|--------|--------------|-----------------|-----------------|--------|
| M_0 | .000 | .000 | .000 | 1.569 | 702.06 | 708.53 | – | 0 | 186 | – |
| M_1 | .780 | .608 | .606 | 0.985 | 529.01 | 538.70 | .608 | 1 | 185 | < .001 |
| M_2 | .798 | .637 | .633 | 0.950 | 516.52 | 529.44 | .029 | 1 | 184 | < .001 |

Fonte: Dados da Pesquisa

A análise de variância (ANOVA) corroborou a significância global dos modelos testados. No modelo 1, o valor de F foi de 286.761 ($p < 0.001$), enquanto no modelo 2, o valor de F foi de 161.511 ($p < 0.001$), indicando que os modelos com as variáveis COMP e TEST explicam significativamente a variância da variável dependente quando comparados ao modelo nulo.

Em relação aos coeficientes estimados (Tabela 4), no modelo final (M_2), o intercepto foi de 0.772 ($p < 0.001$), indicando o valor esperado da variável dependente quando as variáveis independentes são zero. O coeficiente de COMP foi de 0.613 ($p < 0.001$), indicando que, mantendo TEST constante, cada aumento de uma unidade em COMP está associado a um aumento médio de 0.613 unidades na variável dependente. O coeficiente padronizado (β) de COMP foi de 0.668, demonstrando o efeito sobre o modelo gerado. O fator TEST apresentou coeficiente de 0.192 ($p < 0.001$), indicando que cada unidade adicional em TEST está associada a um aumento médio de 0.192 unidades na variável dependente, controlada a variável COMP. O coeficiente padronizado (β) de TEST foi de 0.204, indicando efeito adicional, porém menor em magnitude em relação a COMP.

Tabela 4: Coeficiente de Regressão dos Modelos – Nível de Uso

| Modelo | Variável | B | SE | β | t | P | Tolerance | VIF |
|--------|------------|-------|-------|---------|--------|--------|-----------|-------|
| M_0 | Intercepto | 3.840 | 0.115 | – | 33.472 | < .001 | – | – |
| M_1 | Intercepto | 1.023 | 0.181 | – | 5.641 | < .001 | – | – |
| | COMP | 0.715 | 0.042 | 0.780 | 16.934 | < .001 | 1.000 | 1.000 |
| M_2 | Intercepto | 0.772 | 0.187 | – | 4.136 | < .001 | – | – |
| | COMP | 0.613 | 0.049 | 0.668 | 12.621 | < .001 | 0.703 | 1.423 |
| | TEST | 0.192 | 0.050 | 0.204 | 3.851 | < .001 | 0.703 | 1.423 |

Fonte: Dados da Pesquisa

Os valores dos fatores de inflação de variância (VIF) foram 1.423 para ambas as variáveis no modelo final, não indicando problemas de multicolinearidade. De forma geral, os resultados sugerem que as variáveis COMP e TEST contribuem de maneira significativa para a explicação da variável dependente, sendo COMP a variável com maior efeito no modelo.

4.6 Relação entre a Percepção dos Resultados do Uso e o Nível de Uso

Com o objetivo de verificar o efeito da percepção dos benefícios do resultado do uso (RUSO) sobre o nível de uso (NUSO) de ferramentas de inteligência artificial generativa (IAG), foi realizada uma análise de regressão linear simples. O resultado demonstra a percepção em relação ao resultado do uso (RUSO) como preditora do nível de uso de IAG, resultando em um R^2 de 0.257 e R^2 ajustado de 0.253. Esses resultados indicam que aproximadamente 25,3% da variância em NUSO foi explicada por RUSO.

A análise de variância (ANOVA) confirmou a significância do modelo testado, apresentando $F(1,185)$ igual a 64.104, com $p < 0.001$. Em relação ao modelo de regressão estimado, o intercepto foi de 0.901 ($p = 0.019$), indicando o valor esperado para NUSO quando RUSO é igual a zero. O coeficiente de RUSO foi de 0.577 ($p < 0.001$), o que significa que, para cada aumento de uma unidade em RUSO, há um aumento médio de 0.577 unidades em NUSO. O coeficiente padronizado (β) foi de 0.507, indicando efeito de magnitude moderada. Esses resultados sugerem que maiores percepções dos benefícios do resultado do uso estão positivamente associadas a níveis mais elevados de uso da IAG, demonstrando uma relação estatisticamente significativa entre as variáveis.

4.7 Discussão dos Resultados

Os resultados deste estudo indicam que a vantagem relativa (VREL) foi o principal fator associado à percepção dos benefícios do resultado do uso (RUSO) da IAG, corroborando os achados de Rogers (1983) e Alamri (2025), que destacam que inovações percebidas como superiores às soluções existentes tendem a apresentar maior aceitação e percepção de benefícios. Esse efeito foi observado na presente pesquisa com $\beta = 0.473$, sugerindo que quando os usuários percebem a IAG como mais eficiente ou benéfica em comparação a práticas anteriores, sua avaliação sobre os resultados do uso tende a ser mais positiva.

O fator uso voluntário (UVOL) também apresentou contribuição significativa, embora menor, no aumento da percepção de benefícios ($\beta = 0.187$). Este resultado está alinhado com Moore e Benbasat (1991), que apontam que a liberdade de escolha no uso da tecnologia aumenta a sensação de autonomia e engajamento dos usuários, impactando positivamente suas percepções de resultado. Outro a se destacar, é que a inclusão da compatibilidade (COMP) como fator preditor significativo ($\beta = 0.204$) reforça a importância do alinhamento entre a tecnologia e os valores, práticas e necessidades do usuário, conforme evidenciado por Jin et al. (2024) e Paiva et al. (2024), que identificaram a compatibilidade como fator facilitador crucial para a adoção de IAG em contextos organizacionais e educacionais.

Na análise dos fatores que influenciam diretamente o nível de uso de IAG, compatibilidade (COMP) apareceu novamente como a variável de maior efeito ($\beta = 0.668$), explicando mais de 60% da variância. Esse resultado confirma a literatura de Paiva et al. (2024), que aponta que a percepção de alinhamento tecnológico aos objetivos e práticas organizacionais reduz resistências e amplia a utilização prática da inovação. A adição da variável testabilidade (TEST) ao modelo aumentou significativamente a variância explicada, com efeito adicional moderado ($\beta = 0.204$). Este resultado converge com Alamri (2025), que destaca a experimentabilidade (testabilidade) como fator facilitador da adoção, permitindo aos usuários reduzir incertezas e desenvolver confiança no uso da tecnologia.

A análise da relação entre percepção dos benefícios do resultado do uso (RUSO) e o nível de uso (NUSO) demonstrou que RUSO explica 25,3% da variância de NUSO ($\beta = 0.507$), indicando uma relação positiva moderada. Esse achado reforça a proposição de Zacharias et al. (2021) e Perez e Zwicker (2010), de que a percepção dos benefícios de uma inovação influencia

diretamente sua adoção e uso subsequente. Na prática, isso significa que, quanto mais os usuários percebem benefícios tangíveis no uso da IAG, maior tende a ser seu nível de uso efetivo, confirmando o papel central das percepções de resultado como motivadoras do comportamento de adoção tecnológica.

Em relação ao fator complexidade, o presente estudo não encontrou impacto significativo na adoção da IAG, o que diverge de Rogers (1983), que a identifica como uma barreira à inovação. Essa diferença pode ser atribuída à evolução recente das interfaces de IAG, que se tornaram mais acessíveis e intuitivas, reduzindo a percepção de dificuldade entre os usuários.

De maneira geral, os resultados estão em consonância com os pressupostos da Teoria da Difusão da Inovação (Rogers, 1983), que destaca atributos como vantagem relativa, compatibilidade, experimentabilidade e uso voluntário como determinantes no processo de adoção de tecnologias. Além disso, corroboram estudos recentes que analisaram especificamente a IAG, os quais apontam que benefícios percebidos, apoio organizacional e prontidão individual são fatores-chave para sua integração bem-sucedida (Alamri, 2025; Jin et al., 2024; Paiva et al., 2024).

5 CONCLUSÕES

Os resultados evidenciam que vantagem relativa, compatibilidade, testabilidade e uso voluntário influenciam de maneira significativa tanto a percepção de benefícios quanto o nível de utilização da Inteligência Artificial Generativa (IAG), na universidade estudada. Esses achados confirmam a relevância da vantagem relativa como fator influenciador na adoção de tecnologias, ao mesmo tempo que reforçam a importância do alinhamento entre a IAG e as rotinas profissionais já estabelecidas na instituição.

Os modelos de regressão empregados explicaram uma parcela substantiva da variância das variáveis dependentes, alcançando o objetivo de identificar fatores determinantes da adoção da IAG nas tarefas administrativas do setor público. Entretanto, a utilização de uma amostra não probabilística e restrita a uma única instituição limita a generalização dos resultados, recomendando-se a realização de investigações futuras com amostras multi-institucionais e em diferentes contextos administrativos.

Do ponto de vista prático, os dados sugerem que estratégias de comunicação que destaquem benefícios concretos, iniciativas de integração da IAG às práticas vigentes e oportunidades de experimentação controlada podem favorecer sua incorporação no serviço público. A capacitação continuada dos servidores, o estímulo à experimentação das ferramentas, a divulgação sistemática de resultados obtidos e a implementação de políticas de gestão da mudança emergem como ações recomendadas para reduzir resistências culturais e organizacionais.

Como agenda de pesquisa, sugere-se a realização de estudos qualitativos para aprofundar a compreensão das percepções individuais sobre a IAG; realizar análises longitudinais que monitorem a evolução do uso ao longo do tempo; e realizar estudos comparativos em diferentes órgãos públicos, a fim de verificar a consistência dos fatores identificados em contextos variados.

REFERÊNCIAS BIBLIOGRÁFICAS

AGUILERA, Andrés; BARRERA, María Gabriela R.. Technological unemployment: An approximation to the Latin American case. *AD-minister*, n. 29, p. 58-78, 2016.

AHMAD, Sayed Fayaz et al. Academic and administrative role of artificial intelligence in education. **Sustainability**, v. 14, n. 3, p. 1101, 2022.

ALAMRI, Jamilah Mohammed. Antecedents of Generative Artificial Intelligence Technology Adoption: Extended Innovation of Diffusion Model with Cultural Dimensions and Risks Perceptions. **Journal of Ecohumanism**, v. 4, n. 1, p. 1718–1738-1718–1738, 2025.

ALNAGGAR, Samer Ahmed Mohamed; ABDULKADER, Waleed Fathi Abdulkarim. How administrative AI applications enhance organizational innovation and quality of work life for disabled employees: a case study of a Saudi University. **Access Journal**, v. 5, n. 1, p. 68-84, 2024.

BARTLETT, James; BARTLETT, Michelle. Enhancing Community College Leadership Development through AI: Enriching the Andragogical Approach. In: **Society for Information Technology & Teacher Education International Conference**. Association for the Advancement of Computing in Education (AACE), 2024. p. 1213-1219.

BRASIL. PORTAL DA TRANSPAÊNCIA. **Destaques dos valores de orçamento e despesas do Governo Federal**. 2024. Disponível em: <https://portaldatransparencia.gov.br/orgaos/26282-universidade-federal-de-vicosa>. Acesso em: 03 dez. 2024.

COELHO, Marcos Rafael; SILVA, Marcelo Ribeiro. A INTELIGÊNCIA ARTIFICIAL COMO FERRAMENTA DE EFICIÊNCIA NA ADMINISTRAÇÃO PÚBLICA. **Revista Ft**, [S.L.], v. 29, n. 140, p. 13-14, 12 nov. 2024.

COSTA, Francisco José da. **Mensuração e Desenvolvimento de Escalas**: aplicações em administração. Rio de Janeiro: Ciência Moderna, 2011.

DEARING, James W. Evolution of diffusion and dissemination theory. **Journal of public health management and practice**, v. 14, n. 2, p. 99-108, 2008.

DOMINGO-ALEJO, Josephine. AI Integrated Administration tool design with ML Technology for Smart Education System. **2024 4Th International Conference On Advance Computing And Innovative Technologies In Engineering (Icacite)**, [S.L.], p. 1423-1428, 14 maio 2024.

GARCÍA-AVILÉS, José-Alberto. Diffusion of innovation. **The international Encyclopedia of media psychology**, v. 7, n. 1, p. 1-8, 2020.

GE, Zhenxing; HU, Ying. Innovative application of artificial intelligence (AI) in the management of higher education and teaching. In: **Journal of Physics: Conference Series**. IOP Publishing, 2020. p. 032089.

GIL, Antônio Carlos et al. **Como elaborar projetos de pesquisa**. São Paulo: Atlas, 2002.

HAMIRUL et al. The Role of Artificial Intelligence in Government Services: A Systematic Literature Review. **Open Access Indonesia Journal of Social Sciences**, v. 6, n. 3, p. 998-1003, 2023.

JIN, Yueqiao et al. Generative AI in higher education: A global perspective of institutional adoption policies and guidelines. **Computers and Education: Artificial Intelligence**, v. 8, p. 100348, 2025.

KAR, Arpan Kumar; VARSHA, P. S.; RAJAN, Shivakami. Unravelling the impact of generative artificial intelligence (GAI) in industrial applications: A review of scientific and grey literature. **Global Journal of Flexible Systems Management**, v. 24, n. 4, p. 659-689, 2023.

KOUZIOKAS, Georgios N. A aplicação da inteligência artificial na administração pública para a previsão de áreas de transporte com alto risco de criminalidade em ambientes urbanos. **Transportation Research Procedia** , v. 24, p. 467-473, 2017.

LIU, Yue et al. Generative artificial intelligence and its applications in materials science: Current situation and future perspectives. **Journal of Materiomics**, v. 9, n. 4, p. 798-816, 2023.

LU, Yu et al. The Impact of Artificial Intelligence Technology on Market Public Administration in a Complex Market Environment. **Wireless Communications and Mobile Computing**, v. 2022, 2022.

LV, Zhihan *et al.* Generative artificial intelligence in the metaverse era. **Cognitive Robotics**, [S.L.], v. 3, p. 208-217, 2023.

MIYAZAKI, Kunihiro et al. Public perception of generative AI on Twitter: an empirical study based on occupation and usage. **EPJ Data Science**, v. 13, n. 1, p. 2, 2024.

MAESTRO, Susan; RANA, Puja et al. Variables Impacting the AI Adoption in Organizations. **International Journal of Science and Research Archive**, v. 12, n. 2, p. 1055-1060, 2024.

MOORE, Gary C.; BENBASAT, Izak. Development of an instrument to measure the perceptions of adopting an information technology innovation. **Information systems research**, v. 2, n. 3, p. 192-222, 1991.

NURJAMAN, Asep. Artificial intelligence as an instrument to improve the quality of public service. In: SUKMANA, Oman *et al.* **Social and Political Issues on Sustainable Development in the Post Covid-19 Crisis**. Malang: Routledge, 2022. p. 121-130. Disponível em: <https://www.taylorfrancis.com/chapters/oa-edit/10.1201/9781003263586-15/artificial-intelligence-instrument-improve-quality-public-service-asep-nurjaman>. Acesso em: 06 maio 2024.

PAIVA, Jerónimo. Exploring the Drivers of AI Adoption: a meta-analysis of technological, organizational and environmental (toe) factors. **Research Square**, [S.L.], p. 1-19, 16 dez. 2024. Springer Science and Business Media LLC. <http://dx.doi.org/10.21203/rs.3.rs-5634577/v1>.

PARK, Eunice. The AI Bill of Rights: a step in the right direction. **Orange County Lawyer Magazine**, v. 65, n. 2, 2023.

PEDRO, Ricardo. Artificial intelligence on public sector in Portugal: first legal approach. **Juridical Trib.**, v. 13, p. 149, 2023.

PEREZ, Gilberto; ZWICKER, Ronaldo. Fatores determinantes da adoção de sistemas de informação na área de saúde: um estudo sobre o prontuário médico eletrônico. **RAM. Revista de Administração Mackenzie**, v. 11, p. 174-200, 2010.

POPESCU, Ruxandra Irina; SABIE, Oana Matilda; TRUȘCĂ, Marian Iulian. The Contribution of Artificial Intelligence to Stimulating the Innovation of Educational Services and University Programs in Public Administration. **Transylvanian Review of Administrative Sciences**, v. 19, n. 70, p. 85-108, 2023.

RIOS-CAMPOS, Carlos et al. Artificial Intelligence and Education. **South Florida Journal Of Development**, [S.L.], v. 4, n. 2, p. 641-655, 6 abr. 2023. Brazilian Journals.

ROGERS, Everett. M. **Diffusion of innovation**. 3. ed. New York: The Free Press, 1983.

RUVALCABA-GOMEZ, Edgar A. Systematic and axiological capacities in artificial intelligence applied in the public sector. **Public Policy and Administration**, p. 09520767231170321, 2023.

RUVALCABA-GOMEZ, Edgar A.; CIFUENTES-FAURA, Javier. Analysis of the perception of digital government and artificial intelligence in the public sector in Jalisco, Mexico. **International Review of Administrative Sciences**, v. 89, n. 4, p. 1203-1222, 2023.

SCHEUER, John Damm. Diffusion of innovations. In: SCHEUER, John Damm. **How Ideas Move: theories and models of translation in organizations**. London: Routledge, 2021. Cap. 3. p. 1-7. Disponível em: <https://www.taylorfrancis.com/books/mono/10.4324/9780429424540/ideas-move-john-damm-scheuer?refId=de6bd327-3e84-4e62-ba6f-11fee3a0ccb2&context=ubx>. Acesso em: 06 maio 2024.

SILVA, Washington Fernando da; SILVA, Fernando Selleri; SILVA RABÊLO, Oliven da. Tendências no uso de inteligência artificial e sua influência na requalificação da força de trabalho no setor público. **Cadernos de Prospecção**, v. 14, n. 3, p. 824-824, 2021.

SOUSA, Weslei Gomes de et al. How and where is artificial intelligence in the public sector going? A literature review and research agenda. **Government Information Quarterly**, v. 36, n. 4, p. 101392, 2019.

TARISAYI, Kudzayi S. Strategic leadership for responsible artificial intelligence adoption in higher education. **CTE Workshop Proceedings**. v.1, p. 4-14, 2024.

TOLEDO, Adriana Teixeira de; MENDONÇA, Milton. A Aplicação da Inteligência Artificial na Busca de Eficiência pela Administração. **Revista do Serviço Público (RSP)**, v. 74, n. 2, p. 410-438, 2023.

VARGO, Stephen L. et al. Rethinking the process of diffusion in innovation: A service-ecosystems and institutional perspective. **Journal of business research**, v. 116, p. 526-534, 2020.

ZACHARIAS, Fabiana Costa Machado et al. e-SUS Atenção Primária: atributos determinantes para adoção e uso de uma inovação tecnológica. **Cadernos de Saúde Pública**, v. 37, p. e00219520, 2021.