

PERFIS DOCENTES E INTELIGÊNCIA ARTIFICIAL NO ENSINO SUPERIOR NO ESTADO DO PARANÁ, BRASIL

TEACHING PROFILES AND ARTIFICIAL INTELLIGENCE IN HIGHER EDUCATION IN THE STATE OF PARANÁ, BRAZIL

Pedro Paulo da Silva Ayrosa¹; José Antônio Marques Moreira²

CITATION

Ayrosa, P. P. da S., Moreira, & J. A. M. (2025). Perfis docentes e inteligência artificial no ensino superior no estado do Paraná, Brasil. Video Journal of Social and Human Research, 4(2), 2-14. <https://doi.org/10.18817/vjshr.v4i2.77>

SUBMITTED

11/11/2025

ACCEPTED

18/11/2025

PUBLISHED

30/12/2025

DOI

<https://doi.org/10.18817/vjshr.v4i2.77>

AUTHOR

¹Doutor e Mestre em Engenharia de Sistemas e Computação pela Universidade Federal do Rio de Janeiro (UFRJ/COPPE). Professor Associado do Departamento de Computação da Universidade Estadual de Londrina (UEL). Email: ayrosa@uel.br. ORCID: <https://orcid.org/0000-0002-5280-0419>.

²Doutor em Ciências da Educação. Professor Catedrático no Departamento de Educação e Ensino a Distância da Universidade Aberta. Investigador no Grupo de Políticas e Organizações Educativas e Dinâmicas Educacionais do Centro de Estudos Interdisciplinares (CEIS20) da Universidade de Coimbra. E-mail: jmoreira@uab.pt. ORCID: <http://orcid.org/0000-0003-0147-0592>.

RESUMO

Este artigo apresenta uma análise exploratória de dados realizada com uma amostra de 611 docentes pertencentes a sete universidades estaduais públicas do Paraná. A partir da aplicação de técnicas de inteligência artificial (IA) e ciência de dados, os participantes foram classificados em três grupos (clusters), considerando quatro dimensões analíticas: percepção de competência em IA, reconhecimento da urgência do tema nas áreas de ensino, pesquisa, extensão e gestão, postura ética frente ao uso da IA e interesse em formação continuada. Foram utilizadas as técnicas de Análise de Componentes Principais (PCA) e de clusterização por meio do algoritmo K-Means. A análise resultou na identificação de três perfis distintos: “veteranos cautelosos” (ou tradicionalistas), “realistas abertos” (possíveis articuladores institucionais) e “novos entusiastas” (potenciais multiplicadores). Conclui-se pela necessidade de formulação de políticas formativas segmentadas e flexíveis, com percursos formativos adaptados aos perfis identificados.

Palavras-chave: competências em IA; educação e tecnologia; análise multivariada.

ABSTRACT

This article presents an exploratory data analysis conducted with a sample of 611 faculty members from seven public state universities in Paraná, Brazil. By applying artificial intelligence (AI) and data science techniques, participants were classified into three groups (clusters) based on four analytical dimensions: perceived AI competence, recognition of the urgency of the topic across teaching, research, outreach, and management areas, ethical stance toward AI use, and interest in continuing education. Principal Component Analysis (PCA) and clustering using the K-Means algorithm were

employed. The analysis identified three distinct profiles: cautious veterans (or traditionalists), open realists (potential institutional articulators), and new enthusiasts (potential multipliers). The findings highlight the need for segmented and flexible training policies, with learning pathways tailored to the identified profiles.

Keywords: AI competencies; education and technology; multivariate analysis.

INTRODUÇÃO

A Inteligência Artificial (IA) não é um tema recente. Seu marco científico pode ser atribuído ao trabalho seminal de Turing (1950), intitulado “Computing Machinery and Intelligence”, no qual o autor propõe a célebre questão: As máquinas podem pensar? Tal indagação permanece atual, renovando-se continuamente com os avanços tecnológicos e os esforços para compreender e modelar a cognição humana.

A recente explosão do uso da IA pode ser atribuída a diversos fatores, como o progresso dos microprocessadores, o aprimoramento de sistemas de hardware e software, e o desenvolvimento e otimização de algoritmos. No entanto, alguns pesquisadores destacam, de modo particular, o papel da interface com o usuário (UI) e da experiência do usuário (UX) na popularização da IA (Lu et al., 2025). Em outras palavras, a acessibilidade proporcionada pela linguagem natural e a satisfação com as respostas geradas – geralmente positivas, progressivas e alinhadas às expectativas do usuário – têm desempenhado um papel fundamental na difusão desses sistemas.

Tais interfaces tornaram o uso de ferramentas baseadas em IA extremamente simples, inclusive em dispositivos móveis, o que facilita sua incorporação ao cotidiano escolar por pro-

fessores e estudantes. No entanto, a facilidade de acesso e consulta não implica, necessariamente, em um uso pedagógico ou apropriado. Conforme observa Lima-Lopes (2025), a fascinação pela interação dialógica com a máquina tem gerado posicionamentos ambíguos ou até contraditórios na avaliação dos potenciais e desafios da IA no contexto educacional.

Em 2023, a Organização das Nações Unidas para a Educação, a Ciência e a Cultura – UNESCO (2023) publicou o guia intitulado “Para aproveitar a era da inteligência artificial na educação superior: um guia às partes interessadas do ensino superior” (p. 10), no qual enfatiza a importância de que todos os atores envolvidos no ensino superior avaliem de forma crítica e responsável as oportunidades e os desafios associados à inserção da inteligência artificial na educação.

Entretanto, todo processo de conscientização, análise e tomada de decisões fundamentadas deve iniciar-se pela aquisição de uma compreensão básica acerca do que se entende por Inteligência Artificial (IA). Tal processo deve promover, por parte do ensino superior, uma resposta à sociedade que contemple diversas dimensões (culturais, políticas, econômicas, éticas, entre outras). Nesse sentido, é recomendável a construção de uma postura crítica e fundamentada (Sayad, 2022) por parte de todos os agentes envolvidos no ensino superior, de modo a colocar a IA a serviço do ser humano, evitando que se tornem meros consumidores passivos, ou mesmo refratários, em virtude da ausência de conhecimento, das novas tecnologias.

Apesar da complexidade inerente à organização acadêmica e administrativa do ensino superior, impõe-se, com urgência, uma refle-

xão crítica e embasada sobre a aplicação da IA nos processos de ensino, aprendizagem e avaliação, considerando-se suas múltiplas interconexões e implicações.

Embora o foco inicial deste estudo esteja voltado para o diagnóstico da necessidade de formação básica em inteligência artificial (IA) para docentes do ensino superior, reconhece-se plenamente a complexidade que envolve a presença efetiva da IA no campo educacional. Trata-se de um tema multifacetado, que suscita reflexões e provocações em diferentes cenários e dimensões institucionais (Azambuja & Silva, 2025).

Essa complexidade manifesta-se tanto nas abordagens mais ingênuas quanto naquelas marcadas por críticas e perspectivas pessimistas. De um lado, vislumbra-se que a inteligência artificial poderá efetivamente enriquecer os processos de ensino-aprendizagem e ampliar o acesso ao conhecimento. De outro, há o receio de que a IA aprofunde desigualdades educacionais, marginalizando grupos que não dispõem de infraestrutura tecnológica adequada nem de profissionais capacitados para sua mediação.

Além disso, coloca-se em debate se a emergência da IA resultará no desenvolvimento de metodologias pedagógicas inovadoras (Kukulska-Hulme et al., 2024) ou se suas técnicas serão simplesmente incorporadas a modelos educativos tradicionais, sem transformações significativas. Nesse contexto, torna-se imprescindível reconhecer que, em face de uma realidade em constante transformação, impõe-se uma reflexão aprofundada e um planejamento criterioso, com vistas à promoção de uma educação emancipadora, significativa, democrática e eticamente responsável, no

sentido mais amplo e humano (Barrios-Tao et al., 2021).

Segundo Miao & Cukurova (2024), a ascensão da Inteligência Artificial (IA) como fenômeno educacional impõe a necessidade de novas competências por parte dos docentes. No entanto, observa-se um descompasso entre a velocidade de avanço tecnológico e os processos formativos nas instituições de ensino.

Este artigo apresenta o relato da segunda etapa de um projeto mais amplo, intitulado “Avaliando e capacitando professores em Inteligência Artificial no contexto do Ensino Superior: uma proposta inspirada no padrão do Dig-CompEdu”. A etapa aqui descrita concentra-se na identificação de relações subjacentes ao conjunto de dados obtidos na fase inicial da pesquisa, cujo objetivo foi investigar a existência de letramento em inteligência artificial entre docentes do ensino superior paranaense.

Nesta fase, valemo-nos de técnicas oriundas da própria inteligência artificial, atualmente integradas ao campo da ciência de dados, com o intuito de explicitar padrões ocultos e relações implícitas que possam subsidiar a estruturação de ações formativas mais adequadas, fundamentadas em um conhecimento mais refinado do público-alvo.

Assim, este artigo aprofunda os resultados da pesquisa sobre a necessidade de capacitação em inteligência artificial para docentes do ensino superior público do Estado do Paraná (Ayrosa, 2024), estando inserido e alinhado com os objetivos do Novo Arranjo de Pesquisa e Inovação (NAPI) Educação do Futuro, especialmente o Eixo Temático 2 do NAPI, “Competências Digitais dos Professores da Educação Básica e Ensino Superior públicos” citado por Moreira et al. (2024) e com as diretrizes da

Política Nacional de Educação Digital (PNED) (Lei nº 14.533, 2023, p. 1).

No planejamento inicial utilizou-se um instrumento de coleta de dados, composto por 10 questões objetivas, que tinha como objetivo mapear o perfil demográfico da população-alvo e identificar, por meio de autoavaliação, a percepção dos docentes quanto à posse de competências mínimas em Inteligência Artificial (IA) para apoiar atividades de ensino, pesquisa, extensão e gestão acadêmica. Além disso, buscou-se aferir a necessidade de uma reflexão crítica e fundamentada sobre a aplicação da IA nos processos de ensino, aprendizagem e avaliação, bem como a importância da dimensão ética e sua centralidade nas discussões sobre o tema.

A amostra foi composta por docentes do ensino superior paranaense vinculados a uma das sete universidades estaduais sob a coordenação da Secretaria da Ciência, Tecnologia e Ensino Superior do Paraná (SETI/PR): Universidade Estadual de Londrina (UEL), Universidade Estadual de Maringá (UEM), Universidade Estadual do Norte do Paraná (UENP), Universidade Estadual de Ponta Grossa (UEPG), Universidade Estadual do Paraná (UNESPAR), Universidade Estadual do Centro-Oeste (UNICENTRO) e Universidade Estadual do Oeste do Paraná (UNIOESTE). O total de respondentes foi de $n = 611$, dentro de um universo estimado de 7.500 docentes, o que resulta em uma margem de erro de 3,8% para um nível de confiança de 95%.

A Tabela 1 apresenta um resumo dos principais resultados estatísticos descritivos, indicando um perfil majoritário composto por docentes com as seguintes características: idade superior a 40 anos, do gênero feminino,

com titulação de doutorado, experiência docente no ensino superior acima de 15 anos, e pertencentes às áreas de Ciências Sociais Aplicadas, Ciências Humanas e Ciências da Saúde. Esses docentes expressam interesse em uma formação inicial em IA, que está sendo estruturada com base em referenciais teóricos consolidados, como os trabalhos de Long e Magerko (2020), Ng et al. (2021), Unesco (2022, 2023) e Perchik (2023).

Tabela 1 - Resumo estatístico da pesquisa realizada com docentes do Ensino Superior Público do Estado do Paraná sobre a necessidade de capacitação em IA

| Variável | Categoria / Valor | Frequência Absoluta (n) | Percentual (%) |
|----------------------|----------------------------|-------------------------|----------------|
| IES | UEL | 247 | 40,4 |
| IES | UENP | 94 | 15,4 |
| IES | UNIOESTE | 87 | 14,2 |
| IES | UNICENTRO | 77 | 12,6 |
| Faixa etária | 40 a 49 anos | | 34,7 |
| Faixa etária | 50 a 59 anos | | 32,6 |
| Gênero | Feminino | | 80,6 |
| Gênero | Masculino | | 39,3 |
| Titulação Acadêmica | Doutorado | 461 | 75,5 |
| Tempo de experiência | Mais de 15 anos | 332 | 54,3 |
| Área de Formação | Ciências Sociais Aplicadas | 138 | 22,6 |
| Área de Formação | Ciências Humanas | 128 | 20,9 |

Nota: Dados da pesquisa (2024)

A análise de dados é um campo em constante expansão, impulsionado pelo avanço da computação, tanto no que se refere aos aspectos de hardware e software quanto pela crescente acessibilidade aos mecanismos e serviços de armazenamento de dados. O termo mais abrangente Knowledge Discovery in Databases (KDD) foi cunhado no primeiro workshop dedicado à análise de dados (Silva et al., 2016).

Trata-se de um processo sistemático, passível de automatização em diversas de suas etapas, sendo uma delas denominada mineração de dados (data mining).

É importante destacar, conforme elucidado por Larry Wasserman em sua obra *All of Statistics: A Concise Course in Statistical Inference* (2010), que estatísticos e cientistas da computação frequentemente utilizam terminologias distintas para referirem-se a conceitos semelhantes. Por exemplo, o que os estatísticos denominam clusterização, estimativa e classificação, os cientistas da computação, especialmente no campo da inteligência artificial, denominam, respectivamente, aprendizado não supervisionado, aprendizado e aprendizado supervisionado. Não é incomum que esses termos sejam empregados de maneira intercambiável.

Por definição, mineração de dados refere-se a uma atividade exploratória voltada à descoberta de padrões em bases de dados. A partir desses padrões, aplicam-se procedimentos inferenciais que visam à geração de conhecimento útil para subsidiar a tomada de decisões (Silva et al., 2016).

Estudos sobre competências digitais docentes, como o DigCompEdu (Lucas & Moreira, 2018), ressaltam que o domínio técnico deve estar necessariamente articulado a uma reflexão crítica e pedagógica. A dimensão ética da IA, por sua vez, adquire relevância diante de riscos associados, como o viés algorítmico e a desumanização dos processos de aprendizagem (Unesco, 2022).

Conforme argumenta Bekiaridis (2024), a IA está transformando rapidamente os processos de ensino e aprendizagem, sendo essencial que educadores, tanto da educação formal quanto da educação de adultos, estejam preparados com competências que lhes permitam compreender, avaliar e utilizar as tecnologias de IA de forma eficaz e responsável.

A análise de perfis por meio de técnicas de clusterização possibilita compreender a heterogeneidade de práticas, percepções e valores entre os docentes, contribuindo para o planejamento de ações formativas em IA mais adequadas às características do público-alvo, o que pode fortalecer a efetividade dos processos de ensino e aprendizagem.

METODOLOGIA

Este trabalho fundamenta-se metodologicamente em uma abordagem quantitativa, de natureza descritiva e exploratória, com aplicação de técnicas de análise multivariada de dados e clusterização. Participaram do estudo 611 docentes de instituições públicas do estado do Paraná, abrangendo diferentes áreas do conhecimento, faixas etárias e tempos de atuação na docência, conforme apresentado na Tabela 1.

O instrumento de coleta foi inspirado no questionário desenvolvido pelo projeto AIPioneers – Artificial Intelligence in Education & Training (aipioneers.org), vinculado ao programa ERASMUS+, na modalidade Projetos Orientados para o Futuro. Trata-se de uma iniciativa multifacetada que visa integrar a Inteligência Artificial (IA) à educação, com foco especial na educação de adultos e na formação profissional (EFP), conforme descrito em (Bekiaridis, 2024).

O questionário aplicado foi composto por dez questões, sendo seis de natureza sociodemográfica e quatro voltadas à percepção sobre competências em IA. As questões foram estruturadas com escalas do tipo Likert (1932) e respostas binárias. Considerando o número de participantes e

de variáveis, a base resultante totaliza mais de 6.000 dados brutos, viabilizando análises robustas e representativas do perfil docente investigado.

Preparação dos dados

Nesta fase inicial da Análise Exploratória de Dados (AED), procedeu-se à avaliação dos tipos de variáveis envolvidas, considerando-se que cada questão do instrumento corresponde a uma variável distinta. Para essa classificação, adotou-se a taxonomia clássica dos tipos de variáveis proposta por (Peck & Devore, 2012), que distingue entre variáveis qualitativas (ou categóricas, podendo ser nominais ou ordinais) e variáveis quantitativas (ou numéricas, subdivididas em discretas e contínuas).

A Tabela 2 apresenta a tipologia adotada para cada uma das variáveis analisadas, estabelecendo a base para as etapas subsequentes de tratamento e modelagem dos dados.

Tabela 2 - Tipos de variáveis utilizadas na pesquisa

| Questão | Descrição | Tipo de Variável | Subtipo | Categoria Analítica |
|---------|--------------------------------|------------------|-----------------|---------------------|
| 1 | Instituição de vínculo | Qualitativa | Nominal | Sociodemográfica |
| 2 | Faixa etária | Qualitativa | Ordinal | Sociodemográfica |
| 3 | Gênero | Qualitativa | Nominal | Sociodemográfica |
| 4 | Titulação acadêmica | Qualitativa | Ordinal | Sociodemográfica |
| 5 | Grande área do conhecimento | Qualitativa | Nominal | Sociodemográfica |
| 6 | Tempo de experiência docente | Qualitativa | Ordinal | Sociodemográfica |
| 7 | Autoavaliação das competências | Qualitativa | Ordinal binária | Perceptiva |
| 8 | Reflexão sobre IA | Qualitativa | Escala Likert | Perceptiva |
| 9 | Prioridade da ética | Qualitativa | Escala Likert | Perceptiva |
| 10 | Interesse em capacitação | Qualitativa | Ordinal binária | Comportamental |

Nota. Dados da pesquisa (2024)

Em uma 1a análise do mapeamento geral

dos tipos de variáveis, observou-se, predominantemente, seu caráter qualitativo. No entanto, para a aplicação de algoritmos de inteligência artificial, é necessário que os dados estejam em formato quantitativo, uma vez que o processamento computacional é essencialmente numérico. Diante disso, torna-se imprescindível a transformação ou codificação numérica dos dados originais.

Para essa finalidade, empregaram-se três técnicas de transformação comumente utilizadas na etapa de pré-processamento de dados, conforme descrito por (Hair Jr. et al., 2009), Ordinal Encoding, One-Hot Encoding e Binary Encoding. Além das transformações, foi realizada a limpeza da base de dados, com a exclusão dos registros cujos respondentes indicaram vínculo com a opção “outras” (em relação à instituição de ensino superior), de modo a restringir a análise exclusivamente às instituições públicas do estado do Paraná. Após esse procedimento, a amostra final resultou em 595 registros válidos, correspondentes ao número de indivíduos considerados para as análises subsequentes.

A nova base de dados, após o processo de codificação, resultou em um aumento expressivo da dimensionalidade, passando de 10 para 26 variáveis. Para reduzir essa dimensionalidade e preparar os dados para o processo de agrupamento, optou-se pela aplicação da técnica de Análise de Componentes Principais (PCA), conforme descrito por (Hair Jr. et al., 2009), seguida pela utilização do algoritmo de clusterização K-means.

Contudo, nas simulações iniciais observou-se que o coeficiente de variância explicada acumulada pelas duas primeiras componentes principais (PCA1 e PCA2) era considerado

baixo, o que poderia comprometer a eficácia da análise. Como solução, adotou-se uma estratégia alternativa de codificação, inspirada na representação do conhecimento por micro-características, tradicionalmente empregada em redes neurais (Spitzer, 2000), a fim de melhorar a estrutura dos dados para a aplicação dos algoritmos.

Todas as simulações foram realizadas utilizando o software Orange Data Mining, versão 3.39.0. A Figura 1 apresenta o workflow utilizado na condução das análises. O processo de clusterização classificou os dados em três grupos distintos (clusters), a saber: C1, com 256 indivíduos; C2, com 250 indivíduos; e C3, com 89 indivíduos. Esses agrupamentos totalizam os 595 respondentes válidos considerados na amostra final, após o pré-processamento e a codificação dos dados.

Procedimentos de Análise

Durante a fase de exploração dos dados, as seguintes etapas foram realizadas de forma sequencial:

1. Carregamento da planilha de dados gerada a partir do formulário Google;
2. Pré-processamento, com a limpeza dos dados e exclusão de registros não elegíveis (redução de 611 para 595 registros válidos);
3. Transformação e codificação das variáveis por meio de técnicas apropriadas (Ordinal Encoding, One-Hot Encoding e Binary Encoding);
4. Aplicação da Análise de Componentes Principais (PCA), com o objetivo de reduzir a dimensionalidade do conjunto de dados

codificados;

5. Verificação do percentual acumulado de variância explicada pelas componentes PCA1 e PCA2, com vistas à adequação para visualização e interpretação;
6. aplicação do algoritmo K-means para agrupamento dos dados em três clusters;
7. Visualização bidimensional dos agrupamentos com base nas duas primeiras componentes principais (PCA1 e PCA2).

As Tabelas 3, 4, 5 e 6 apresentam resultados descritivos dessas dimensões para os clusters C1, C2 e C3, respectivamente.

Tabela 3 - Distribuição de respostas por cluster

| Cluster | Reflexão (sim%) | Ética (sim%) | Competência (sim%) | Capacitação (sim%) |
|---------|-----------------|--------------|--------------------|--------------------|
| C1 | 81 | 89 | 5 | 96 |
| C2 | 84 | 90 | 46 | 98 |
| C3 | 80 | 92 | 74 | 99 |

Nota. Percentuais de respostas positivas em cada dimensão analítica (2024).

Tabela 4 - Distribuição etária por cluster

| Faixa etária | C1 (%) | C2 (%) | C3 (%) |
|--------------|--------|--------|--------|
| 20-29 | 0 | 0 | 13 |
| 30-39 | 0 | 27 | 46 |
| 40-49 | 9 | 62 | 29 |
| 50-59 | 63 | 11 | 11 |
| >60 | 28 | 0 | 0 |

Nota. Percentuais de respostas positivas em cada dimensão analítica (2024).

Tabela 5 - Titulação acadêmica por cluster

| Titulação | C1 (%) | C2 (%) | C3 (%) |
|----------------|--------|--------|--------|
| Graduação | 0 | 0 | 4 |
| Especialização | 2 | 1 | 35 |
| Mestrado | 11 | 16 | 33 |
| Doutorado | 87 | 84 | 28 |

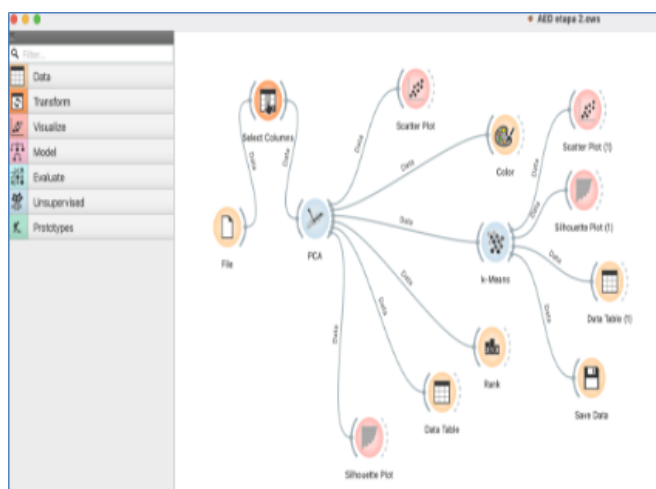
Nota. Percentuais de respostas positivas em cada dimensão analítica (2024).

Tabela 6 - Tempo de experiência docente no ensino superior

| Experiência (Anos) | C1 (%) | C2 (%) | C3 (%) |
|--------------------|--------|--------|--------|
| 2-5 | 0 | 0 | 45 |
| 6-10 | 0 | 3 | 45 |
| 11-15 | 1 | 66 | 10 |
| 16-20 | 20 | 31 | 0 |
| >20 | 79 | 0 | 0 |

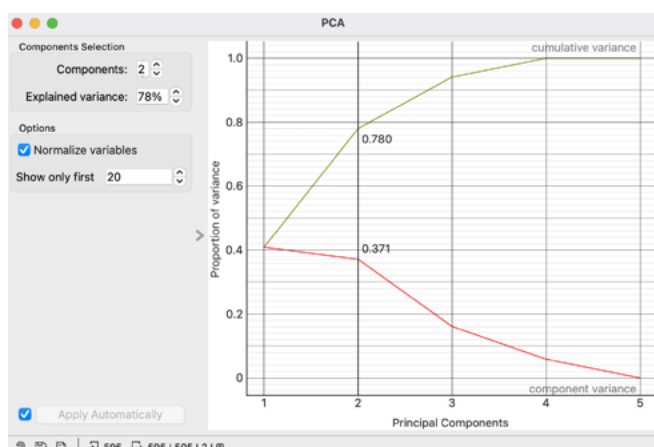
Nota. Percentuais de respostas positivas em cada dimensão analítica (2024).

Figura 1 - Workflow no software de mineração de dados Orange (versão 3.39.0)




Nota. Fluxo analítico adotado para aplicação de PCA e K-Means

Figura 2 - Análise da variância




Nota. Representação gráfica dos componentes principais

Figura 3 - Representação dos agrupamentos C1, C2 e C3



Nota. Disposição espacial dos clusters resultantes da análise K-Means

Figura 4 - Regiões de abrangência dos agrupamentos C1, C2 e C3



Nota. Disposição espacial

RESULTADOS

Recuperando os resultados da etapa anterior (Ayrosa, 2024) e conforme descrito na Tabela 1, todas as sete universidades estaduais paranaenses participaram da pesquisa, embora algumas tenham se mostrado numericamente mais representativas. As instituições responsáveis por 82,6% das respostas foram: Universidade Estadual de Londrina – UEL (247 respostas; 40,4%), Universidade Estadual do Norte do Paraná – UENP (94 respostas; 15,4%), Universidade Estadual do Oeste do Paraná – UNIOESTE (87

respostas; 14,2%) e Universidade Estadual do Centro-Oeste – UNICENTRO (77 respostas; 12,6%).

Quanto ao perfil sociodemográfico dos participantes, a faixa etária predominante foi de 40 a 49 anos (34,7%), seguida de perto pelo grupo de 50 a 59 anos (32,6%). O gênero feminino foi majoritário, com 60,6% dos respondentes, em comparação a 39,3% do gênero masculino. No que diz respeito à titulação acadêmica, observou-se uma elevada concentração de doutores (461 respondentes; 75,5%).

Em relação à experiência docente no ensino superior, 54,3% dos participantes afirmaram possuir mais de 15 anos de atuação, sendo que 33,4% declararam ter 20 anos ou mais. As áreas de formação com maior representatividade foram: Ciências Sociais Aplicadas (138 respostas; 22,6%), Ciências Humanas (128 respostas; 20,9%) e Ciências da Saúde (122 respostas; 20%). Por outro lado, destacaram-se como as menos representadas as áreas de Engenharias (12 respostas; 2%) e Ciências Agrárias (28 respostas; 4,6%).

Na presente etapa do estudo, foram identificados três agrupamentos distintos: C1, com 256 indivíduos (42% da amostra); C2, com 250 indivíduos (42%); e C3, com 89 indivíduos (16%).

Observamos que o cluster C1 apresenta a menor concordância com a percepção da competência (47%), a menor percepção da prioridade da questão ética (89%) e o menor interesse na capacitação (96%), a faixa etária entre 50 e 59 anos é a maioria (63%), a titulação de doutores também é a maior (87%) e são os professores com maiores experiência docente (mais de vinte anos) no ensino superior (79%).

O cluster C2 foi o que apresentou a maior concordância o reconhecimento da urgência do tema nas áreas de ensino, pesquisa, extensão e gestão (84%), com a faixa etária entre 40 e 49 anos (62%), porém com a menor número de doutores (84%) com comparados ao cluster C1. A experiência docente de grupo também é intermediária com (66%) na faixa entre 10 e 15 anos.

Já o cluster C3, o menor dos 3 clusters, tem o menor índice de concordância (80%) com reconhecimento da urgência do tema nas áreas de ensino, pesquisa, extensão e gestão, porém com a maior concordância com a prioridade da questão ética (92%). Também foi o grupo que melhor se autoavaliou com possuidor das mínimas competências em IA (74%) e apresentou o maior índice de interesse na capacitação (99%), são os mais jovens, na faixa etária de 30 a 39 anos (46%) menor titulação, apenas 28% de doutores, 90% com experiência docente inferior a 10 anos. Resumimos as características de cada grupo nas tabelas 7, 8 e 9.

Tabela 7 - Características do Cluster C1 ("Veteranos cautelosos")

| Característica | Descrição |
|--------------------------|--|
| Idade | Predominância entre 50 e 59 anos (63%) |
| Titulação | 87% doutores |
| Experiência docente | 79% com mais de 20 anos |
| Competência mínima em IA | 43% afirmam possuir |
| Percepção da ética | 89% reconhecem a importância |
| Interesse em capacitação | 96% (mais baixo entre os grupos) |

Nota. Dados da pesquisa.

Tabela 8 - Características do Cluster C2 ("Realistas abertos")

| Característica | Descrição |
|--------------------------|--|
| Idade | Predominância entre 40 e 49 anos (62%) |
| Titulação | 84% doutores |
| Experiência docente | 66% entre 10 e 15 anos |
| Urgência da IA | 84% reconhecem |
| Competência mínima em IA | 54% |
| Interesse em capacitação | 98% |

Nota. Dados da pesquisa.

Tabela 9 - Características do Cluster C3 (“Novos entusiastas”)

| Característica | Descrição |
|--------------------------|----------------------------------|
| Idade | Maioria entre 30 e 39 anos (46%) |
| Titulação | 28% doutores |
| Experiência docente | 90% com menos de 10 anos |
| Urgência da IA | 57% |
| Competência mínima em IA | 57% |
| Percepção da ética | 92% |
| Interesse em capacitação | 99% |

Nota. Dados da pesquisa.

DISCUSSÃO

A partir das características de cada grupo podemos desenhar três tipos de perfil: Custer C1 - “Veteranos cautelosos” ou tradicionalistas, C2 - “Realistas abertos” ou possíveis articuladores institucionais e C3 - “Novos entusiastas” ou potenciais multiplicadores. O cluster C1 é composto de docentes experientes, com alta titulação, mas com menor percepção de competência mínimas em IA e menor entusiasmo pela capacitação. O cluster C2 comparável em número de docentes ao grupo C1, mas composto de docentes no meio da trajetória da carreira acadêmica, equilibrando experiência, abertura à formação e percepção de urgência do tema. Já o cluster C3, chamados aqui de novos entusiastas, são os docentes mais jovens, com menor titulação, mas altamente engajados, éticos e dispostos a aprender. Com a definição dos 3 perfis minerados dos dados, podemos expandir a interpretação para cada grupo.

O C1, “Veteranos cautelosos” ou tradicionalistas, parece formado por docentes experientes, possivelmente mais inseridos em rotinas institucionais consolidadas e com maior capital acadêmico, mas menos conectados com as transformações digitais trazidas pela IA. A percepção reduzida de competência e a ligeira resistência à capacitação indicam a

necessidade de abordagens formativas que reconheçam sua trajetória e valorizem práticas reflexivas e institucionais.

O C2, “Realistas abertos” ou possíveis articuladores institucionais, expressa consciência da relevância estratégica da IA nas diversas dimensões da atuação docente (ensino, pesquisa, extensão e gestão). Embora não se destaque tanto em titulação ou experiência quanto o C1, demonstra alta receptividade a políticas formativas. Representa um segmento promissor para liderar mudanças pedagógicas com suporte institucional.

Já o C3, “Novos entusiastas” ou potenciais multiplicadores, trata-se de um grupo mais jovem, mas que se autoavalia como mais competente em IA e demonstra elevada adesão aos princípios éticos. Seu entusiasmo e predisposição para a formação o tornam um público-alvo ideal para programas inovadores e multiplicadores de práticas pedagógicas com IA.

CONSIDERAÇÕES FINAIS

Os resultados apresentados neste artigo evidenciam a heterogeneidade dos perfis docentes frente à Inteligência Artificial nas universidades estaduais públicas do Paraná, com a identificação de três grupos, denominados aqui “veteranos cautelosos”, “realistas abertos” e “novos entusiastas”. Essa classificação constitui uma das possibilidades interpretativas, considerando as características da amostra, as técnicas empregadas, os parâmetros ajustados e a calibração do modelo.

A elevada concordância dos docentes quanto à necessidade de reflexão crítica sobre a IA e à centralidade da ética no tema, bem como o expressivo interesse por formação continuada, ressaltam tanto a urgência quanto a receptividade da comunidade acadêmica a iniciativas nessa direção.

À luz de uma visão mais integrada dos projetos paranaenses, representada pelos objetivos e pela estrutura do Novo Arranjo de Pesquisa e Inovação (NAPI) Educação do Futuro — em particular do Eixo Temático 2, “Competências Digitais dos Professores da Educação Básica e do Ensino Superior Públicos” —, bem como das diretrizes da Política Nacional de Educação Digital (PNED), instituída pela Lei nº 14.533/2023, é possível afirmar que os resultados aqui apresentados contribuem para a construção de perfis docentes no contexto do ensino superior público estadual do Paraná. Tais perfis podem subsidiar a formulação de políticas formativas segmentadas e flexíveis, com percursos adaptados às especificidades de cada grupo identificado. Dessa forma, espera-se avançar na consecução do objetivo central do NAPI Educação do Futuro — em particular do Eixo Temático 2, que é produzir conhecimento socialmente relevante sobre as competências digitais dos docentes paranaenses, com vistas a fundamentar propostas e programas de formação.

Nota sobre os recursos computacionais utilizados

Para a coleta de dados, foi utilizado o serviço Google Forms para a elaboração e aplicação do questionário online. As etapas de tabulação e análise preliminar dos dados

foram realizadas com o auxílio do software Microsoft Excel e do software de mineração de dados Orange Data Mining. Para a revisão ortográfica e aprimoramento do estilo do texto, recorreu-se ao modelo linguístico ChatGPT. Todas as atividades computacionais foram executadas em um computador Apple Mac Mini com processador M4.

AGRADECIMENTOS

O autor agradece o apoio da Fundação Araucária de Apoio ao Desenvolvimento Científico e Tecnológico do Estado do Paraná, no âmbito das atividades fomentadas pelo projeto “Avaliando e capacitando professores em Inteligência Artificial no contexto do Ensino Superior: uma proposta inspirada no padrão do DigCompEdu”. Agradece, igualmente, ao Centro de Estudos Globais da Universidade Aberta de Portugal (CEG-UAb), pelo acolhimento no programa de pós-doutoramento que contribuiu para o desenvolvimento desta pesquisa.

REFERÊNCIAS

- Ayrosa, P. P. (2024). Pesquisa sobre a necessidade de capacitação em inteligência artificial para docentes do ensino superior público do estado do Paraná. In *Anais da 20ª Semana da Educação*. Galoá. <https://proceedings.scienc/sedu-2024/trabalhos/pesquisa-sobre-a-necessidade-de-capacitacao-em-inteligencia-artificial-para-doce?lang=pt-br>
- Azambuja, C. C. De, Silva, G. F. (2025) Novos desafios para a educação na Era da Inteligência Artificial. *Filosofia Unisinos*,

- 25(1), 1–16. <https://doi.org/10.4013/fsu.2024.251.07>.
- Barrios-Tao, H., Díaz, V., & Guerra, Y. M. (2021, 10 de dezembro). Propósitos de la educación frente a desarrollos de inteligencia artificial. *Cadernos de Pesquisa*, 51, e07767.
- Bekiaridis, G. (2024). *Suplemento ao quadro DigCompEdu: Definição das aptidões e competências dos educadores em matéria de IA na educação. AIPioneers*. https://aipioneers.org/wpcontent/uploads/2024/01/WP3_Suplemento_ao_DigCompEdu_Portuguese.pdf
- Hair, J. F., Jr., Black, W. C., Babin, B. J., & Anderson, R. E. (2009). *Multivariate data analysis* (7th ed.). Pearson Prentice Hall.
- Han, J., Kamber, M., & Pei, J. (2012). *Data mining: Concepts and techniques* (3rd ed.). Morgan Kaufmann.
- Kukulska-Hulme, A., Wise, A.F., Coughlan, T., Biswas, G., Bossu, C., Burriss, S.K., Charitonos, K., Crossley, S.A., Enyedy, N., Ferguson, R., FitzGerald, E., Gaved, M., Herodotou, C., Hundley, M., McTamaney, C., Molvig, O., Pendergrass, E., Ramey, L., Sargent, J., Scanlon, E., Smith, B.E., & Whitelock, D. (2024). *Innovating Pedagogy 2024: Open University Innovation Report 12*. The Open University.
- Lei nº 14.533, de 11 de janeiro de 2023. (2023, janeiro 11). Institui a Política Nacional de Educação Digital (PNED). Diário Oficial da União, seção 1. https://www.planalto.gov.br/ccivil_03/_ato20232026/2023/lei/l14533.htm
- Likert, R. (1932). *A technique for the measurement of attitudes*. Archives of Psychology.
- Lima-Lopes, R.E. (2025). *Por uma revisão crítica do uso de inteligência artificial na educação*. SciELO Preprints. <https://doi.org/10.1590/SciELOPreprints.11450>
- Long, D., & Magerko, B. (2020). *What is AI literacy? Competencies and design considerations*. In Proceedings of the CHI Conference on Human Factors in Computing Systems (Honolulu, HI). ACM.
- Lu, Y., Yang, Y., Zhao, Q., Zhang, C., & Li, T. J. (2024). *AI assistance for UX: A literature review through human-centered AI*. arXiv. <https://arxiv.org/abs/2402.06089>
- Lucas, M., & Moreira, A. (2018). *DigCompEdu: Quadro europeu de competência digital para educadores*. Universidade de Aveiro.
- Miao, F., & Cukurova, M. (2024). *AI competency framework for teachers*. UNESCO. <https://www.unesco.org/en/articles/ai-competency-framework-teachers>
- Moreira, J. A., Dias-Trindade, S., Knuppel, M. A., & Serra, I. (2024). *Quadro de referência das competências pedagógico-digitais de professores: Pedagogical DigCompEdu reloaded*. EDUEMA. <https://editorauema.uema.br>
- Ng, D. T. K., Leung, J. K. L., Chu, S. K. W., & Qiao, M. S. (2021). *Conceptualizing AI literacy: An exploratory review*. Computers and Education: Artificial Intelligence, 2.
- Organização das Nações Unidas para a Educação, a Ciência e a Cultura (2022). *Recomendação sobre a ética da inteligência artificial*. https://unesdoc.unesco.org/ark:/48223/pf0000381137_por
- Organização das Nações Unidas para a Educação, a Ciência e a Cultura (2023).

Para aproveitar a era da inteligência artificial na educação superior: Um guia às partes interessadas do ensino superior. https://unesdoc.unesco.org/ark:/48223/pf0000386670_por.

Peck, R., & Devore, J. L. (2012). *Statistics: The exploration and analysis of data* (7^a ed.). Cengage Learning.

Pinheiro, C. A. R. (2008). *Inteligência analítica: Mineração de dados e descoberta de conhecimento*. Ciência Moderna.

Sayad, A. V. (2022). *Inteligência artificial e seu impacto no desenvolvimento do pensamento crítico* [Dissertação de Mestrado, Pontifícia Universidade Católica de São Paulo]. Pontifícia Universidade Católica de São Paulo Repositório. <https://repositorio.pucsp.br/jspui/handle/29620/1/Alexandre%20Le%20Voci%20Sayad.pdf>

Silva, L. A., Peres, S. M., & Boscarioli, C. (2016). *Introdução à mineração de dados: Com aplicações em R*. Elsevier.

Spitzer, M. (2000). *The mind within the net: Models of learning, thinking, and acting*. MIT Press.

Turing, A. (1950). Computing machinery and intelligence. *Mind*, 59(236), 433–460. <https://academic.oup.com/mind/article/LIX/236/433/986238>.