

# EFEITOS DA INTELIGÊNCIA ARTIFICIAL SOBRE O EMPREGO E RENDA: UMA PERSPECTIVA REGIONAL

Heloisa Ribeiro Lopes\*

Kênia Barreiro de Souza†

**Resumo:** O avanço da inteligência artificial (IA) nas sociedades contemporâneas tem transformado a dinâmica do mercado de trabalho, ao criar ocupações que exigem novas competências técnicas, mas também ao ampliar os desafios associados à destruição de empregos. Este artigo tem por objetivo analisar os efeitos da exposição à IA em nível regional para o Brasil. A metodologia proposta é composta por duas etapas. Na primeira, estima-se o Índice de Exposição das Ocupações à IA, combinando informações de patentes com as descrições da Classificação Brasileira de Ocupações (CBO), a partir de uma adaptação da proposta de [Webb \(2019\)](#) ao contexto brasileiro. Na segunda etapa, esse índice é utilizado para estimar a exposição à IA no nível municipal, ponderando-se pela estrutura de empregos formais (RAIS). Os resultados descritivos indicam forte heterogeneidade espacial: diversos municípios apresentam baixa exposição à IA, enquanto os mais afetados são, em geral, pequenos municípios com reduzida diversificação econômica. Nas capitais, a exposição agregada tende a ser relativamente baixa, em consonância com maior diversidade ocupacional. A análise exploratória de dados espaciais (AEDE) revela autocorrelação espacial global positiva moderada para o índice de IA e a presença de padrões locais, com *clusters* do tipo *High-High* e *Low-Low*. Os achados sugerem que a exposição regional à IA decorre mais da composição ocupacional e setorial do que do nível de emprego. Do ponto de vista de políticas públicas, os resultados apontam para a relevância de estratégias de requalificação profissional, diversificação produtiva e difusão tecnológica com foco territorial.

**Palavras-chave:** Inteligência artificial, Emprego, Renda, Impactos regionais.

**Abstract:** The advance of artificial intelligence (AI) in contemporary societies has been transforming the dynamics of labor markets by creating occupations that demand new technical skills, while also intensifying the challenges associated with job destruction. This study aims to analyze the effects of AI exposure at the regional level in Brazil. The proposed methodology comprises two stages. In the first, the Occupational AI Exposure Index is estimated by combining patent information with the descriptions of the Brazilian Classification of Occupations (CBO), through an adaptation of the approach proposed by [Webb \(2019\)](#) to the Brazilian context. In the second stage, this index is used to estimate AI exposure at the municipal level, weighted by the structure of formal employment (RAIS). The descriptive results indicate strong spatial heterogeneity: many municipalities exhibit low exposure to AI, while the most

---

\*Mestranda no Programa de Pós-Graduação em Desenvolvimento Econômico da Universidade Federal do Paraná, UFPR. Diretora Jurídica na URBS.

†Professora Adjunta na Universidade Federal do Paraná, UFPR. Bolsista de Produtividade em Pesquisa no Conselho Nacional de Desenvolvimento Científico e Tecnológico, CNPq.

affected are generally small municipalities with limited economic diversification. In contrast, capital cities tend to present relatively low aggregate exposure, consistent with greater occupational diversity. Exploratory spatial data analysis (ESDA) reveals a moderate positive global spatial autocorrelation for the AI index and the presence of local clusters of the *High–High* and *Low–Low* types. The findings suggest that regional AI exposure is driven more by occupational and sectoral composition than by employment levels. From a policy perspective, the results highlight the importance of professional requalification, productive diversification, and technology diffusion strategies with a territorial focus.

**Keywords:** Artificial intelligence, Employment, Income, Regional impacts.

**Área 11:** Mercado de trabalho, Demografia e Migração

**Classificação JEL:** J01, J21, J23

## 1. Introdução

O advento da inteligência artificial (IA) tem promovido avanços sem precedentes na sociedade contemporânea. Por meio de sua aplicação em diversos contextos econômicos e sociais, a IA se consolida como uma tecnologia disruptiva capaz de reformular padrões estabelecidos, ao mesmo tempo em que suscita debates sobre seus limites éticos e seus impactos sobre o mercado de trabalho ([Amaral, 2023](#)).

No século XXI, a Quarta Revolução Industrial, marcada pela expansão da capacidade computacional aliada ao uso intensivo de tecnologias físicas, digitais e biológicas ([Magalhães and Vendramini, 2018](#)), tem provocado transformações tecnológicas rápidas e profundas na sociedade. Por sua vez, a era digital e a crescente interação entre seres humanos e máquinas têm gerado rearranjos nos campos econômico, político e social ([Amaral, 2023](#)). É nesse contexto que a inteligência artificial encontra um campo propício para se desenvolver e somar forças com tecnologias emergentes tais quais a Internet das Coisas (IoT), *big data* e Indústria 4.0, alterando profundamente a maneira como as pessoas se conectam, trabalham e se relacionam ([von Dietrich and Garcia, 2022](#)).

O termo “inteligência artificial” foi cunhado por [McCarthy et al. \(1955\)](#), durante a proposta para a Conferência de Dartmouth em 1956. O objetivo original dos pesquisadores era desenvolver máquinas capazes de realizar tarefas associadas à inteligência humana, como aprendizado, raciocínio, percepção e tomada de decisão. Desde então, a IA se expandiu para uma ampla gama de atividades humanas, oferecendo soluções em áreas diversas: de assistentes virtuais como Siri e Alexa, ao controle veicular por sistemas como o Tesla Autopilot, e até ferramentas de apoio à aprendizagem, como o ChatGPT. Essas inovações prometem ampliar a comodidade, a segurança, a mobilidade urbana e a eficiência dos serviços ([Santos et al., 2022](#); [dos Santos and Vasconcelos, 2024](#)).

Na saúde, a IA vem sendo utilizada para aprimorar procedimentos cirúrgicos e prever doenças, muitas vezes identificando padrões que escapam à percepção humana ([Lemes and Le-](#)

mos, 2020). No setor financeiro, algoritmos inteligentes atuam na gestão de investimentos, na detecção de fraudes e na antecipação de flutuações de mercado (Buani Gonçalves and De Almeida Reinaldi, 2024). Por outro lado, os avanços também impõem dilemas éticos, relacionados à privacidade, à segurança de dados, à discriminação algorítmica, à disseminação de desinformação (Amaral, 2023), à manipulação política e às ameaças à democracia (Lins de Araujo et al., 2023). Muito embora se reconheça a existência de uma dependência de trajetória de escolhas feitas no passado (Bernardi, 2012), a sociedade tem alcançado níveis de progresso tecnológico cada vez mais ágeis decorrentes do advento da inteligência artificial nas diversas e cotidianas tarefas humanas (Amaral, 2023).

Essa revolução da inteligência artificial traz um novo paradigma tecnológico que movimentava as estruturas da sociedade, gerando ondas de desenvolvimento ou de desemprego tecnológico, remontando a discussão schumpeteriana de destruição criativa inerente ao capitalismo (Figliuzzi, 2018). Para Schumpeter (2017)<sup>1</sup>, o movimento dialético de “destruição criativa” é inerente ao capitalismo. Segundo o autor, esse movimento é o "motor do capitalismo", pois representa um processo contínuo de inovação e transformação desse modo de produção que traz novas ondas de bens, serviços ou tecnologias que substituem as anteriores, resultando na destruição de setores ou modelos de negócios mais tradicionais e obsoletos que não conseguem se adaptar ao rápido avanço dos novos anseios sociais. No entanto, esse processo também cria oportunidades e traz avanços, de tal forma que, segundo o autor, a existência de um processo evolucionário é intrínseca ao capitalismo. Esse conceito abrange as transformações nos padrões sociais, a criação de novos modelos de negócios e de novas práticas organizacionais, muitas das quais podem provocar mudanças substanciais no mercado de trabalho.

Os reflexos sociais advindos dos novos arranjos econômicos e sociais decorrentes da interação humana com a inteligência artificial, como a automação (dos Santos and Vasconcelos, 2024), a construção de cidades inteligentes (Santos et al., 2022), entre outros, têm sido objeto de investigação na literatura mundial, que tem debatido os impactos que a inteligência artificial pode causar na sociedade, especialmente em relação aos diversos processos cognitivos humanos. Historicamente, tecnologias disruptivas tendem a ser incorporadas pelas cadeias produtivas, provocando reconfigurações profundas nos modos de vida e nas relações sociais, inclusive nas formas como homens e mulheres interagem no mundo do trabalho (Cahuc et al., 2014). A substituição de tarefas rotineiras por sistemas automatizados (Yang and Kim, 2024), combinada ao surgimento de novas demandas para ocupações tecnológicas (Ofori and Ofori, 2024), evidencia a complexidade e a ambiguidade dos efeitos da inteligência artificial sobre o emprego e a renda.

Os resultados encontrados pela literatura sobre os impactos dessa tecnologia sobre o mercado de trabalho são ambíguos, com abordagens tanto otimistas quanto pessimistas em relação às suas consequências sobre o trabalho. Essa dualidade é explorada no trabalho de Webb (2019), que por sua vez, constitui a base teórica desse artigo. Webb (2019), fundamentando-se na teoria

---

<sup>1</sup>Originalmente publicado em 1942.

proposta por [Acemoglu and Restrepo \(2018\)](#), desenvolve um modelo em que a economia produz um único bem final a partir de uma função de produção hierárquica do tipo CES (*Constant Elasticity of Substitution*). No primeiro nível dessa hierarquia, as firmas combinam diferentes tipos de ocupações, assumindo elasticidades de substituição constantes entre elas. No segundo nível, cada ocupação é composta por um conjunto de tarefas, que podem ou não ser automatizadas. Para as tarefas passíveis de automação, humanos e máquinas são considerados substitutos perfeitos para dado nível de produtividade. Assim, a estrutura da função de produção permite analisar em que medida as tarefas desempenhadas por trabalhadores humanos podem ser substituídas por tecnologias como softwares, robôs e sistemas de inteligência artificial. Conforme destaca [Webb \(2019\)](#), sua principal contribuição em relação ao modelo original de [Acemoglu and Restrepo \(2018\)](#) é considerar as ocupações, e não as tarefas isoladas, como unidade de análise, o que, para o autor, possibilita avaliar de forma mais realista os efeitos da automação sobre o emprego e a estrutura ocupacional.

Partindo dessa base teórica, o desenvolvimento das máquinas e o aumento de sua produtividade poderia gerar efeitos ambíguos sobre o mercado de trabalho ([Webb, 2019](#)). A medida em que aumenta a produtividade das máquinas, os trabalhadores que executam tarefas que podem ser automatizadas serão substituídos por máquinas. No entanto, isso ocorrerá apenas quando o preço das máquinas for menor do que o preço da mão de obra humana. Consequentemente, o aumento da automação estará diretamente relacionado à redução nos custos de produção, o que tende a deixar as empresas mais competitivas e aumentar sua produção, reduzindo as perdas potenciais em emprego humano.

Nesse contexto, a motivação para esta pesquisa decorre da necessidade de compreender de que maneira a inteligência artificial vem moldando as relações de emprego e renda, considerando as variações regionais desses efeitos. O artigo preenche uma lacuna importante no que diz respeito à aplicação de metodologias quantitativas que analisem essa relação para o caso brasileiro, e avança ao propor a uma análise regionalizada dos efeitos da inteligência artificial em um país em desenvolvimento.

A metodologia proposta pode ser dividida em duas etapas. Na primeira, o modelo proposto por [Webb \(2019\)](#) foi adaptado para calcular um índice de exposição das ocupações brasileiras à Inteligência Artificial, a partir da combinação de dados de patentes com informações de descrição das ocupações na Classificação Brasileira de Ocupações (CBO). Na segunda parte, adaptando [Yang and Kim \(2024\)](#), os dados de emprego da Relação Anual de Informações Sociais (RAIS) foram utilizados para criar um índice regional de exposição à Inteligência Artificial.

## **2. Base de Dados**

A base de dados utilizada nesta pesquisa foi construída a partir de diferentes fontes oficiais e complementares, de modo a permitir uma análise abrangente sobre os impactos da inteligência artificial no mercado de trabalho brasileiro.

Para as patentes, recorreu-se ao repositório *Google Patents* para a obtenção de títulos de

patentes registradas no Brasil que estejam relacionadas à inteligência artificial. Seguindo [Webb \(2019\)](#), deve-se buscar por títulos de patentes, e não seus descritivos, a fim de evitar ruídos linguísticos que impedem de encontrar a aplicação da invenção.

A coleta dessas informações foi realizada mediante a aplicação de um conjunto de palavras-chave representativas das tecnologias associadas à inteligência artificial, considerando tanto os termos em português quanto suas respectivas traduções em inglês. As expressões utilizadas na busca foram: em português, "inteligência artificial", "aprendizado de máquina", "aprendizado profundo", "rede neural", "rede neural convolucional", "sistema especialista", "processamento de linguagem natural", "visão computacional", "robótica inteligente", "algoritmo de IA", "mineração de dados", "análise preditiva", "modelo preditivo" e "classificação automática"; e, em inglês, "artificial intelligence", "machine learning", "deep learning", "neural network", "convolutional neural network", "expert system", "natural language processing", "computer vision", "intelligent robotics", "AI algorithm", "data mining", "predictive analytics", "predictive model" e "automatic classification".

Esses dados foram analisados conjuntamente com as informações descritivas de cada uma das ocupações da Classificação Brasileira de Ocupações (CBO). Para este estudo, foram extraídas as descrições das tarefas associadas a cada ocupação, conforme apresentadas nas publicações oficiais da CBO, que detalham as atividades desempenhadas e as responsabilidades inerentes a cada função.

Conforme detalha a seção a próxima seção, os resultados do Índice de Exposição à Inteligência Artificial, obtidos por ocupação, foram combinados com informações da Relação Anual de Informações Sociais (RAIS), do Ministério do Trabalho e Emprego, a qual oferece dados sobre vínculos empregatícios formais no Brasil. A partir dessa base, foram extraídas informações relativas à composição regional das ocupações classificadas segundo a CBO, bem como dados referentes ao número de vínculos e à renda média de cada ocupação, com desagregação por município e por ano.

### **3. Metodologia**

A metodologia adotada neste trabalho utiliza-se de forma complementar, das abordagens propostas por [Webb \(2019\)](#) e [Yang and Kim \(2024\)](#), que serão detalhadas nos tópicos subsequentes. Enquanto a proposta de [Webb \(2019\)](#) serve de embasamento para a construção do índice de exposição das ocupações brasileiras à inteligência artificial, a contribuição de [Yang and Kim \(2024\)](#) fundamenta a aplicação de técnicas de análise espacial, permitindo examinar eventuais efeitos de transbordamento desses impactos em todos os municípios do país.

#### **3.1. Índice de Exposição das Ocupações Brasileiras à Inteligência Artificial**

O índice de exposição ocupacional à inteligência artificial foi construído com base na metodologia proposta por [Webb \(2019\)](#), porém adaptado ao contexto das ocupações brasileiras segundo a Classificação Brasileira de Ocupações (CBO) agrupadas por família.

A abordagem metodológica adotada consiste no emprego de técnicas de Processamento de Linguagem Natural (NLP, *Natural Language Processing*), que envolvem métodos computacionais e estatísticos para o tratamento e análise de textos não estruturados (Jurafsky and Martin, 2025), que permitiram que fossem quantificados e relacionados os textos de patentes de inteligência artificial obtidos da base de dados do *Google Patents* com as descrições das tarefas relacionadas às ocupações brasileiras constantes da CBO.

Para o processamento dos dados, visando à construção do índice, foram utilizados pacotes de algoritmos já consolidados para análise de dados textuais via NLP. Os pacotes escolhidos seguem as recomendações da literatura, especialmente Silge et al. (2017) e Welbers et al. (2017)<sup>2</sup>

A organização e tratamentos dos textos de patentes e CBO foi realizada a partir do pacote UDPipe (Wijffels, 2021; Straka and Straková, 2017). Trata-se de modelo previamente treinado com uma grande base de textos que permite identificar automaticamente palavras, suas funções gramaticais (como verbos, substantivos e adjetivos) e até mesmo simplificar as palavras às suas formas básicas (lematização) (Wijffels, 2021; Straka and Straková, 2017)

Sendo assim, a partir do carregamento dos dois conjuntos de dados (*i*) as descrições sumárias das tarefas das ocupações da CBO e (*ii*) o texto das patentes brasileiras relacionadas à IA, foi feita uma pré-filtragem e concatenação das descrições válidas, conforme técnicas de limpeza textual descritas por Feinerer et al. (2008), que garantem a relevância e qualidade dos dados.

Segundo os autores, textos em formato bruto contêm informações irrelevantes (exemplo de “e” ou “o”), lacunas ou inconsistências que prejudicam análises que devem ser feitas a partir deles, motivo pelo qual realizar a limpeza inicial e organizar adequadamente os dados selecionando apenas textos relevantes, removendo duplicidades e concatenando-os em um formato estruturado é imprescindível para assegurar a qualidade, clareza e relevância dos dados utilizados em estudos que envolvam a mineração de texto via PLN. (Feinerer et al., 2008)

A etapa subsequente à de pré-processamento textual foi a de anotação linguística dos textos utilizando o modelo UDPipe. Esse processo aplica análise sintática e morfológica aos textos das tarefas da CBO e das patentes, o que permitiu extrair informações como lemas, classes gramaticais e relações de dependência entre as mais diversas palavras (Wijffels, 2021; Straka and Straková, 2017). Essa etapa faz-se necessária para a posterior extração estruturada dos pares verbo–substantivo de patentes e descrição das tarefas, conforme proposta por Webb (2019), uma vez que fornece informações sintáticas que são capazes de identificar as relações de interesse entre os *tokens*.

Após a anotação linguística e em conformidade com a metodologia proposta por Webb (2019), procedeu-se à extração de pares verbo–substantivo provenientes de patentes e tarefas, com base na estrutura sintática das sentenças, a partir do *parsing* gerado pelo pacote *udpipe*<sup>3</sup>.

---

<sup>2</sup>O detalhamento dos pacotes utilizados, bem como toda a programação e etapas metodológicas não foi incluído devido ao limite de páginas, mas pode ser requisitado às autoras.

<sup>3</sup>O *parsing* sintático (*syntactic parsing*) é uma técnica de Processamento de Linguagem Natural (NLP) que atribui uma representação gramatical formal a uma sentença, permitindo a análise das relações entre as palavras que a compõem

Esse processo possibilita identificar quais substantivos estão associados a determinados verbos, bem como a função sintática desempenhada por cada termo-sujeito, objeto direto ou modificador. A representação resultante, segundo [Dan and Martin James \(2009\)](#), frequentemente estruturada em árvores sintáticas (*parse trees*), constitui um recurso fundamental para múltiplas tarefas de análise linguística e semântica.

Os pares verbo-substantivo extraídos das descrições ocupacionais (CBO) e das patentes foram transformados em representações numéricas por meio do algoritmo *Global Vectors for Word Representation* (GloVe), que, segundo [Pennington et al. \(2014\)](#), é uma técnica amplamente utilizada em NLP pela capacidade de capturar relações semânticas entre palavras. A partir de uma *document-term matrix* (DTM), foram adotados os parâmetros  $rank = 300$ ,  $x_{max} = 100$  e  $n_{iter} = 30$ , conforme recomendações de [Pennington et al. \(2014\)](#), buscando equilibrar detalhamento semântico e robustez estatística. Para garantir reprodutibilidade, definiu-se uma semente aleatória, conforme sugerem [Bouthillier et al. \(2021\)](#).

A etapa seguinte foi definir a similaridade entre os vetores médios dos pares verbo-substantivo, medida por meio da similaridade por cosseno, que avalia a proximidade entre vetores com base no cosseno do ângulo entre eles, priorizando a direção em detrimento da magnitude ([Martin and Jurafsky, 2009](#); [Goldberg, 2017](#)). Para assegurar consistência e eficiência, os *embeddings* foram armazenados de forma estruturada e reutilizável, em conformidade com [Martin and Jurafsky \(2009\)](#).

Finalmente, foi calculado o índice de exposição ocupacional à inteligência artificial como a média dos escores de similaridade obtidos para os pares verbo-substantivo de cada tarefa:

$$\text{Índice}_{IA_j} = \frac{1}{n_j} \sum_{i=1}^{n_j} s_{ij} \quad (1)$$

em que  $n_j$  representa o número de pares da tarefa  $j$  e  $s_{ij}$  o escore de similaridade do par  $i$ . Seguindo [Webb \(2019\)](#), agregaram-se os resultados por tarefa; porém, na ausência de pesos para a CBO, utilizou-se a média aritmética simples por ocupação, posteriormente ponderada pelo número de trabalhadores na ocupação correspondente.

### 3.1.1. Diferenças metodológicas

A metodologia empregada neste trabalho fundamenta-se no trabalho de [Webb \(2019\)](#) que utiliza o método de similaridade semântica para mensurar o grau de exposição ocupacional à inteligência artificial. Porém, foram necessárias adaptações ao contexto ocupacional e linguístico brasileiro. As principais diferenças serão pontuadas a seguir e encontram-se resumidas na [Tabela 1](#).

No trabalho original, [Webb \(2019\)](#) extrai de pares verbo-substantivo das descrições de tarefas da base norte-americana O\*NET (*Occupational Information Network*) e os compara com pares extraídos de títulos de patentes tecnológicas, especialmente aquelas relacionadas à IA. A partir dessa comparação, o autor atribuiu um escore de exposição a cada tarefa, que posterior-

**Tabela 1:** Comparação entre Webb (2019) e a versão adaptada neste trabalho

Etapa	Webb (2020)	Versão Adaptada
<b>Fonte das tarefas</b>	O*NET (tarefas estruturadas com pesos e categorias)	CBO (descrições sumárias textuais)
<b>Fonte das patentes</b>	Google Patents	Google Patents
<b>Texto das patentes</b>	Títulos (alta relação sinal-ruído)	Títulos (alta relação sinal-ruído)
<b>Extração linguística</b>	Parser de dependência (modelo em inglês)	UDPipe (modelo em português treinado por corpus)
<b>Agrupamento semântico</b>	Sim (WordNet para categorias conceituais)	Não (pares analisados diretamente)
<b>Vetorização</b>	Não especificado	GloVe treinado localmente com vocabulário combinado
<b>Cálculo da similaridade</b>	Frequência relativa de pares semelhantes nas patentes	Similaridade por cosseno (máxima) entre vetores dos pares verbo-substantivo
<b>Agregação por tarefa / ocupação</b>	Média ponderada por importância, frequência e relevância	Média aritmética simples (sem ponderação, por ausência de atribuição de pesos pela CBO)
<b>Idioma</b>	Inglês técnico (padrão O*NET)	Português brasileiro (padrão CBO)
<b>Ferramentas</b>	Não especificado.	R (UDPipe, text2vec, GloVe, tidyverse)

Fonte: Elaboração própria.

mente foi agregado por ocupação, ponderando-se a relevância das tarefas segundo critérios da O\*NET. No presente trabalho, foi mantida a lógica central dessa abordagem, mas com ajustes técnicos importantes e necessários aos dados e à linguagem do Brasil. As tarefas foram extraídas da Classificação Brasileira de Ocupações (CBO), utilizando Processamento de Linguagem Natural com o pacote *udpipe* para a anotação sintática em língua portuguesa, conforme detalha a seção anterior. No entanto, na CBO, não há uma estrutura correspondente ao que a O\*NET traz quanto a informações estruturadas e quantificadas sobre tarefas (incluindo frequência, importância e relevância) (National Center for O\*NET Development, 2023; Webb, 2019).

Desta forma, no presente trabalho, os pares verbo-substantivo foram extraídos de ambas as bases (tarefas e patentes) e vetorizados utilizando *embeddings* semânticos com base no modelo GloVe. Diferentemente de Webb (2019), que mede a frequência relativa de pares semelhantes nas patentes, utilizou-se neste trabalho a similaridade por cosseno entre os vetores semânticos dos pares, para medir o grau de correspondência entre as tarefas ocupacionais e os conteúdos das patentes de IA. Essa decisão metodológica ocorreu devido a três fatores principais: (i) o modelo GloVe possibilita representar o significado das palavras de forma vetorial ao aprender, a partir de grandes volumes de texto, como elas costumam aparecer juntas em diferentes contextos, ou seja, ele capta relações de sentido com base na coocorrência entre os termos (Pennington et al., 2014); (ii), a ausência de dados estruturados no padrão O\*NET em português, como frequência e relevância de tarefas, inviabilizou a aplicação direta da métrica baseada em frequência relativa usada por Webb (2019); e, por fim, (iii) a similaridade por cosseno é uma medida amplamente reconhecida em PLN para comparar vetores semânticos, sendo adequada para avaliar proximidade contextual entre expressões textuais (Martin and Jurafsky, 2009; Pennington et al., 2014).

Além disso, [Webb \(2019\)](#) realiza agrupamento semântico dos substantivos com auxílio da base WordNet desenvolvida pela Universidade de Princeton e pondera cada tarefa segundo sua importância, frequência e relevância na ocupação, conforme disponível no O\*NET. Tais recursos não possuem equivalentes diretos em português ou na CBO, motivo pelo qual adotou-se a média aritmética simples dos escores de similaridade como critério de agregação por tarefa.

Conforme descrito na Seção 3.2, para a análise regional será feita a ponderação do índice de IA obtido, o que permitirá avaliar o seu impacto regionalmente.

Assim, a metodologia ora desenvolvida preserva a essência da abordagem de [Webb \(2019\)](#), qual seja, a de mensurar a sobreposição semântica entre tarefas ocupacionais e tecnologias de inteligência artificial descritas em patentes, mas implementa um conjunto de procedimentos adaptados para garantir aplicabilidade ao caso brasileiro.

### 3.2. Índice de Exposição Regional à Inteligência Artificial

O índice de exposição da ocupação à IA, calculado conforme descreve a seção anterior, não é suficiente para avaliar o impacto agregado dessa tecnologia sobre uma determinada localidade, pois sua medida varia apenas por ocupações. Para viabilizar essa análise, foi construído um indicador regional de exposição dos municípios à IA, que considere não apenas o grau de exposição das ocupações, mas também a estrutura de emprego de cada município brasileiro.

A lógica por trás dessa abordagem se baseia no fato de que regiões cujas estruturas ocupacionais estão mais concentradas em ocupações com altos índices de exposição à IA estarão mais vulneráveis à automação devido ao avanço da inteligência artificial.

Seguindo essa perspectiva, a metodologia adotada pondera o índice de IA de cada família de ocupação pela participação relativa dessa mesma ocupação na unidade geográfica de interesse, no caso todos os municípios brasileiros. Essa ponderação reflete a importância de cada ocupação na estrutura produtiva local e torna o indicador agregado sensível às dinâmicas regionais do mercado de trabalho, o que permite identificar municípios mais expostos à automação, comparar padrões territoriais de vulnerabilidade tecnológica e oferecer subsídios para a formulação de políticas públicas de requalificação profissional e mitigação de impactos da IA no emprego.

A equação proposta é inspirada na literatura de [Acemoglu and Restrepo \(2017\)](#), que propõem indicadores ponderados de exposição tecnológica a partir da composição ocupacional de uma dada base territorial. Para este trabalho, o índice agregado de exposição à IA para uma região  $R$  é dado por:

$$\text{Exposição}_{R,t} = \sum_{i=1}^{N_R} \left( \frac{E_{Ri,t}}{\sum_{j=1}^{N_R} E_{Rj,t}} \cdot IA_i \right) \quad (2)$$

Em que,  $E_{Ri,t}$  representa o número de vínculos ativos em 31/12 da ocupação  $i$  no município  $R$  no ano  $t = 2024$ ;  $\sum_{j=1}^{N_R} E_{Rj,t}$  é o total de vínculos ativos no município  $R$  no ano  $t = 2024$ ;  $IA_i$  é o índice de exposição à inteligência artificial da ocupação  $i$ , previamente calculado;  $N_R$  é o número total de ocupações observadas no município  $R$ .

Essa equação corresponde a uma média ponderada dos índices de exposição das ocupações, em que as ponderações refletem a participação relativa de cada ocupação na estrutura de empregos da região considerada, no caso, todos os municípios brasileiros. Essa ponderação foi feita em duas formas básicas: considerando o total de pessoas ocupadas e considerando a massa salarial de cada ocupação.

Para o cálculo do indicador regional, optou-se pela inclusão de todas as ocupações, inclusive daquelas cujo índice de exposição à IA resultou em zero. Essa decisão decorre da necessidade de representar de forma integral a estrutura ocupacional dos municípios, com intuito de que o índice reflita não apenas o grau de exposição das ocupações expostas, mas também o peso relativo das atividades não expostas. Excluir ocupações com índice nulo implicaria um viés de seleção, ao superestimar a vulnerabilidade tecnológica das regiões e comprometer a comparabilidade entre localidades com diferentes estruturas produtivas.

Desse modo, o índice agregado torna-se sensível à composição do mercado de trabalho local, atribuindo maior peso às ocupações que concentram mais trabalhadores, ou maiores salários. Ainda que o Índice de Exposição das Ocupações à Inteligência Artificial seja único por ocupação, como a estrutura ocupacional tende a se modificar ao longo do tempo, o indicador é variável ao longo do tempo, possibilitando um acompanhamento da evolução da exposição regional à IA. Esse artigo limita-se a analisar estatísticas descritivas básicas desses indicadores, seguindo a proposta de [Yang and Kim \(2024\)](#).

## **4. Resultados**

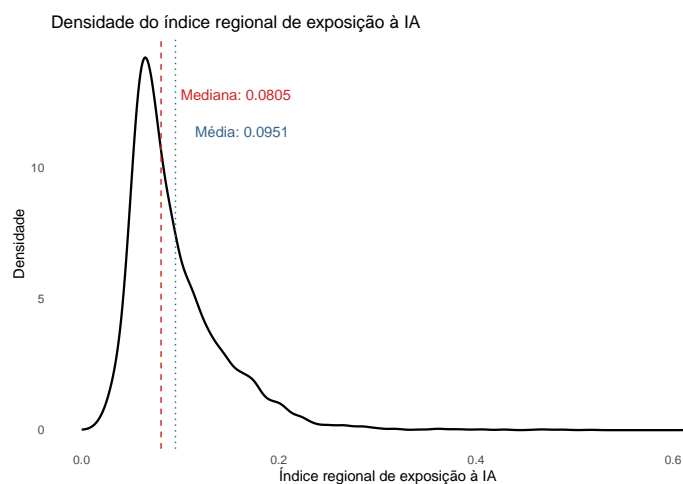
Os resultados mostram que as ocupações mais expostas à inteligência artificial concentram-se em atividades rotineiras e padronizadas, como Apontadores e Conferentes e Supervisores de Produção, ambas com índice máximo de exposição. Em contrapartida, ocupações com maior complexidade técnica ou que exigem intervenção humana, como as ligadas à segurança pública e à construção civil, tendem a apresentar exposição parcial, refletindo o papel complementar, e não necessariamente substitutivo, da IA no mercado de trabalho brasileiro. Dado o limite de espaço, esses resultados não serão detalhados nesse artigo. Nesta seção serão reportados os resultados da [Subseção 3.2](#), cujo índice regional, a nível de municípios, foi construído como a média ponderada dos índices ocupacionais pela distribuição do emprego formal em cada município. O indicador resume, em um único valor para cada município, a exposição potencial da sua estrutura ocupacional à IA com dados de 2024, permitindo comparar localidades e identificar padrões territoriais de maior exposição a essa tecnologia.

### **4.1. Análise Descritiva dos Dados**

A estatística descritiva do índice de exposição dos municípios brasileiros à inteligência artificial revela uma distribuição bastante heterogênea entre os entes federados. O valor mínimo observado é igual a zero, indicando que há municípios sem qualquer exposição à IA. O primeiro quartil, situado em 0,0619, mostra que 25% dos municípios apresentam baixa exposição

relativa, com valores bem abaixo da média e da mediana nacional. O município mediano tem um índice de 0,0805, valor próximo à média nacional de 0,0951, o que sugere que a maioria das localidades se concentra em níveis moderados de exposição. O terceiro quartil, em 0,1154, e o valor máximo, de 0,6211, evidenciam a existência de municípios altamente expostos, reforçando o caráter desigual da distribuição.

A diferença entre média e mediana indica uma assimetria positiva, reforçada pela cauda longa à direita da curva de distribuição que pode ser visualizada na [Figura 1](#). Enquanto o terceiro quartil é 0,1154, o máximo alcança 0,6211, evidenciando a existência de municípios *outliers* fortemente expostos à IA. Observa-se que como a média (0,0951) posiciona-se acima da mediana há uma assimetria positiva, que decorre da influência exercida por um conjunto reduzido de municípios com elevada exposição à IA. Essa configuração indica que, muito embora a maioria das localidades esteja sujeita a níveis moderados de exposição, uma fração menor, mas relevante dos municípios brasileiros concentra maior exposição à IA que pode levar a riscos mais elevados de automação, demandando políticas de capacitação e adaptação tecnológica mais específicas.

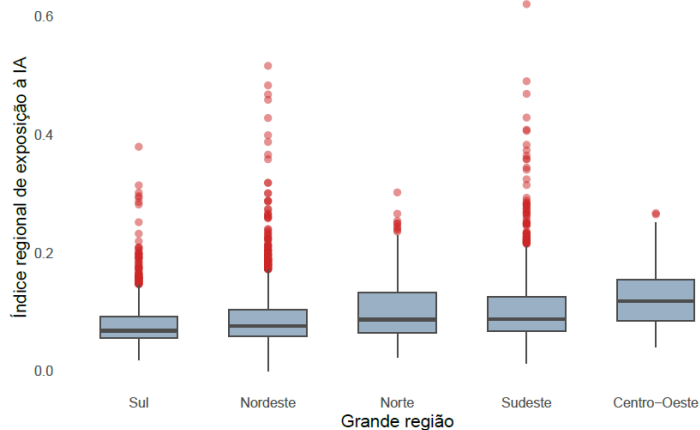


**Figura 1:** Densidade da exposição dos municípios brasileiros à IA

Fonte: Elaboração própria.

A [Figura 2](#) mostra a decomposição regional da exposição dos municípios brasileiros à inteligência artificial. Pode-se verificar que o Centro-Oeste apresenta a mediana mais elevada, sugerindo que seus municípios estão mais expostos à IA. O Sudeste e o Norte exibem medianas muito próximas, mas o Sudeste apresenta maior dispersão e a presença de municípios *outliers*, que puxam a cauda da distribuição e reforçam a assimetria positiva no agregado nacional. A região Nordeste situa-se em posição intermediária, enquanto a região Sul concentra a mediana mais baixa do país, indicando que seus municípios são os menos expostos à IA, resultados que denotam que a exposição ocupacional à inteligência artificial no Brasil não é homogênea.

O município que aparece como o mais exposto à IA no Brasil é Comendador Gomes ([Tabela A1](#)), pertencente ao Triângulo Mineiro, que possui uma economia altamente especializada



**Figura 2:** Exposição das grandes regiões à IA

Fonte: Elaboração própria.

e orientada ao agronegócio<sup>4</sup>, com forte encadeamento em operações mecanizadas, manutenção de maquinário, logística e rotinas administrativas. De acordo com RAIS, no ano de 2024 Comendador Gomes registrou cerca de 2,4 mil vínculos formais e apenas 71 famílias ocupacionais da CBO, o que reforça o efeito de concentração devido a limitada diversificação ocupacional local. Ou seja, a combinação de (i) carteira produtiva pouco diversificada, (ii) participação elevada de tarefas rotineiras e mecanizáveis relacionadas à agricultura e (iii) base de empregos concentrada em poucas ocupações com alto índice de potencial exposição à IA explica por que o município lidera o ranking nacional de exposição à IA.

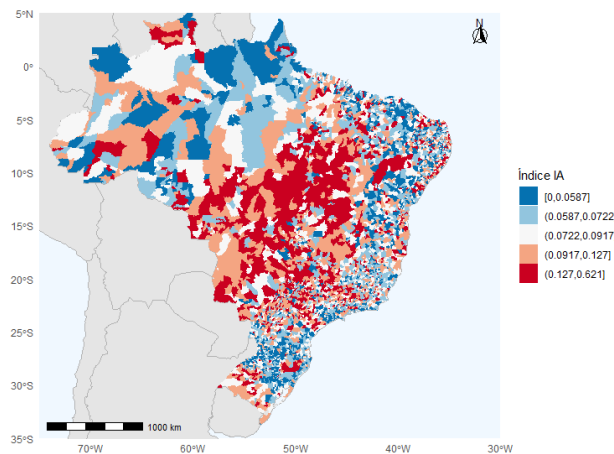
A Tabela A2 mostra o ranking das capitais brasileiras cuja estrutura ocupacional está mais exposta à IA. Observa-se que todas as capitais se concentram no primeiro quartil da distribuição, ou seja, no agregado sua estrutura ocupacional apresenta baixa exposição relativa à IA. Esse resultado pode ser explicado por fatores estruturais do mercado de trabalho urbano. Isso porque, como as capitais brasileiras concentram o maior número absoluto de vínculos formais de trabalho, há grande diversificação ocupacional, já que os vínculos abrangem os setores de comércio, serviços, indústria, administração pública, além de também haver atividades de baixa intensidade tecnológica que compõem parcela substancial do emprego formal, diluindo o peso relativo das ocupações mais expostas à IA.

Outro fator importante é a heterogeneidade interna, pois em municípios maiores, a presença de setores altamente expostos, como os de tecnologia da informação e serviços financeiros, convivem com atividades de baixa exposição, de modo que o índice agregado pode resultar moderado. Por fim, a elevada base de empregos nas capitais faz com que a ponderação reduza o impacto relativo de nichos ocupacionais muito expostos, ao contrário do que ocorre em municípios pequenos, onde a especialização em um conjunto restrito de ocupações pode elevar fortemente a média ponderada.

<sup>4</sup>Do ponto de vista socioeconômico, Comendador Gomes é um município de pequeno porte, com população de 2.773 pessoas conforme dados do último censo demográfico (IBGE, 2025), tendo como principal valor adicionado municipal a agropecuária e atividades correlatas (DataMPE Brasil, 2025).

Esclarece-se que os resultados até então obtidos dizem respeito à exposição agregada dos municípios, mas a análise pode apresentar um quadro muito distinto quando o recorte é feito por setor de atividade econômica. Isso porque a exposição à inteligência artificial não é homogênea entre setores, já que alguns, como tecnologia da informação, finanças e atividades administrativas, concentram ocupações que podem estar altamente suscetíveis à IA, enquanto outros, como serviços públicos locais tendem a apresentar índices mais baixos.

A **Figura 3** traz um mapa que contém a distribuição espacial do índice municipal de exposição à inteligência artificial. Pode-se observar que a maior parcela dos municípios brasileiros apresenta níveis baixos a moderados de exposição à IA caracterizados pelas cores mais fortes, com valores concentrados em torno da média nacional (0,09515), denotando que as estruturas ocupacionais locais brasileiras, no agregado, são menos suscetíveis a eventual automação por IA e também à obtenção dos benefícios que emergem junto a esta nova tecnologia.



**Figura 3:** Exposição regional à IA

Fonte: Elaboração própria.

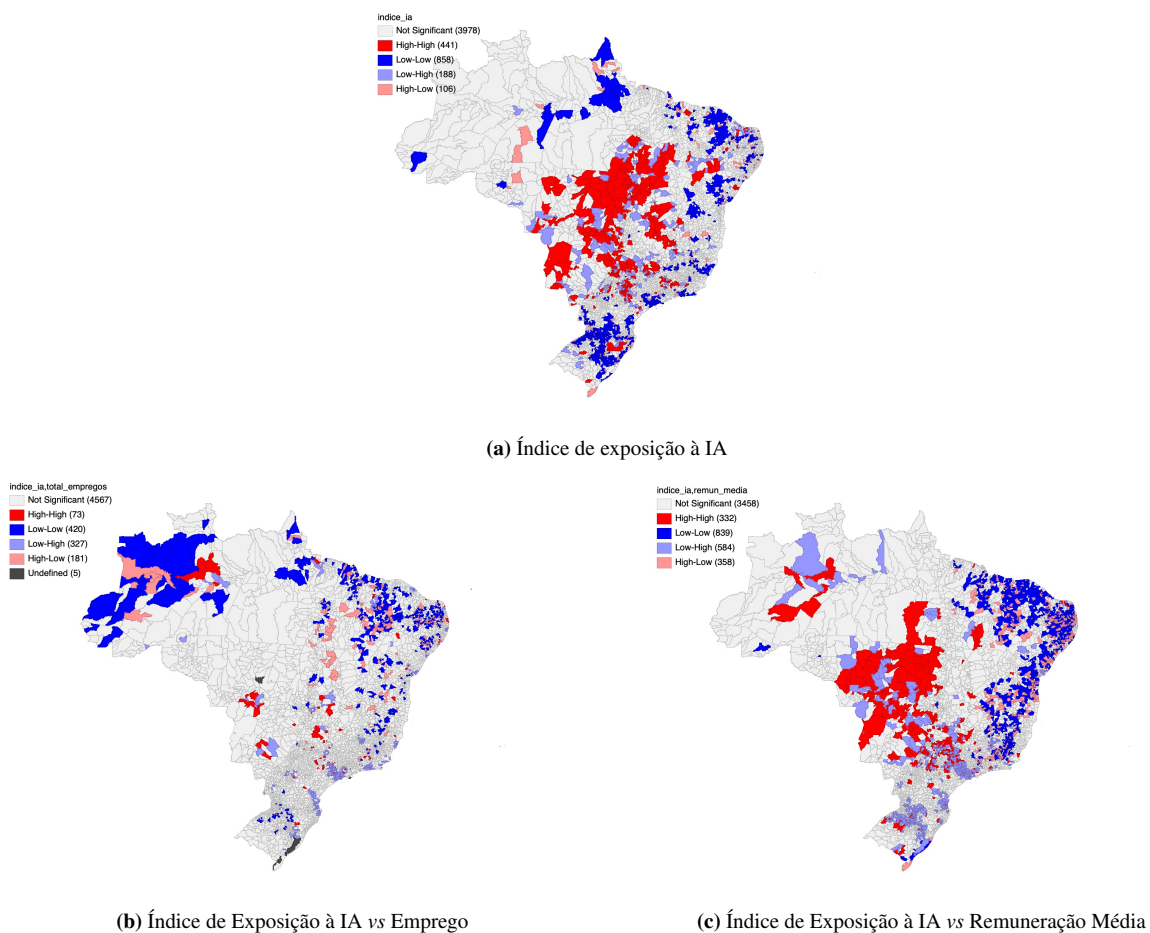
Por outro lado, observam-se pontos isolados em vermelho e laranja, que correspondem a municípios que atingem níveis de exposição muito superiores à média, próximos ao limite superior da escala (0,6). Esses casos configuram *outliers*, associados a mercados de trabalho locais altamente concentrados em atividades intensivas em tarefas padronizadas e de fácil aprendizado por máquinas. A distribuição desses municípios não se restringe a uma região específica, mas aparece dispersa pelo território nacional, denotando que a exposição tecnológica é mais ou menos intensa conforme a especialização produtiva de cada localidade.

Desta forma, a distribuição do índice se mostra heterogênea entre os diferentes entes federativos subnacionais, o que demonstra a importância de políticas públicas voltadas à qualificação profissional em áreas tecnológicas e ao estímulo à diversificação produtiva, de maneira a aumentar a resiliência de emprego e renda no mercado de trabalho.

#### **4.2. Análise Exploratória de Dados Espaciais - AEDE**

A análise espacial do índice de exposição à inteligência artificial mensura e aponta para a existência de heterogeneidade regional no Brasil. Essa assimetria manifesta-se pela concentra-

ção de municípios pouco expostos à IA, em grande parte do território, especialmente no Sul, Nordeste e uma parte do Norte, enquanto os municípios com alta exposição à IA se distribuem de forma mais localizada em áreas do Centro-Oeste e Sudeste, tal qual demonstrado anteriormente no [Figura 2](#). A Figura (a) do [Figura 4](#) apresenta uma autocorrelação espacial global positiva moderada (I de Moran de 0,283), o que confirma a existência de *clusters* espaciais, indicando que municípios com altos índices de exposição à IA tendem a se agrupar. Os *clusters High-High* se localizam em regiões de maior inserção produtiva, reforçando que embora a maioria dos municípios apresente baixa exposição, há bolsões específicos de concentração acima da média e do terceiro quartil que formam ilhas de especialização. Já os agrupamentos *Low-Low* reforçam a predominância de áreas de baixíssima exposição, em linha com a posição central da distribuição.



**Figura 4:** Análise AEDE — distribuição regional dos índices de exposição à IA

Fonte: Elaboração própria.

Ao relacionar o índice regional de IA com o total de empregos ([Figura 4b](#)), o I de Moran negativo (-0,058) e significativo, porém com valores muito baixos de concentração espacial. Esse resultado dialoga com a estatística descritiva, uma vez que municípios de alta exposição que estão localizados acima do terceiro quartil, não necessariamente coincidem com os de maior volume de empregos, conforme se verifica na [Tabela A1](#) que traz os 10 (dez) municípios brasileiros mais expostos à IA, há elevada concentração em municípios com pouco emprego.

Como o mapa LISA<sup>5</sup> (Figura 4a) indica, em diversas regiões observa-se a presença *outliers* espaciais, formando *clusters* do tipo *High-Low* e *Low-High*, de tal forma que municípios altamente expostos à IA podem estar cercados por vizinhos pouco expostos, e vice-versa. Esse padrão espacial indica indícios de que a exposição à IA esteja mais relacionada à estrutura ocupacional específica de cada localidade do que ao número absoluto de vínculos empregatícios, reforçando a importância de considerar a natureza das atividades exercidas pela força de trabalho regional.

No caso da relação entre o índice regional de IA e a remuneração média (Figura 4c), o I de Moran praticamente nulo (0,036) porém significativo indica que locais com maior exposição estão próximos de locais com maior nível salarial. Embora a concentração seja baixa, o LISA identifica agrupamentos *High-High* sobretudo no Centro-Oeste e em algumas áreas das demais regiões do país, indicando que a difusão tecnológica da IA está mais presente em economias locais associadas ao agronegócio intensivo em tecnologia e a serviços urbanos especializados, que tendem a oferecer salários mais elevados. Por outro lado, os agrupamentos *Low-Low* concentram-se principalmente no Nordeste e parte de Minas Gerais, enquanto no Sudeste, há diversos *clusters Low-High* reforçando a existência de disparidades regionais.

Esses resultados indicam um padrão heterogêneo e relacionado às estruturas produtivas locais, como consequência da maior exposição concentrada em ocupações específicas, esse ponto será analisado de forma preliminar na próxima seção.

#### 4.3. Inteligência Artificial e Estrutura do Valor Adicionado - Evidência Descritiva


Nesta subseção será analisada a associação entre a exposição ocupacional à inteligência artificial e o nível de atividade econômica municipal nas grandes regiões brasileiras, sendo este medido pela transformação logarítmica em base 10 das variáveis econômicas PIB e Valores Adicionados setoriais. O índice de exposição à IA dos municípios foi dividido em tercís, a saber, Baixa, Média e Alta exposição à IA, permitindo compará-lo dentro de cada região com as distribuições do PIB e dos Valores Adicionados setoriais, sendo eles a agropecuária, indústria, serviços e a administração pública/despesas sociais.

A Figura 5 mostra a associação entre o índice de IA e as variáveis que medem o nível de atividade econômica regional. Na figura, há indícios de uma associação positiva entre exposição à inteligência artificial e a escala econômica quando a mediana do nível de atividade econômica aumenta ao passar de Baixa para Média e para Alta exposição à IA. Por outro lado, se as medianas se mostrarem estáveis, há ausência de padrão e, se caem, indicam associação negativa. Nota-se que o padrão de uma associação negativa é o mais recorrente, ou seja, a baixa exposição à IA está relacionada a maiores níveis de atividade econômica em quase todas as regiões e setores, exceto na região Sul e para a agropecuária.

No caso da região Sul, para a variável PIB observa-se um padrão em U invertido, pois a mediana do PIB é mais alta na faixa Média IA e mais baixa na Alta IA. Esse padrão indica que os

---

<sup>5</sup>*Local Indicators of Spatial Association*



**Figura 5:** Exposição à IA e atividade econômica

Fonte: Elaboração própria.

municípios moderadamente expostos concentram maior nível de atividade econômica, ao passo que a exposição muito alta está associada a localidades possivelmente menores e especializadas. Em relação ao valor adicionado agropecuário, as medianas são semelhantes entre Baixa, Média e Alta IA, indicando ausência de associação entre exposição à IA e a escala do agro na região Sul. Para a indústria, a mediana do valor adicionado industrial é menor em Alta IA do que em Baixa/Média IA, sugerindo que os municípios mais expostos não são, via de regra, os de maior valor adicionado industrial, o mesmo padrão observado para o setor de serviços e administração pública.

Já para a região Sudeste, verifica-se que a distribuição do PIB municipal em escala logarítmica apresenta um padrão decrescente ao longo das faixas de exposição à IA, ou seja, a mediana é mais elevada em Baixa IA, reduz-se em Média IA e atinge seu menor nível em Alta IA. Esse comportamento indica que, na região, os municípios posicionados na faixa de maior exposição exibem, em média, nível de atividade econômica inferior ao observado entre aqueles de exposição baixa ou intermediária. No valor adicionado da agropecuária, as medianas permanecem muito próximas entre Baixa, Média e Alta IA, não se evidenciando associação entre exposição à IA e escala do agro no Sudeste. Para o valor adicionado da indústria, verifica-se redução da mediana na transição para Alta IA em relação a Baixa/Média IA; padrão análogo aparece em serviços e em administração pública/despesas sociais, cujas medianas também declinam na faixa de maior exposição, resultados esses que demonstram que maior exposição à IA não vem acompanhada de maior valor adicionado setorial.

Verifica-se padrões muito semelhantes aos da região Sul e Sudeste para as demais regiões do país, sendo curioso notar que em nenhuma região do país a alta exposição à IA pode ser

associada a um maior valor adicionado setorial, porém tal resultado deve ser lido com cautela, já que trata-se de evidência não causal e descritiva, em que são excluídos os valores não positivos de PIB e VA. Essa configuração é relevante do ponto de vista do mercado de trabalho, pois, seguindo o modelo proposto por Webb (2019) sem contrapartida de escala econômica, não se espera, no agregado, expansão do emprego ou aceleração salarial nas faixas de maior exposição à IA.

## 5. Conclusões

O artigo estima uma medida de exposição à inteligência artificial (IA) para o Brasil, combinando (i) um índice ocupacional obtido por similaridade semântica entre tarefas da CBO e títulos de patentes e (ii) uma agregação municipal ponderada pela estrutura de empregos formais (RAIS). A estratégia permite captar, de forma sintética, a vulnerabilidade potencial dos mercados de trabalho locais à automação por IA.

Os principais resultados evidenciam: (a) elevada heterogeneidade espacial, com assimetria positiva e municípios *outliers* altamente expostos; (b) capitais com exposição agregada relativamente baixa, coerente com maior diversificação ocupacional; e (c) autocorrelação espacial moderada do índice (padrões locais do tipo *High–High* e *Low–Low*), ao passo que emprego total e remuneração média não exibem padrão espacial global robusto em relação à exposição. Em conjunto, esses achados apontam que a composição ocupacional, e não apenas a escala econômica, é central para compreender a incidência regional da IA. Ademais, uma análise preliminar da relação entre o indicador e a estrutura produtiva, indica que regiões com elevado valor adicionado da indústria e serviços tendem a estar menos expostas à IA.

Do ponto de vista de políticas públicas, os resultados indicam a conveniência de: programas de requalificação e reconversão profissional focados em ocupações mais expostas; incentivos à diversificação produtiva em localidades especializadas em tarefas mais automatizáveis; e estratégias territoriais de difusão tecnológica que ampliem complementaridades entre trabalho e IA, mitigando riscos de substituição.

Este estudo é descritivo e não pretende inferir causalidade. Três frentes compõem a agenda de pesquisa: (1) identificação causal com dados em painel municipal; (2) decomposições setoriais de emprego e salários; e (3) extensões em equilíbrio geral que incorporem realocação ocupacional, efeitos de encadeamento e diferenciais de produtividade. Avanços nessas direções permitirão quantificar com maior precisão os impactos de curto e médio prazo da IA sobre emprego e rendimentos e orientar o desenho de políticas públicas frente a esse desafio.

## Referências

- Acemoglu, D. and Restrepo, P. (2017). Robots and jobs: Evidence from us labor markets. NBER Working Paper 23285, National Bureau of Economic Research. JEL No. J23, J24.
- Acemoglu, D. and Restrepo, P. (2018). The race between man and machine: Implications of technology for growth, factor shares, and employment. *American economic review*,

108(6):1488–1542.

- Amaral, J. G. (2023). A expansão da inteligência artificial e seu impacto nas dinâmicas sociais: desafios e responsabilidades. *Revista UFMG*, 30:80–107. Fluxo contínuo.
- Bernardi, B. B. (2012). O conceito de dependência da trajetória (path dependence): definições e controvérsias teóricas. *Perspectivas, Revista de Ciências Sociais, Universidade Estadual Paulista (UNESP)*, 41:137–167.
- Bouthillier, X., Delaunay, P., Bronzi, M., Trofimov, A., Nichyporuk, B., Szeto, J., Mohammadi Sepahvand, N., Raff, E., Madan, K., Voleti, V., et al. (2021). Accounting for variance in machine learning benchmarks. *Proceedings of Machine Learning and Systems*, 3:747–769.
- Buani Gonçalves, L. and De Almeida Reinaldi, M. A. (2024). Impacto da inteligência artificial no controle interno de instituições financeiras. *Revista Contabilidade & Inovação*, 3(1).
- Cahuc, P., Carcillo, S., and Zylberberg, A. (2014). *Labor Economics*. The MIT Press, 2nd edition.
- Dan, J. and Martin James, H. (2009). *Speech and language processing: An introduction to natural language processing, computational linguistics, and speech recognition*.
- DataMPE Brasil (2025). Perfil geográfico: Comendador Gomes — DataMPE Brasil. <https://datampe.sebrae.com.br/profile/geo/comendador-gomes#bespoke-title-25>. Acessado em 31 de agosto de 2025.
- dos Santos, R. M. and Vasconcelos, R. O. (2024). A atuação dos sistemas de transportes inteligentes no transporte público via ônibus impulsionado pelo 5g: uma revisão sistemática. *P2P E INOVAÇÃO*, 10(2).
- Feinerer, I., Hornik, K., and Meyer, D. (2008). Text mining infrastructure in r. *Journal of Statistical Software*, 25(5):1–54.
- Figliuzzi, R. S. (2018). *Inteligência artificial: um novo paradigma tecnológico?*
- Goldberg, Y. (2017). *Neural network methods in natural language processing*. Morgan & Claypool Publishers.
- IBGE (2025). Comendador Gomes — Minas Gerais — Cidades e Estados — IBGE. <https://www.ibge.gov.br/cidades-e-estados/mg/comendador-gomes.html>. Acessado em 31 de agosto de 2025.
- Jurafsky, D. and Martin, J. H. (2025). *Speech and Language Processing: An Introduction to Natural Language Processing, Computational Linguistics, and Speech Recognition with Language Models*. 3rd edition. Online manuscript released January 12, 2025.
- Lemes, M. M. and Lemos, A. N. L. E. (2020). O uso da inteligência artificial na saúde pela administração pública brasileira. *Cadernos Ibero-Americanos De Direito Sanitário*, 9(3):166–182.
- Lins de Araujo, R. D., Bagagi Lima, G., and da Silva Barbosa, B. (2023). Inteligência artificial e a política brasileira: Análise do chatgpt e seu potencial uso político, como ferramenta de manipulação de informações. *Conversas & Controvérsias*, 10(1):e44996.
- Magalhães, R. and Vendramini, A. (2018). Os impactos da quarta revolução industrial. *GV-*

- EXECUTIVO*, 17(1):40–43.
- Martin, J. H. and Jurafsky, D. (2009). *Speech and language processing: An introduction to natural language processing, computational linguistics, and speech recognition*, volume 23. Pearson/Prentice Hall Upper Saddle River.
- McCarthy, J., Minsky, M. L., Rochester, N., and Shannon, C. E. (1955). A proposal for the dartmouth summer research project on artificial intelligence. Accessed: 2024-09-20.
- National Center for O\*NET Development (2023). O\*net resource center. Accessed: 2025-07-16.
- Ofori, P. E. and Ofori, I. K. (2024). The impact of frontier technology adoption on gender inequality: Evidence from africa.
- Pennington, J., Socher, R., and Manning, C. D. (2014). Glove: Global vectors for word representation. In *Proceedings of the 2014 conference on empirical methods in natural language processing (EMNLP)*, pages 1532–1543.
- Santos, V. S., Ribeiro, N. M., Lima, A. M. F., and Santos, A. S. (2022). Prospecção bibliométrica e patentária de tecnologias com inteligência artificial aplicáveis a smart cities. *Cadernos de Prospecção*, 15(2):523–540.
- Schumpeter, J. A. (2017). *Capitalismo, socialismo e democracia*. Editora da Unesp, São Paulo. Publicado originalmente em 1942. Tradução de Luiz Antônio Oliveira de Araújo. São Paulo: Editora da Unesp.
- Silge, J., Robinson, D., and Robinson, D. (2017). *Text mining with R: A tidy approach*. O’reilly Boston (MA).
- Straka, M. and Straková, J. (2017). Tokenizing, POS tagging, lemmatizing and parsing UD 2.0 with UDPipe. In Hajič, J. and Zeman, D., editors, *Proceedings of the CoNLL 2017 Shared Task: Multilingual Parsing from Raw Text to Universal Dependencies*, pages 88–99, Vancouver, Canada. Association for Computational Linguistics.
- von Dietrich, P. and Garcia, M. H. (2022). New challenges for women workers in brazil facing the wave of industry 4.0 technologies. *Gender & Development*, 30(3):459–476.
- Webb, M. (2019). The impact of artificial intelligence on the labor market. Disponível em SSRN 3482150.
- Welbers, K., van Atteveldt, W., and Benoit, K. (2017). Text analysis in r. *Communication Methods and Measures*, 11(4):245–265.
- Wijffels, J. (2021). udpipe: Tokenization, parts of speech tagging, lemmatization and dependency parsing with the “udpipe”“nlp” toolkit [manual].
- Yang, S. and Kim, D. (2024). Spatial distribution and characteristics of vulnerable occupations to artificial intelligence: cases from south korea. *The Annals of Regional Science*, 72:1079–1103.

## Apêndice

**Tabela A1:** Dez municípios brasileiros mais expostos à IA

Município	UF	Índice IA Regional	Total de Empregos
Comendador Gomes	MG	0,6211	2.427
João Costa	PI	0,5166	36
Reginópolis	SP	0,4910	1.571
Casa Nova	BA	0,4836	9.773
Lucianópolis	SP	0,4692	838
Ipanguaçu	RN	0,4683	1.258
Lagoa Grande	PE	0,4591	2.762
Ubajara	SP	0,4291	955
Afonso Bezerra	RN	0,4283	568
Delfinópolis	MG	0,4086	1.885

*Nota:* Os valores correspondem ao índice regional, nível município, de exposição à inteligência artificial ponderado pelo emprego formal (RAIS, 2024).

Fonte: Elaboração própria.

**Tabela A2:** Ranking das capitais brasileiras mais expostas à IA

Rank	Capital	UF	Índice IA Regional	Total de Empregos
1	Manaus	AM	0,0760	495.003
2	João Pessoa	PB	0,0645	216.389
3	Natal	RN	0,0632	229.614
4	Macapá	AP	0,0618	77.225
5	Cuiabá	MT	0,0603	212.360
6	Belém	PA	0,0599	298.241
7	Boa Vista	RR	0,0593	69.843
8	Campo Grande	MS	0,0593	232.394
9	Vitória	ES	0,0592	165.952
10	Aracaju	SE	0,0585	176.748
11	Curitiba	PR	0,0577	789.748
12	Teresina	PI	0,0575	220.061
13	Maceió	AL	0,0566	226.419
14	São Luís	MA	0,0563	301.793
15	Palmas	TO	0,0558	78.908
16	Goiânia	GO	0,0557	517.006
17	Rio Branco	AC	0,0546	74.537
18	Salvador	BA	0,0545	636.884
19	Rio de Janeiro	RJ	0,0542	1.973.299
20	Porto Velho	RO	0,0537	98.580
21	Fortaleza	CE	0,0534	712.523
22	Belo Horizonte	MG	0,0527	1.002.659
23	Recife	PE	0,0524	543.387
24	São Paulo	SP	0,0512	4.822.431
25	Porto Alegre	RS	0,0509	525.916
26	Florianópolis	SC	0,0497	219.624
27	Brasília	DF	0,0496	984.370

Fonte: Elaboração própria.