

UNIVERSIDADE FEDERAL DO PARANÁ

HELOISA RIBEIRO LOPES

EFEITOS DA INTELIGÊNCIA ARTIFICIAL SOBRE A RENDA E O EMPREGO NO  
BRASIL: PERSPECTIVAS REGIONAL E DE GÊNERO

CURITIBA

2026

HELOISA RIBEIRO LOPES

EFEITOS DA INTELIGÊNCIA ARTIFICIAL SOBRE A RENDA E O EMPREGO NO  
BRASIL: PERSPECTIVAS REGIONAL E DE GÊNERO

Trabalho apresentado como requisito parcial para a obtenção do título de Mestre em Desenvolvimento Econômico pelo Programa de Pós Graduação em Desenvolvimento Econômico do Setor de Ciências Sociais Aplicadas da Universidade Federal do Paraná.

Orientadora: Prof<sup>a</sup> Kênia Barreiro de Souza

CURITIBA

2026

DADOS INTERNACIONAIS DE CATALOGAÇÃO NA PUBLICAÇÃO (CIP)  
UNIVERSIDADE FEDERAL DO PARANÁ  
SISTEMA DE BIBLIOTECAS – BIBLIOTECA DE CIÊNCIAS SOCIAIS APLICADAS

Lopes, Heloisa Ribeiro

Efeitos da inteligência artificial sobre a renda e o emprego no Brasil:  
perspectivas regional e de gênero / Heloisa Ribeiro Lopes. – 2026.

1 recurso on-line: PDF.

Dissertação (mestrado) - Universidade Federal do Paraná, Setor de  
Ciências Sociais Aplicadas, Programa de Pós-Graduação em  
Desenvolvimento Econômico.

Orientadora: Kênia Barreiro de Souza.

1. Desenvolvimento Econômico. 2. Inteligência artificial. 3. Renda.  
4. Mulheres - Emprego. I. Souza, Kênia Barreiro. II. Universidade Federal  
do Paraná. Setor de Ciências Sociais Aplicadas. Programa  
Pós-Graduação em Desenvolvimento Econômico. III. Título.

Bibliotecário Eduardo Silveira – CRB – 9/1921



## TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação DESENVOLVIMENTO ECONÔMICO da Universidade Federal do Paraná foram convocados para realizar a arguição da dissertação de Mestrado de **HELOISA RIBEIRO LOPES**, intitulada: **EFEITOS DA INTELIGÊNCIA ARTIFICIAL SOBRE A RENDA E O EMPREGO NO BRASIL: PERSPECTIVAS REGIONAL E DE GÊNERO**, sob orientação da Profa. Dra. **KÊNIA BARREIRO DE SOUZA**, que após terem inquirido a aluna e realizada a avaliação do trabalho, são de parecer pela sua **APROVAÇÃO** no rito de defesa.

A outorga do título de mestra está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

CURITIBA, 12 de Fevereiro de 2026.

Assinatura Eletrônica

12/02/2026 16:07:43.0

**KÊNIA BARREIRO DE SOUZA**

Presidente da Banca Examinadora

Assinatura Eletrônica

18/02/2026 14:21:03.0

**LEONARDO CHAVES BORGES CARDOSO**

Avaliador Externo (UNIVERSIDADE FEDERAL DE VIÇOSA)

Assinatura Eletrônica

12/02/2026 17:43:22.0

**DENISE FUKUMI TSUNODA**

Avaliador Externo (UNIVERSIDADE FEDERAL DO PARANÁ - UFPR)

## RESUMO

O avanço da inteligência artificial (IA) tem transformado a dinâmica do mercado de trabalho ao criar novos requerimentos técnicos, ao mesmo tempo em que pode gerar substituição de tarefas, destruição de empregos, e efeitos de complementariedade. No caso das mulheres, não há consenso na literatura sobre qual seria o resultado sobre o emprego e os salários; por um lado, os efeitos de substituição e destruição de empregos podem ser intensificados, dado que as mulheres estão mais presentes em ocupações rotineiras e de menor qualificação e menos representadas em áreas STEM, por outro lado, a digitalização tem o potencial de ampliar suas oportunidades de inserção produtiva. Esta dissertação organiza-se em dois ensaios. O primeiro apresenta a construção pioneira de um índice nacional de exposição ocupacional à IA para as ocupações brasileiras, elaborado com técnicas de processamento de linguagem natural aplicadas às descrições da CBO e às patentes registradas no Brasil. A partir desse índice, desenvolveu-se também um índice regional de exposição à IA em nível municipal, obtido pela ponderação da exposição ocupacional pela estrutura de emprego e renda de cada município. Essa abordagem permitiu identificar diferenças regionais e potenciais efeitos de transbordamento entre municípios, além de viabilizar uma análise regional do impacto da IA sobre o emprego e a renda no Brasil, por meio da Análise Exploratória de Dados Espaciais (AEDE). Por sua vez, utilizando o índice construído no primeiro ensaio, o segundo ensaio analisa, sob uma perspectiva de gênero, como a exposição inicial à IA afeta o emprego e a renda das mulheres no período 2010 e 2024, incluindo as diferenças entre mulheres brancas e negras e os impactos sobre os *gaps* de gênero e raça. Os resultados indicam que no Brasil o avanço da inteligência artificial tem produzido efeitos negativos relativamente mais intensos sobre o grupo feminino no mercado de trabalho formal, o que tende a intensificar os *gaps* de gênero. De forma conjunta, os resultados contribuem para compreender como a difusão da IA interage com desigualdades estruturais e com a organização do mercado de trabalho brasileiro.

**Palavras-chave:** Índice de Inteligência artificial; Análise Regional; Emprego; Renda; Desigualdade de Gênero; Impactos Regionais.

## ABSTRACT

The advancement of artificial intelligence (AI) has transformed labor market dynamics by creating new technical requirements, while simultaneously generating task substitution, job destruction, and complementarity effects. In the case of women, there is no consensus in the literature regarding the expected impacts on employment and wages. On the one hand, substitution and job destruction effects may be intensified, given that women are more concentrated in routine and lower-skilled occupations and are underrepresented in STEM fields; on the other hand, digitalization has the potential to expand their opportunities for productive labor market participation. This dissertation is organized into two essays. The first presents the pioneering construction of a national index of occupational exposure to AI for Brazilian occupations, developed using natural language processing techniques applied to the descriptions of the Brazilian Classification of Occupations (CBO) and to patents registered in Brazil. Based on this index, a regional index of AI exposure at the municipal level was also developed, obtained by weighting occupational exposure by the employment and income structure of each municipality. This approach made it possible to identify regional differences and potential spillover effects across municipalities, as well as to enable a regional analysis of the impact of AI on employment and income in Brazil through Exploratory Spatial Data Analysis (ESDA). In turn, using the index constructed in the first essay, the second essay analyzes, from a gender perspective, how initial exposure to AI affects women's employment and income over the period 2010 and 2024, including differences between White and Black women and the impacts on gender and racial *gaps*. The results indicate that in Brazil the advancement of artificial intelligence has generated relatively more intense negative effects on women in the formal labor market, which tends to widen gender *gaps*. Taken together, the findings contribute to a better understanding of how the diffusion of AI interacts with structural inequalities and with the organization of the Brazilian labor market.

**Key-words:** Artificial Intelligence Index; Regional Analysis; Employment; Earnings; Gender Gaps; Regional Impacts.

## LISTA DE TABELAS

TABELA 2.1 – Comparação entre Webb (2019) e a versão adaptada nesta dissertação . . . . .	36
TABELA 2.2 – Dez ocupações brasileiras mais expostas à inteligência artificial .	38
TABELA 2.3 – Estatística descritiva do índice regional de exposição à IA . . . .	42
TABELA 2.4 – Dez municípios brasileiros mais expostos à IA . . . . .	45
TABELA 2.5 – Ranking das capitais brasileiras mais expostas à IA . . . . .	46
TABELA 3.1 – Municípios criados ou instalados após 2010, seus municípios de origem, bases legais e datas de instalação . . . . .	64
TABELA 3.2 – Emprego formal e renda média real do trabalho por gênero, 2010 e 2024. . . . .	71
TABELA 3.3 – Variações de emprego e renda feminina (2010–2024) . . . . .	72
TABELA 3.4 – Variações dos <i>gaps</i> de gênero e raça (2010–2024) . . . . .	74
TABELA 3.5 – Efeitos da exposição municipal à IA sobre emprego e renda formais (TWFE): comparação mulher vs. homem . . . . .	78
TABELA 3.6 – Efeitos da exposição municipal à IA por gênero e raça (TWFE). Referência: homem branco . . . . .	81
TABELA 3.7 – Efeitos da exposição municipal à IA sobre os <i>gaps</i> de emprego e renda (TWFE) — Hipótese H4 . . . . .	82
TABELA 3.8 – Efeitos da exposição municipal à IA sobre a participação no emprego formal (TWFE): comparação mulher vs. homem — Hipótese H5 . . . . .	83
TABELA 3.9 – Síntese dos resultados empíricos — Hipóteses H1 a H5 . . . . .	84

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO GERAL . . . . .</b>	<b>9</b>
<b>2</b>	<b>EFEITOS DA INTELIGÊNCIA ARTIFICIAL SOBRE O EMPREGO E A RENDA: UMA PERSPECTIVA REGIONAL . . . . .</b>	<b>12</b>
2.1	INTRODUÇÃO . . . . .	12
2.2	REVISÃO DE LITERATURA . . . . .	17
2.2.1	Aspectos Teóricos . . . . .	17
2.2.2	Medidas de Exposição à Inteligência Artificial . . . . .	19
2.2.3	Evidências Empíricas . . . . .	21
2.3	DADOS E METODOLOGIA . . . . .	26
2.3.1	Dados . . . . .	26
2.3.2	Metodologia . . . . .	28
2.3.2.1	Metodologia de Webb (2019) . . . . .	28
2.3.2.2	Construção do índice de exposição à IA . . . . .	31
2.3.2.3	Índice de Exposição das Ocupações Brasileiras à Inteligência Artificial	31
2.3.2.4	Índice de Exposição Regional à Inteligência Artificial . . . . .	34
2.3.2.5	Diferenças metodológicas . . . . .	35
2.4	RESULTADOS . . . . .	37
2.4.1	Índice de Exposição das Ocupações Brasileiras à Inteligência Artificial	37
2.4.2	Inovações de Mercado . . . . .	38
2.4.3	Exposição Regional à Inteligência Artificial . . . . .	42
2.4.3.1	Análise Descritiva dos Dados . . . . .	42
2.4.3.2	Análise Exploratória de Dados Espaciais - AEDE . . . . .	48
2.4.3.3	Inteligência Artificial e Estrutura do Valor Adicionado - Evidência Des- critiva . . . . .	50
2.5	CONSIDERAÇÕES FINAIS . . . . .	52
<b>3</b>	<b>EFEITOS DA INTELIGÊNCIA ARTIFICIAL SOBRE EMPREGO E RENDA DAS MULHERES: UMA ABORDAGEM EMPÍRICA PARA O CASO BRASILEIRO . . . . .</b>	<b>53</b>
3.1	INTRODUÇÃO . . . . .	54
3.2	REVISÃO DE LITERATURA . . . . .	56
3.2.1	Desigualdade de Gênero no Mercado de Trabalho . . . . .	56
3.2.2	Inteligência Artificial e Mercado de Trabalho Feminino . . . . .	59
3.3	DADOS E METODOLOGIA . . . . .	63

3.3.1	Base de dados . . . . .	63
3.3.2	Índice de exposição à IA, Gap de gênero e Participação feminina . .	65
3.3.3	Estratégia empírica . . . . .	66
3.4	RESULTADOS . . . . .	71
3.4.1	Evolução do emprego formal e da renda real por gênero e raça entre 2010 e 2024 . . . . .	71
3.4.2	Resultados das regressões . . . . .	77
3.4.3	Hipóteses da pesquisa e discussão com a literatura . . . . .	84
3.5	CONSIDERAÇÕES FINAIS . . . . .	87
<b>4</b>	<b>CONCLUSÃO GERAL . . . . .</b>	<b>88</b>
	<b>REFERÊNCIAS . . . . .</b>	<b>90</b>
	<b>APÊNDICE 1 – PROGRAMAÇÃO COMENTADA . . . . .</b>	<b>102</b>

## 1 INTRODUÇÃO GERAL

O debate internacional sobre os impactos da inteligência artificial (IA) no mercado de trabalho tem se intensificado diante da rápida expansão de tecnologias baseadas em aprendizado de máquina, processamento de linguagem natural e automação cognitiva. Embora exista consenso de que essas inovações reconfiguram a organização produtiva, ainda persistem dúvidas sobre a magnitude e a direção de seus efeitos sobre emprego, renda e desigualdades socioeconômicas. Em economias avançadas, estudos empíricos (Webb, 2019; Acemoglu; Restrepo, 2018a) têm mostrado que a IA altera tanto a estrutura das ocupações quanto as competências demandadas. No entanto, a compreensão dessas dinâmicas em países em desenvolvimento permanece limitada, sobretudo devido à ausência de métricas nacionais de exposição tecnológica e à heterogeneidade regional que caracteriza esses mercados de trabalho.

No caso brasileiro, esse debate adquire contornos particulares. A estrutura ocupacional do país combina elevados níveis de informalidade, desigualdades regionais persistentes e forte segmentação por gênero (Yahmed, 2018), elementos que podem amplificar ou mitigar os efeitos da automação. Assim, investigar como a IA se difunde nos municípios e como interage com a composição do emprego e com a remuneração do trabalho é fundamental para compreender a natureza das transformações produtivas em curso e suas implicações. A literatura aponta que a adoção tecnológica tende a se concentrar em espaços produtivamente dinâmicos, o que pode gerar assimetrias territoriais e reforçar disparidades já existentes (Yang; Kim, 2024; Sun et al., 2024). Avaliar tais efeitos demanda, portanto, instrumentos analíticos capazes de captar diferenças espaciais e ocupacionais no contexto brasileiro.

Além das desigualdades regionais sobre renda e emprego que o avanço da inteligência artificial pode provocar, as desigualdades de gênero constituem outra dimensão central para entender os efeitos dessa tecnologia. Diversos estudos têm destacado que a distribuição sexual do trabalho, historicamente marcada pela segregação ocupacional e por diferenças salariais, pode influenciar o modo como mulheres e homens experimentam a transição tecnológica (Albanesi et al., 2025; Ofori; Ofori, 2024; Lu et al., 2023). Ocupações com maior intensidade de tarefas rotineiras ou administrativas tendem a ser mais suscetíveis à automação, enquanto funções que requerem maior criatividade, interação socioemocional ou tomada de decisão complexa parecem relativamente menos expostas (Yang; Kim, 2024). Tais evidências colocam em pauta se a IA funcionará como vetor de ampliação das desigualdades ou se poderá abrir novas oportunidades de inclusão produtiva.

A literatura sobre inteligência artificial e mercado de trabalho ainda apresenta

limitações quando aplicada ao contexto brasileiro. Em termos metodológicos, observa-se a ausência de um índice nacional de exposição ocupacional à IA; no plano empírico, permanecem escassas as evidências sistemáticas sobre os efeitos potenciais dessas tecnologias no mercado de trabalho do país. Além disso, a literatura nacional ainda carece de análises que investiguem como tais efeitos podem se manifestar de forma heterogênea entre diferentes grupos populacionais, particularmente no que se refere às desigualdades de gênero e raça.

Portanto, o problema central identificado reside na ausência de evidência empírica sistemática para o Brasil, conduzida por meio de pesquisa quantitativa aplicada, que permita mensurar a exposição ocupacional e regional à Inteligência Artificial e examinar seus efeitos sobre emprego e a renda, considerando desigualdades regionais e de gênero.

A justificativa consiste na necessidade de ampliar as evidências empíricas sobre os reflexos da inteligência artificial no mercado de trabalho brasileiro, buscando contribuir para o debate ao propor uma investigação quantitativa aplicada sobre os potenciais efeitos da inteligência artificial no mercado de trabalho brasileiro a partir de duas frentes complementares. A primeira refere-se à construção de um Índice Nacional de Exposição Ocupacional à IA baseado em técnicas de processamento de linguagem natural e comparação semântica entre descrições da Classificação Brasileira de Ocupações (CBO) e patentes registradas no país, seguindo a metodologia proposta por Webb (2019).

A inexistência de medidas equivalentes no contexto nacional confere caráter pioneiro a esse esforço metodológico, ao permitir que a exposição tecnológica seja coerente às características das ocupações brasileiras. A partir desse índice ocupacional, desenvolve-se também um Índice Regional de Exposição à IA, ponderado pela composição ocupacional dos municípios brasileiros para o ano de 2024, permitindo compreender não apenas quais ocupações são mais expostas, mas também onde os efeitos potenciais podem ser mais intensos.

A segunda frente de investigação concentra-se sobre o mercado de trabalho feminino. A partir da medida de exposição ocupacional à inteligência artificial associada às ocupações observadas nos anos de 2010 e 2024, examinam-se os efeitos dessa exposição sobre a evolução do emprego e da renda de mulheres para os respectivos anos. Essa análise incorpora ainda as dimensões raciais, dada a relevância das interseccionalidades para explicar padrões diferenciados de inserção produtiva no Brasil. Considerando o histórico de desigualdade e a composição ocupacional feminina, compreender se a IA reforça vulnerabilidades ou se está associada a trajetórias de mobilidade econômica possibilita orientar políticas públicas e privadas de qualificação educacional e profissional, proteção social e promoção da igualdade de oportunidades.

Assim, o estudo busca contribuir para o avanço da literatura nacional e internacional, bem como para o debate sobre as implicações das transformações tecnológicas para o desenvolvimento econômico e regional do país, com enfoque especial em questões de gênero e raça, em consonância com a linha de pesquisa do programa.

Os resultados obtidos neste trabalho oferecem evidências inéditas para o caso brasileiro, ao integrar técnicas de processamento de linguagem natural (PLN), análise espacial e modelos econométricos aplicados a um horizonte temporal marcado por intensas transformações tecnológicas no Brasil e no mundo, tendo como principal questão de pesquisa a ser respondida se a exposição ocupacional à Inteligência Artificial está associada a mudanças na estrutura do emprego e da renda no Brasil, reforçando desigualdades regionais e de gênero, ou, então, se está atuando para mitigá-las.

Em conjunto, os dois ensaios contribuem para o entendimento de como a inteligência artificial se insere no mercado de trabalho brasileiro e quais grupos e regiões podem ser mais afetados por sua difusão. Neste aspecto, este estudo dialoga com a agenda contemporânea de pesquisa sobre automação devido ao advento da IA, desigualdades de gênero e desenvolvimento econômico regional, aderente às pesquisas desenvolvidas pelo PPGDE/UFPR, oferecendo subsídios para o debate acadêmico e para a formulação de políticas públicas que visem uma transição tecnológica inclusiva e sensível às desigualdades estruturais do país que se manifestam no mercado de trabalho.

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

### Resumo:

Este artigo desenvolve uma medida inédita de exposição ocupacional e regional à inteligência artificial (IA) para o Brasil e analisa sua distribuição espacial e potenciais padrões de dependência espacial entre municípios. Apesar da rápida difusão de tecnologias baseadas em IA, evidências empíricas para economias em desenvolvimento ainda são escassas, em grande parte devido à ausência de indicadores nacionais padronizados e à elevada heterogeneidade regional dos mercados de trabalho. A estratégia metodológica combina técnicas de processamento de linguagem natural aplicadas às descrições textuais das ocupações brasileiras e aos títulos de patentes relacionadas à IA, permitindo mensurar a similaridade semântica entre tarefas ocupacionais e tecnologias emergentes. A partir desse procedimento, constrói-se um índice nacional de exposição ocupacional à IA, que é posteriormente agregado ao nível municipal por meio de ponderação pela estrutura local de emprego e rendimentos, com base em microdados administrativos da Relação Anual de Informações Sociais (RAIS). O indicador resultante capta a heterogeneidade espacial da exposição tecnológica nos municípios brasileiros. A análise empírica utiliza estatísticas descritivas e técnicas de Análise Exploratória de Dados Espaciais para identificar padrões de concentração, autocorrelação espacial e possíveis efeitos de transbordamento entre regiões. Os resultados evidenciam a presença de clusters estatisticamente significativos de alta exposição, concentrados sobretudo em regiões economicamente dinâmicas e em mercados de trabalho metropolitanos, enquanto municípios de menor diversificação produtiva apresentam níveis sistematicamente mais baixos de exposição. Adicionalmente, o estudo explora associações entre o índice municipal de exposição à IA e indicadores de emprego e rendimentos formais. As evidências sugerem forte heterogeneidade territorial e a presença de *spillovers* espaciais, indicando que a difusão tecnológica não ocorre de forma neutra no espaço e pode reforçar desigualdades regionais preexistentes. O artigo contribui ao disponibilizar uma medida nacionalmente consistente de exposição à IA adaptada à estrutura ocupacional brasileira e ao documentar seus padrões espaciais em uma grande economia em desenvolvimento, oferecendo subsídios relevantes para o desenho de políticas de inovação, qualificação da força de trabalho e desenvolvimento regional.

**Palavras-chave:** inteligência artificial; processamento de linguagem natural, mercado de trabalho; desigualdades regionais.

### 2.1 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; 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 a Indústria 4.0, alterando profundamente a maneira como as pessoas se conectam, trabalham e se relacionam (von Dietrich; 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, gama de serviços públicos como a mobilidade urbana e a eficiência dos serviços (Santos et al., 2022; Santos; 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; Lemos, 2020). No setor financeiro, algoritmos inteligentes atuam na gestão de investimentos, na detecção de fraudes e na antecipação de flutuações de mercado (Buani Gonçalves; 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).

Verifica-se que a literatura mundial tem debatido os impactos que a inteligência artificial tem causado 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; Kim,

2024), combinada ao surgimento de novas demandas para ocupações tecnológicas (Ofori; Ofori, 2024), evidencia a complexidade — e a ambiguidade — dos efeitos da inteligência artificial sobre o emprego e a renda, especialmente para as mulheres.

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). Compreender essa dinâmica sobre emprego e renda é algo que se mostra relevante, já que a automação intensificada pela inteligência artificial pode levar à substituição dos empregos existentes (Webb, 2019), gerando desemprego e crise econômica.

Isso porque a revolução provocada pela inteligência artificial traz um novo paradigma tecnológico que movimentará as estruturas da sociedade, gerando ondas de desenvolvimento ou de desemprego tecnológico, remontando a antiga discussão schumpeteriana de destruição criativa inerente ao capitalismo (Figliuzzi, 2018).

Para Schumpeter (2017), originalmente publicado em 1942, 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 de "destruição criativa" de Schumpeter (2017) também 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 (Santos; Vasconcelos, 2024), a construção de cidades inteligentes (Santos et al., 2022), entre outros — têm sido objeto de investigação por pesquisadores de diversos países, como Brasil, Estados Unidos, China e Coreia do Sul, além de diferentes campos científicos.

Os resultados encontrados pela literatura acerca dos impactos dessa tecnologia sobre o mercado de trabalho são ambíguos, com abordagens tanto otimistas em relação às consequências da emergência da IA sobre o trabalho, que compreendem que há uma complementariedade entre automação e trabalho humano (Autor, 2015), quanto pessimistas, que compreendem que a IA tem o potencial de substituir tarefas humanas

em larga escala (Gruetzemacher et al., 2020).

Essa dualidade também é explorada no trabalho de Webb (2019), que por sua vez, constitui a base teórica deste ensaio. Webb (2019), fundamentando-se na teoria proposta por Acemoglu e Restrepo (2018b), e 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 e Restrepo (2018b) 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 justificativa reside na necessidade de desenvolver uma medida de exposição ocupacional à inteligência artificial adaptada à estrutura do mercado de trabalho brasileiro, bem como de investigar sua distribuição espacial e suas possíveis implicações sobre emprego e renda nos municípios do país. Do ponto de vista científico, o estudo contribui para a literatura ao propor um índice aplicado ao contexto nacional e ao incorporar técnicas de análise exploratória de dados espaciais (AEDE) para analisar as

variáveis emprego e renda. Em termos sociais e econômicos, a pesquisa busca oferecer evidências que auxiliem a compreensão dos efeitos das transformações tecnológicas sobre o mercado de trabalho e o desenvolvimento regional, dialogando com a linha de pesquisa do PPGDE voltada à análise das dinâmicas econômicas regionais.

Por sua vez, o objetivo geral deste estudo é desenvolver uma pesquisa quantitativa aplicada voltada a construir uma medida de exposição ocupacional à Inteligência Artificial adaptada ao contexto brasileiro e analisar sua associação com a dinâmica do emprego e da renda no mercado de trabalho brasileiro, considerando o ano de 2024 como referência.

Especificamente, busca-se investigar em que medida a inteligência artificial influencia esses dois aspectos do mercado de trabalho, considerando as variações regionais desses efeitos. Para isso, inicialmente será construído um índice de inteligência artificial para o Brasil e municípios brasileiros, com base na metodologia de sobreposição semântica via processamento de linguagem natural (PLN) adotada por Webb (2019).

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 e 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, de onde será utilizada uma abordagem de análise espacial - AEDE, com o intuito de identificar padrões de distribuição e potenciais efeitos de transbordamento entre os municípios brasileiros.

O presente ensaio de dissertação está organizado em cinco capítulos, incluindo esta introdução. O Capítulo 2 reúne a revisão de literatura, dividida em três eixos: (i) os aspectos teóricos que discutem a relação entre tecnologia e mercado de trabalho; (ii) os aspectos metodológicos que embasam a construção do índice de inteligência artificial e os modelos econométricos mais adotados na literatura; (iii) e, por fim, um panorama das principais evidências empíricas sobre o tema.

No Capítulo 3, são apresentados os dados e a metodologia utilizados nesta dissertação, com destaque para a adaptação da proposta de Webb (2019) ao contexto brasileiro, à construção do índice de exposição ocupacional à inteligência artificial e os procedimentos adotados para se promover a análise espacial e econométrica. O Capítulo 4 traz os resultados empíricos da pesquisa, reunindo os principais achados, ao passo que o Capítulo 5 é dedicado às conclusões, as possíveis implicações para a formulação de políticas públicas e sugestões para trabalhos futuros.

## 2.2 REVISÃO DE LITERATURA

Neste capítulo serão abordados os aspectos teóricos, metodológicos e as evidências empíricas sobre os reflexos que novas tecnologias relacionadas à IA ocasionam no mercado de trabalho, notadamente o feminino.

### 2.2.1 Aspectos Teóricos

A partir da Primeira Revolução Industrial, que trouxe o surgimento de inovações como a máquina a vapor, bem como após a ocorrência de fatos históricos como o advento da eletricidade e dos computadores, a sociedade experienciou sequenciais ondas de desenvolvimento que modificaram profundamente os modos de produção e as exigências de qualificação técnica da força de trabalho (Rocha et al., 2020). No século XX, modelos organizacionais como o Fordismo, baseado na produção em massa e na padronização de tarefas, e o Toyotismo, com sua ênfase em flexibilidade, controle de qualidade e fluxo de componentes coordenado com base no sistema *just-in-time*, além do Volvismo, caracterizado por uma flexibilidade criativa, passaram a moldar diferentes dinâmicas produtivas do mercado de trabalho (Wood Jr, 1992). A partir da década de 1970, a revolução das TICs (Tecnologias da Informação e Comunicação) intensificou o processo de globalização, inaugurando uma nova fase de automação e digitalização da comunicação e dos processos produtivos, de tal maneira que, segundo Castells (1999), a própria informação se torna produto do processo produtivo.

No início do século XXI, tem-se o advento da Indústria 4.0 que é marcada pela digitalização e, dentre outros elementos, pela integração entre sistemas ciberfísicos, inteligência artificial, *big data* e Internet das Coisas (IoT), o que tem acelerado transformações nas tarefas ocupacionais em busca de maior eficiência e flexibilidade operacional.

Muito embora o progresso técnico tenha servido para aumentar a eficiência dos fatores de produção, seu efeito sobre emprego e desemprego é ambíguo, pois ao mesmo tempo em que a tecnologia aumenta os lucros e, assim, gera novos investimentos que levam as firmas a demandarem mais mão de obra, consequência do que Cahuc et al. (2014) chama de efeito capitalização, ela também acaba destruindo ocupações que se tornam obsoletas frente à nova realidade tecnológica que dela emerge (Cahuc et al., 2014).

Neste sentido, Cahuc et al. (2014) apresenta um modelo teórico de destruição criativa que, ao endogeneizar a duração de um emprego que depende se o custo de mantê-lo é menor do que o custo por ele gerado, traz como proposta que o progresso técnico não beneficia proporcionalmente todos os empregos da economia, pois gera custos aos empregos já existentes que têm em si fixada a tecnologia existente à época

da contratação do trabalhador e que, portanto, se tornará obsoleta e deixará de existir. Logo, a obsolescência de algumas ocupações já existentes faz com que empregos sejam destruídos, gerando desemprego, de maneira que a taxa de desemprego é determinada pela taxa de inovações (Cahuc et al., 2014).

Isso ocorre porque, para o modelo de destruição criativa, novas tecnologias são incorporadas apenas aos empregos recém criados, enquanto os empregos antigos mantêm sua produtividade original sem a incorporação do avanço tecnológico, sendo então destruídos tão logo se tornam inviáveis economicamente (Cahuc et al., 2014). A criação de novos empregos, para os autores, ocorre a partir do encontro entre trabalhadores desempregados e vagas disponíveis, com produtividade determinada pelas inovações mais recentes. Assim, a destruição de empregos é um fenômeno endógeno, determinado pelo ritmo do progresso tecnológico e pelas condições do mercado de trabalho.

O modelo teórico de destruição criativa apresentado por Cahuc et al. (2014) mostra que à medida que o crescimento da produtividade se acelera com o advento das inovações tecnológicas, a duração média dos empregos preexistentes diminui e a taxa de destruição de empregos aumenta, já que os antigos empregos rapidamente se tornam obsoletos, pois a tecnologia a eles incorporada, por ser antiga e gerar menor produtividade, deixa de trazer excedente positivo.

Como consequência, mesmo com a criação de novos empregos mais produtivos, o aumento da taxa de destruição pode superar o ritmo de geração de empregos, elevando a taxa de desemprego. Contudo, essa conclusão depende da suposição de que as inovações tecnológicas não são incorporadas aos empregos preexistentes à tecnologia recém criada. Se, ao contrário, os empregos pudessem ser atualizados tecnologicamente com baixo custo, o impacto do progresso técnico sobre o desemprego poderia ser positivo. Desta forma, o efeito líquido da tecnologia sobre o emprego depende da maneira como o progresso tecnológico é difundido na economia (Cahuc et al., 2014).

Nesse contexto, para fins desta dissertação, é necessário compreender quais tarefas e grupos ocupacionais são os mais expostos às novas tecnologias em IA, pois tais informações são fundamentais para a análise empírica dos efeitos que essas novas tecnologias possuem sobre o emprego e renda do trabalhador, servindo também para lançar luz sobre as políticas públicas que sejam vocacionadas a fomentar a formação profissional, proteção social e promoção de uma transição digital mais equilibrada e equitativa para os trabalhadores afetados.

### 2.2.2 Medidas de Exposição à Inteligência Artificial

A literatura tem adotado diferentes estratégias metodológicas para mensurar a exposição das ocupações à inteligência artificial, sendo a proposta de Webb (2019) uma das mais influentes, utilizada por Yang e Kim (2024) e Albanesi et al. (2025), além de ter servido de *benchmark* comparativo para Acemoglu et al. (2022), Huang (2025), Tolan et al. (2021) e Babina et al. (2024). O autor utiliza técnicas de mineração de texto (*text mining*) para estabelecer uma medida de proximidade entre descrições ocupacionais e o conteúdo de patentes relacionadas à inteligência artificial. A partir desse processo, constrói-se um índice de exposição ocupacional à IA, que permite avaliar em que medida determinadas profissões estão suscetíveis à substituição.

A metodologia de Webb (2019) baseia-se na vinculação entre três bases textuais distintas: (i) descrições de tarefas ocupacionais extraídas do banco de dados O\*NET; (ii) descrição de patentes de tecnologias de inteligência artificial obtidas no *Google Patents*; e (iii) um vocabulário técnico de inteligência artificial construído a partir de artigos científicos e documentos especializados. Por meio da identificação de termos comuns entre tarefas humanas e patentes de IA, com o uso de técnicas como *dependency parsing*, o autor calcula o grau de exposição de cada ocupação à IA. O índice resultante expressa o potencial de substituição de tarefas humanas por sistemas de inteligência artificial.

Adaptando essa metodologia ao contexto sul-coreano, Yang e Kim (2024) vincularam patentes de IA registradas no país às tarefas e ocupações descritas na Classificação Internacional Padrão de Ocupações (ISCO-08). Similarmente, Albanesi et al. (2025) adaptaram a metodologia de Webb (2019) ao contexto europeu para investigar os efeitos da difusão de tecnologias de inteligência artificial sobre o mercado de trabalho feminino em 16 países europeus entre 2011 e 2019. O estudo associa descrições textuais de patentes de IA (obtidas via *Google Patents* — a tarefas ocupacionais classificadas no nível de 3 dígitos da ISCO-08), utilizando uma técnica de sobreposição textual baseada em análise sintática e *term matching*, abordagem essa que permite calcular a exposição ocupacional à automação por inteligência artificial, capturando, desta forma, o grau em que tarefas atualmente realizadas por seres humanos podem ser replicadas por sistemas de inteligência artificial.

No mesmo estudo, Albanesi et al. (2025) também utilizam a medida de exposição à inteligência artificial desenvolvida por Felten et al. (2019), denominada *AI Occupational Impact Score*. Essa medida relaciona os avanços nas aplicações de inteligência artificial, como a capacidade de identificar padrões em dados e fazer previsões sobre o futuro, às habilidades exigidas por cada ocupação. Ao incorporar essa abordagem, os autores analisam uma dimensão complementar da exposição ocupacional à IA, distinta daquela capturada pela metodologia de Webb (2019).

Com uma abordagem diferente e mais aderente à realidade do mercado de trabalho, a metodologia de Acemoglu et al. (2022) para mensurar a adoção de inteligência artificial baseia-se na análise de dados de anúncios de vagas de emprego publicados online nos Estados Unidos entre 2010 e 2018. Os autores identificam vagas relacionadas à IA por meio da presença de palavras-chave específicas (como *aprendizado supervisionado e não supervisionado* e *processamento de linguagem natural*) nos textos dos anúncios. A partir dessas ocorrências, constroem uma medida empírica que classifica ocupações de acordo com a intensidade com que estão associadas à IA no mercado de trabalho, o que reflete a adoção efetiva da tecnologia pelas firmas.

Visando mensurar a adoção de inteligência artificial no nível da firma, Babina et al. (2024) propõem uma metodologia baseada em anúncios de vagas de emprego, em que desenvolvem um método orientado por dados, explorando a coocorrência empírica entre cerca de 15 mil habilidades profissionais identificadas nos anúncios e um conjunto de habilidades centrais relacionadas à inteligência artificial — como aprendizado de máquina, processamento de linguagem natural e visão computacional. A metodologia empregada atribui a cada habilidade uma pontuação contínua de "proximidade à IA", refletindo a frequência com que ela aparece em vagas que também mencionam competências claramente relacionadas à inteligência artificial. A pontuação de cada vaga é, então, definida como a média das pontuações de IA de todas as habilidades exigidas. Os autores classificam como relacionadas à IA os empregos técnicos cuja média ultrapassa o limite de 0,1 e, a partir disso, constroem o índice de adoção de IA por firma, calculado como a fração de vagas relacionadas à IA publicadas por cada empresa em cada ano analisado, o que permite capturar de forma dinâmica o grau de envolvimento das firmas com tecnologias de inteligência artificial.

Por sua vez, Tolan et al. (2021) propõem uma abordagem inovadora para mensurar o impacto da inteligência artificial sobre o mercado de trabalho, focando na relação entre o conteúdo das ocupações e o avanço técnico da IA. Em vez de estimar diretamente o potencial de substituição, os autores identificam, com base no banco O\*NET, o grau com que tarefas e habilidades cognitivas associadas a 119 ocupações se sobrepõem a 328 *benchmarks* de desempenho em IA, como *ImageNet*, *Robocup* e *Machine Translation*. Ao estruturar sua análise em três níveis (ocupações, tarefas e habilidades) o estudo oferece uma estimativa precisa e atualizada da exposição ocupacional à IA, conectando o progresso tecnológico à natureza das atividades humanas.

Apesar das variações metodológicas, a literatura converge na tentativa de quantificar a relação entre o avanço tecnológico em IA e a estrutura ocupacional, bem como na busca de investigar empiricamente os impactos da IA sobre o mercado de trabalho. Diante da variedade de abordagens disponíveis, optou-se, neste ensaio de

dissertação, pela adoção da metodologia proposta por Webb (2019), em razão de sua replicabilidade e ampla aplicação na literatura mundial<sup>1</sup>. A abordagem de Webb (2019) está se consolidando como uma das mais influentes e tecnicamente rigorosas no campo, amplamente utilizada direta ou indiretamente por estudos de referência que analisam os impactos da IA sobre o mercado de trabalho (Yang; Kim, 2024; Albanesi et al., 2025; Acemoglu et al., 2022; Babina et al., 2024).

### 2.2.3 Evidências Empíricas

O amplo debate em torno da inteligência artificial e suas repercussões no mercado de trabalho revela uma intersecção complexa entre avanços tecnológicos, desigualdades sociais e transformações estruturais na organização econômica. A literatura aponta tanto para os impactos negativos da automação e desmaterialização do trabalho que podem ser provocados pela inteligência artificial (Gruetzemacher et al., 2020), quanto para as oportunidades associadas à criação de empregos mais qualificados e potencialmente mais inclusivos (Ofori; Ofori, 2024).

Esta seção tem como objetivo trazer as evidências empíricas encontradas na literatura sobre o tema, que vem despertando cada vez mais interesse nos cientistas.

Vertente metodológica cada vez mais presente na literatura é a análise espacial dos impactos da inteligência artificial, especialmente em contextos marcados por desigualdades regionais. A compreensão da distribuição geográfica das ocupações expostas à IA permite identificar padrões espaciais de vulnerabilidade e potenciais efeitos de transbordamento entre localidades vizinhas. Nessa vertente destacam-se os trabalhos de Fang et al. (2022), Yang e Kim (2024) e Sun et al. (2024).

A análise espacial foi empregada no estudo de Yang e Kim (2024) para examinar a distribuição regional das ocupações vulneráveis na Coreia do Sul. Utilizando dados do censo populacional e classificações ocupacionais, os autores identificam concentrações espaciais de profissões com maior exposição à IA e relacionam tais padrões à trajetória industrial do país, marcada por especializações produtivas regionais e dinâmicas migratórias internas. Os autores argumentam que a inteligência artificial possui capacidade para substituir não apenas ocupações baseadas em tarefas físicas, mas também aquelas que envolvem processos cognitivos, como aprendizado e tomada de decisão, notadamente as atividades intelectuais que seguem métodos bem definidos, passíveis de serem aprendidos por máquinas. A análise revelou autocorrelação espacial significativa, sobretudo nas regiões onde predominam setores tradicionais, como a manufatura, e nas quais a transição tecnológica tende a provocar maior disrupção.

---

<sup>1</sup> Os detalhes da metodologia estão descritos na seção 2.3.

Yang e Kim (2024) identificaram três *clusters* ocupacionais: (i) ocupações elementares e físicas, com baixa exposição à IA; (ii) ocupações com maior nível educacional e técnico, mas cujas tarefas são rotineiras e, portanto, altamente expostas à IA; e (iii) ocupações administrativas e gerenciais, com elevada complexidade e baixa exposição à substituição tecnológica. A análise espacial revelou forte autocorrelação positiva em todos os clusters, indicando a formação de padrões geográficos distintos de vulnerabilidade ocupacional. Os autores concluem que a IA representa um risco real de substituição para determinadas ocupações, em especial aquelas que embora sejam atividades intelectuais, possuam métodos que podem ser facilmente reproduzidos, podendo, contudo, ser transformada em oportunidade por meio de políticas adequadas, e assim contribuir para a reestruturação produtiva e eventual redução das disparidades regionais.

Outros autores, como Fang et al. (2022) e Sun et al. (2024), também enfatizam a importância de considerar o território como elemento mediador dos efeitos tecnológicos. A título ilustrativo, visando analisar os impactos da IA no desenvolvimento verde regional sob o sistema de descentralização ambiental chinês, Fang et al. (2022) utilizam informações de produtividade do fator total verde (medido pelo modelo de função de distância direcional fraca e forte, e pelo modelo SBM) de 30 cidades chinesas entre 2011 e 2020, e empregam o modelo econométrico Spatial Durbin Model - SDM - para captar os efeitos diretos e indiretos da IA sobre a Produtividade Total dos Fatores Verdes (GTFP). A abordagem permite identificar a existência de transbordamentos espaciais (*spillovers*), sugerindo que o progresso em inteligência artificial em uma cidade pode beneficiar também as regiões vizinhas. Por sua vez, Sun et al. (2024) propõem um sistema de avaliação que visa mensurar o desenvolvimento da inteligência artificial nas províncias chinesas entre 2011 e 2020, aplicando ferramentas de análise espacial e de dinâmica temporal para medir o desenvolvimento da IA nas províncias vizinhas. A análise espacial é utilizada para examinar a distribuição geográfica do desenvolvimento da IA, identificar padrões de aglomeração regional e medir a correlação espacial entre as províncias chinesas.

Nesse sentido, estudos como os de Fang et al. (2022), Sun et al. (2024) e Yang e Kim (2024), baseados em análise espacial, vêm utilizando estatísticas e modelos econométricos espaciais para captar relações de dependência entre unidades geográficas e identificar padrões locais de concentração ou dispersão de eventuais impactos, abordagens estas que se mostram fundamentais para compreender como os efeitos da IA sobre o emprego e a renda se manifestam de forma heterogênea no espaço.

Percebe-se que a análise espacial tem ganhado destaque como uma abordagem metodológica contemporânea e relevante nos estudos sobre os impactos da

inteligência artificial sobre diversas variáveis de interesse, especialmente ao permitir a identificação de padrões de concentração, dispersão e interdependência regional. Assim, a adoção dessa perspectiva nesta dissertação busca não apenas captar os efeitos locais da inteligência artificial sobre o mercado de trabalho, mas também compreender possíveis transbordamentos entre municípios, se mostrando adequada para que se obtenha maior precisão na análise das dinâmicas territoriais.

Muito embora a análise espacial venha se relevando como uma ferramenta importante para identificar padrões geográficos e dependências espaciais na relação entre a inteligência artificial e o mercado de trabalho, ela não esgota as possibilidades de investigação. Para compreender de forma mais ampla os impactos da IA, especialmente sobre o emprego e a renda das mulheres nesse novo contexto de digitalização da economia, é necessário que se recorra também a outras abordagens metodológicas que permitam explorar dimensões setoriais, temporais e mesmo individuais. É nesse sentido que a investigação se amplia, incorporando métodos capazes de revelar mecanismos e dinâmicas que a análise espacial, isoladamente, não alcança.

Em interessante artigo que analisa o caso norte-americano, Acemoglu et al. (2022) investiga os impactos da inteligência artificial sobre o mercado de trabalho a partir de dados de anúncios de vagas coletados pela *Burning Glass Technologies*, abrangendo praticamente o universo de vagas online publicadas nos Estados Unidos em 2007 e entre 2010 e 2018. A abordagem metodológica combina os dados de vagas de emprego que contêm informações detalhadas sobre ocupações e habilidades requisitadas dos trabalhadores, com tarefas que sejam compatíveis com as tecnologias de IA provenientes de três índices distintos formulados por Felten et al. (2019), Webb (2019) e Brynjolfsson et al. (2018). A partir dessa integração, os autores estimam modelos econométricos em nível de estabelecimento para analisar como diferentes graus de exposição à IA se associam à evolução de contratações e às mudanças nas habilidades dos trabalhadores demandadas pelas empresas.

Os autores encontram três resultados principais sobre os impactos da inteligência artificial no mercado de trabalho, sendo eles, (i) um aumento nas atividades relacionadas à inteligência artificial a partir de 2015, refletido pela maior incidência de anúncios de vagas de emprego que demandam competências que requerem habilidades específicas em IA, o que está concentrado especialmente em estabelecimentos cuja estrutura de tarefas seja favorável à adoção dessa tecnologia, isto é, aqueles com alta exposição à IA; (ii) uma mudança sistemática no perfil de habilidades demandadas pelas empresas com alta exposição à IA, pois tais estabelecimentos deixam de requerer certas competências anteriormente comuns e passam a demandar novas habilidades, o que sugere uma reorganização das tarefas desempenhadas agora mais voltadas a tarefas relacionadas à IA; (iii) uma redução nas contratações totais e nas vagas

de emprego não relacionadas à IA nos estabelecimentos mais expostos à tecnologia, resultados estes que são estatisticamente significativos e robustos com grande parte das medidas apresentadas por Felten et al. (2019) e Webb (2019). Apesar dessas transformações em nível de firma, os autores não encontram efeitos significativos da IA sobre o emprego ou os salários em nível setorial ou ocupacional agregado, o que pode ser atribuído à adoção ainda restrita da tecnologia no conjunto da economia norte-americana.

Já Huang (2025) faz uma abordagem empírica a nível macroeconômico, identificando como principais achados que, no agregado, a IA gera efeitos negativos sobre emprego na indústria de manufatura e de serviços nos quais predomina a baixa qualificação, para trabalhadores de média qualificação e para ocupações não STEM, além de ter maior impacto adverso sobre os homens do que sobre as mulheres. O estudo utiliza dados da *Annual Business Survey (ABS)* para os Estados Unidos, que incluem taxas de adoção de diferentes tecnologias de IA por setor de atividade, combinados com informações da base europeia *ICT Usage in Enterprises*, que reporta a proporção de empresas que adotam ao menos uma tecnologia de IA na União Europeia referente a mineração de texto, reconhecimento de fala, dentre outras. Além disso, recorre a microdados do *American Community Survey (ACS)*, que fornecem características demográficas, composição ocupacional e rendimentos da população, e ao *County Business Patterns (CBP)*, que apresenta dados de emprego setorial, todos cobrindo o período de 2010 a 2021. A análise mede a exposição local à IA a partir da variação setorial na adoção da tecnologia e da distribuição do emprego nas zonas de deslocamento (*commuting zone*), aplicando modelo econométrico que visa identificar a variação do nível das *commuting zone* na adoção de IA, buscando estimar o efeito local de emprego. Os resultados indicam que os efeitos adversos da IA são maiores em setores de serviços intensivos em tarefas rotineiras e menos qualificados, enquanto setores de alta qualificação apresentam resiliência ou até ganhos líquidos de emprego.

Sob uma perspectiva otimista dos impactos da IA sobre o mercado de trabalho, Yeh et al. (2020) argumentam que a inteligência artificial cria novas tarefas e empregos, além de apoiar os empregadores na tomada de decisões mais eficientes. De forma semelhante, Liu et al. (2022) destacam que a introdução de robôs industriais de inteligência artificial no setor manufatureiro chinês provocou efeitos positivos por meio de transbordamentos tecnológicos, aumentando a capacidade de inovação e a produtividade do trabalho, o que impulsionou investimentos em pesquisa e desenvolvimento (P&D). Alekseeva et al. (2021) destacam que a crescente demanda por qualificação profissional em IA, sobretudo nos setores de tecnologia da informação, arquitetura, engenharia e gestão, tem contribuído para o aumento dos salários nesses segmentos.

Embora não adotem diretamente essa ótica otimista, Yang e Kim (2024) mos-

tram que ocupações com elevado grau de complexidade, criatividade e experiência (Cluster 3), como cargos administrativos e gerenciais, tendem a apresentar menor vulnerabilidade à substituição por tecnologias inteligentes, ao passo que mesmo setores qualificados podem ser significativamente expostos, caso suas tarefas sejam rotineiras e baseadas em padrões.

Em contrapartida, parte da literatura adota uma visão mais pessimista, segundo a qual a inteligência artificial tende a produzir efeitos adversos sobre o mercado de trabalho. As transformações desencadeadas pela inteligência artificial teriam o potencial de alterar significativamente a estrutura ocupacional ao substituir postos de trabalho por sistemas automatizados (Gruetzemacher et al., 2020). Nesse contexto, a difusão de técnicas de *machine learning* (ML) nos processos produtivos representa um fator com elevado potencial para reduzir a demanda por trabalho humano. Conforme estimativas apresentadas por Gruetzemacher et al. (2020), há uma probabilidade de 50% de que sistemas de IA sejam capazes de automatizar até 90% das tarefas atualmente desempenhadas por humanos nos próximos 25 anos, e 99% das tarefas humanas atuais em 50 anos. Tais estimativas foram obtidas a partir de pesquisas feitas com especialistas em IA, conduzidas por meio de questionários que capturaram suas previsões sobre o progresso tecnológico e o tempo estimado para que a IA possa substituir tarefas humanas. A base de dados utilizada pelo autor compreende respostas de pesquisadores que trabalham com IA, coletadas em 2018, e o método aplicado envolveu modelagem econométrica por OLS (para questões com anos fixos) e regressões SUR (*Seemingly Unrelated Regressions*), para probabilidades fixas. Os resultados revelam alta concordância de que avanços substanciais na automação decorrente do uso de IA ocorrerão nas próximas décadas, ainda que com variações nas previsões individuais quanto ao ritmo desse progresso.

Nesse novo cenário de avanço tecnológico que exige novos requerimentos técnicos, Rampersad (2020) e Yang e Kim (2024), indicam que a manutenção da empregabilidade do trabalhador exigirá que os trabalhadores desenvolvam habilidades voltadas à realização de tarefas menos repetitivas e monótonas, devendo se qualificar para exercerem atividades que envolvam maior complexidade cognitiva, com ênfase em competências como pensamento crítico e resolução de problemas.

Por sua vez, ao analisar a relação entre salários e capital na economia chinesa, Wang et al. (2023) destacam que a inteligência artificial reduz a demanda por trabalho e aumenta a produtividade do capital, deslocando a distribuição de renda do trabalho para o capital. As hipóteses do estudo sugerem que a inteligência artificial tem um efeito em formato de U na distribuição de renda, cujos impactos decorrem de se reduzir a demanda por trabalho, o que afeta a produtividade do capital e do trabalho de forma desproporcional. Para os autores, inicialmente a inteligência artificial beneficia

trabalhadores qualificados, mas, com o tempo, favorece o capital, especialmente em empresas lideradas por mulheres, nas quais a redistribuição de renda é mais rápida. O estudo utiliza dados anuais de empresas industriais e do setor de serviços da China para os anos de 2008, 2010, 2012, 2014 e 2016, provenientes do *Chinese Private Enterprise Surveys*, que contém informações sobre características das empresas, bem como de relatórios estatísticos nacionais com indicadores macroeconômicos e setoriais, dentre outros. A metodologia utilizada se vale de modelo de dados em painel com efeitos fixos e variáveis instrumentais para examinar o impacto da adoção da inteligência artificial sobre a distribuição de renda entre capital e trabalho. Os resultados indicam que a IA tende a reduzir a participação do trabalho na renda e aumentar a produtividade do capital, com efeitos mais rápidos e intensos em empresas lideradas por mulheres. Para mitigar os efeitos dos resultados obtidos, os autores recomendam políticas públicas que orientem as inovações em IA como complementares ao trabalho humano e incentivem a qualificação contínua dos trabalhadores.

Os resultados empíricos ambíguos obtidos pela literatura, associado aos resultados teóricos de possibilidade tanto de efeito substituição quanto de efeito complementariedade (Cahuc et al., 2014), denotam a relevância do estudo do tema para o caso brasileiro, notadamente ante à ausência de estudos quantitativos que possam clarificar os efeitos da IA sobre o mercado de trabalho no que se refere às variáveis emprego e renda do trabalhador.

## 2.3 DADOS E METODOLOGIA

Nessa seção serão apresentados os dados e a metodologia utilizados na presente dissertação. Inicialmente, será descrita a base de dados utilizada e os critérios de seleção das variáveis. Em continuidade, será detalhada a construção do índice de exposição ocupacional à inteligência artificial, bem como a abordagem de análise espacial e os modelos econométricos adotados para estimar os efeitos da inteligência artificial sobre o emprego e a renda das mulheres no Brasil.

### 2.3.1 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 feminino brasileiro. Três conjuntos principais de dados foram mobilizados, conforme descrito abaixo.

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. Para 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.

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

Por fim, foram incorporadas variáveis relacionadas a gênero, obtidas a partir dos microdados da RAIS, permitindo identificar e comparar a participação feminina e masculina no mercado de trabalho formal brasileiro, de onde é possível analisar a proporção de mulheres e homens em cada ocupação, a renda média por sexo e a distribuição regional desses vínculos, classificados segundo a CBO.

Esses dados são fundamentais para avaliar de que forma a exposição ocupacional à inteligência artificial afeta homens e mulheres, possibilitando mensurar eventuais disparidades salariais e padrões de participação e alocação das mulheres nas ocupações brasileiras. A combinação dessas informações com o índice de exposição à IA permitirá examinar a sua distribuição espacial, o que viabilizará análises de dependência espacial voltadas à compreensão das desigualdades de gênero diante do avanço dessa nova tecnologia.

### 2.3.2 Metodologia

A metodologia adotada neste trabalho fundamenta-se, de forma complementar, nas abordagens propostas por Webb (2019) e Yang e 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 e Kim (2024) fundamenta a aplicação de técnicas de análise espacial, permitindo examinar eventuais efeitos de transbordamento desses impactos em todos os municípios do país.

Cumprido destacar que o índice construído neste estudo não mensura diretamente processos efetivos de automação ou substituição do trabalho humano pela inteligência artificial. O indicador captura, na realidade, o grau de proximidade semântica entre as tarefas associadas às ocupações e as descrições tecnológicas presentes em documentos de patentes relacionadas à IA. Dessa forma, o índice deve ser interpretado como uma medida de exposição potencial das ocupações às tecnologias de inteligência artificial, refletindo a afinidade entre o conteúdo das atividades ocupacionais e o desenvolvimento tecnológico registrado nas patentes, contudo, isso não retira a sua originalidade e relevância para a análise dos possíveis reflexos dessa tecnologia sobre o mercado de trabalho brasileiro.

#### 2.3.2.1 Metodologia de Webb (2019)

O modelo proposto por Webb (2019) fundamenta-se na teoria desenvolvida por Acemoglu e Restrepo (2018b), segundo a qual a economia produz um único bem final por meio de tarefas realizadas por humanos ou por aquelas que podem ser automatizadas. Os autores baseiam sua metodologia na função de produção do tipo CES (*Constant Elasticity of Substitution*) e é essa função que permite investigar em qual medida as tarefas desempenhadas por humanos podem ser substituídas por tecnologias como softwares, robôs e inteligência artificial, mantendo constante a elasticidade de substituição entre os insumos produtivos. Para Webb (2019), sua principal contribuição em relação ao modelo original de Acemoglu e Restrepo (2018b) é a adoção das ocupações como unidade de análise.

A proposta empírica de Webb (2019) para estimação de um índice de inteligência artificial, combina técnicas de mineração de texto e comparação semântica para estimar em que medida as tarefas realizadas por trabalhadores se amoldam às funcionalidades descritas em patentes tecnológicas. Com base nesse método, o autor desenvolve três diferentes índices de exposição em seu artigo, um voltado à inteligência artificial, outro a softwares tradicionais e um terceiro dedicado a robôs industriais. Apesar de seguirem uma lógica comum, cada índice é construído a partir de critérios e fontes específicas, de acordo com a natureza da tecnologia analisada.

Nesta dissertação, o foco recai sobre o índice de exposição ocupacional à inteligência artificial.

A metodologia proposta por Webb (2019) consiste na construção de um índice de exposição ocupacional à inteligência artificial a partir da mensuração da sobreposição semântica entre as tarefas desempenhadas pelas ocupações e os conteúdos técnicos descritos em títulos de patentes associadas a tecnologias de IA. Quanto maior o índice atribuído a uma ocupação, maior o grau de aderência entre suas tarefas e as funcionalidades descritas em patentes de IA, e, portanto, maior o seu potencial de automação.

Esse processo metodológico pode ser dividido em três grandes blocos: (i) a construção da base de tarefas ocupacionais; (ii) a identificação e o processamento textual das patentes de IA; e (iii) o cálculo do índice de exposição com base na correspondência entre as tarefas e as tecnologias descritas (software, robôs e IA).

Vale ressaltar, que o modelo desenvolvido ao utilizar como pressuposto que a sobreposição semântica entre tarefas e funcionalidades tecnológicas de IA indicaria quais são as ocupações com um maior potencial de substituição. No entanto, o próprio Webb (2019) reconhece que os impactos da inteligência artificial sobre o mercado de trabalho ainda são incertos, de tal forma que não seja possível excluir a possibilidade de que o índice também seja positivo para ocupações que sejam complementares à inteligência artificial. Desta forma, a alta exposição de uma ocupação à inteligência artificial pode refletir riscos de automação, mas também pode indicar oportunidades de complementação tecnológica ou de transformação qualitativa das tarefas desempenhadas.

A primeira etapa consiste na construção de uma base estruturada de tarefas por ocupação. Para isso, Webb (2019) utiliza o banco de dados do O\*NET (*Occupational Information Network*) que fornece descrições detalhadas das atividades realizadas em centenas de ocupações para os Estados Unidos. Cada ocupação é composta por um conjunto de tarefas que refletem as atividades rotineiras desempenhadas pelos trabalhadores em seu contexto profissional. A base de dados do O\*NET traz informações sobre a frequência e a importância relativa de cada tarefa dentro de sua respectiva ocupação, permitindo, assim, a atribuição de pesos diferenciados no cálculo do índice de exposição. Observe-se que, no Brasil, não existe estrutura de dados parecida, pois a CBO não fornece esse tipo de atribuição de pesos às ocupações nacionais.

A partir dessas descrições, o autor se vale de técnicas de Processamento de Linguagem Natural (PLN), mais especificamente o método de *dependency parsing*, para extrair pares verbo-substantivo (*verb-noun pairs*) que sintetizam, de forma padronizada, a ação e o objeto de cada tarefa. Ilustrativamente, da tarefa *“Document and maintain*

*records of precision agriculture information*”, é extraído o par (“*maintain*”, “*record*”). Os pares extraídos são então utilizados como unidade básica de comparação semântica com os pares verbo-substantivo identificados nos títulos das patentes de inteligência artificial.

A segunda etapa é formada pela coleta e processamento das patentes relacionadas à inteligência artificial. Para identificar essas patentes, Webb (2019) utiliza a base do Google Patents, realizando uma busca com base em uma lista refinada de palavras-chave diretamente associadas à IA, que incluiu expressões como “*deep learning*” e “*neural network*”.

Os títulos das patentes extraídas por meio desses termos foram, então, submetidos ao mesmo processo de tratamento linguístico aplicado às tarefas ocupacionais, com o uso de *dependency parsing* para extrair os pares verbo-substantivo (*verb-noun pairs*) representativos das funcionalidades tecnológicas descritas.

A partir dessas informações, calcula-se para cada par verbo-substantivo  $c$  extraídos dos títulos das patentes sua frequência relativa em relação a uma determinada tecnologia  $t$ , denotada por  $rf_c^t$ , o que permite quantificar a intensidade com que aquele par aparece no conjunto de patentes vinculadas à inteligência artificial. A equação utilizada é:

$$rf_c^t = \frac{f_c^t}{\sum_{c \in C^t} f_c^t} \quad (2.1)$$

em que:

- $rf_c^t$  é a frequência relativa do par verbo-substantivo  $c$  nas patentes da tecnologia  $t$ ;
- $f_c^t$  é o número de ocorrências do par  $c$  nos títulos das patentes associadas à tecnologia  $t$ ;
- $C^t$  é o conjunto total de pares verbo-substantivo extraídos das patentes da tecnologia  $t$ .

A frequência relativa  $rf_c^t$  expressa, desta forma, o peso de cada par no universo tecnológico da IA, capturando a recorrência de determinada ação nas inovações registradas. Quanto maior esse valor, maior a influência do par no cálculo do índice de exposição ocupacional à inteligência artificial.

### 2.3.2.2 Construção do índice de exposição à IA

A última etapa consiste em calcular, para cada ocupação  $i$ , um índice de exposição à IA com base na frequência relativa dos pares verbo-substantivo extraídos de suas tarefas. A ideia central é medir o grau de sobreposição entre os pares das tarefas humanas e os pares extraídos das patentes de IA, ponderando essa sobreposição pela intensidade com que cada tarefa é mencionada nessas novas tecnologias.

Formalmente, o índice de exposição é definido como:

$$Exposure_{i,t} = \frac{1}{|K_i|} \sum_{k \in K_i} \left( \sum_{c \in S_k} r f_c^t \right) \quad (2.2)$$

em que:

- $Exposure_{i,t}$  representa o índice de exposição da ocupação  $i$  à tecnologia  $t$ ;
- $K_i$  é o conjunto de tarefas da ocupação  $i$ ;
- $S_k$  é o conjunto de pares verbo-substantivo extraídos da tarefa  $k \in K_i$ ;
- $r f_c^t$  é a frequência relativa do par verbo-substantivo  $c$  nas patentes da tecnologia  $t$ ;
- $w_{k,i}$  é o peso da tarefa  $k$  na ocupação  $i$ . Na presente pesquisa, em virtude da inexistência de informações equivalentes às métricas de frequência, importância e relevância do banco de dados O\*NET utilizada por Webb (2019), adota-se ponderação uniforme entre as tarefas da ocupação, de modo que  $w_{k,i} = \frac{1}{|K_i|}$ . Assim, cada tarefa recebe o mesmo peso e a soma dos pesos das tarefas em cada ocupação é igual a 1.

Portanto, o índice  $Exposure_{i,t}$  representa a intensidade da atividade tecnológica referente à IA direcionada às tarefas que compõem uma determinada ocupação, refletindo o quanto as tarefas realizadas por uma ocupação estão representadas nas tecnologias de IA patenteadas.

Aquelas ocupações com tarefas que aparecem com frequência em patentes de IA recebem índices mais altos, indicando maior exposição — potencial maior risco de automação.

### 2.3.2.3 Índice de Exposição das Ocupações Brasileiras à Inteligência Artificial

Nesta dissertação, 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; 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 e respectivos livros.

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

A organização e o tratamento dos textos de patentes e CBO foram realizados a partir do pacote UDPipe (Wijffels, 2021; Straka; Straková, 2017), que fornece modelos pré-treinados para análise linguística detalhada de texto. 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; 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

---

<sup>2</sup> Os pacotes utilizados, bem como toda a programação e etapas metodológicas estão descritas em detalhes no Apêndice 1.

informações como lemas, classes gramaticais e relações de dependência entre as mais diversas palavras (Wijffels, 2021; Straka; 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*. 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, frequentemente estruturada em árvores sintáticas (*parse trees*), constitui um recurso fundamental para múltiplas tarefas de análise linguística e semântica (Dan; Martin James, 2009).

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), técnica amplamente utilizada em NLP pela capacidade de capturar relações semânticas entre palavras (Pennington et al., 2014). 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; Jurafsky, 2009; Goldberg, 2017). Para assegurar consistência e eficiência, os *embeddings* foram armazenados de forma estruturada e reutilizável, em conformidade com Martin e Jurafsky (2009).

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

$$\text{Índice}_{IA_j} = \frac{1}{n_j} \sum_{i=1}^{n_j} s_{ij} \quad (2.3)$$

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, posteriormente ponderada pelo número de trabalhadores na ocupação correspondente.

#### 2.3.2.4 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, propõe-se a construção de 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 nesta dissertação 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 e Restrepo (2017), que propõem indicadores ponderados de exposição tecnológica a partir da composição ocupacional de uma dada base territorial. Para esta dissertação, o índice agregado de exposição à IA para uma região  $R$  é dado por:

$$\text{Exposição}_{R,t} = \sum_{i=1}^{N_R} \left( \frac{E_{Ri,t}}{\sum_{j=1}^{N_R} E_{Rj,t}} \cdot IA_i \right) \quad (2.4)$$

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 será feita considerando o total de trabalhadores de cada ocupação em cada região.

Para o cálculo do indicador regional, opta-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. Como a estrutura ocupacional tende a se modificar ao longo do tempo, o indicador acaba sendo dinâmico, o que possibilita o acompanhamento da evolução da exposição regional à IA.

#### 2.3.2.5 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:

TABELA 2.1 – Comparação entre Webb (2019) e a versão adaptada nesta dissertação

<b>Etapa</b>	<b>Webb (2020)</b>	<b>Versão Adaptada</b>
<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 usado</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 de processamento</b>	Inglês técnico (padrão O*NET)	Português brasileiro (padrão CBO)
<b>Ferramentas</b>	Não especificado.	R (UDPipe, text2vec, GloVe, tidyverse)

Fonte: Elaboração própria.

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 posteriormente 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 Processamento de Linguagem Natural para comparar vetores semânticos, sendo adequada para avaliar proximidade contextual entre expressões textuais (Martin; 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 2.3.2.4, 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.

## 2.4 RESULTADOS

Neste Capítulo serão apresentados os principais resultados obtidos a partir da aplicação da metodologia proposta para mensurar o grau de exposição ocupacional à inteligência artificial, e seus reflexos em emprego e renda das mulheres.

### 2.4.1 Índice de Exposição das Ocupações Brasileiras à Inteligência Artificial

Um dos principais resultados empíricos da pesquisa consiste em medir o quanto as ocupações brasileiras estão expostas ao avanço da inteligência artificial. Os resultados são apresentados na Tabela 2.2, com destaque para as dez ocupações mais impactadas, permitindo uma visão clara de quais áreas do mercado de trabalho

podem estar mais suscetíveis à automação. A análise é acompanhada de reflexões à luz da literatura sobre mudanças tecnológicas e seus efeitos sobre o emprego.

TABELA 2.2 – Dez ocupações brasileiras mais expostas à inteligência artificial

Código	Ocupação	Índice de IA
4142	APONTADORES E CONFERENTES	1,000
8103	SUPERVISORES DE PRODUÇÃO EM INDÚSTRIAS DE PRODUTOS FARMACÊUTICOS, COSMÉTICOS E AFINS	1,000
6225	TRABALHADORES AGRÍCOLAS NA FRUTICULTURA	0,786
0301	OFICIAIS SUPERIORES DO CORPO DE BOMBEIROS MILITAR	0,601
7157	APLICADORES DE MATERIAIS ISOLANTES	0,598
6110	PRODUTORES AGROPECUÁRIOS EM GERAL	0,584
7166	PINTORES DE OBRAS E REVESTIDORES DE INTERIORES	0,578
3546	CORRETORES DE IMÓVEIS	0,576
2342	PROFESSORES DE CIÊNCIAS FÍSICAS, QUÍMICAS E AFINS DO ENSINO MÉDIO	0,571
7827	TRABALHADORES AQUAVIÁRIOS	0,571

Fonte: Elaboração própria.

No tópico subsequente, serão exploradas algumas tecnologias que podem corroborar os resultados obtidos para as ocupações brasileiras mais expostas ao advento da inteligência artificial.

#### 2.4.2 Inovações de Mercado

Nesta seção, serão apresentadas algumas das inovações tecnológicas de mercado de cada uma das cinco ocupações brasileiras mais expostas à inteligência artificial.

A ocupação brasileira mais exposta à inteligência artificial é a de Apontadores e Conferentes (Código 4142), cujo descritivo da atividade constante dos livros da CBO é o que segue abaixo:

*Apontam a produção e controlam a frequência de mão-de-obra. Acompanham atividades de produção, conferem cargas e verificam documentação. Preenchem relatórios, guias, boletins, plano de carga e recibos. Controlam movimentação de carga e descarga nos portos, terminais portuários e embarcações. Podem liderar equipes de trabalho* (Trabalho e Emprego, 2010a, p. 709).

Do descritivo da atividade, percebe-se que sua execução envolve um conjunto de funções com alta densidade de tarefas repetitivas e rotineiras, o que pode explicar sua total exposição à inteligência artificial, conforme indicado pelo índice 1,000. Esta

conclusão está de acordo com o que diz Yang e Kim (2024), segundo o qual as atividades mais expostas à inteligência artificial são aquelas que envolvem trabalhos que possuem rotinas bem definidas. Conforme indicam Costa et al. (2022), no atual cenário de digitalização industrial e logística, acelerado pós-situação pandêmica da COVID-19, a inteligência artificial tem sido aplicada para automatizar e otimizar as rotinas e processos desempenhados por esses profissionais. Um exemplo concreto é o uso de sistemas de reconhecimento óptico e visão computacional para conferência de cargas e verificação de documentos. Plataformas como o *Amazon Rekognition* já são utilizadas em centros de distribuição para identificar, rastrear e conferir mercadorias automaticamente (Amazon Web Services, 2025). No Brasil, a Nstech é um ecossistema que agrega soluções de IA para diversos produtos, incluindo a gestão de armazéns, pátios, entregas, planejamento logístico, dentre outros (Nstech, 2025).

A outra ocupação brasileira que também conta com total exposição à inteligência artificial, com índice igual a 1,000, é a de Supervisores de Produção em Indústrias de Produtos Farmacêuticos, Cosméticos e Afins (Código 8103), cujo descritivo da atividade constante dos livros da CBO é o que segue abaixo:

*Planejam atividades de supervisão; supervisionam e otimizam processos de produção de produtos farmacêuticos, cosméticos e afins; supervisionam e treinam equipes de trabalho, assegurando o cumprimento de normas e zelando pela segurança, saúde e meio ambiente (Trabalho e Emprego, 2010b, p. 403).*

O descritivo mostra que esta ocupação reúne funções estratégicas e com forte vínculo à padronização, controle de processos e tomada de decisão baseada em rotinas produtivas, o que explica a elevada exposição à IA. Resultados similares foram obtidos por Yang e Kim (2024). Ademais, segundo Almeida (2023), na indústria farmacêutica, ferramentas de inteligência artificial têm sido incorporadas para realizar desde o controle em tempo real da linha de produção até a detecção de desvios de qualidade e segurança.

No terceiro lugar do ranking de atividades mais expostas à inteligência artificial no Brasil está a de trabalhadores agrícolas na fruticultura (Código 6225), com Índice de exposição à IA de 0,786, que têm a descrição abaixo:

*Realizam tratos culturais em fruticultura; preparam o solo e plantam espécies frutíferas; produzem mudas e sementes. Colhem, beneficiam e acondicionam frutas e frutos. Auxiliam na irrigação das plantações (Trabalho e Emprego, 2010b, p. 61).*

No contexto da agricultura de precisão, conforme indica Ferreira et al. (2024), a inteligência artificial tem sido empregada em diversas frentes para automatizar e aumentar a eficiência das atividades de plantio, cultivo, colheita e beneficiamento, ga-

nhando destaque as aplicações de sensoriamento remoto. No Brasil, essas atividades contam com importante projeto denominado Centro de Ciência para Desenvolvimento em Agricultura Digital (CCD-AD), capitaneado pela EMBRAPA, que visa ao crescimento da produtividade com inclusão do pequeno e médio produtor a partir do uso de tecnologias digitais e inteligência artificial.

Dois dos principais eixos de atuação do CCD-AD, concentram-se no (i) uso de inteligência artificial e sensoriamento remoto, bem como na (ii) automação e agricultura de precisão. O primeiro abrange o desenvolvimento de soluções com imagens multiespectrais, sensoriamento tridimensional, fusão de dados heterogêneos, além do uso de aprendizado de máquina, computação em nuvem e de borda, e estruturação de bases de dados agrícolas. Já a segunda linha de atuação, focada em automação e agricultura de precisão, contempla aplicações de *machine learning*, *analytics*, *blockchain*, robótica e arquiteturas de sistemas embarcados, além do uso de drones e sensoriamento proximal, compondo um ecossistema tecnológico de fronteira voltado à modernização da produção rural brasileira com ênfase na inclusão digital e aumento de produtividade de pequenos e médios produtores. (Embrapa, 2025)

Outra ocupação que está entre as mais expostas à inteligência artificial, ocupando a quarta colocação, é a de Oficiais Superiores do Corpo de Bombeiros Militar (Código 0301), que conta com o seguinte descritivo:

*Definem estratégias e comandam unidades operacionais e administrativas do Corpo de Bombeiros, destinadas à proteção da vida e do patrimônio do cidadão e ao meio ambiente. Gerenciam pessoal e recursos financeiros; controlam logística e dirigem serviços de inteligência e de prevenção, de acordo com normas da instituição (Trabalho e Emprego, 2010a, p. 39).*

Muito embora esta atividade seja realizada dentro da estrutura do órgão do Corpo de Bombeiros Militares para o exercício de um serviço público essencial ligado à segurança pública (Brasil, 1988), e, portanto, com forte restrição quanto à automatização, existem importantes aplicações em IA que estão sendo utilizadas pelo Corpo de Bombeiros para a melhoria da segurança pública.

Um exemplo, no Distrito Federal, é o projeto Sem Fogo-DF que utiliza inteligência artificial para reconhecimento de imagens aéreas voltadas à detecção precoce e apoio às respostas em caso de incêndios florestais (CBM-DF et al., 2025). No Paraná, o Corpo de Bombeiros Militar emprega drones de alta tecnologia, equipados com câmeras com zoom de alta definição e visão termal, para monitorar praias e áreas de risco. (Estado do Paraná, 2025)

Outro interessante exemplo de tecnologia em inteligência artificial aplicável à logística operacional que pode auxiliar nas atividades desempenhadas por Oficiais

Superiores do Corpo de Bombeiros é o sistema desenvolvido pelo laboratório ProLogIS da Universidade Federal de Santa Catarina (UFSC). A solução utiliza algoritmos de otimização e simulação em tempo real para apoiar decisões sobre alocação de equipes, definição de rotas e priorização de recursos em situações de emergência, contribuindo para respostas mais rápidas e eficazes (ProLogIS - UFSC, 2024).

Trata-se de exemplo real que demonstra que existem atividades que, devido à sua própria natureza, não são passíveis de serem automatizadas, mas que podem sofrer grande ganho de produtividade com a aplicação de inteligência artificial, estando presente, aqui, o efeito complementaridade e não o efeito substituição, possibilidade esta expressamente reconhecida por Webb (2019).

Em relação à ocupação de Aplicadores de Materiais Isolantes (Código 7157), que ocupa a quinta colocação do *ranking*, o descritivo das funções demonstra que se caracteriza parcialmente por tarefas operacionais e de intervenção direta no ambiente físico que necessitam de intervenção humana, o que limitaria a automação total:

*Identificam serviços de instalação de materiais isolantes, selecionam materiais a serem aplicados, solicitam liberação da área de trabalho, preparam o local e executam a instalação de acordo com projetos, normas técnicas, normas de segurança e recomendações dos fabricantes. Providenciam descarte de resíduos* (Trabalho e Emprego, 2010b, p. 145).

Contudo, note-se que existem importantes etapas que podem ser desempenhadas com uso de inteligência artificial. Soluções reais já em uso incluem softwares de simulação térmica assistida por IA, tal qual o software DOMUS desenvolvido pelo Laboratório de Sistemas Térmicos da PUCPR (PUC/PR, 2025), utilizado por Gasparin et al. (2019) para a condução dos estudos em que propõem um método adaptativo de malha para determinar a espessura ideal de isolamento em edificações brasileiras por meio de simulação térmica avançada.

Na prática construtiva, Soares Júnior (2021) mostra como a IoT e a inteligência artificial têm remodelado a indústria da construção civil, trazendo exemplos de uso de câmeras acopladas a drones ou capacetes inteligentes, bem como do método BIM (*Building Information Modeling*), funcionalidades estas capazes de mapear áreas de aplicação, detectar falhas, identificar problemas estruturais e garantir conformidade com normas técnicas, notadamente às normas de segurança do trabalho.

Esses são apenas alguns exemplos que mostram como a inteligência artificial vem remodelado as relações do mercado de trabalho no Brasil. Como visto da farta referência bibliográfica até então trazida, essa mudança traz ganhos de eficiência, mas também impõe desafios à qualificação profissional.

O tópico subsequente tem por objetivo verificar como a inteligência artificial

tem afetado os municípios brasileiros no contexto de sua estrutura ocupacional.

### 2.4.3 Exposição Regional à Inteligência Artificial

Nesta seção serão reportados os resultados da subseção 2.3.2.4, cujo índice regional, a nível de municípios, foi construído como a média ponderada dos índices ocupacionais pela distribuição do emprego formal em cada município para o ano de 2024. O indicador resume, em um único valor para cada município, a exposição potencial da sua estrutura ocupacional à IA, permitindo comparar localidades e identificar padrões territoriais de maior exposição a essa tecnologia.

#### 2.4.3.1 Análise Descritiva dos Dados

Nesta subseção são apresentadas as estatísticas descritivas da variável índice de exposição regional à IA. O objetivo é oferecer uma visão geral da amostra, de modo a contextualizar a análise regional realizada na seção seguinte que recairá sobre emprego e renda.

A Tabela 2.3 apresenta a estatística descritiva do índice de exposição dos municípios brasileiros à IA, cuja distribuição demonstra heterogeneidade entre os entes federados.

TABELA 2.3 – Estatística descritiva do índice regional de exposição à IA

	Min.	1º Q	Mediana	Média	3º Q	Máx.
<i>Índice regional</i>	0,00000	0,06191	0,08054	0,09515	0,11544	0,62110

Fonte: Elaboração própria.

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 da Tabela 2.3 denota nível de exposição zero, enquanto o primeiro quartil situa-se em 0,0619, indicando que 25% dos municípios apresentam baixa exposição relativa à IA, pois a exposição à IA está bem abaixo da média e da mediana nacional. O município mediano apresenta um índice de 0,0805, valor próximo à média (0,0951), sugerindo que a maior parte das localidades se concentra em níveis moderados de exposição à IA.

A diferença entre média e mediana indica uma assimetria positiva, reforçada pela cauda longa à direita da curva de distribuição que pode ser visualizada no Gráfico 2.1. Enquanto o terceiro quartil é 0,1154, o máximo alcança 0,6211, evidenciando a existência de municípios *outliers* fortemente expostos à IA. Esse resultado implica

que aproximadamente 25% dos municípios brasileiros apresentam índices superiores a 0,1154, compondo a faixa de maior exposição relativa.

Esse padrão distributivo pode ser visualizado no Gráfico 2.1, que apresenta a função de densidade do índice regional, nível municipal, de exposição à IA.




FIGURA 2.1 – Densidade da exposição dos municípios brasileiros à IA  
Fonte: Elaboração própria.

Por a mediana ser uma medida de posição central que divide a amostra em duas partes iguais (Sartoris, 2008), temos que 50% dos municípios situam-se à sua esquerda, com valores de exposição à IA inferiores a 0,0805, enquanto os 50% dos municípios brasileiros restantes se concentram à direita.

Observa-se do Gráfico 2.1 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.

O Gráfico 2.2 mostra a decomposição regional da exposição dos municípios brasileiros à inteligência artificial, vejamos:

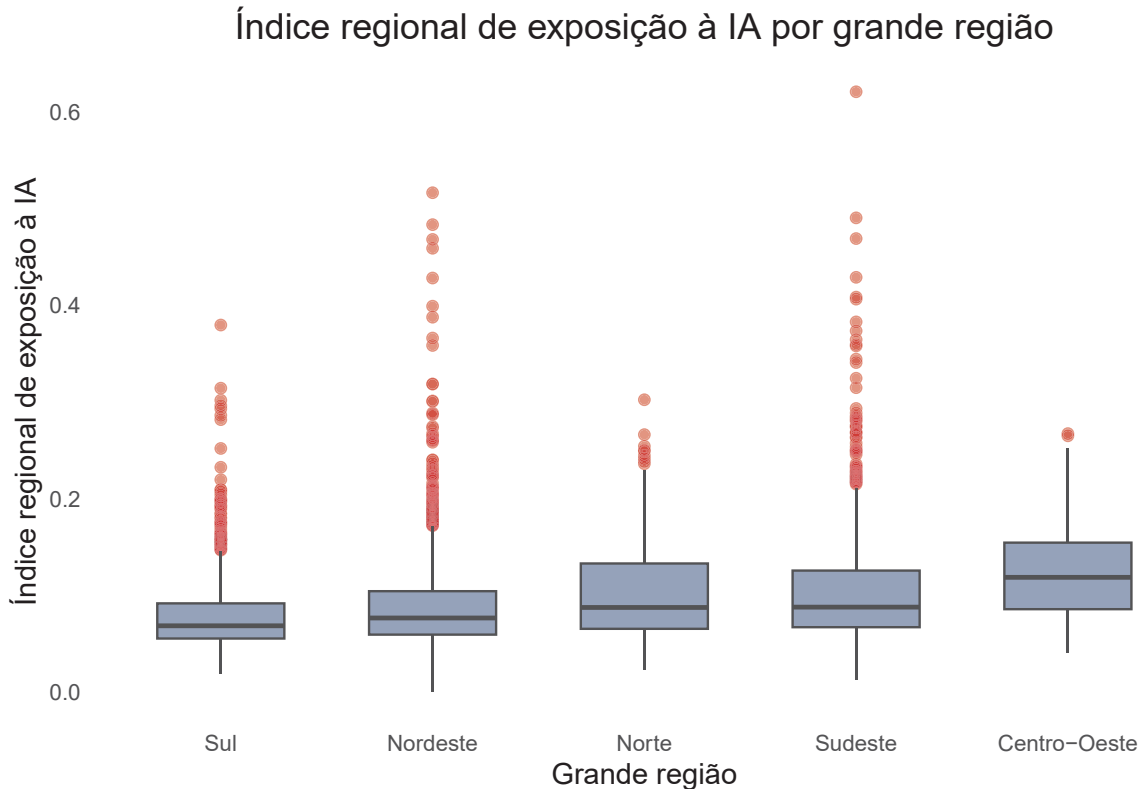


GRÁFICO 2.2 – Exposição das grandes regiões à IA  
Fonte: Elaboração própria.

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.

As 10 (dez) cidades brasileiras mais expostas à IA constam da Tabela 2.4.

TABELA 2.4 – 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, em nível municipal, de exposição à inteligência artificial ponderado pelo emprego formal (RAIS, 2024).

Fonte: Elaboração própria.

O município que aparece como o mais exposto à IA no Brasil é Comendador Gomes, pertencente ao Triângulo Mineiro, que possui uma economia altamente especializada e orientada ao agronegócio, com forte encadeamento em operações mecanizadas, manutenção de maquinário, logística e rotinas administrativas. De acordo com a 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.

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, 2025a), tendo como principal valor adicionado municipal a agropecuária e atividades correlatas (DataMPE Brasil, 2025). 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.

Já a Tabela 2.5 mostra o ranking das capitais brasileiras cuja estrutura ocupacional está mais exposta à IA.

TABELA 2.5 – 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.

Veja-se que todas as capitais se concentram abaixo da mediana nacional e quase todas 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 (veja-se que o setor público é menos flexível à entrada de novas tecnologias), 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.

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.

Por fim, o Gráfico 2.3 traz um mapa que contém a distribuição espacial do índice municipal de exposição à inteligência artificial, veja-se:

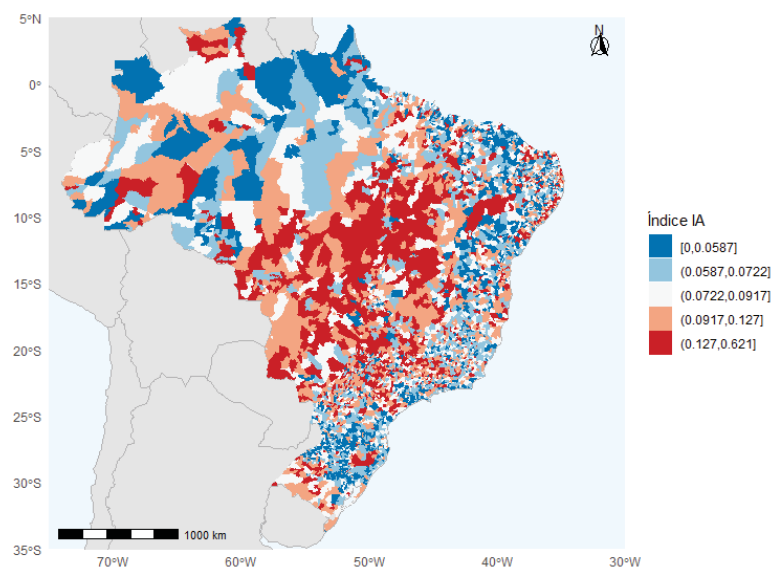


GRÁFICO 2.3 – Exposição regional à IA

Fonte: Elaboração própria.

O Gráfico 2.3 demonstra 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.

Por outro lado, observam-se pontos isolados em amarelo e laranja, que cor-

respondem 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 e, portanto, mais suscetíveis à substituição ou aprimoramento por sistemas de inteligência artificial. 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, embora a exposição à IA em nível agregado seja moderada no Brasil, 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 frente ao avanço da inteligência artificial.

#### 2.4.3.2 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 concentração 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 Gráfico 2.3.

A Figura (a) do Gráfico 2.4 indica 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* reforçam 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.

Ao relacionar o índice regional de IA com o total de empregos (Gráfico 2.4b), 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 2.4 que traz os 10 (dez) municípios brasileiros mais expostos à IA, há elevada concentração em municípios com pouco emprego.

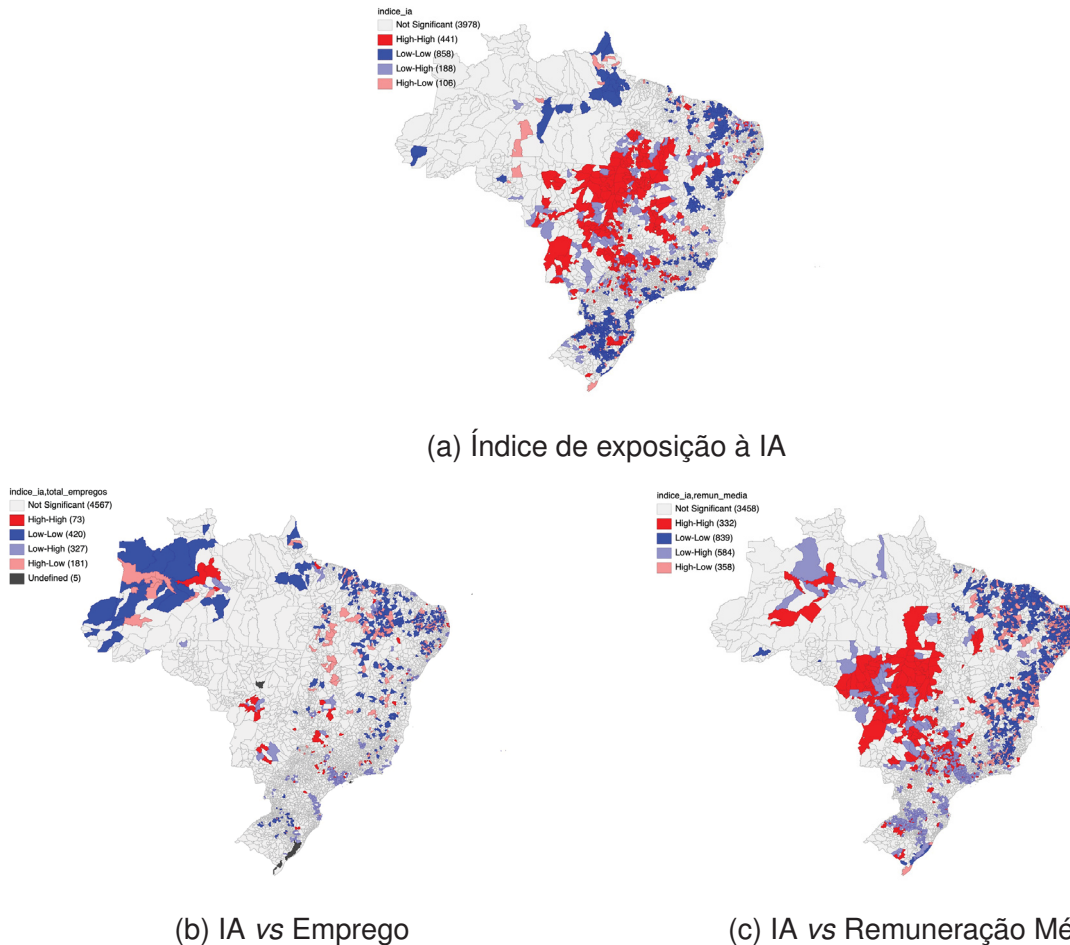


GRÁFICO 2.4 – Análise AEDE — distribuição regional dos índices de exposição à IA  
 Fonte: Elaboração própria.

Como o mapa LISA<sup>3</sup> (Gráfico 2.4a) 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 (Gráfico 2.4c), 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

<sup>3</sup> *Local Indicators of Spatial Association*

principalmente no Nordeste e parte de Minas Gerais, enquanto no Sudeste, há diversos *clusters Low-High* reforçando a existência de disparidades regionais.

Muito embora a análise AEDE não constitua um modelo causal estrutural, os 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.

#### 2.4.3.3 Inteligência Artificial e Estrutura do Valor Adicionado - Evidência Descritiva

Nesta subseção será analisada a associação descritiva entre a exposição ocupacional à inteligência artificial e o nível econômico 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 tercis, 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. O Gráfico 2.5 mostra a associação entre o índice de IA e as variáveis que medem o nível econômico regional.

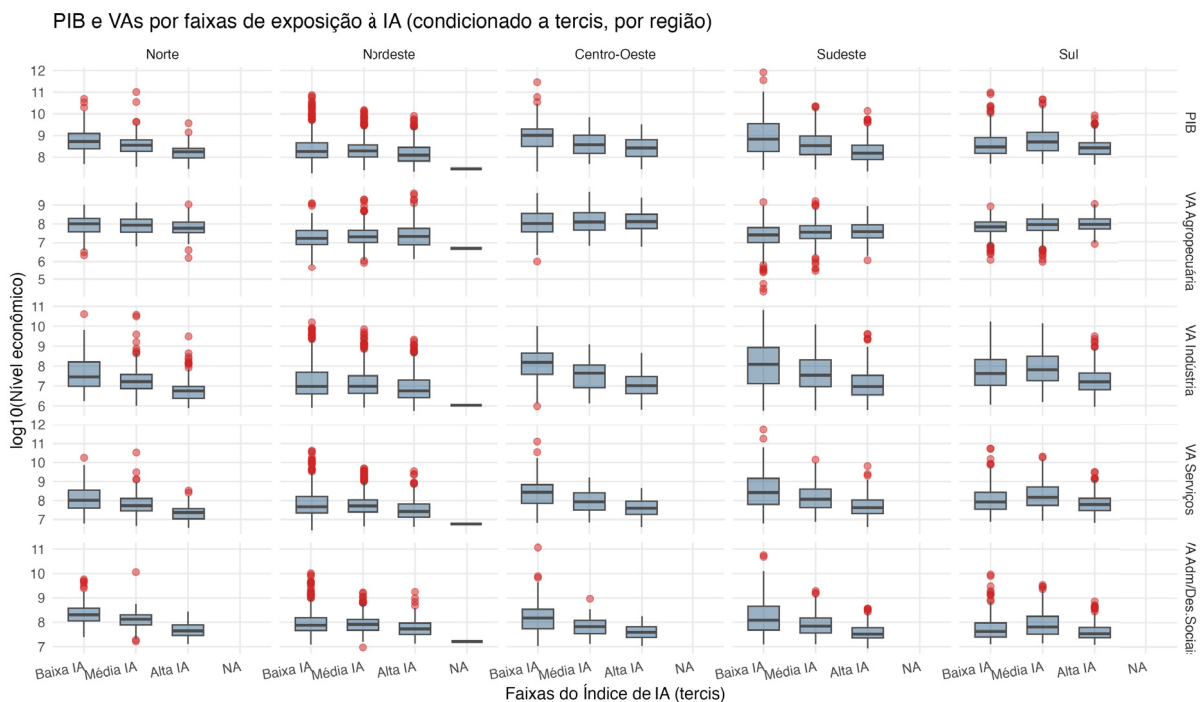


GRÁFICO 2.5 – Exposição à IA e atividade econômica

Fonte: Elaboração própria.

A leitura do Gráfico 2.5 é estritamente descritiva, sendo que, se a mediana do log10 do PIB/VA aumentar ao passar de Baixa para Média e para Alta IA, interpreta-se que há associação positiva entre exposição à inteligência artificial e a escala econômica;

se as medianas se mostrarem estáveis, há ausência de padrão e, se caem, indicam associação negativa.

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 municípios moderadamente expostos concentram maior escala econômica (PIB/VA), 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, porte econômico (PIB/VA) 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 em escala logarítmica, 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.

## 2.5 CONSIDERAÇÕES FINAIS

O trabalho 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. Quatro frentes compõem a agenda de pesquisa futura: (1) efeitos da inteligência artificial sobre renda e emprego feminino; (2) identificação causal com dados em painel municipal; (3) decomposições setoriais de emprego e salários; e (4) 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.

### 3 EFEITOS DA INTELIGÊNCIA ARTIFICIAL SOBRE EMPREGO E RENDA DAS MULHERES: UMA ABORDAGEM EMPÍRICA PARA O CASO BRASILEIRO

#### Resumo:

Este artigo investiga como a exposição à inteligência artificial (IA) afeta o emprego e os rendimentos no mercado de trabalho formal brasileiro, com ênfase nas desigualdades de gênero, em sua interseccionalidade com raça e distribuição territorial. Embora a adoção de tecnologias baseadas em IA possa elevar a produtividade e gerar novas oportunidades ocupacionais, seus efeitos distributivos podem aprofundar processos de segmentação do mercado de trabalho, sobretudo quando ocupações mais expostas concentram grupos socialmente vulneráveis. Evidências empíricas para economias em desenvolvimento ainda são limitadas, especialmente sob uma perspectiva interseccional. A análise utiliza um índice inédito de exposição ocupacional à IA construído a partir de técnicas de processamento de linguagem natural aplicadas às descrições de ocupações brasileiras e a dados de patentes relacionadas à IA. Esse indicador é agregado ao nível municipal com base na estrutura local de emprego e rendimentos, permitindo a construção de medidas desagregadas por gênero e raça para os anos de 2010 e 2024, a partir de microdados da Relação Anual de Informações Sociais (RAIS). A estratégia empírica emprega modelos em painel com efeitos fixos bidimensionais, explorando a variação intra-municipal entre 2010 e 2024 e controlando para heterogeneidade não observada e choques macroeconômicos comuns. Termos de interação entre exposição à IA e indicadores demográficos permitem identificar efeitos heterogêneos entre grupos populacionais. Especificações adicionais analisam impactos sobre diferenciais de gênero e raça no emprego e nos rendimentos, bem como sobre a participação feminina no emprego formal. Os resultados apontam forte heterogeneidade nos processos de ajuste do mercado de trabalho. Para os homens, maior exposição à IA associa-se a expansão do emprego formal, sugerindo predominância de efeitos de complementaridade tecnológica. Em contraste, para as mulheres, observa-se redução do emprego formal, indicando que mecanismos de substituição tendem a prevalecer em ocupações femininas. A desagregação por raça revela padrões interseccionais complexos: homens negros apresentam ganhos relativos mais elevados de emprego, enquanto mulheres brancas registram as maiores perdas. Ainda que alguns resultados sugiram possível redução de diferenciais raciais dentro de determinados grupos, a desigualdade de gênero no emprego formal tende a se ampliar com o aumento da exposição à IA. Os efeitos sobre rendimentos são menores e mais heterogêneos, possivelmente refletindo segmentação ocupacional, rigidez institucional dos salários e diferentes margens de ajuste entre regiões. De forma geral, os achados indicam que a difusão tecnológica interage com estruturas regionais preexistentes do mercado de trabalho e com padrões de segregação ocupacional, reforçando desigualdades de gênero e produzindo dinâmicas distributivas espacialmente diferenciadas, com implicações relevantes para políticas de qualificação, desenvolvimento regional e promoção da equidade no mercado de trabalho.

**Palavras-chave:** inteligência artificial; mercado de trabalho; desigualdades regionais; gênero; raça.

### 3.1 INTRODUÇÃO

As desigualdades de gênero no mercado de trabalho têm sido objeto de ampla investigação na literatura econômica (Blau; Winkler, 2018), especialmente à luz das transformações estruturais provocadas pela digitalização, automação e emergência de tecnologias como a inteligência artificial (Zhang et al., 2024; Yu et al., 2024). Historicamente mulheres enfrentam diversos desafios no mercado de trabalho, que vão desde lacunas salariais e segregação ocupacional até normas sociais restritivas e penalidades associadas à carga do trabalho doméstico e à maternidade (Blau; Kahn, 2017).

Por seu turno, o avanço da inteligência artificial representa uma nova fronteira tecnológica com potencial de elevar a produtividade, criar novas tarefas e ocupações e reconfigurar o valor das habilidades humanas (Acemoglu; Restrepo, 2018a), podendo reduzir as desigualdades materiais de gênero existentes no mercado de trabalho (Albanesi et al., 2025), em uma possível conciliação entre o que Acemoglu e Restrepo (2018a) chamam de *displacement effect* e os efeitos compensatórios que ampliam produtividade e demanda por trabalho.

Muito embora a inteligência artificial prometa ganhos expressivos de eficiência (Acemoglu; Restrepo, 2018a), os efeitos potenciais em países em desenvolvimento permanecem incertos, sobretudo porque os impactos da IA podem depender de variáveis como o nível de infraestrutura do país, de inclusão digital da população, além de heterogeneidades regionais e setoriais (Ofori; Ofori, 2024), e dos níveis de formalidade ou informalidade do mercado de trabalho (Gmyrek et al., 2024). Ademais, no que tange aos efeitos de gênero, os resultados de Albanesi et al. (2025) mostram-se positivos, ainda que os próprios autores indiquem que tal resultado pode depender do nível inicial de participação das mulheres no mercado de trabalho e do grau de qualificação profissional.

Desta forma, a discussão sobre os impactos da inteligência artificial no mercado de trabalho ganha relevância à medida que novas tecnologias de automação e aprendizado de máquina reconfiguram a demanda por novas habilidades (Acemoglu; Restrepo, 2018a), além de influenciar no tempo despendido com o trabalho doméstico (Lu et al., 2023), alterando a composição ocupacional e os retornos do trabalho. Neste contexto, as evidências indicam que a difusão da IA pode tanto ampliar quanto mitigar desigualdades, dependendo da natureza das tarefas automatizáveis e da capacidade dos trabalhadores de se adaptar a novas funções intensivas em tecnologia (Acemoglu; Restrepo, 2018a; Webb, 2019; Albanesi et al., 2025).

A literatura que tem enfoque em questões afetas a gênero sugere que o efeito dessas transformações pode ser particularmente assimétrico para as mulheres, em

razão da maior concentração em ocupações de serviços e de rotina, bem como de barreiras históricas de acesso à educação técnica e digital, estando sub-representadas nas áreas de STEM (Lane, 2024). Porém, também há evidências empíricas fortes de que essas novas tecnologias têm o potencial de reduzir tais assimetrias principalmente para o grupo de mulheres mais excluídas, como no caso das trabalhadoras rurais, que se mostram as maiores beneficiadas pela economia digital na China, conforme os achados de Lu et al. (2023).

Investigar a relação entre a inteligência artificial e o emprego feminino torna-se, portanto, essencial para compreender as novas dinâmicas do mercado de trabalho e avaliar se as tecnologias emergentes tendem a reproduzir ou reduzir disparidades pré-existentes. Mais do que analisar o impacto agregado da IA, é necessário compreender quem são os ganhadores e perdedores diante das novas configurações do mercado de trabalho, especialmente na realidade de uma economia emergente como a brasileira, caracterizada por heterogeneidades regionais, setoriais e educacionais marcantes (Gmyrek et al., 2024).

Neste ensaio, busca-se contribuir para essa discussão ao examinar, sob uma perspectiva empírica, de que forma o avanço da inteligência artificial se relaciona com o emprego e a renda das mulheres no Brasil, oferecendo evidências que permitam avaliar se o progresso tecnológico experimentado devido ao avanço da IA constitui um vetor de inclusão ou de aprofundamento das desigualdades de gênero no mercado de trabalho brasileiro, especificamente em relação às variáveis renda e emprego femininos.

Para tanto, este ensaio utiliza os resultados do primeiro ensaio para o índice de exposição ocupacional à inteligência artificial para cada município brasileiro, calculado com base na metodologia de sobreposição semântica proposta por Webb (2019), como variável explicativa principal, associando o grau de exposição à IA das ocupações ao emprego feminino, à participação feminina e à renda do trabalho das mulheres nos municípios brasileiros, para os anos de 2010 e 2024, analisando, ainda, efeitos sobre o *gap* de gênero e interseccionais.

O objetivo geral deste estudo é analisar os impactos da inteligência artificial sobre o emprego e a renda das mulheres no Brasil. Especificamente, busca-se investigar em que medida a inteligência artificial influencia esses dois aspectos do mercado de trabalho feminino tendo como comparação os anos de 2010 e 2024, considerando as variações regionais desses efeitos.

Para tanto, a análise empírica busca verificar cinco hipóteses. A primeira hipótese a ser testada é se maiores níveis de exposição ocupacional à inteligência artificial, estão associados a maiores taxas de crescimento do emprego feminino entre 2010 e 2024. A segunda hipótese buscar fazer a mesma análise, agora para o crescimento da renda média feminina no período, ou seja, busca avaliar se maiores níveis de exposição

à IA estão associados à maiores níveis de salários para as mulheres. A terceira hipótese é de que o impacto da exposição à IA sobre a renda e o emprego se comporta de forma heterogênea entre mulheres brancas e negras, refletindo desigualdades estruturais de gênero e raça. A quarta hipótese é de que a exposição ocupacional à inteligência artificial afeta o *gap* de gênero no mercado de trabalho, podendo reduzi-lo (caso a IA amplie oportunidades de emprego e renda feminina) ou ampliá-lo (caso a IA beneficie de forma desproporcional os trabalhadores do sexo masculino). Por fim, a quinta hipótese é de que a exposição ocupacional à inteligência artificial em 2010 e 2024 está associada a variações na participação feminina no emprego formal municipal entre 2010 e 2024. A fim de verificar essas hipóteses, adota-se uma abordagem empírica inspirada em Lu et al. (2023), estimando modelos econométricos que relacionam a variação da renda e do emprego feminino à exposição ocupacional à IA.

Além dessa introdução, este ensaio está organizado em sete seções. Traz-se na seção 2 a revisão de literatura sobre os desafios percorridos para a promoção de um ambiente mais igualitário entre homens e mulheres no mercado de trabalho, além de trazer-se luz a alguns estudos que refletem como a IA impacta ou tem o potencial de impactar nesses resultados. Na seção 3, são apresentados os dados e a metodologia utilizados, com destaque para a utilização do índice de inteligência artificial criado para os municípios brasileiros conforme metodologia adotada no primeiro ensaio desta dissertação e a análise de regressão para emprego e renda femininos que tem no índice de IA sua principal variável explicativa. A seção 4 reúne os resultados empíricos da pesquisa, com os principais achados, a seção 5 é dedicada às conclusões e a seção 6 reúne as tabelas de regressão.

## 3.2 REVISÃO DE LITERATURA

Nesta seção será trazido um panorama dos resultados teóricos e empíricos de como a literatura vem abordando a desigualdade de gênero no mercado de trabalho, avançando sobre a emergência da IA e seus reflexos sobre o trabalho feminino.

### 3.2.1 Desigualdade de Gênero no Mercado de Trabalho

O progresso das mulheres no mercado de trabalho tem sido expressivo ao longo das últimas décadas, mas incompleto, conforme destaca Bertrand (2020). A autora ressalta que muito embora mulheres tenham ultrapassado os homens em níveis educacionais e, também, tenham aumentado sua participação no mercado de trabalho, ainda persistem desigualdades salariais e uma baixa representação em cargos de STEM.

Em sua análise, Bertrand (2020) destaca que essas disparidades não podem ser explicadas apenas por diferenças de produtividade ou preferências individuais, pois

estão fortemente entrelaçadas a estereótipos de gênero que moldam expectativas sobre os papéis de mulheres e homens na sociedade, a exemplo do cuidado com os filhos. Esses estereótipos produzem uma profecia autorrealizável e atuam muitas vezes de forma implícita, restringindo as decisões profissionais das mulheres e reforçando desigualdades históricas. Desta forma, na visão da autora, torna-se fundamental investigar os motivos pelos quais mulheres estão fazendo escolhas que as colocam em situação de desigualdade em relação aos homens.

A persistência do gap salarial de gênero é uma das evidências mais claras das barreiras enfrentadas pelas mulheres no mercado de trabalho. Blau e Kahn (2017) mostram que devido aos avanços na educação, na representação sindical e da crescente participação feminina no mercado de trabalho, houve forte redução do hiato salarial de gênero nos Estados Unidos a partir dos anos 80. Contudo, as mulheres ainda ganham, em média, menos que os homens. Segundo Goldin (2024), a penalidade da maternidade, a menor oferta de mão de obra feminina decorrente da necessidade de trabalhos mais flexíveis, associada à estrutura do mercado de trabalho que não remunera por produtividade individual, mas sim por horas trabalhadas, são fatores relevantes para que persista a desigualdade de gênero no mercado de trabalho. Olivetti et al. (2024), acrescenta que não só a penalidade da maternidade aumenta a desigualdade de gênero, mas também um efeito que com frequência vem a ela associado, que é o efeito de prêmio à paternidade.

Resultados obtidos por Gallen (2018) ao analisar o mercado de trabalho dinamarquês mostram que o gap salarial entre homens e mulheres mães, pode ser explicado pela diferença de produtividade entre esse grupo, o que não ocorre na diferença salarial entre homens e mulheres não mães, pois a produtividade entre esse grupo é a mesma. Para o autor, isso indica que mulheres não mães em idade reprodutiva sofrem discriminação estatística por empregadores, pois, acreditando que a produtividade da mulher reduzirá quando do advento da maternidade, como os salários não são flexíveis, oferecem às mulheres não mães uma remuneração mais baixa do que aquela ofertada ao público masculino.

Outros obstáculos à equidade de gênero incluem as barreiras sociais que afetam a inserção das mulheres, especialmente em contextos de informalidade. Analisando dados do Chile, Berniell et al. (2021) encontram como penalidade do primeiro filho a probabilidade de mulheres migrarem para empregos informais em busca de maior flexibilidade de horário, fenômeno que contribui para a persistência das desigualdades e deterioração de melhores perspectivas no mercado de trabalho.

A segregação ocupacional por gênero é outro fator persistente, embora nem sempre traga consigo efeitos negativos. Ao analisar a distribuição ocupacional para o Brasil no período compreendido entre 1978 a 2007, Madalozzo (2010) reconhece que a

desigualdade salarial de gênero no país está diminuindo. No entanto, a autora identifica que as diferenças na distribuição ocupacional acabam refletindo menores salários, ainda que mulheres e homens possuam as mesmas características individuais.

Interessante literatura tem buscado demonstrar que normas sociais também desempenham papel central nas escolhas profissionais e familiares das mulheres. Caminhando nesta direção, Bertrand et al. (2015) mostram que se a mulher possui probabilidade de ter maior renda que o homem, há redução da taxa de casamento. As autoras demonstram, ainda, que em casais nos quais a mulher tem renda superior à do homem, há maior probabilidade de divórcio, o que sugere que normas de identidade de gênero podem impor limites às decisões econômicas das mulheres, mesmo nos contextos de maior empoderamento feminino.

Para além de aspectos microeconômicos, a desigualdade de gênero no mercado de trabalho pode reduzir a produtividade do trabalho e, como consequência, o crescimento do país. Conforme demonstrado por Cuberes e Teignier (2016) e Hsieh et al. (2019), barreiras de gênero implicam alocação ineficiente de talentos, reduzindo produtividade agregada e limitando o crescimento econômico. Ademais, Anggraeni et al. (2022) e Bertay et al. (2025) demonstram que a igualdade de gênero também é elemento necessário para que se promova mais crescimento econômico do país, muito embora não seja elemento suficiente. Por outro lado, Eastin e Prakash (2013) encontram evidências de que há uma relação curvilínea em formato de S (utilizando o conceito de curva Kuznets) na relação entre desenvolvimento econômico e igualdade de gênero, o que sugere que quanto mais desenvolvido o país, maior a igualdade de gênero, limitado, pelos resultados empíricos, à renda *per capita* inferior a US\$ 8.000–10.000.

É dentro desse multifacetado contexto de longa e persistente disparidade de gênero no mercado de trabalho e seus potenciais impactos macroeconômicos que a literatura vem se interessando em investigar se o advento de novas tecnologias digitais, como a inteligência artificial, gera um dividendo de gênero para o emprego feminino, e quais são seus potenciais efeitos na economia. Mulheres que já enfrentam barreiras estruturais no mercado de trabalho, como a sub-representação em áreas de ciência, tecnologia, engenharia e matemática (STEM) (von Dietrich; Garcia, 2022) podem ser ainda mais impactadas pela automação e pela exclusão digital. Por outro lado, há estudos que buscam identificar a existência de vantagem comparativa a favor das mulheres no mercado de trabalho quando se trata da mudança de requerimentos técnicos da força de trabalho que cada vez mais deixa de depender de força física (*brawn*) e passa a requerer maior esforço mental (*brain*) (Rendall, 2017), podendo, assim, a IA gerar um dividendo de gênero favorável às mulheres no mercado de trabalho.

### 3.2.2 Inteligência Artificial e Mercado de Trabalho Feminino

Embora a literatura revele impactos diversos da inteligência artificial sobre o mercado de trabalho, os efeitos não se distribuem de forma homogênea entre os diferentes grupos sociais, em especial entre homens e mulheres. Ao analisar os efeitos da inteligência artificial sobre o mercado de trabalho feminino em 16 países europeus para o período de 2011 a 2019, Albanesi et al. (2025), a partir do índice descrito na seção 3.2.1, identificam uma relação positiva entre a exposição das ocupações às tecnologias de inteligência artificial e o aumento da participação das mulheres no mercado de trabalho. De modo mais específico, os autores mostram que um avanço de 10 percentis na exposição à IA está associado a um crescimento de 2,2% a 2,9% na proporção de mulheres empregadas nas ocupações analisadas. Demonstram, ainda, que os ganhos são maiores nos países em que mulheres já apresentavam taxas mais altas de participação no mercado de trabalho e níveis de escolaridade superiores aos dos homens. Os achados indicam que em contextos de maior inclusão e qualificação feminina, a expansão da inteligência artificial pode ampliar oportunidades, sobretudo em ocupações que valorizam competências cognitivas e interpessoais, áreas em que, conforme aduz Rendall (2017), as mulheres têm se destacado.

Por sua vez, Ofori e Ofori (2024) exploram como a adoção de tecnologias de fronteira (entre elas a inteligência artificial) tem influenciado a desigualdade de gênero para 29 países africanos. Os autores encontram evidências de que essas tecnologias estão associadas à redução das disparidades de gênero, em especial nos países de média e alta renda, em que o acesso à eletricidade é mais amplo. Segundo os autores, a presença de infraestrutura básica, especialmente o acesso à eletricidade, potencializa os efeitos positivos da inovação tecnológica, contribuindo para a redução das desigualdades de gênero. Ainda assim, o estudo evidencia desafios persistentes, como o predomínio masculino no uso de tecnologias mais avançadas e a elevada concentração de mulheres em funções rotineiras, mais suscetíveis à automação. Diante desse cenário, Ofori e Ofori (2024) defendem a adoção de políticas públicas que ampliem o acesso das mulheres à infraestrutura digital, incentivem sua formação em áreas STEM e promovam a requalificação profissional voltada a setores menos expostos à substituição por máquinas, medidas consideradas essenciais para o avanço da igualdade de gênero em um contexto de rápida transformação tecnológica.

No contexto brasileiro, von Dietrich e Garcia (2022) analisam os impactos da Indústria 4.0 sobre o mercado de trabalho feminino e concluem que, embora as mulheres apresentem níveis educacionais mais elevados, ainda estão sub-representadas em áreas de STEM e se concentram majoritariamente em ocupações de baixa qualificação, justamente as mais suscetíveis à automação. Em resposta a esse cenário, as autoras sugerem a adoção de políticas de requalificação voltadas para as áreas técnicas e

científicas, a promoção de uma divisão mais equitativa das tarefas domésticas e o fortalecimento do papel dos sindicatos na proteção dos empregos ocupados por mulheres. O estudo baseia-se em dados provenientes da Relação Anual de Informações Sociais (RAIS), do Censo da Educação Superior e de estimativas de probabilidade de automação para o Brasil elaboradas por Albuquerque et al. (2019) e LIMA et al. (2019), para o período compreendido entre 2010 e 2020. A metodologia combina análise estatística descritiva e cruzamento de dados ocupacionais com estimativas de automação. Os resultados mostram que, embora a participação feminina em STEM para o período tenha aumentado ligeiramente (de 22,9% para 23,3%), as mulheres continuam sub-representadas e com salários inferiores aos dos homens em todas as ocupações analisadas, sendo as maiores disparidades observadas na área de engenharia, onde mulheres recebem em média 76,6% do salário percebido pelos homens.

Explorando a dimensão salarial, Zhang et al. (2024) analisam os impactos da digitalização (que inclui o avanço da IA) sobre os salários femininos, com base em microdados do *Chinese Household Income Project* (CHIP) e do *Chinese Family Panel Studies* (CFPS). Os autores aplicam um modelo de regressão com dados em painel, controlando por idade, escolaridade e PIB per capita. A variável dependente é o logaritmo do salário-hora, e a principal variável explicativa corresponde ao índice de economia digital. Os resultados obtidos indicam que a economia digital reduz a diferença salarial de gênero, especialmente entre os grupos de baixa e média renda, nos setores de serviços e nas regiões urbanas. Zhang et al. (2024) demonstram, ainda, que o aumento no índice de digitalização está associado à redução de 3,1% no gap salarial de gênero, ao incremento de 21,2% no emprego formal feminino e à diminuição relevante do tempo dedicado ao trabalho doméstico feminino. A correlação negativa entre o salário feminino por hora e o número de horas dedicadas ao trabalho doméstico reforça a hipótese de que a redução da sobrecarga doméstica contribui para o aumento da renda das mulheres e para a diminuição das desigualdades salariais. Ainda assim, os autores destacam que a perspectiva de maior igualdade de gênero não implica, necessariamente, um aumento nos salários femininos. Concluem que os principais mecanismos para a redução do gap salarial incluem a promoção do emprego formal com vínculos contratuais mais estáveis para mulheres, a diminuição do trabalho doméstico e o fortalecimento de perspectivas igualitárias de gênero no mercado de trabalho.

Para investigar o caso chinês para o período de 2014 a 2018, Yu et al. (2024) utilizam dados em nível micro do *China Family Panel Studies*, pesquisa nacional representativa de indivíduos e domicílios, combinados com os dados da *International Federation of Robotics* sobre o estoque de robôs industriais por setor e ano, além de registros históricos da introdução de tecnologia durante o denominado *Self-Strengthening Movement*, estes últimos utilizados como variável instrumental. A estratégia empírica

desenvolvida envolveu o emprego de um modelo de regressão com efeitos fixos e estimações em dois estágios (*Two-Stage Least Squares* - 2SLS), na qual os autores exploram variações regionais na exposição a robôs. Os autores analisam variáveis como emprego, renda, horas trabalhadas, casamento, divórcio e número de filhos. A principal variável explicativa é a exposição regional à robotização, enquanto os controles incluem indicadores econômicos e demográficos locais. Os resultados mostram que a automação reduziu desproporcionalmente o emprego e os salários dos homens, enquanto as mulheres aumentaram suas horas de trabalho e melhoraram sua relativa no mercado. A exposição a robôs também levou a mudanças no comportamento familiar, pois as regiões mais automatizadas apresentaram quedas nas taxas de casamento e fertilidade, o que, segundo os autores, decorre da crescente autonomia econômica das mulheres. No agregado, os efeitos da robotização sobre emprego e renda resultaram em redução das disparidades de gênero tanto nas esferas econômicas quanto familiares, pois houve ampliação da participação feminina no mercado de trabalho, bem como aumento do poder de barganha da mulher para tomada de decisões dentro do núcleo familiar, notadamente quanto as decisões de casamento e de maternidade.

Na mesma linha, Rendall (2017) demonstra que a medida em que o paradigma produtivo se desloca de um modelo centrado em esforço físico para outro baseado em habilidades cognitivas e intelectuais, o gap de gênero tende a diminuir, dado que essas novas exigências beneficiam relativamente mais as mulheres que possuem vantagem comparativa sobre os homens para tarefas intelectuais. Contudo, Bloom et al. (2015) e Ofori e Ofori (2024) alertam que a predominância masculina nas áreas de STEM ainda representa um fator de exclusão das mulheres na era digital. Por esse motivo, os autores defendem a formulação de políticas públicas voltadas à inclusão feminina nos campos de ciência, tecnologia, engenharia e matemática, a fim de evitar uma maior segregação ocupacional no contexto da transformação digital.

De modo geral, pode-se observar que os estudos presentes na literatura oferecem resultados ambíguos, sugerindo que a inteligência artificial pode tanto reduzir quanto acentuar as desigualdades de gênero. Em última instância, os efeitos concretos desses processos dependerão das políticas adotadas para promover a inserção das mulheres em setores tecnológicos e em ocupações de maior complexidade cognitiva.

Para Yang e Kim (2024), a compreensão dessas dinâmicas é essencial para a formulação de políticas públicas que garantam maior igualdade de gênero e inclusão no mercado de trabalho tecnológico e de maior complexidade cognitiva. A autora esclarece que a automação intensificada pela inteligência artificial tem o potencial de exacerbar a desigualdade de gênero no mercado de trabalho, ao mesmo tempo em que pode criar novas oportunidades para as mulheres, levantando preocupações sobre os efeitos nas desigualdades de gênero.

Nesse aspecto, a hipótese levantada por Eastin e Prakash (2013) sugere que a segmentação de mercado e discriminação de gênero também podem ser reduzidas devido ao progresso tecnológico, eis que este oferece novas oportunidades de emprego às mulheres, de maneira que a inteligência artificial pode ter importante papel para a redução das disparidades de gênero no mercado de trabalho.

Ainda que não esteja analisando exclusivamente o impacto da inteligência artificial, o trabalho de Lu et al. (2023) indica que o avanço da economia digital gera um dividendo de gênero no emprego feminino na China. Segundo as autoras, o desenvolvimento da economia digital aumenta significativamente a probabilidade de emprego das mulheres, resultado que se explica pela formação de perspectivas de gênero mais igualitárias, pelo maior uso de tecnologias digitais pelo grupo feminino e pela ampliação da demanda por ocupações com preferência feminina. Os achados indicam, ainda, que os efeitos são heterogêneos, beneficiando sobretudo mulheres de baixa qualificação, mais velhas e residentes em áreas rurais. Contudo, embora a digitalização traga benefícios relevantes a esses grupos que acabam sendo os mais excluídos, ela não é capaz de reduzir substancialmente o hiato de gênero no emprego, em razão da persistente divisão digital de gênero evidenciada pelo crescimento mais que proporcional no uso dessas tecnologias pelo grupo masculino (Lu et al., 2023).

Por sua vez, Albanesi et al. (2025) analisam a relação entre a difusão de tecnologias baseadas em inteligência artificial e a participação feminina no mercado de trabalho europeu. Utilizando dados de 16 países entre 2011 e 2019 e medidas de exposição ocupacional à IA derivadas de Felten et al. (2019) e Webb (2019), as autoras constataam que ocupações mais expostas à IA apresentaram maior crescimento na participação feminina. Esse impacto positivo é mais intenso em países com maior nível educacional feminino e maior taxa inicial de participação das mulheres, sugerindo que a educação e a inserção prévia no mercado de trabalho potencializam os ganhos decorrentes da adoção de tecnologias baseadas em IA.

Dessa forma, as evidências de Lu et al. (2023) e Albanesi et al. (2025) convergem ao indicar que, embora a digitalização e a inteligência artificial possam ampliar as oportunidades de emprego feminino, seus efeitos permanecem condicionados às estruturas educacionais e sociais que moldam o acesso das mulheres às novas tecnologias e às oportunidades no mercado de trabalho, conclusão esta também endereçada por Lane (2024), cujo trabalho reforça a necessidade de promoção de capacitação inclusiva e de uma maior participação feminina nas áreas de STEM, sob pena de a IA potencializar as desigualdades de gênero já existentes, ao invés de reduzi-las.

Em síntese, a literatura demonstra que as desigualdades de gênero no mercado de trabalho decorrem de um conjunto complexo de fatores interligados que percorrem temas como normas sociais e a estrutura familiar, caminhando até pelas transforma-

ções tecnológicas mais disruptivas, denotando, ainda, que em que pese o avanço da economia digital e da inteligência artificial tragam potenciais ganhos de inclusão da participação feminina e redução das disparidades salariais, seus efeitos dependem de contextos institucionais, econômicos, educacionais e culturais, que determinam o modo como mulheres e homens se inserem nas novas dinâmicas produtivas. Nesse sentido, torna-se fundamental compreender como a difusão dessas novas tecnologias, aqui mais precisamente da inteligência artificial, têm impactado o emprego e a renda das mulheres no contexto brasileiro, marcado por profundas heterogeneidades regionais e estruturais.

### 3.3 DADOS E METODOLOGIA

Este segundo ensaio constitui uma continuação direta do primeiro, no qual foi construído o índice de exposição ocupacional à inteligência artificial (IA) para o Brasil, com base na metodologia de sobreposição semântica proposta por Webb (2019). No presente estudo, esse índice é incorporado à análise empírica como variável explicativa principal, permitindo investigar de que forma a exposição à IA está associada à variação do emprego e da renda feminina nos municípios brasileiros entre 2010 e 2024.

#### 3.3.1 Base de dados

A base de dados é composta majoritariamente por microdados da RAIS - Relação Anual de Informações Sociais, que permitem mensurar o emprego formal e a renda média do trabalho por ocupação e município, além de dados demográficos e regionais complementares (IBGE, 2025b). A análise contempla todas as famílias de ocupações, inclusive aquelas com valores nulos de emprego ou renda para determinado ano ou município.

As variáveis dependentes consideradas neste trabalho foram: (i) o total de emprego formal por gênero do município  $m$  em 2010 e 2024; (ii) a renda média do trabalho por gênero no município  $m$  no mesmo período; (iii) A diferença de gênero no emprego e na renda, correspondente à diferença percentual entre homens e mulheres, negros e brancos, bem como entre mulheres brancas e mulheres negras; (iv) A diferença de gênero no emprego e na renda, correspondente à diferença percentual entre homens e mulheres em termos de emprego e renda, por ocupação e município, permitindo avaliar se a exposição à IA está associada à ampliação ou redução dessas disparidades; e (v) A participação das mulheres no emprego formal total do município  $m$  em 2010 e 2024.

As remunerações médias foram deflacionadas pelo IPCA (IBGE), trazendo todos os valores para preços de dezembro de 2024. Foram utilizados os números-índice de dezembro de cada ano (dez/2010 e dez/2024), uma vez que a RAIS aqui utilizada

considera apenas vínculos ativos em 31 de dezembro, de modo que a comparação se refere ao salário médio ao final de cada ano em termos reais, assegurando, desta forma, que as diferenças salariais desse período reflitam mudanças reais no poder de compra das famílias e não meras oscilações inflacionárias.

Em conformidade com as orientações metodológicas do IBGE relativas às *Áreas Mínimas Comparáveis* (AMC), procedeu-se à harmonização territorial do painel municipal de 2010 a 2024. As alterações na divisão político-administrativa brasileira ocorridas após 2010 exigem que a unidade de análise seja mantida constante ao longo do tempo, de forma a evitar que mudanças meramente cartográficas gerem variações indevidas na análise estatística a ser realizada neste trabalho. Assim, todos os novos municípios brasileiros instituídos no período foram reintegrados aos respectivos municípios de origem na etapa de preparação dos dados referentes a 2010. A Tabela 3.1 apresenta os pares completos de municípios de origem e municípios novos, conforme a estrutura territorial disponibilizada pelo IBGE (2023).

TABELA 3.1 – Municípios criados ou instalados após 2010, seus municípios de origem, bases legais e datas de instalação

<b>Município-mãe</b>	<b>IBGE</b>	<b>Município criado</b>	<b>IBGE</b>	<b>UF</b>	<b>Base legal de criação</b>	<b>Instalação</b>
Santarém	1506807	Mojuí dos Campos	1504754	PA	Lei Estadual n.º 6.268, de 07/12/1999	01/01/2013
Laguna	4209409	Pescaria Brava	4212650	SC	Lei Estadual n.º 12.690, de 25/10/2003	01/01/2013
Içara	4207007	Balneário Rincão	4220000	SC	Lei Estadual n.º 12.668, de 03/10/2003	01/01/2013
Bento Gonçalves	4302105	Pinto Bandeira	4314548	RS	Lei Estadual n.º 10.749	2013
Costa Rica	5003702	Paraíso das Águas	5006275	MS	Lei Estadual n.º 2.679 de 29/09/2003	01/01/2013
Nova Ubiratã	5106240	Boa Esperança do Norte	5108300	MT	Lei Estadual n.º 7.264, de 29/03/2000	01/01/2025

Fonte: Elaboração própria a partir de IBGE (2023).

O procedimento adotado assegura que as medidas de emprego, renda e exposição ocupacional à inteligência artificial reflitam variações reais entre os anos analisados, e não alterações decorrentes de simples redefinições dos limites administrativos.

Como variáveis de controle, foram incluídas características municipais que po-

dem afetar simultaneamente a estrutura ocupacional e a inserção feminina no mercado de trabalho, tais como a taxa de participação feminina inicial, seguindo a proposta de Albanesi et al. (2025), além da taxa de participação inicial de mulheres negras e o log do emprego total. Características individuais que denotam atributos observáveis do trabalhador também foram incorporadas ao modelo como controle, sendo elas a idade, escolaridade e experiência médias de cada região, aproximando-se, assim, literatura sobre o tema, i.e., Lu et al. (2023).

### 3.3.2 Índice de exposição à IA, Gap de gênero e Participação feminina

O índice de exposição ocupacional à IA ( $IA_{ocupação}$ ) foi originalmente obtido a partir da correspondência semântica entre descrições de tarefas da Classificação Brasileira de Ocupações (CBO) e descritores tecnológicos associados à inteligência artificial, conforme metodologia de Webb (2019). O resultado expressa, para cada ocupação, o grau de suscetibilidade das tarefas à automação ou complementação por tecnologias baseadas em IA. Para fins deste ensaio, o índice é ponderado pela estrutura de emprego observada em 2010, de modo a capturar a distribuição inicial das ocupações nos municípios brasileiros.

A ponderação é realizada conforme a equação abaixo:

$$IA_m = \sum_o IA_o \times peso_{o,m,2010} \quad (3.1)$$

em que:

$IA_m$  representa o índice ponderado de exposição à IA no município  $m$ ;

$IA_o$  é o índice de exposição para a ocupação  $o$ ; e

$peso_{o,m,2010}$  é a participação da ocupação  $o$  no total do emprego formal do município  $m$  no ano base de 2010.

Essa ponderação fixa o peso no período inicial, seguindo a abordagem de Albanesi et al. (2025), o que permite identificar se municípios com maior exposição inicial à IA apresentaram ao longo do tempo maior variação na participação feminina e na renda do trabalho.

Mesma ponderação foi feita para o ano de 2024, permitindo, assim, a utilização de técnicas de painel de dados.

Por sua vez, a mensuração dos *gaps* de emprego e renda foi calculada para cada município  $m$ , a cada ano  $t \in \{2010, 2024\}$ , considerando as diferenças de gênero e raça, da seguinte forma:

$$\text{Gap}_{m,t}^Y = \frac{Y_{m,t}^i - Y_{m,t}^j}{Y_{m,t}^i} \times 100 \quad (3.2)$$

Em que a variável  $Y$  pode ser a renda, ou o emprego, e o comparativo pode ser entre homens e mulheres, ( $i = \text{homens}, j = \text{mulheres}$ ), ou entre raças ( $i = \text{branca}, j = \text{negra}$ ), considerando as combinações possíveis de gênero e raça.

Por fim, a mensuração da participação feminina no emprego formal foi calculada para cada município  $m$ , a cada ano  $t \in \{2010, 2024\}$ , como a razão entre o emprego formal feminino e o emprego formal total, conforme equação abaixo:

$$\text{Share}_{m,t}^{\text{Fem}} = \frac{\text{Emp}_{m,t}^{\text{Fem}}}{\text{Emp}_{m,t}^{\text{Tot}}} \times 100 \quad (3.3)$$

Em que  $\text{Emp}_{m,t}^{\text{Fem}}$  representa o número de vínculos formais ocupados por mulheres no município  $m$  no ano  $t$ , e  $\text{Emp}_{m,t}^{\text{Tot}}$  corresponde ao total de vínculos formais no mesmo município e ano, i.e.,  $\text{Emp}_{m,t}^{\text{Tot}} = \text{Emp}_{m,t}^{\text{Fem}} + \text{Emp}_{m,t}^{\text{Masc}}$ . Assim,  $\text{Share}_{m,t}^{\text{Fem}}$  expressa a participação das mulheres no emprego formal municipal, em termos percentuais.

### 3.3.3 Estratégia empírica

A estratégia empírica buscará analisar os efeitos da inteligência artificial sobre (i) o emprego feminino entre os anos de 2010 e 2024, consistente com a primeira hipótese (levantada na introdução do trabalho)<sup>1</sup>; (ii) a renda feminina para os anos de 2010 e 2024, consistente com a segunda hipótese<sup>2</sup>; (iii) o nível de renda e emprego entre a amostra para mulheres brancas e mulheres negras, consistente com a terceira hipótese<sup>3</sup>; ou (iv) o *gap* de gênero no emprego e na renda entre os anos de 2010 e 2024, consistente com a quarta hipótese do trabalho<sup>4</sup>; (v) a participação feminina no emprego total formal entre os anos de 2010 e 2024, consistente com a quinta hipótese<sup>5</sup>.

A estratégia empírica congrega elementos das abordagens de Lu et al. (2023), Albanesi et al. (2025) e Webb (2019), adaptada aos dados disponíveis, ao contexto municipal brasileiro e considerando as diferentes composições de ocupações de cada

<sup>1</sup> Municípios com maior exposição ocupacional à inteligência artificial apresentaram maior nível de emprego feminino formal entre 2010 e 2024.

<sup>2</sup> Municípios com maior exposição ocupacional à IA apresentaram maior nível de renda média feminina no período 2010–2024.

<sup>3</sup> O impacto da exposição à IA sobre a renda e o emprego se comporta de forma heterogênea entre mulheres brancas e negras, refletindo desigualdades estruturais de gênero e raça.

<sup>4</sup> A quarta hipótese é de que a exposição ocupacional à inteligência artificial afeta o *gap* de gênero no mercado de trabalho, podendo reduzi-lo (caso a IA amplie oportunidades de emprego e renda feminina) ou ampliá-lo (caso a IA beneficie de forma desproporcional os trabalhadores do sexo masculino).

<sup>5</sup> A quinta hipótese levantada testa se municípios com maior exposição ocupacional à inteligência artificial em 2010 apresentaram maior participação feminina no emprego formal entre 2010 e 2024.

município ao longo do tempo. O objetivo é identificar se a exposição ocupacional à inteligência artificial ao nível do município está associada à evolução do emprego e da renda feminina, bem como às diferenças de gênero, no período de 2010 a 2024.

Utiliza-se como variáveis de controle o tamanho inicial do mercado de trabalho (log do emprego total), a participação feminina inicial, a participação inicial da amostra negra feminina, idade, escolaridade e experiência. Esses controles seguem a literatura de desigualdades no mercado de trabalho (Albanesi et al., 2025; Blau; Kahn, 2017), de estratificação racial (Bayer; Charles, 2018; Chetty et al., 2020), bem como a literatura de choques tecnológicos e estrutura produtiva local (Acemoglu; Restrepo, 2017; Lu et al., 2023).

A escolha do ano de 2010 como referência para o índice municipal de exposição à IA apoia-se no fato de que 2010 corresponde ao ano do Censo Demográfico brasileiro, o que oferece um marco territorial e populacional sólido para facilitar comparações posteriores e apoiar estudos futuros. Já para 2024, este foi o último ano de dados consolidados na RAIS disponíveis até a conclusão do estudo.

A partir desses dados, a equação básica de regressão estimada é representada pelo modelo de regressão em painel com efeitos fixos bidimensionais (*Two-Way Fixed Effects – TWFE*), que controla simultaneamente por heterogeneidade não observada e invariável no tempo a nível municipal, bem como por choques agregados comuns a todos os municípios em cada ano. Não obstante, como a base de dados contempla apenas dois pontos no tempo, a inclusão simultânea de efeitos fixos de município e de ano implica que a identificação dos parâmetros decorre exclusivamente das variações observadas entre 2010 e 2024. Nesse contexto, o modelo é equivalente a uma regressão em primeira diferença implícita, de modo que os coeficientes estimados capturam associações entre mudanças de longo prazo nas variáveis explicativas e a variação do emprego formal no período considerado, não sendo possível identificar dinâmicas temporais, efeitos de curto prazo ou trajetórias intermediárias.

Para a Hipótese 1, em que se quer testar se municípios com maior variação na exposição ocupacional à inteligência artificial apresentaram maior variação no emprego formal feminino, estima-se um modelo em painel com efeitos fixos bidimensionais (TWFE) em base empilhada por gênero, com homens como grupo de referência, sendo a equação de regressão dada por:

$$\begin{aligned} \ln(Emp_{m,t}) = & \beta_1 IA_{m,t} + \beta_2 Mulher_{m,t} + \beta_3 (IA_{m,t} \times Mulher_{m,t}) \\ & + \beta_4 PF_{m,t} + \beta_5 PMN_{m,t} + \beta_6 \ln(Emp_{m,t}^{tot}) \\ & + \beta_7 Idade_{m,t} + \beta_8 Exper_{m,t} + \beta_9 Esc_{m,t} + \alpha_m + \lambda_t + \varepsilon_{m,t} \end{aligned} \quad (3.4)$$

Em que,  $\ln(Emp_{m,t})$  representa o logaritmo do emprego formal no município

$m$  no ano  $t \in \{2010, 2024\}$ , estimado a partir de um painel municipal empilhado por gênero.

A variável  $IA_{m,t}$  corresponde ao índice municipal de exposição à inteligência artificial, construído de forma dinâmica e centrada, refletindo a intensidade relativa da difusão de tecnologias associadas à IA no mercado de trabalho local. A variável *dummy*  $Mulher_{m,t}$  assume valor igual a um para observações femininas e zero para masculinas, de modo que os homens constituem o grupo de referência da análise. O termo de interação ( $IA_{m,t} \times Mulher_{m,t}$ ) permite identificar se o impacto da exposição à IA sobre o emprego formal difere entre mulheres e homens, sendo o coeficiente associado a esse termo interpretado como o efeito diferencial da IA sobre o emprego feminino em relação ao masculino. As variáveis  $PF_{m,t}$  e  $PMN_{m,t}$  representam, respectivamente, a participação feminina total e a participação de mulheres negras no emprego formal municipal, sendo que ambas variam ao longo do tempo e capturam mudanças na composição de gênero e raça do mercado de trabalho local.

Funcionando como um controle de escala econômica e de demanda agregada por trabalho, o termo  $\ln(Emp^{tot}_{m,t})$  corresponde ao logaritmo do emprego total municipal. As variáveis  $Idade_{m,t}$ ,  $Exper_{m,t}$  e  $Esc_{m,t}$  representam, respectivamente, a idade média, a experiência média (medida pelo tempo no mesmo emprego), e a escolaridade média da força de trabalho formal municipal, capturando características demográficas e de capital humano que variam ao longo do tempo. Por fim,  $\alpha_m$  denota os efeitos fixos de município,  $\lambda_t$  os efeitos fixos de ano, e  $\varepsilon_{m,t}$  o termo de erro aleatório.

Para a Hipótese 2, em que se quer testar se municípios com maior aumento na exposição ocupacional à IA apresentaram maior variação na renda média por gênero entre 2010 e 2024, estima-se uma especificação análoga à Hipótese 1, substituindo-se a variável dependente pela renda. A equação de regressão é dada por:

$$\begin{aligned} \ln(1 + Renda_{m,t}) = & \beta_1 IA_{m,t} + \beta_2 Mulher_{m,t} + \beta_3 (IA_{m,t} \times Mulher_{m,t}) \\ & + \beta_4 PF_{m,t} + \beta_5 PMN_{m,t} + \beta_6 \ln(Emp^{tot}_{m,t}) \\ & + \beta_7 Idade_{m,t} + \beta_8 Exper_{m,t} + \beta_9 Esc_{m,t} + \alpha_m + \lambda_t + \varepsilon_{m,t} \end{aligned} \quad (3.5)$$

Em que,  $\ln(1 + Renda_{m,t,g})$  corresponde ao logaritmo da renda formal média do município  $m$ , no ano  $t$ , para o grupo de gênero  $g$ .

Na Hipótese 3, se quer testar se as variações na exposição à IA possuem relações interseccionais de gênero e raça distintos sobre a renda e o emprego. Ou seja, nessa especificação, são comparados os resultados para homens brancos, homens negros, mulheres brancas e mulheres negras, tomando homem branco (HB) como categoria de referência. Para a variável emprego, estima-se:

$$\begin{aligned}
\ln(Emp_{m,t,g}) = & \beta_0 + \beta_1 IA_{m,t} + \beta_2 HN_g + \beta_3 MB_g + \beta_4 MN_g \\
& + \beta_5 PF_{m,t} + \beta_6 PMN_{m,t} + \beta_7 \ln(Emp_{m,t}^{tot}) \\
& + \beta_8 Idade_{m,t} + \beta_9 Exper_{m,t} + \beta_{10} Esc_{m,t} \\
& + \beta_{11}(IA_{m,t} \times HN_g) + \beta_{12}(IA_{m,t} \times MB_g) + \beta_{13}(IA_{m,t} \times MN_g) \\
& + \alpha_m + \lambda_t + \varepsilon_{m,t,g}
\end{aligned} \tag{3.6}$$

e, para a renda, a equação é formalmente idêntica, alterando-se apenas a variável dependente:

$$\begin{aligned}
\ln(1 + Renda)_{m,t,g} = & \beta_0 + \beta_1 IA_{m,t} + \beta_2 HN_g + \beta_3 MB_g + \beta_4 MN_g \\
& + \beta_5 PF_{m,t} + \beta_6 PMN_{m,t} + \beta_7 \ln(Emp_{m,t}^{tot}) \\
& + \beta_8 Idade_{m,t} + \beta_9 Exper_{m,t} + \beta_{10} Esc_{m,t} \\
& + \beta_{11}(IA_{m,t} \times HN_g) + \beta_{12}(IA_{m,t} \times MB_g) + \beta_{13}(IA_{m,t} \times MN_g) \\
& + \alpha_m + \lambda_t + \varepsilon_{m,t,g}
\end{aligned} \tag{3.7}$$

Em que  $\ln(Emp_{m,t,g})$  é o logaritmo do emprego formal do grupo  $g$  no município  $m$  e no ano  $t$ , com  $g \in \{HB, HN, MB, MN\}$  representando, respectivamente, homem branco (referência), homem negro, mulher branca e mulher negra;  $\ln(1 + Renda)_{m,t,g}$  é o logaritmo da renda formal do grupo  $g$  no município  $m$  e no ano  $t$ ;  $IA_{m,t}$  é o índice municipal de exposição à inteligência artificial, cujo coeficiente base  $\beta_1$  mede o efeito da exposição à IA para o grupo de referência (homem branco). As variáveis indicadoras  $HN_g$ ,  $MB_g$  e  $MN_g$  capturam diferenças de nível (intercepto) de cada grupo em relação ao homem branco, enquanto os termos de interação  $IA_{m,t} \times HN_g$ ,  $IA_{m,t} \times MB_g$  e  $IA_{m,t} \times MN_g$  medem como o efeito da IA difere em cada grupo relativamente ao efeito-base dos homens brancos. Os controles que variam no tempo incluem  $PF_{m,t}$  (Participação Feminina no emprego municipal),  $PMN_{m,t}$  (Participação de Mulheres Negras no emprego municipal),  $\ln(Emp_{m,t}^{tot})$  (log do emprego total municipal),  $Idade_{m,t}$  (idade média),  $Exper_{m,t}$  (experiência média em meses) e  $Esc_{m,t}$  (escolaridade média).  $\alpha_m$  representa efeitos fixos de município e  $\lambda_t$  efeitos fixos de ano (2010 vs. 2024).

Já para a Hipótese 4, em que se quer testar se a variação na exposição ocupacional do município à inteligência artificial está relacionada a variações no *gap* de gênero no mercado de trabalho entre 2010 e 2024, a estratégia empírica utiliza o *gap* como variável dependente, estimando um painel municipal “puro” por município (sem empilhamento) com TWFE. Para o *gap* de emprego e renda, estima-se:

$$\text{Gap}_{m,t}^{emp} = \alpha + \beta_1 IA_{m,t} + \mathbf{X}_{m,t}' \gamma + \mu_m + \lambda_t + \varepsilon_{m,t}, \tag{3.8}$$

$$\text{Gap}_{m,t}^{\text{ren}} = \alpha + \beta_1 \text{IA}_{m,t} + \mathbf{X}'_{m,t} \boldsymbol{\gamma} + \mu_m + \lambda_t + \varepsilon_{m,t}, \quad (3.9)$$

Em que  $m$  denota o município,  $t$  o período de tempo,  $\mu_m$  representa os efeitos fixos específicos de cada município,  $\lambda_t$  captura os efeitos fixos de ano e  $\varepsilon_{m,t}$  corresponde ao termo de erro aleatório. As variáveis dependentes  $\text{Gap}_{m,t}^{\text{emp}}$  e  $\text{Gap}_{m,t}^{\text{ren}}$  representam, respectivamente, o *gap* percentual de gênero no emprego formal e o *gap* percentual de gênero na renda formal no município  $m$  e no ano  $t$ . Referidos indicadores mensuram a desigualdade relativa entre homens e mulheres e foram construídos a partir da diferença proporcional entre os resultados masculinos e femininos, de modo que valores positivos indicam maior vantagem masculina. Já o vetor de controles  $\mathbf{X}'_{m,t}$  inclui as mesmas características estruturais do mercado de trabalho local e do perfil médio da força de trabalho, incluídos nos demais modelos, porém sem a desagregação por gênero e raça. Ou seja, os controles incluem o log do emprego total do município, a idade média, a experiência média e a escolaridade média dos trabalhadores.

Por fim, na Hipótese 5, em que se quer testar se municípios com maior crescimento no índice de exposição ocupacional à inteligência artificial entre 2010 e 2024 estão associados à maior participação das mulheres, estima-se um modelo em painel com TWFE tomando como variável dependente a participação feminina no emprego total formal. A equação de regressão é dada por:

$$\begin{aligned} \text{Share}_{g,m,t} = & \beta_0 + \beta_1 \text{IA}_{m,t} + \beta_2 \text{Mulher}_g + \beta_3 (\text{IA}_{m,t} \times \text{Mulher}_g) \\ & + \mathbf{X}'_{m,t} \boldsymbol{\gamma} + \alpha_m + \lambda_t + \varepsilon_{g,m,t} \end{aligned} \quad (3.10)$$

Em que  $\text{Share}_{g,m,t}$  representa a participação do grupo de gênero  $g$  no emprego formal do município  $m$  no ano  $t$ ; a variável  $\text{IA}_{m,t}$  corresponde ao índice municipal de exposição à inteligência artificial; a *dummy*  $\text{Mulher}_g$  identifica o grupo feminino, tendo os homens como categoria de referência; o termo de interação  $\text{IA}_{m,t} \times \text{Mulher}_g$  permite identificar se o efeito da exposição à inteligência artificial difere entre mulheres e homens; o vetor  $\mathbf{X}_{m,t}$  inclui variáveis de controle que variam no tempo, tais como a participação de mulheres negras no emprego, o logaritmo do emprego total municipal, a idade média, a experiência média medida pelo tempo de emprego e a escolaridade média da força de trabalho; os termos  $\alpha_m$  e  $\lambda_t$  representam, respectivamente, os efeitos fixos de município e de ano, controlando por características não observáveis invariantes no tempo e por choques macroeconômicos comuns a todos os municípios; por fim, o termo  $\varepsilon_{g,m,t}$  denota o termo de erro aleatório.

### 3.4 RESULTADOS

Esta seção apresenta os principais resultados da pesquisa, estruturados de modo a evidenciar como a exposição ocupacional à inteligência artificial se relaciona com a dinâmica do emprego e da renda feminina no Brasil entre 2010 e 2024. Inicialmente, são discutidas as estatísticas descritivas das principais variáveis analisadas, permitindo destacar os padrões regionais, ocupacionais e de gênero. Em seguida, são exploradas as medidas de exposição à IA construídas a partir da metodologia de Webb (2019), adaptada ao contexto brasileiro, conforme metodologia explicada no primeiro ensaio desta dissertação. Ao final, são apresentados os resultados das estimativas econométricas.

#### 3.4.1 Evolução do emprego formal e da renda real por gênero e raça entre 2010 e 2024

Antes da estimação dos modelos econométricos, serão apresentados os resultados descritivos que caracterizam a estrutura do emprego formal brasileiro e sua evolução entre 2010 e 2024, considerando gênero, raça e suas interseções. Tais agregados foram obtidos por meio dos dados da RAIS e permitem compreender a dinâmica do mercado de trabalho no período analisado, servindo de base para o cálculo das variações e dos *gaps* utilizados na análise econométrica.

A Tabela 3.2 mostra o emprego e a renda média para mulheres e homens em 2010 e 2024. Em 2010, o emprego formal feminino contabilizava aproximadamente 18,3 milhões de vínculos, enquanto o masculino atingia 25,7 milhões. Em 2024, ambos os grupos cresceram, chegando a 19,1 milhões e 27,1 milhões, respectivamente. Observa-se, assim, que o emprego formal expandiu-se para ambos os gêneros no período, entretanto, o crescimento absoluto do emprego masculino foi superior ao feminino, podendo-se observar que a participação relativa das mulheres manteve-se praticamente estável, indicando persistência da disparidade de gênero na estrutura ocupacional.

TABELA 3.2 – Emprego formal e renda média real do trabalho por gênero, 2010 e 2024.

Ano	Sexo	Emprego formal	Renda média real (R\$ de 2024)
2010	Feminino	18.315.597	3.143
2010	Masculino	25.752.758	3.803
2024	Feminino	19.129.726	2.844
2024	Masculino	27.140.788	3.445

Fonte: Elaboração própria a partir de dados da RAIS (MTE, 2025).

No que pertine à renda média real, esta apresenta trajetória distinta da obser-

vada no emprego. Em 2010, as mulheres recebiam, em média, R\$ 3.143 mensais, a preços de 2024, enquanto os homens recebiam R\$ 3.803. Em 2024, verifica-se queda para ambos os grupos: a renda feminina recua para R\$ 2.844, enquanto a masculina diminui para R\$ 3.445. Esses resultados indicam que houve perda real de poder de compra dos trabalhadores de ambos os grupos no período, porém, embora a diferença absoluta entre os rendimentos tenha diminuído, a distância proporcional entre homens e mulheres permanece elevada.

A Tabela 3.3 apresenta a variação percentual do emprego feminino e a variação percentual da renda média real feminina entre 2010 e 2024. Os resultados obtidos demonstram a heterogeneidade entre os municípios brasileiros. No que diz respeito à variável emprego feminino, a mediana negativa indica que em pelo menos metade dos municípios o número de vínculos formais femininos diminuiu ao longo do período analisado. Apesar disso, os valores máximos indicam que existem casos extremos de forte expansão do emprego feminino.

TABELA 3.3 – Variações de emprego e renda feminina (2010–2024)

<b>Medida</b>	$\Delta Emp_{fem}$ (%)	$\Delta Renda_{fem}$ (%)
Mínimo	-99,32	-100,00
1º quartil	-69,43	-11,16
Mediana	-27,76	1,39
Média	-22,18	2,08
3º quartil	11,37	13,45
Máximo	1633,33	260,71

Fonte: Elaboração própria a partir de dados da RAIS (MTE, 2025).

A análise na média (–22,18%), corrobora que em termos agregados o emprego formal das mulheres apresentou retração no período 2010–2024. Esse valor médio negativo, combinado com a mediana ainda mais negativa (–27,76%), indica que a queda no emprego feminino não se deve apenas a poucos municípios com retrações que possam ser mais acentuadas, mas a um comportamento generalizado, ainda que coexistam municípios com grande expansão.

Para a renda feminina, a média (2,08%) e a mediana (1,39%) são ambas positivas e bastante próximas, denotando uma distribuição mais simétrica em torno do centro, com menos influência de *outliers* sobre o valor médio. Porém, a amplitude entre o valor mínimo (–100%) e o valor máximo (260,71%) reforça a heterogeneidade nos municípios brasileiros.

Essa combinação de médias negativas para emprego e positivas para renda indica a possibilidade de que a dinâmica do mercado de trabalho feminino no período de 2010–2024 pode ter sido marcada por efeitos de composição ocupacional, em que

a retração do emprego em ocupações de baixa remuneração pode elevar a renda média, mesmo sem ganhos generalizados em termos de qualidade dos empregos ou produtividade. Trata-se de um fenômeno de mudanças estruturais e polarização ocupacional descrito na literatura de Autor e Dorn (2013).

Ao adicionar a informação de raça, é possível observar um aumento na participação de pessoas negras no mercado formal de trabalho, como ilustra o Gráfico 3.1. Em 2010, mulheres brancas contabilizavam cerca de 8,46 milhões de vínculos, enquanto mulheres negras possuíam aproximadamente 4,04 milhões. Entre os homens, observam-se 12,7 milhões de vínculos entre brancos e 8,08 milhões entre negros. Em 2024, o cenário muda substancialmente, podendo-se observar que o emprego de mulheres brancas cresce moderadamente, atingindo 8,74 milhões; o emprego de mulheres negras cresce mais intensamente, chegando a 8,63 milhões, praticamente dobrando em relação a 2010. Entre homens, o emprego para negros cresce mais fortemente que o emprego para brancos, alterando parcialmente a composição racial da força de trabalho formal.

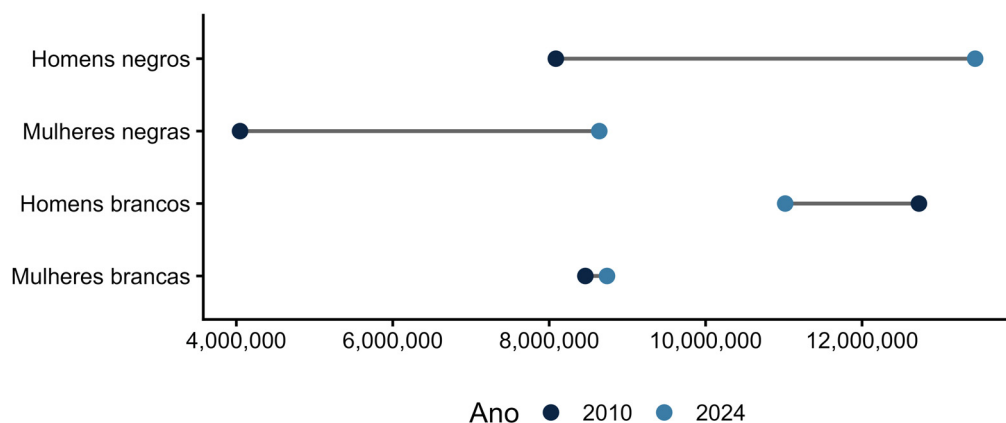


GRÁFICO 3.1 – Número de vínculos formais por gênero e raça no Brasil, 2010 e 2024  
Fonte: Elaboração própria a partir de dados da RAIS (MTE, 2025).

Embora o padrão interseccional mostre forte expansão da participação de mulheres negras no emprego formal, ainda que persistam desigualdades estruturais que geram barreiras a entrada no mercado de trabalho para esse grupo, o que se reflete na rigidez da estrutura de salários, ilustrada no Gráfico 3.2. Percebe-se que em 2024, as rendas reais tiveram leve crescimento que não acompanhou a mesma taxa de crescimento do emprego formal. A disparidade racial e de gênero persiste no período, com mulheres negras como o grupo com menor remuneração média, enquanto homens brancos continuam ocupando a posição de maior rendimento. A persistência dessas desigualdades reforça a justificativa para o interesse na análise do papel da inteligência artificial e das mudanças tecnológicas sobre tais disparidades.

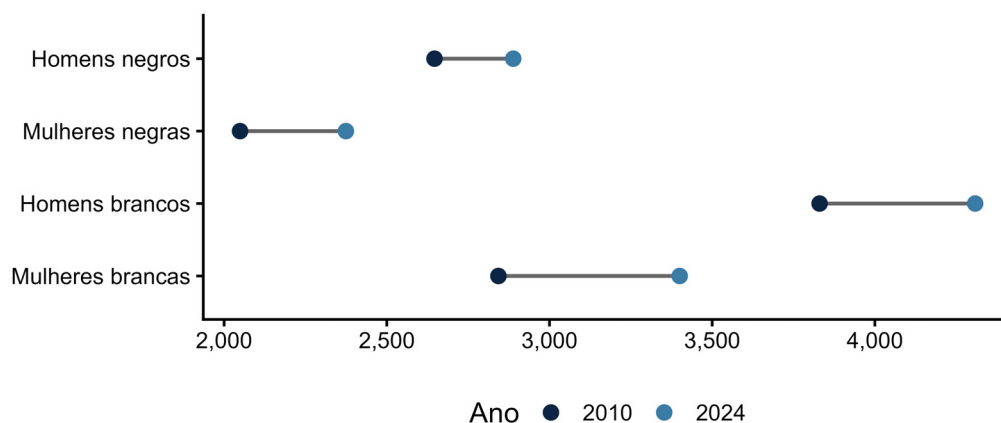


GRÁFICO 3.2 – Renda real do emprego formal por gênero e raça no Brasil, 2010 e 2024  
 Fonte: Elaboração própria a partir de dados da RAIS (MTE, 2025).

Esses fatores estão refletidos nos *gaps* de gênero, cujas estatísticas estão resumidas na Tabela 3.4. Os resultados obtidos demonstram que o diferencial de emprego entre homens e mulheres cresceu na maior parte dos municípios. Neste aspecto, a mediana (22,53) e a média (39,13), ambas positivas, indicam que, de forma geral, o *gap* de emprego formal ampliou-se entre 2010 e 2024. A presença de valores máximos elevados pode indicar que mudanças estruturais locais ampliaram de forma desigual a ocupação entre gêneros.

TABELA 3.4 – Variações dos *gaps* de gênero e raça (2010–2024)

Medida	$\Delta Gap_{gen}^{emp}$	$\Delta Gap_{gen}^{ren}$	$\Delta Gap_{race}^{emp}$	$\Delta Gap_{race}^{ren}$
Mínimo	-357,14	-146,44	-12.775,00	-645,13
1º quartil	3,52	-3,54	-202,22	-10,32
Mediana	22,53	5,18	-53,36	0,20
Média	39,13	5,76	-136,98	1,99
3º quartil	60,54	15,00	-13,88	11,38
Máximo	800,33	200,67	10.428,57	949,07

Fonte: Elaboração própria a partir de dados da RAIS (MTE, 2025).

O Gráfico 3.3 mostra o comportamento da variação do *gap* de gênero no emprego no país. O mapa demonstra heterogeneidade espacial na evolução do *gap* de gênero no emprego formal entre 2010 e 2024. Muito embora a maior parte dos municípios apresente variações moderadas, observam-se áreas pontuais com aumentos expressivos do diferencial de emprego com viés de gênero, indicando que em referidos locais o emprego masculino cresceu, ou caiu menos, em ritmo muito superior ao emprego feminino. Por sua vez, o diferencial de renda também apresentou ampliação no período. A mediana (5,18) e a média (5,76), ambas positivas, demonstram que em boa parte dos municípios a renda masculina cresceu mais rapidamente que a feminina.

O Gráfico 3.4 mostra o comportamento da variação do gap de gênero no emprego no país.

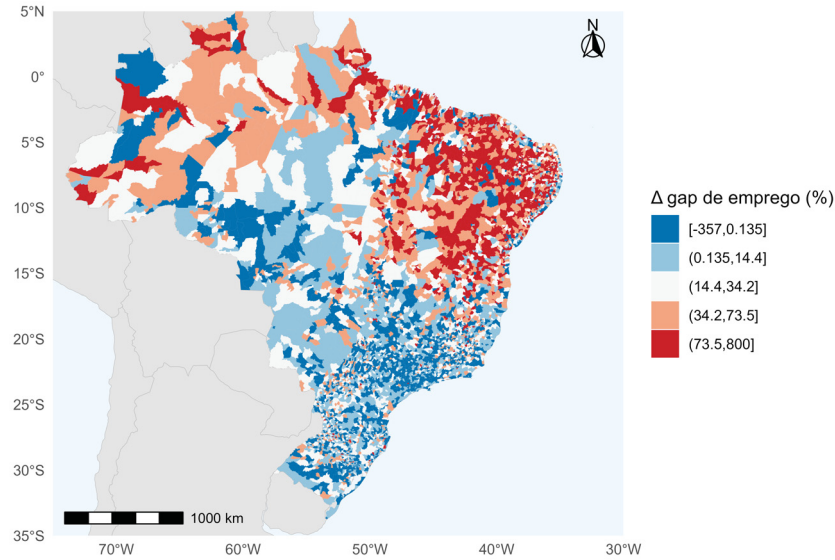


GRÁFICO 3.3 – Variação do gap de gênero no emprego (2010–2024)

Fonte: Elaboração própria a partir de dados da RAIS (MTE, 2025).

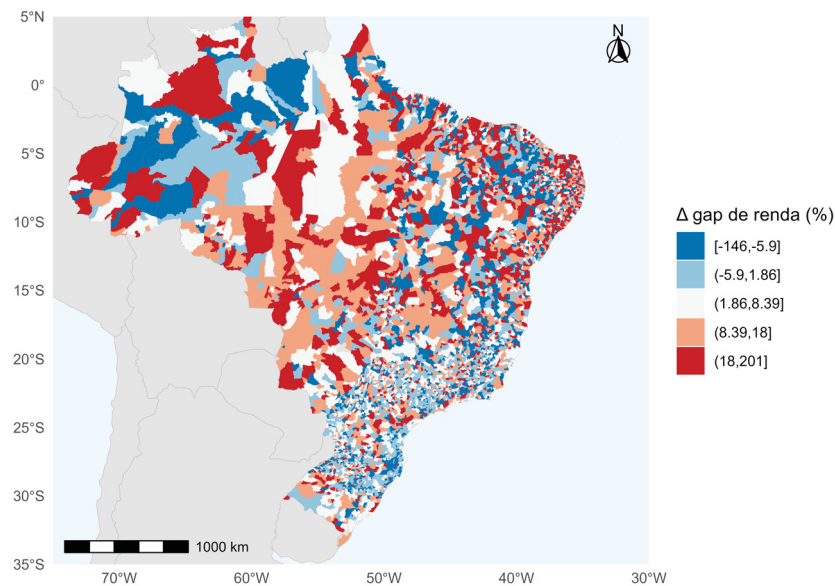


GRÁFICO 3.4 – Variação do gap de gênero na renda real (2010–2024)

Fonte: Elaboração própria a partir de dados da RAIS (MTE, 2025).

Acrescentando a perspectiva racial, os dados indicam, elevada redução do *gap* de emprego. Veja-se, que tanto a mediana (−53,36) quanto a média (−136,98) são negativas, o que significa que, em média, a participação relativa da população negra no emprego formal cresceu mais do que a da população branca no período

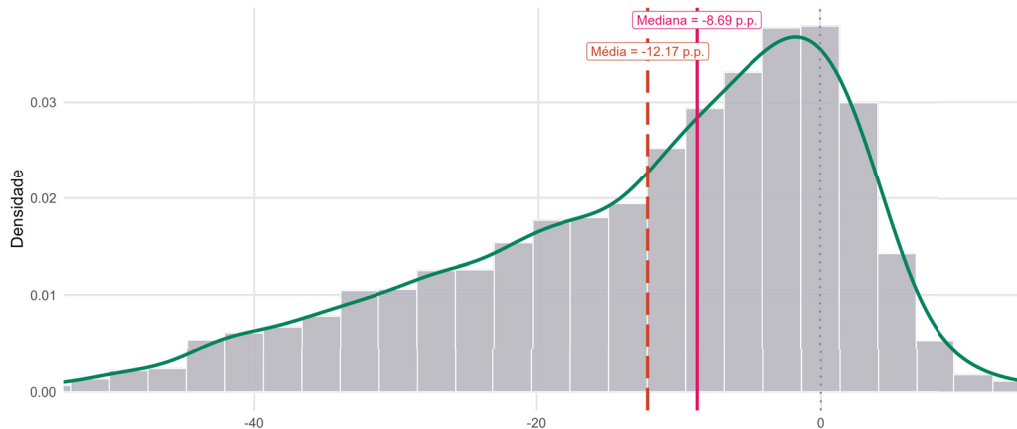


GRÁFICO 3.5 – Evolução participação feminina emprego formal 2010 – 2024  
 Fonte: Elaboração própria a partir de dados da RAIS (MTE, 2025).

analisado. Apesar disso, a dispersão é elevada e há municípios em que o *gap* aumentou substancialmente (máximo de 10.428,57), revelando elevada heterogeneidade regional e setorial.

Para a renda, a mediana próxima de zero (0,20) e a média moderadamente positiva (1,99) sugerem estabilidade do diferencial racial entre 2010 e 2024. Entretanto, observa-se a presença de valores mínimos expressivos (−645), o que denota que em certos municípios a renda da população negra cresceu mais rapidamente do que a da população branca. Os valores máximos (949) indicam que em outros houve intensificação das desigualdades salariais de raça.

Em relação à participação feminina no emprego formal entre 2010 e 2024, mensurada pelo indicador  $\Delta share_{fem}$ , os dados demonstram um padrão amplamente desfavorável às mulheres na maioria dos municípios brasileiros, conforme ilustrado no Gráfico 3.5.

Percebe-se que a distribuição municipal dessa variável apresenta deslocamento pronunciado para valores negativos, com mediana de −8,69 pontos percentuais e média de −12,17 pontos percentuais, indicando que, no município típico, a participação feminina no emprego formal reduziu-se de forma substantiva ao longo do período analisado.

A distribuição assimétrica à esquerda é marcada pela presença de municípios com quedas particularmente acentuadas na participação feminina no emprego formal, o que reforça a heterogeneidade espacial do fenômeno. Ainda que se observe um subconjunto restrito de municípios com variação positiva da participação feminina, esses casos constituem exceções e não alteram o padrão dominante de retração relativa do emprego feminino. Em conjunto, o comportamento de  $\Delta share_{fem}$  traz como evidência que as transformações ocorridas no mercado de trabalho formal brasileiro no período analisado não foram neutras do ponto de vista de gênero, o que reforça a

hipótese de que mudanças estruturais e tecnológicas de IA podem ter contribuído para aprofundar desigualdades pré-existentes na inserção ocupacional feminina.

Os padrões observados nos dados reforçam a necessidade de analisar em que medida a exposição inicial à inteligência artificial em 2010 contribuiu para ampliar ou reduzir tais disparidades, mais precisamente no que diz respeito a gênero.

### 3.4.2 Resultados das regressões

Esta seção apresenta os resultados das regressões que investigam a relação entre a exposição à inteligência artificial e as, o emprego e a renda feminina entre 2010 e 2024, incorporando variáveis de controle que capturam a estrutura inicial do mercado de trabalho municipal, seguindo a lógica proposta por Lu et al. (2023) e Albanesi et al. (2025).

A Tabela 3.5 apresenta os resultados das regressões associadas às Hipóteses 1 e 2. Observa-se que a exposição municipal à inteligência artificial está associada a efeitos heterogêneos sobre o emprego formal segundo o gênero. Para o grupo de referência masculino, o coeficiente do índice municipal de IA é positivo e estatisticamente significativo. Em contraste, o termo de interação entre a IA e a *dummy* de mulher é negativo e altamente significativo,

A Tabela 3.5 traz o resultado da regressão para às Hipóteses 1 e 2. Observa-se que a exposição municipal à inteligência artificial está associada a efeitos heterogêneos sobre o emprego formal por gênero. Para o grupo de referência masculino, o coeficiente do índice municipal de IA é positivo e estatisticamente significativo. Por outro lado, o termo de interação entre a IA e a *dummy* de mulher é negativo e altamente significativo, indicando que a sensibilidade do emprego feminino à expansão da IA é substancialmente menor do que a observada para os homens. Como a magnitude do coeficiente de interação supera o efeito base, o efeito marginal total da exposição à IA sobre o emprego feminino torna-se negativo no período analisado.

Dessa forma, os resultados sugerem que, no período analisado, municípios que experimentaram maior aumento da exposição à IA também apresentaram uma expansão relativamente maior do emprego formal masculino, ao passo que o crescimento do emprego formal feminino foi relativamente menor, podendo inclusive assumir sinal negativo em termos marginais. Em termos interpretativos, esse padrão é consistente com a predominância de efeitos de complementariedade da IA em relação ao emprego masculino, enquanto, para o emprego feminino, os resultados são compatíveis com a dominância de efeitos de substituição.

Essas evidências não corroboram a Hipótese H1 e indicam que, no contexto analisado, a difusão da inteligência artificial tem se associado a um aprofundamento

TABELA 3.5 – Efeitos da exposição municipal à IA sobre emprego e renda formais (TWFE): comparação mulher vs. homem

	$\ln(\text{Emprego})$	$\ln(1 + \text{Renda})$
Índice municipal de exposição à IA	2,436*** (0,0881)	0,1568** (0,0788)
Índice de IA (centrado) × Mulher	-5,515*** (0,1734)	-0,4735*** (0,0553)
Mulher	-0,4725*** (0,0046)	-0,1543*** (0,0021)
<i>Controles</i>		
Participação feminina no emprego	0,6201*** (0,0168)	-0,1994*** (0,0355)
Participação feminina negra no emprego	0,1464*** (0,0391)	-0,1548*** (0,0426)
Emprego total (log)	0,9495*** (0,0037)	0,0513*** (0,0063)
Idade média	-0,0103*** (0,0014)	-0,0001 (0,0023)
Experiência	$-3,21 \times 10^{-6}$ (0,0002)	0,0004 (0,0004)
Escolaridade média	0,0063 (0,0050)	0,0863*** (0,0111)
<i>Efeito total da IA para mulheres (<math>\beta_{IA} + \beta_{IA \times Mulher}</math>)</i>	-3,079*** <sup>a</sup>	-0,3167 <sup>a</sup>
Num. Obs.	22.252	22.244
$R^2$	0,97897	0,72180
$R^2$ (within)	0,77278	0,25948

*Notas:* Erros-padrão entre parênteses, clusterizados por município. Efeitos fixos de município e ano incluídos.

\*\*\* $p < 0,01$ , \*\* $p < 0,05$ , \* $p < 0,1$ .

<sup>a</sup> A significância do efeito total para mulheres requer erro-padrão obtido via *delta method*. Nesta tabela reporta-se apenas a soma pontual dos coeficientes.

Fonte: Elaboração própria.

das desigualdades de gênero no mercado de trabalho formal brasileiro, sobretudo por meio de uma dinâmica assimétrica de crescimento do emprego entre homens e mulheres.

Verifica-se das variáveis de controle que a participação feminina e a participação de mulheres negras no emprego municipal apresentam efeitos positivos e estatisticamente significativos, indicando que mercados de trabalho locais mais inclusivos tendem a registrar níveis mais elevados de emprego formal, o que vai ao encontro com os resultados de Albanesi et al. (2025). Analisando o caso europeu, a autora encontra que a maior participação feminina no mercado de trabalho reduz as desigualdades de gênero.

O logaritmo do emprego total municipal tem efeito positivo e elevado, refletindo a importância da escala econômica local, enquanto a idade média da força de trabalho apresenta coeficiente negativo, sugerindo maiores dificuldades de adaptação em municípios com maior nível de envelhecimento populacional. As variáveis de experiência média e escolaridade média não se mostram estatisticamente significativas, indicando que seus efeitos são absorvidos por outras características estruturais capturadas pelo modelo.

Resultado semelhante ocorre para a renda (Tabela 3.5). Para o grupo de referência masculino, o coeficiente do índice municipal de IA é positivo e estatisticamente significativo, o que indica que municípios mais expostos à IA tendem a apresentar maior renda formal masculina. De maneira oposta, em relação à amostra feminina, cujo coeficiente de regressão é de elevada magnitude e altamente significativo, o efeito total da IA na renda feminina é negativo, o que demonstra que a difusão da IA está associada à redução relativa da renda feminina.

Esse resultado confirma a persistência de um diferencial médio de renda desfavorável às mulheres, mesmo após o controle por heterogeneidade fixa municipal e por variáveis observáveis. Percebe-se que a penalização salarial feminina além de ser persistente, também pode se intensificar em contextos de maior exposição à IA. Sendo assim, os resultados fornecem evidências contrárias à Hipótese H2, ou seja, de que a exposição à IA está associada a ganhos de renda concentrados entre os homens, contribuindo para o aprofundamento das desigualdades de gênero na renda formal no nível municipal.

Além do resultado principal, foram adicionados os mesmos controles da primeira regressão. Entre os controles, pode-se observar que a participação feminina no emprego e a participação de mulheres negras apresentam coeficientes negativos e significativos, demonstrando que em municípios com composição do emprego relativamente mais feminina, e especialmente com maior presença de mulheres negras, a tendência é de que registrem menores níveis de renda média, o que é compatível com mecanismos de segregação ocupacional e diferenças setoriais de remuneração, tal qual amplamente abordado no referencial teórico deste ensaio. Por sua vez, a escolaridade média apresenta efeito positivo e significativo, corroborando o papel do capital humano na elevação da renda, enquanto idade média e experiência não se mostram estatisticamente significativas.

Em conjunto, H1 e H2 demonstram que há barreiras estruturais no mercado de trabalho brasileiro que fazem com que o avanço tecnológico aumente desigualdades de gênero em relação a emprego e renda.

A Tabela 3.6 traz o resultado da regressão para a Hipótese 3, que adiciona a interação entre gênero e raça. Os resultados demonstram que, tomando homens

brancos como grupo de referência, a exposição à IA está associada a aumento do emprego formal desse grupo, enquanto não há evidência estatisticamente significativa de efeito direto sobre sua renda formal. As *dummies* de grupo revelam desigualdades estruturais persistentes, em que homens negros, mulheres brancas e, sobretudo, mulheres negras apresentam níveis significativamente inferiores de emprego e renda em relação aos homens brancos, trazendo a tona um gradiente interseccional de desigualdade que não é eliminado pelos controles observáveis.

As interações entre IA e os grupos revelam que, no emprego, homens negros se beneficiam relativamente mais da exposição tecnológica do que os homens brancos, resultando em um efeito total positivo e ampliado da IA sobre seu emprego formal. Ou seja, entre os homens, os resultados sugerem uma possível redução relativa do diferencial racial no crescimento do emprego, uma vez que os homens negros apresentam maior sensibilidade positiva à expansão da IA do que os homens brancos. Em contraste, as interações entre IA e mulheres, tanto brancas quanto negras, são negativas e estatisticamente significativas, implicando efeitos totais adversos da IA sobre o emprego feminino, com maior magnitude para mulheres brancas e penalização também relevante para mulheres negras.

Na renda, a interação IA  $\times$  homem negro é positiva e significativa, sugerindo ganho relativo de renda para esse grupo, enquanto a interação IA  $\times$  mulher branca é negativa e marginalmente significativa, indicando piora relativa da renda feminina branca quando há maior exposição à IA; para mulheres negras, não há evidência estatisticamente significativa de efeito diferencial da IA sobre a renda. Esses padrões sugerem que a difusão da IA pode estar associada a uma reconfiguração das desigualdades relativas dentro de cada grupo de gênero, sem que seja possível inferir, a partir deste modelo, uma redução da desigualdade racial agregada no mercado de trabalho.

Por sua vez, os controles reforçam a leitura de que os efeitos atribuídos à IA não decorrem apenas de mudanças na estrutura do mercado de trabalho local, havendo o componente de desigualdade interseccional.

A Tabela 3.7 traz o resultado da regressão para a Hipótese 4. Consistentes com os resultados obtidos até aqui que apontam que o aumento da IA aprofunda a desigualdade de gênero em renda e emprego, os resultados da Hipótese H4 indicam que a maior exposição municipal à inteligência artificial está associada a um aumento estatisticamente significativo dos *gaps* de gênero tanto no emprego quanto na renda formal. No caso do emprego, o coeficiente estimado sugere que um aumento de 0,01 ponto no índice municipal de exposição à IA está associado a uma elevação aproximada de 0,76 ponto percentual no gap de emprego entre homens e mulheres, sugerindo que a difusão tecnológica esteve associado com a ampliação da desigualdade relativa de inserção da mulher no mercado de trabalho formal. Esse resultado permanece robusto

TABELA 3.6 – Efeitos da exposição municipal à IA por gênero e raça (TWFE). Referência: homem branco

	(A) $\ln(\text{Emprego})$	(B) $\ln(1 + \text{Renda})$
<b>Exposição à IA (efeito base: homem branco)</b>	0,5922** (0,2333)	-0,0741 (0,1035)
<i>Diferenças no efeito da IA (interações vs. homem branco)</i>		
IA × Homem negro	1,466*** (0,3433)	0,3077*** (0,0679)
IA × Mulher branca	-3,034*** (0,1428)	-0,1865* (0,0993)
IA × Mulher negra	-1,714*** (0,3321)	-0,0437 (0,0762)
<i>Diferenças de nível (vs. homem branco)</i>		
Homem negro	-0,0921*** (0,0201)	-0,1481*** (0,0036)
Mulher branca	-0,6116*** (0,0062)	-0,2293*** (0,0041)
Mulher negra	-0,9823*** (0,0190)	-0,3581*** (0,0040)
<i>Controles</i>		
Participação feminina no emprego	-0,6756*** (0,0714)	-0,2117*** (0,0471)
Participação feminina negra no emprego	2,096*** (0,1052)	-0,1198** (0,0593)
Emprego total (log)	0,6044*** (0,0131)	0,1110*** (0,0083)
Idade média	-0,0551*** (0,0047)	0,0044 (0,0033)
Experiência	-0,0029*** (0,0007)	0,0004 (0,0004)
Escolaridade média	-0,1884*** (0,0170)	0,0585*** (0,0112)
Num. Obs.	43.206	43.206
$R^2$	0,83396	0,51651
$R^2$ (within)	0,21393	0,21756

*Notas:* Erros-padrão entre parênteses, clusterizados por município. Efeitos fixos de município e ano incluídos. Grupo de referência: homens brancos.

\*\*\* $p < 0,01$ , \*\* $p < 0,05$ , \* $p < 0,1$ .

Fonte: Elaboração própria.

mesmo após o controle por características estruturais dos municípios, como o tamanho do mercado de trabalho, a idade média, a experiência e o nível educacional da força de trabalho.

TABELA 3.7 – Efeitos da exposição municipal à IA sobre os *gaps* de emprego e renda (TWFE) — Hipótese H4

	Gap de Emprego (%)	Gap de Renda (%)
Exposição municipal à IA	76,29*** (15,21)	24,53*** (7,231)
Emprego total (log)	-21,08*** (1,219)	1,738*** (0,5908)
Idade média	-4,828*** (0,4380)	-0,0146 (0,1956)
Experiência	-0,7933*** (0,0649)	-0,1455*** (0,0308)
Escolaridade média	-25,01*** (1,575)	0,3973 (0,8670)
Num. Obs.	11.124	11.110
$R^2$	0,81737	0,66943
$R^2$ (within)	0,51177	0,02068

*Notas:* Erros-padrão entre parênteses, clusterizados por município. Efeitos fixos de município e ano incluídos.

\*\*\* $p < 0,01$ , \*\* $p < 0,05$ , \* $p < 0,1$ .

Fonte: Elaboração própria.

Para a renda, observa-se efeito qualitativamente semelhante. O coeficiente positivo indica que o avanço da IA também contribui para ampliar o diferencial salarial médio entre homens e mulheres, sugerindo que os ganhos que decorrem da adoção tecnológica são apropriados de forma desigual entre homens e mulheres, em benefício dos primeiros.

Veja mais, os resultados obtidos indicam de que a inteligência artificial, no período analisado, pode ter contribuído para ampliar as desigualdades de gênero, não apenas reduzindo o emprego feminino em termos absolutos, mas também aprofundando disparidades relativas de emprego e renda no mercado formal nacional.

Finalmente, a Tabela 3.8 traz o resultado da regressão para a Hipótese 5, permitindo observar mais uma vez o componente de desigualdade. Os resultados indicam que a IA está associada ao aumento da participação masculina no emprego formal e conseqüente redução da participação feminina no emprego formal para o Brasil. A maior absorção relativa do grupo masculino ao mercado de trabalho em contextos de maior difusão tecnológica indica que o avanço da IA tem contribuído para um processo de masculinização relativa do emprego formal.

TABELA 3.8 – Efeitos da exposição municipal à IA sobre a participação no emprego formal (TWFE): comparação mulher vs. homem — Hipótese H5

	Share <sub>g</sub>
Exposição municipal à IA (homens — referência)	1,209*** (0,0370)
Mulher (ref.: homem)	-0,2174*** (0,0020)
Índice de IA × Mulher	-2,418*** (0,0741)
<i>Efeitos marginais da IA (por gênero)</i>	
Efeito da IA para homens (referência)	1,209*** (0,0370)
Diferença no efeito da IA para mulheres (vs. homens)	-2,418*** (0,0741)
Efeito total da IA para mulheres ( $\beta_{IA} + \beta_{IA \times Mulher}$ )	-1,209 <sup>a</sup>
<i>Controles</i>	
Participação feminina negra	$1,1 \times 10^{-15}$ ( $1 \times 10^{-6}$ )
Emprego total (log)	$8,29 \times 10^{-16}$ ( $1 \times 10^{-6}$ )
Idade média	$-8,22 \times 10^{-17}$ ( $1 \times 10^{-6}$ )
Experiência média	$1,02 \times 10^{-17}$ ( $1 \times 10^{-6}$ )
Escolaridade média	$6,04 \times 10^{-16}$ ( $1 \times 10^{-6}$ )
Num. Obs.	22.252
$R^2$	0,55704
$R^2$ (within)	0,55704

*Notas:* Erros-padrão entre parênteses, clusterizados por município. Efeitos fixos de município e ano incluídos.

\*\*\* $p < 0,01$ , \*\* $p < 0,05$ , \* $p < 0,1$ .

<sup>a</sup> O efeito total para mulheres é calculado como  $\beta_{IA} + \beta_{IA \times Mulher}$ ; sua significância requer erro-padrão via *delta method*. Nesta tabela reporta-se apenas a soma pontual dos coeficientes.

Fonte: Elaboração própria.

### 3.4.3 Hipóteses da pesquisa e discussão com a literatura

Os resultados encontrados indicam que, no Brasil, o avanço da inteligência artificial tem produzido efeitos negativos relativamente mais intensos sobre o grupo feminino no mercado de trabalho formal, o que reforça a importância de que sejam promovidas políticas públicas por todas as esferas de governo voltadas à reestruturação do mercado de trabalho e à mitigação de desigualdades de gênero no contexto da transformação tecnológica. A Tabela 3.9 resume os resultados obtidos a partir de cada uma das hipóteses levantadas no trabalho.

TABELA 3.9 – Síntese dos resultados empíricos — Hipóteses H1 a H5

Hipótese	Variável dependente	Efeito da IA	Resultado empírico
H1	Emprego feminino	–	Municípios mais expostos à IA apresentaram menor crescimento relativo do emprego feminino
H2	Renda feminina	–	A exposição à IA reduziu o crescimento relativo da renda feminina
H3 (emprego)	Emprego (gênero e raça)	Heterogêneo	Efeitos negativos mais intensos para mulheres, sobretudo mulheres negras
H3 (renda)	Renda (gênero e raça)	Heterogêneo	Penalização salarial persistente para mulheres e grupos racializados
H4 (emprego)	Gap de emprego	+	A exposição à IA ampliou o diferencial de emprego em desfavor das mulheres
H4 (renda)	Gap de renda	+	A IA contribuiu para o aumento do diferencial salarial por gênero
H5	Participação no emprego (mulher vs. homem)	–	A exposição à IA aumentou a participação relativa dos homens no emprego formal, resultando em redução da participação feminina relativa

*Notas:* Os sinais indicam o efeito marginal do índice municipal de exposição à IA sobre a variável dependente. Todas as regressões incluem efeitos fixos de município e ano, além de controles demográficos e de capital humano.

Fonte: Elaboração própria.

Em termos gerais, os resultados obtidos nesta dissertação indicam que a exposição municipal à inteligência artificial está associada a profundas transformações no mercado de trabalho formal que se distribuem de forma desigual entre homens e mulheres.

Municípios com maior crescimento na exposição à IA apresentam expansão do emprego e da renda formal mais concentrada entre os homens, resultado este que sugere um *efeito de complementariedade* tecnológica entre a difusão da IA e ocupações predominantemente masculinas. Já para as mulheres o efeito é oposto, pois a exposição à IA está associada a menor crescimento e, em alguns casos, à redução relativa tanto do emprego quanto da renda formal, caracterizando um efeito substituição da tecnologia sobre ocupações com maior presença feminina, resultado

que é consistente com a hipótese de pesquisa assumida por Webb (2019), que advoga pelo efeito substituição da IA, com possibilidade pontual de também ocorrer o efeito complementariedade a depender da estrutura do mercado de trabalho.

A análise conjunta de emprego, renda e composição do mercado de trabalho demonstra que além de afetar negativamente o nível de emprego feminino, a IA também está associada à uma deterioração relativa da renda das mulheres e redução de sua participação no emprego formal nos municípios com maior aumento na exposição à IA, ou seja, as diversas oportunidades geradas pela adoção de tecnologias baseadas em IA acabam por se concentrar em tarefas ocupacionais menos acessíveis às mulheres, o que tende a aprofundar o hiato tanto na qualidade, quanto na estabilidade das interações femininas no mercado de trabalho. Quando se incorpora a dimensão racial, observa-se que esses efeitos são homogêneos entre os diferentes grupos, com homens negros relativamente mais beneficiados e mulheres brancas relativamente mais penalizadas.

Em conjunto, os resultados trazidos neste trabalho dialogam com a literatura sobre inteligência artificial e mercado de trabalho, especialmente no que se refere à heterogeneidade dos efeitos e à natureza distributiva do progresso tecnológico. Porém, também há importantes pontos que os resultados caminham em direções opostas.

Em particular, a presença de um efeito substituição do emprego feminino vai ao encontro do trabalho de Webb (2019), que muito embora não faça uma análise detalhada sobre gênero, embasa seu modelo partindo da premissa do efeito substituição da IA sobre emprego. Além disso, o mesmo autor enfatiza que a exposição ocupacional à IA não permite inferir automaticamente efeitos negativos ou positivos sobre emprego e salários, uma vez que a automação de tarefas depende da heterogeneidade das ocupações e da própria estrutura do mercado de trabalho, porém, tais heterogeneidades, notadamente qualificação, têm o potencial de gerar maior desigualdade salarial (Felten et al., 2019).

Por outro lado, os efeitos estatisticamente significativos quando a análise incorpora a dimensão racial indicam que os impactos da IA não são neutros na perspectiva distributiva, corroborando a hipótese de heterogeneidade intra-grupo, resultado este que é consistente com a literatura advoga pela necessidade de análise interseccional do mercado de trabalho devido às disparidades existentes entre os trabalhadores de grupos demográficos distintos (Browne; Misra, 2003), e também com a literatura que destaca que a adoção de tecnologias de fronteira tende a interagir com desigualdades pré-existentes no mercado de trabalho (Autor, 2022).

A evidência encontrada neste trabalho, de retração do emprego para o grupo feminino relativamente ao masculino, acompanhada da persistência de desigualdades salariais, dialoga ainda com Felten et al. (2019) e Webb (2019), ao indicar que a ex-

posição à IA não se traduz automaticamente em ganhos distributivos homogêneos, uma vez que a tecnologia incide sobre conjuntos específicos de habilidades e tarefas, frequentemente valorizando atributos cognitivos e técnicos que nem sempre são recompensados de forma equitativa no mercado de trabalho.

Por sua vez, Albanesi et al. (2025) demonstram, para países europeus, que a exposição à IA está associada ao aumento da participação feminina no emprego em ocupações mais expostas, sendo tais efeitos condicionados por fatores estruturais, como nível educacional, participação inicial no mercado de trabalho e características institucionais, indicando que ganhos médios podem coexistir com assimetrias relevantes entre subgrupos. Em contraste com a literatura sobre o tema, os resultados obtidos neste trabalho para participação feminina, contudo, caminham em sentido oposto, o que demonstra que diferenças estruturais entre o mercado de trabalho europeu e o brasileiro podem conduzir a resultados opostos.

A evidência de que a exposição inicial à IA está associada à ampliação do gap de gênero no emprego e na renda é compatível com a abordagem de Acemoglu et al. (2022) e Webb (2019), segundo a qual novas tecnologias podem alterar a distribuição relativa entre grupos de trabalhadores mesmo na ausência de efeitos agregados expressivos.

Conforme discutido por Felten et al. (2019), a exposição ocupacional à inteligência artificial não implica, necessariamente, ganhos automáticos de emprego, embora possa estar associada a aumentos salariais em ocupações específicas. Esses ganhos tendem a se concentrar entre trabalhadores que dispõem de competências complementares às novas tecnologias, especialmente habilidades ligadas ao uso de software.

Nesse sentido, os achados deste trabalho sugerem que a difusão da inteligência artificial, ao interagir com estruturas ocupacionais e desigualdades prévias, tem gerado ganhadores e perdedores no mercado de trabalho brasileiro, beneficiando relativamente mais o grupo masculino, enquanto as mulheres enfrentam perdas em termos de emprego, renda e participação, em um contexto de barreiras estruturais preexistentes que a IA tem se mostrado incapaz de superar.

À luz desses resultados, a ampliação dos *gaps* observada neste trabalho sugere que, na ausência de políticas e investimentos voltados à qualificação da força de trabalho, o avanço tecnológico pode reforçar desigualdades, ao beneficiar de forma desproporcional trabalhadores e ocupações melhor posicionados em termos de habilidades. Nesse sentido, a adaptação das competências e a redução das barreiras de acesso às novas qualificações tornam-se centrais e necessários para mitigar a intensificação da polarização no mercado de trabalho.

### 3.5 CONSIDERAÇÕES FINAIS

Os resultados deste ensaio indicam que a exposição inicial à inteligência artificial vem gerando perdas relevantes para as mulheres no mercado de trabalho em termos do nível de emprego e renda, com efeitos distintos por raça. Quando se analisam os *gaps* de gênero, constata-se que a IA, ao contrário da hipótese de neutralidade, está associada a um aumento estatisticamente significativo tanto do gap de emprego quanto do gap de renda. Ou seja, em média, municípios que aumentaram o nível de exposição à IA, entre 2010 e 2024, ampliaram a vantagem masculina em ambos os indicadores, reforçando a baixa inclusão das mulheres no mercado de trabalho e a persistência do gap salarial com viés de gênero.

Esses resultados demonstram que a tecnologia, quando introduzida em um mercado de trabalho já marcado por desigualdades estruturais, tende a reproduzir e a ampliar referidas assimetrias, corroborando a importância de políticas públicas que assegurem que os ganhos tecnológicos sejam mais amplamente distribuídos entre os gêneros.

Ao analisar de forma empírica o contexto do mercado de trabalho brasileiro, marcado por fortes desigualdades regionais e ocupacionais, este estudo contribui para a literatura nacional ao mostrar que a relação entre IA, emprego e gênero é mais complexa do que pressupõem narrativas alarmistas ou extremamente otimistas.

A integração de um índice de exposição ocupacional à IA com dados municipais, de gênero e raça, oferece uma leitura empírica inédita sobre como as transformações tecnológicas se distribuem no território brasileiro, leitura esta que dialoga diretamente com agendas atuais sobre inclusão produtiva, desigualdades e sobre o papel das tecnologias emergentes para redesenhar as estruturas sociais e econômicas no país.

Para trabalhos futuros, os achados desta dissertação abrem espaço para investigações mais aprofundadas. Como, por exemplo, estudos que incorporem variáveis de controle municipais, e a variação dos indicadores ao longo do tempo, bem como modelos econométricos mais robustos com abordagens espaciais ou que busquem relações causais a partir do índice criado.

Além disso, acredita-se que compreender os mecanismos específicos de transmissão é essencial para orientar políticas públicas que assegurem que o avanço tecnológico caminhe junto com inclusão e equidade.

## 4 CONCLUSÃO GERAL

Esta dissertação teve como objetivo investigar como o avanço da inteligência artificial se relaciona com a dinâmica do mercado de trabalho brasileiro, com ênfase nas desigualdades de gênero e no papel da heterogeneidade territorial e do mercado de trabalho. Partindo da premissa de que a difusão tecnológica não se traduz automaticamente em efeitos uniformes, o trabalho buscou criar um índice de exposição à IA para o mercado de trabalho a nível municipal e, a partir dessa mensuração, examinar associações empíricas entre exposição inicial e mudanças distributivas no período analisado (2010 e 2024).

Um primeiro avanço do trabalho consiste em tratar a exposição à IA como um fenômeno que opera no nível de tarefas e ocupações, conjugando-as com as patentes tecnológicas de IA registradas no Brasil, e que, ao ser agregado para o território, permite mapear potenciais canais distributivos. A análise descritiva trouxe como evidência a existência de forte heterogeneidade espacial na evolução do emprego e da renda entre 2010 e 2024, tanto no recorte de gênero quanto na dimensão racial. Em particular, observa-se que, na maior parte dos municípios, o *gap* de emprego entre homens e mulheres se ampliou no período (mediana e média positivas), e que o *gap* de renda também apresentou ampliação (mediana e média positivas), ao lado de forte variabilidade local.

No plano inferencial, os resultados podem ser sintetizados em quatro blocos alinhados às hipóteses do estudo. Primeiro, ao se estimar o efeito da exposição à inteligência artificial sobre o emprego e a renda femininos em modelos em painel com efeitos fixos de município e de ano, observa-se que a exposição à IA está associada a impactos diferenciados por gênero ao nível municipal. Embora a exposição à IA apresente efeito positivo e estatisticamente significativo para o emprego e a renda masculinos, o efeito adicional para as mulheres é negativo e altamente significativo, de modo que o efeito total da IA sobre o emprego e a renda femininos se mostra adverso, indicando que a difusão da IA não promove ganhos proporcionais para as mulheres, estando associada a uma dinâmica de crescimento menos favorável para o grupo feminino.

Segundo, ao incorporar simultaneamente as dimensões de gênero e raça na análise do emprego e da renda (Hipótese H3), os resultados revelam heterogeneidade substancial entre os grupos. No emprego, a exposição à IA está associada a um efeito positivo para homens brancos, intensificado para homens negros, enquanto os efeitos para mulheres são negativos e estatisticamente significativos, tanto para mulheres brancas quanto para mulheres negras, sendo a penalização estrutural mais

acentuada para estas últimas. Na renda, embora o efeito direto da IA para homens brancos não seja estatisticamente significativo, observa-se um efeito diferencial positivo para homens negros e um efeito adverso para mulheres brancas, ao passo que, para mulheres negras, a principal fonte de desvantagem permanece associada a diferenças estruturais de nível.

Terceiro, ao deslocar o foco para os *gaps* de gênero, os resultados obtidos neste trabalho apontam para efeitos distributivos assimétricos consistentes. Neste sentido, a exposição à IA apresenta coeficientes estatisticamente significativos para a ampliação dos diferenciais de emprego e de renda entre homens e mulheres, indicando que municípios mais expostos à tecnologia registraram, em média, maior aumento dos *gaps* de gênero no período analisado, ou seja, a IA contribui para a intensificação das desigualdades relativas entre grupos, reforçando assimetrias pré-existentes no mercado de trabalho formal.

Quarto, os resultados aqui obtidos indicam que a exposição à IA não se traduz em efeitos homogêneos sobre o mercado de trabalho feminino. Isso porque essa tecnologia está associada a ganhos relativos para o grupo masculino, com impactos adversos para as mulheres (redução do emprego, da renda e da participação feminina no emprego formal), notando-se que a difusão da IA acentua desigualdades de gênero e raça.

Do ponto de vista de implicações, os resultados reforçam que políticas públicas voltadas à transição tecnológica devem ser orientadas por métricas distributivas, capazes de captar a ampliação de desigualdades entre homens e mulheres e entre grupos raciais. Aderindo às conclusões de Felten et al. (2019), a presença de forte heterogeneidade territorial e de assimetrias distributivas corroboram que o desenho de respostas públicas ao avanço da IA precisa combinar instrumentos de qualificação, proteção e mobilidade ocupacional para que o avanço tecnológico caminhe junto com inclusão e equidade, afastando-se da leitura econômica de eficiência como um fim em si mesmo.

Por fim, por mais que se tenha avançado para a análise de tema cuja abordagem metodológica foi inédita na literatura nacional, permanece espaço para abordagens causais e modelos econométricos mais robustos, que ampliem a precisão das estimativas. Igualmente, buscar compreender os mecanismos específicos de transmissão é fundamental para orientar intervenções públicas e reduzir o risco de que a difusão tecnológica aprofunde disparidades preexistentes. Nesse sentido, estudos futuros que incorporem controles municipais adicionais, diferentes estratégias de identificação e até mesmo uma análise a nível individual com a base da RAIS identificada podem aprofundar o que aqui se estabeleceu como evidência empírica inicial para o mercado de trabalho brasileiro.

## REFERÊNCIAS

ACEMOGLU, D.; AUTOR, D.; HAZELL, J.; RESTREPO, P. Artificial intelligence and jobs: Evidence from online vacancies. **Journal of Labor Economics**, The University of Chicago Press Chicago, IL, v. 40, S1, s293–s340, 2022. Citado 5 vezes nas páginas 19–21, 23, 86.

ACEMOGLU, D.; RESTREPO, P. Artificial intelligence, automation, and work. In: *The economics of artificial intelligence: An agenda*. [S.l.]: University of Chicago Press, 2018. P. 197–236. Citado 6 vezes nas páginas 9, 54.

ACEMOGLU, D.; RESTREPO, P. **Robots and Jobs: Evidence from US Labor Markets**. [S.l.], 2017. JEL No. J23, J24. Disponível em: <https://www.nber.org/papers/w23285>. Citado 2 vezes nas páginas 34, 67.

ACEMOGLU, D.; RESTREPO, P. The race between man and machine: Implications of technology for growth, factor shares, and employment. **American economic review**, American Economic Association 2014 Broadway, Suite 305, Nashville, TN 37203, v. 108, n. 6, p. 1488–1542, 2018. Citado 4 vezes nas páginas 15, 28.

ALBANESI, S. et al. **AI and Women’s Employment in Europe**. [S.l.], 2025. Citado 18 vezes nas páginas 9, 19, 21, 54, 59, 62, 65–67, 77, 78, 86.

ALBUQUERQUE, P. H.; SAAVEDRA, C. A. P. B.; MORAIS, R. L. de; ALVES, P. F.; PENG, Y. **Na era das máquinas, o emprego é de quem? Estimção da probabilidade de automação de ocupações no Brasil**. [S.l.], 2019. Citado 1 vez na página 60.

ALEKSEEVA, L.; AZAR, J.; GINÉ, M. et al. The demand for AI skills in the labor market. **Labour Economics**, v. 71, p. 1–60, 2021. Citado 1 vez na página 24.

ALMEIDA, I. D. D. **A contribuição da inteligência artificial nos processos de controle de qualidade na indústria: uma pesquisa exploratória**. [S.l.]: Centro Universitário Sagrado Coração-UNISAGRADO, 2023. Citado 1 vez na página 39.

AMARAL, J. G. A expansão da Inteligência Artificial e seu impacto nas dinâmicas sociais: desafios e responsabilidades. **Revista UFMG**, Belo Horizonte, v. 30, p. 80–107, 2023. Fluxo contínuo. Citado 4 vezes nas páginas 13, 14.

AMAZON WEB SERVICES. **Amazon Rekognition**. [S.l.: s.n.], 2025. Acesso em: 17 jul. 2025. Disponível em: <https://aws.amazon.com/pt/rekognition/>. Citado 1 vez na página 39.

ANGGRAENI, V. P.; BARIYAH, N.; KURNIAWATI, S. Gender equality and economic growth toward fulfillment of sustainable development goals. **Jurnal geografi**, v. 14, n. 1, p. 107, 2022. Citado 1 vez na página 58.

AUTOR, D. **The labor market impacts of technological change: From unbridled enthusiasm to qualified optimism to vast uncertainty**. [S.l.], 2022. Citado 1 vez na página 85.

AUTOR, D. H. Why are there still so many jobs? The history and future of workplace automation. **Journal of economic perspectives**, American Economic Association 2014 Broadway, Suite 305, Nashville, TN 37203-2418, v. 29, n. 3, p. 3–30, 2015. Citado 1 vez na página 14.

AUTOR, D. H.; DORN, D. The growth of low-skill service jobs and the polarization of the US labor market. **American economic review**, American Economic Association, v. 103, n. 5, p. 1553–1597, 2013. Citado 1 vez na página 73.

BABINA, T.; FEDYK, A.; HE, A.; HODSON, J. Artificial intelligence, firm growth, and product innovation. **Journal of Financial Economics**, v. 151, p. 103745, 2024. ISSN 0304-405X. DOI: <https://doi.org/10.1016/j.jfineco.2023.103745>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0304405X2300185X>. Citado 3 vezes nas páginas 19–21.

BAYER, P.; CHARLES, K. K. Divergent paths: A new perspective on earnings differences between black and white men since 1940. **The Quarterly Journal of Economics**, Oxford University Press, v. 133, n. 3, p. 1459–1501, 2018. Citado 1 vez na página 67.

BERNARDI, B. B. O conceito de dependência da trajetória (path dependence): definições e controvérsias teóricas. **Perspectivas, Revista de Ciências Sociais, Universidade Estadual Paulista (UNESP)**, São Paulo, v. 41, p. 137–167, 2012. Citado 1 vez na página 14.

BERNIELL, I.; BERNIELL, L.; DE LA MATA, D.; EDO, M.; MARCHIONNI, M. Gender gaps in labor informality: The motherhood effect. **Journal of Development Economics**, Elsevier, v. 150, p. 102599, 2021. Citado 1 vez na página 57.

BERTAY, A. C.; DORDEVIC, L.; SEVER, C. Gender inequality and economic growth: Evidence from industry-level data. **Empirical Economics**, Springer, p. 1–36, 2025. Citado 1 vez na página 58.

BERTRAND, M. Gender in the twenty-first century. In: AMERICAN ECONOMIC ASSOCIATION 2014 BROADWAY, SUITE 305, NASHVILLE, TN 37203. AEA Papers and proceedings. [S.l.: s.n.], 2020. v. 110, p. 1–24. Citado 2 vez na página 56.

BERTRAND, M.; KAMENICA, E.; PAN, J. Gender identity and relative income within households. **The Quarterly Journal of Economics**, MIT Press, v. 130, n. 2, p. 571–614, 2015. Citado 1 vez na página 58.

BLAU, F. D.; KAHN, L. M. The gender wage gap: Extent, trends, and explanations. **Journal of economic literature**, American Economic Association 2014 Broadway, Suite 305, Nashville, TN 37203-2425, v. 55, n. 3, p. 789–865, 2017. Citado 3 vezes nas páginas 54, 57, 67.

BLAU, F. D.; WINKLER, A. E. The economics of women, men, and work. (**Oxford University Press**), 2018. Citado 1 vez na página 54.

BLOOM, N.; LIANG, J.; ROBERTS, J.; YING, Z. J. Does working from home work? Evidence from a Chinese experiment. **Quarterly Journal of Economics**, v. 130, n. 1, p. 165–218, 2015. Citado 1 vez na página 61.

BOUTHILLIER, X.; DELAUNAY, P.; BRONZI, M.; TROFIMOV, A.; NICHYPORUK, B.; SZETO, J.; MOHAMMADI SEPAHVAND, N.; RAFF, E.; MADAN, K.; VOLETI, V. et al. Accounting for variance in machine learning benchmarks. **Proceedings of Machine Learning and Systems**, v. 3, p. 747–769, 2021. Citado 2 vezes nas páginas 33, 106.

BRASIL. **Constituição da República Federativa do Brasil de 1988**. [S.l.: s.n.], 1988. Art. 144, inciso V. Acesso em: 18 jul. 2025. Disponível em: [https://www.planalto.gov.br/ccivil\\_03/constituicao/constituicao.htm](https://www.planalto.gov.br/ccivil_03/constituicao/constituicao.htm). Citado 1 vez na página 40.

BROWNE, I.; MISRA, J. The intersection of gender and race in the labor market. **Annual review of sociology**, Annual Reviews 4139 El Camino Way, PO Box 10139, Palo Alto, CA 94303-0139, USA, v. 29, n. 1, p. 487–513, 2003. Citado 1 vez na página 85.

BRYNJOLFSSON, E.; MITCHELL, T.; ROCK, D. What can machines learn and what does it mean for occupations and the economy? In: AMERICAN ECONOMIC ASSOCIATION 2014 BROADWAY, SUITE 305, NASHVILLE, TN 37203. AEA papers and proceedings. [S.l.: s.n.], 2018. v. 108, p. 43–47. Citado 1 vez na página 23.

BUANI GONÇALVES, L.; DE ALMEIDA REINALDI, M. A. Impacto da inteligência artificial no controle interno de Instituições Financeiras. **Revista Contabilidade & Inovação**, v. 3, n. 1, 2024. DOI: [10.56000/rci.v3i1.80817](https://doi.org/10.56000/rci.v3i1.80817). Citado 1 vez na página 13.

CAHUC, P.; CARCILLO, S.; ZYLBERBERG, A. **Labor Economics**. 2nd. [S.l.]: The MIT Press, 2014. cap. 10, p. 627–676. Citado 9 vezes nas páginas 13, 17, 18, 26.

CASTELLS, M. **A era da informação: economia, sociedade e cultura**. [S.l.]: Paz e Terra, 1999. v. 1. Citado 1 vez na página 17.

CBM-DF; UNIVERSIDADE DE BRASÍLIA (UNB/CIC); GIGACANDANGA; TORRE DIGITAL FLOR DO CERRADO. **Projeto Sem Fogo – Detecção automática de focos de incêndio no Distrito Federal**. [S.l.: s.n.], 2025. Acesso em: 18 jul. 2025. Disponível em: <https://semfogo.gigacandanga.net.br>. Citado 1 vez na página 40.

CHETTY, R.; HENDREN, N.; JONES, M. R.; PORTER, S. R. Race and economic opportunity in the United States: An intergenerational perspective. **The Quarterly Journal of Economics**, Oxford University Press, v. 135, n. 2, p. 711–783, 2020. Citado 1 vez na página 67.

COSTA, P.; BRANDÃO, M.; RAMALHO, E.; CARVALHO, J. F. A INTELIGÊNCIA ARTIFICIAL NA OTIMIZAÇÃO DE PROCESSOS LOGÍSTICOS REVISÃO SISTEMÁTICA DE LITERATURA. **Análise**, v. 17, p. 67, jun. 2022. Citado 1 vez na página 39.

CUBERES, D.; TEIGNIER, M. Aggregate effects of gender gaps in the labor market: A quantitative estimate. **Journal of human capital**, University of Chicago Press Chicago, IL, v. 10, n. 1, p. 1–32, 2016. Citado 1 vez na página 58.

DAN, J.; MARTIN JAMES, H. **Speech and language processing: An introduction to natural language processing, computational linguistics, and speech recognition**. [S.l.]: Pearson Prentice Hall Upper Saddle River, NJ, 2009. Citado 2 vezes nas páginas 33, 105.

DATAMPE BRASIL. **Perfil geográfico: Comendador Gomes — DataMPE Brasil**. [S.l.: s.n.], 2025. <https://datampe.sebrae.com.br/profile/geo/comendador-gomes#bespoke-title-25>. Acessado em 31 de agosto de 2025. Citado 1 vez na página 45.

EASTIN, J.; PRAKASH, A. Economic development and gender equality: Is there a gender Kuznets curve? **World Politics**, Cambridge University Press, v. 65, n. 1, p. 156–186, 2013. Citado 2 vezes nas páginas 58, 62.

EMBRAPA. **Semear Digital - Centro de Ciência para o Desenvolvimento em Agricultura Digital (CCD-AD)**. [S.l.: s.n.], 2025. Acesso em: 18 jul. 2025. Disponível em: <https://www.semear-digital.cnptia.embrapa.br>. Citado 1 vez na página 40.

ESTADO DO PARANÁ. **Bombeiros usam drones de alta tecnologia para reforçar proteção de banhistas no Litoral**. [S.l.: s.n.], 2025. Acesso em: 18 jul. 2025. Disponível em: <https://www.parana.pr.gov.br/aen/Noticia/Bombeiros-usam-drones-de-alta-tecnologia-para-reforcar-protecao-de-banhistas-no-Litoral>. Citado 1 vez na página 40.

FANG, Y.; CAO, H.; SUN, J. Impact of artificial intelligence on Regional Green Development under China's environmental decentralization system—based on Spatial Durbin Model and Threshold Effect. **International Journal of Environmental Research and Public Health**, v. 19, n. 22, 2022. ISSN 1660-4601. DOI: [10.3390/ijerph192214776](https://doi.org/10.3390/ijerph192214776). Disponível em: <https://www.mdpi.com/1660-4601/19/22/14776>. Citado 4 vezes nas páginas 21, 22.

FEINERER, I.; HORNIK, K.; MEYER, D. Text Mining Infrastructure in R. **Journal of Statistical Software**, v. 25, n. 5, p. 1–54, 2008. DOI: [10.18637/jss.v025.i05](https://doi.org/10.18637/jss.v025.i05). Disponível em: <https://www.jstatsoft.org/index.php/jss/article/view/v025i05>. Citado 4 vezes nas páginas 32, 103, 104.

FELTEN, E.; RAJ, M.; SEAMANS, R. C. The effect of artificial intelligence on human labor: An ability-based approach. In: 1. Academy of Management Proceedings. Briarcliff Manor, NY 10510: Academy of Management, 2019. v. 2019, p. 15784. Citado 8 vezes nas páginas 19, 23, 24, 62, 85, 86, 89.

FERREIRA, J. A.; BARBOSA, J. M.; LIMA, S. K. R.; NETO, O. C. O uso da inteligência artificial na agricultura. **Revista Multidisciplinar do Nordeste Mineiro**, v. 9, n. 1, 2024. Citado 1 vez na página 39.

FIGLIUZZI, R. S. **Inteligência artificial: um novo paradigma tecnológico?** [S.l.]: Universidade Federal do Rio de Janeiro, 2018. Citado 1 vez na página 14.

GALLEN, Y. **Motherhood and the gender productivity gap.** [S.l.]: SSRN, 2018. Citado 1 vez na página 57.

GASPARIN, S.; BERGER, J.; DUTYKH, D.; MENDES, N. An innovative method to determine optimum insulation thickness based on non-uniform adaptive moving grid. **Journal of the Brazilian Society of Mechanical Sciences and Engineering**, Springer, v. 41, n. 4, p. 173, 2019. Citado 1 vez na página 41.

GMYREK, P.; WINKLER, H.; GARGANTA, S. **Buffer or bottleneck? Employment exposure to generative AI and the digital divide in Latin America.** [S.l.]: ILO Working Paper, 2024. Citado 2 vezes nas páginas 54, 55.

GOLDBERG, Y. **Neural network methods in natural language processing.** [S.l.]: Morgan & Claypool Publishers, 2017. Citado 2 vezes nas páginas 33, 107.

GOLDIN, C. Nobel lecture: An evolving economic force. **American Economic Review**, American Economic Association 2014 Broadway, Suite 305, Nashville, TN 37203, v. 114, n. 6, p. 1515–1539, 2024. Citado 1 vez na página 57.

GRUETZEMACHER, R.; PARADICE, D.; LEE, K. B. Forecasting extreme labor displacement: a survey of AI practitioners. **Technological Forecasting and Social Change**, v. 161, p. 120323, 2020. Citado 4 vezes nas páginas 15, 21, 25.

HSIEH, C.-T.; HURST, E.; JONES, C. I.; KLENOW, P. J. The allocation of talent and us economic growth. **Econometrica**, Wiley Online Library, v. 87, n. 5, p. 1439–1474, 2019. Citado 1 vez na página 58.

HUANG, Y. The labor market impact of artificial intelligence: evidence from US regions. **Available at SSRN 5137231**, 2025. Citado 2 vezes nas páginas 19, 24.

IBGE. **Áreas Mínimas Comparáveis – AMC.** [S.l.: s.n.], 2023. <https://www.ibge.gov.br/geociencias/organizacao-do-territorio/estrutura-territorial/15761-areas-minimas-comparaveis.html>. Acesso em: 8 nov. 2025. Citado 1 vez na página 64.

IBGE. **Comendador Gomes — Minas Gerais — Cidades e Estados — IBGE.** [S.l.: s.n.], 2025. <https://www.ibge.gov.br/cidades-e-estados/mg/comendador-gomes.html>. Acessado em 31 de agosto de 2025. Citado 1 vez na página 45.

IBGE. **Instituto Brasileiro de Geografia e Estatística.** [S.l.: s.n.], 2025. <https://www.ibge.gov.br>. Acesso em: 8 nov. 2025. Citado 1 vez na página 63.

JURAFSKY, D.; MARTIN, J. H. **Speech and Language Processing: An Introduction to Natural Language Processing, Computational Linguistics, and Speech Recognition with Language Models.** 3rd. [S.l.: s.n.], 2025. Online manuscript released January 12, 2025. Disponível em: <https://web.stanford.edu/~jurafsky/slp3/>. Citado 3 vezes nas páginas 32, 106, 107.

LANE, M. **Algorithm and eve: How ai will impact women at work.** [S.l.]: OECD Policy Brief, 2024. Citado 2 vezes nas páginas 55, 62.

LEMES, M. M.; LEMOS, A. N. L. E. O uso da inteligência artificial na saúde pela Administração Pública brasileira. **Cadernos Ibero-Americanos De Direito Sanitário**, v. 9, n. 3, p. 166–182, 2020. DOI: [10.17566/ciads.v9i3.684](https://doi.org/10.17566/ciads.v9i3.684). Citado 1 vez na página 13.

LIMA, Y.; STRAUCH, J.; ESTEVES, M.; SOUZA, J.; CHAVES, M.; GOMES, D. L. et al. **O futuro do emprego no Brasil: estimando o impacto da automação.** **Laboratório do Futuro.** [S.l.]: Rio de Janeiro, 2019. Citado 1 vez na página 60.

LINS DE ARAUJO, R. D.; BAGAGI LIMA, G.; SILVA BARBOSA, B. da. Inteligência artificial e a política brasileira: análise do ChatGPT e seu potencial uso político, como ferramenta de manipulação de informações. **Conversas & Controvérsias**, v. 10, n. 1, e44996, 2023. DOI: [10.15448/2178-5694.2023.1.44996](https://doi.org/10.15448/2178-5694.2023.1.44996). Citado 1 vez na página 13.

LIU, J.; LIU, L.; QIAN, Y.; SONG, S. The effect of artificial intelligence on carbon intensity: evidence from China's industrial sector. **Socio-Economic Planning Sciences**, v. 83, p. 101002, 2022. Citado 1 vez na página 24.

LU, J.; XIAO, Q.; WANG, T. Does the digital economy generate a gender dividend for female employment? Evidence from China. **Telecommunications Policy**, v. 47, 2023. Citado 11 vezes nas páginas 9, 54–56, 62, 65–67, 77.

MADALOZZO, R. Occupational segregation and the gender wage gap in Brazil: an empirical analysis. **Economia aplicada**, SciELO Brasil, v. 14, p. 147–168, 2010. Citado 1 vez na página 57.

MAGALHÃES, R.; VENDRAMINI, A. Os impactos da quarta revolução industrial. **GV-EXECUTIVO**, v. 17, n. 1, p. 40–43, 2018. Citado 1 vez na página 13.

MARTIN, J. H.; JURAFSKY, D. **Speech and language processing: An introduction to natural language processing, computational linguistics, and speech recognition**. [S.l.]: Pearson/Prentice Hall Upper Saddle River, 2009. v. 23. Citado 7 vezes nas páginas 33, 37, 107–109.

MCCARTHY, J.; MINSKY, M. L.; ROCHESTER, N.; SHANNON, C. E. **A proposal for the Dartmouth summer research project on artificial intelligence**. [S.l.: s.n.], 1955. Accessed: 2024-09-20. Disponível em: <http://jmc.stanford.edu/articles/dartmouth/dartmouth.pdf>. Citado 1 vez na página 13.

MIKOLOV, T.; SUTSKEVER, I.; CHEN, K.; CORRADO, G. S.; DEAN, J. Distributed representations of words and phrases and their compositionality. **Advances in neural information processing systems**, v. 26, 2013. Citado 1 vez na página 106.

MINISTÉRIO DO TRABALHO E EMPREGO. **Relação Anual de Informações Sociais (RAIS): Microdados**. [S.l.: s.n.], 2025. <https://www.gov.br/trabalho-e-emprego/pt-br/assuntos/estatisticas-trabalho/microdados-rais-e-caged>. Base de dados administrativa. Citado 0 vezes nas páginas 71–76.

NATIONAL CENTER FOR O\*NET DEVELOPMENT. **O\*NET Resource Center**. [S.l.: s.n.], 2023. Accessed: 2025-07-16. Disponível em: <https://www.onetcenter.org/>. Citado 1 vez na página 36.

NSTECH. **nstech - Soluções em Inteligência Artificial para Logística**. [S.l.: s.n.], 2025. Acesso em: 17 jul. 2025. Disponível em: <https://www.nstech.com.br>. Citado 1 vez na página 39.

OFORI, P. E.; OFORI, I. K. **The impact of frontier technology adoption on gender inequality: Evidence from Africa**. [S.l.]: Kiel, Hamburg: ZBW-Leibniz Information Centre for Economics, 2024. Citado 7 vezes nas páginas 9, 14, 21, 54, 59, 61.

OLIVETTI, C.; PAN, J.; PETRONGOLO, B. The evolution of gender in the labor market. In: HANDBOOK of labor economics. [S.l.]: Elsevier, 2024. v. 5. P. 619–677. Citado 1 vez na página 57.

PENNINGTON, J.; SOCHER, R.; MANNING, C. D. Glove: Global vectors for word representation. In: PROCEEDINGS of the 2014 conference on empirical methods in natural language processing (EMNLP). [S.l.: s.n.], 2014. P. 1532–1543. Citado 8 vezes nas páginas 33, 37, 106, 107.

PROLOGIS - UFSC. **Como a inteligência artificial está revolucionando o combate a incêndios florestais**. [S.l.: s.n.], 2024. Acesso em: 18 jul. 2025. Disponível em: <https://prologis.ufsc.br/wordpress/?p=3073>. Citado 1 vez na página 41.

PUC/PR. **Domus - Centro de Ciências Exatas e Tecnológicas da PUCPR**. [S.l.: s.n.], 2025. Acesso em: 18 jul. 2025. Disponível em: <https://domus.pucpr.br>. Citado 1 vez na página 41.

RAMBERSAD, G. Robot will take your job: Innovation for an era of artificial intelligence. **Journal of Business Research**, v. 116, p. 68–74, 2020. Citado 1 vez na página 25.

RENDALL, M. Brain versus brawn: the realization of women's comparative advantage. **University of Zurich, Institute for Empirical Research in Economics, Working Paper**, n. 491, 2017. Citado 3 vezes nas páginas 58, 59, 61.

ROCHA, B. A. B.; LIMA, F. R. D. S.; WALDMAN, R. L. Mudanças no papel do indivíduo pós-revolução industrial e o mercado de trabalho na sociedade da informação. **Revista Pensamento Jurídico**, v. 14, n. 1, 2020. Citado 1 vez na página 17.

SANTOS, R. M. dos; VASCONCELOS, R. O. A ATUAÇÃO DOS SISTEMAS DE TRANSPORTES INTELIGENTES NO TRANSPORTE PÚBLICO VIA ÔNIBUS IMPULSIONADO PELO 5G: uma revisão sistemática. **P2P E INOVAÇÃO**, v. 10, n. 2, 2024. Citado 2 vezes nas páginas 13, 14.

SANTOS, V. S.; RIBEIRO, N. M.; LIMA, A. M. F.; SANTOS, A. S. Prospecção Bibliométrica e Patentária de Tecnologias com Inteligência Artificial Aplicáveis a Smart Cities. **Cadernos de Prospecção**, v. 15, n. 2, p. 523–540, 2022. Citado 2 vezes nas páginas 13, 14.

SARTORIS, A. **Estatística e introdução à econometria**. [S.l.]: Editora Saraiva, 2008. P. 426–426. Citado 1 vez na página 43.

SCHUMPETER, J. A. **Capitalismo, socialismo e democracia**. São Paulo: Editora da Unesp, 2017. P. 117–123. Publicado originalmente em 1942. Tradução de Luiz Antônio Oliveira de Araújo. São Paulo: Editora da Unesp. Citado 2 vez na página 14.

SILGE, J.; ROBINSON, D.; ROBINSON, D. **Text mining with R: A tidy approach**. [S.l.]: O'reilly Boston (MA), 2017. Citado 2 vezes nas páginas 32, 102.

SOARES JÚNIOR, G. G. **Tecnologias habilitadoras da indústria 4.0 aplicadas para melhoria da segurança do trabalho na construção civil**. [S.l.]: Universidade Nove de Julho, 2021. Citado 1 vez na página 41.

STRAKA, M.; STRAKOVÁ, J. Tokenizing, POS tagging, lemmatizing and parsing UD 2.0 with UDPipe. In: HAJIČ, J.; ZEMAN, D. (Ed.). **Proceedings of the CoNLL 2017 Shared Task: Multilingual Parsing from Raw Text to Universal Dependencies**. Vancouver, Canada: Association for Computational Linguistics, ago. 2017. P. 88–99. DOI: [10.18653/v1/K17-3009](https://doi.org/10.18653/v1/K17-3009). Disponível em: <https://aclanthology.org/K17-3009/>. Citado 6 vezes nas páginas 32, 33, 103, 104.

SUN, Y.; WU, Z.; LAN, J.; LI, Y.; DOU, Z. Spatiotemporal distribution and dynamics evolution of artificial intelligence development in China. **Heliyon**, Elsevier, v. 10, n. 1, 2024. Citado 5 vezes nas páginas 9, 21, 22.

TOLAN, S.; PESOLE, A.; MARTÍNEZ-PLUMED, F.; FERNÁNDEZ-MACÍAS, E.; HERNÁNDEZ-ORALLO, J.; GÓMEZ, E. Measuring the occupational impact of AI: tasks, cognitive abilities and AI benchmarks. **Journal of Artificial Intelligence Research**, v. 71, p. 191–236, 2021. Citado 2 vezes nas páginas 19, 20.

TRABALHO E EMPREGO, B. M. do. **Classificação Brasileira de Ocupações: CBO – Livro 1: Códigos, Títulos e Descrições**. 3. ed. [S.l.: s.n.], 2010. Disponível em: <http://www.mtecbo.gov.br/cbsite/pages/downloads.jsf>. Acesso em: 12 ago. 2025. Citado 2 vezes nas páginas 38, 40.

TRABALHO E EMPREGO, B. M. do. **Classificação Brasileira de Ocupações: CBO – Livro 2: Códigos, Títulos e Descrições**. 3. ed. [S.l.: s.n.], 2010. Disponível em: <http://www.mtecbo.gov.br/cbsite/pages/downloads.jsf>. Acesso em: 12 ago. 2025. Citado 3 vezes nas páginas 39, 41.

VON DIETRICH, P.; GARCIA, M. H. New challenges for women workers in Brazil facing the wave of Industry 4.0 technologies. **Gender & Development**, v. 30, n. 3, p. 459–476, 2022. DOI: [10.1080/13552074.2022.2125240](https://doi.org/10.1080/13552074.2022.2125240). Citado 3 vezes nas páginas 13, 58, 59.

WANG, L.; CAO, Z.; DONG, Z. Are artificial intelligence dividends evenly distributed between profits and wages? Evidence from the private enterprise survey data in China. **Structural Change and Economic Dynamics**, v. 66, p. 342–356, 2023. Citado 1 vez na página 25.

WEBB, M. **The impact of artificial intelligence on the labor market**. [S.l.: s.n.], 2019. Disponível em SSRN 3482150. Citado 55 vezes nas páginas 9, 10, 14–16, 19, 21, 23, 24, 26, 28–31, 33–37, 41, 51, 54, 55, 62, 63, 65, 66, 71, 85, 86, 104, 105.

WELBERS, K.; VAN ATTEVELDT, W.; BENOIT, K. Text analysis in R. English. **Communication Methods and Measures**, Routledge, v. 11, n. 4, p. 245–265, nov. 2017. ISSN 1931-2458. DOI: [10.1080/19312458.2017.1387238](https://doi.org/10.1080/19312458.2017.1387238). Citado 2 vezes nas páginas 32, 102.

WIJFFELS, J. **udpipe: Tokenization, parts of speech tagging, lemmatization and dependency parsing with the “UDPipe”“NLP” Toolkit [Manual]**. [S.l.: s.n.], 2021. Citado 6 vezes nas páginas 32, 33, 103, 104.

WOOD JR, T. Fordismo, toyotismo e volvismo: os caminhos da indústria em busca do tempo perdido. **Revista de administração de Empresas**, SciELO Brasil, v. 32, p. 6–18, 1992. Citado 1 vez na página 17.

YAHMED, S. B. Formal but less equal. Gender wage gaps in formal and informal jobs in urban Brazil. **World Development**, Elsevier, v. 101, p. 73–87, 2018. Citado 1 vez na página 9.

YANG, S.; KIM, D. Spatial distribution and characteristics of vulnerable occupations to artificial intelligence: cases from South Korea. **The Annals of Regional Science**, v. 72, p. 1079–1103, 2024. Citado 18 vezes nas páginas 9, 13, 16, 19, 21, 22, 24, 25, 28, 39, 61.

YEH, C. C. R.; WONG, C. C. J.; CHANG, W. W. V. et al. Labor displacement in artificial intelligence era: a systematic literature review. **Taiwan Journal of East Asian Studies**, v. 17, n. 2, 2020. Citado 1 vez na página 24.

YU, S.; ZHANG, J.; YAN, X. Robots, gender economic opportunities and household adjustment: Evidence from China. **Structural Change and Economic Dynamics**, v. 71, p. 57–67, 2024. Citado 2 vezes nas páginas 54, 60.

ZHANG, C.; JIAN, Y.; ZHOU, Z.; ZHOU, B. Can the digital economy close the gender wage gap? Evidence from China. **International Review of Economics and Finance**, v. 96, p. 103604, 2024. Citado 3 vezes nas páginas 54, 60.

## APÊNDICE 1 – PROGRAMAÇÃO COMENTADA

### Etapa 1: Instalação e carregamento dos pacotes

A etapa inicial envolveu a instalação e carregamento de pacotes do RStudio específicos na linguagem R necessários para a análise textual. Os pacotes foram escolhidos pela sua aderência à manipulação de dados textuais não estruturados - tarefas de NLP.

```
install.packages(c("data.table", "udpipe", "stringr", "dplyr", "readr",  
"text2vec", "textclean", "writexl", "tm", "lsa", "openxlsx"))  
library(data.table)  
library(udpipe)  
library(stringr)  
library(dplyr)  
library(readr)  
library(text2vec)  
library(textclean)  
library(writexl)  
library(tm)  
library(lsa)  
library(openxlsx)  
library(NLP)  
library(SnowballC)  
library(purrr)  
library(tibble)
```

Os pacotes de processamento de dados acima relacionados foram selecionados com base nas recomendações da literatura para NLP em R, especialmente Silge et al. (2017) e Welbers et al. (2017).

### Etapa 2: Carregamento do modelo linguístico (UDPipe)

Nesta etapa, foi utilizado o modelo linguístico UDPipe para o idioma português. O código utilizado segue abaixo:

```
modelo <- udpipes_download_model(language = "portuguese")  
modelo_ud <- udpipes_load_model(modelo$file_model)
```

O pacote *udpipe* fornece modelos pré-treinados para análise linguística detalhada de texto, trazendo funcionalidades que incluem tokenização, detecção de palavras-chave e lematização, sendo essenciais para a extração dos pares verbo-substantivo (Wijffels, 2021; Straka; Straková, 2017).

Trata-se de modelo previamente treinado com uma grande base de textos que permite que ele reconheça e analise de forma mais precisa a estrutura das frases em diversos idiomas. Portanto, o modelo é capaz de identificar automaticamente palavras, suas funções gramaticais (como verbos, substantivos e adjetivos) e até mesmo simplificar as palavras às suas formas básicas (lematização), o que viabilizou a organização e tratamento dos textos de patentes e CBO (Wijffels, 2021; Straka; Straková, 2017).

### **Etapa 3: Leitura e pré-processamento dos arquivos**

Nesta etapa foram carregados dois conjuntos principais de dados textuais, sendo eles, (i) as descrições sumárias das tarefas das ocupações da CBO e (ii) o texto das patentes brasileiras relacionadas à IA.

```

caminho_cbo <- "cbo.xlsx"
caminho_patentes <- "patentes.txt"

df_cbo_raw <- readxl::read_excel(caminho_cbo)
descricoes_validas <- df_cbo_raw %>%
  filter(!is.na('Tarefa - DESCRIÇÃO SUMÁRIA'),
         'Tarefa - DESCRIÇÃO SUMÁRIA' != "") %>%
  distinct('Tarefa - DESCRIÇÃO SUMÁRIA') %>%
  pull()
texto_cbo <- paste(descricoes_validas, collapse = ". ")
texto_patentes <- read_file(caminho_patentes)

```

No intuito de garantir a relevância e a qualidade dos dados, nesta etapa foi feita uma pré-filtragem e concatenação das descrições válidas, conforme técnicas de limpeza textual descritas por Feinerer et al. (2008).

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 quali-

dade, clareza e relevância dos dados utilizados em estudos que envolvam a mineração de texto via PLN (Feinerer et al., 2008).

#### **Etapa 4: Anotação Linguística**

A etapa subsequente à de pré-processamento textual foi a de anotação linguística dos textos utilizando o modelo UDPipe já carregado. 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; Straková, 2017).

O código correspondente é o que segue abaixo:

```

anot_cbo <- udpipe_annotate(modelo_ud, texto_cbo)
anot_patentes <- udpipe_annotate(modelo_ud, texto_patentes)

df_cbo <- as.data.frame(anot_cbo)
df_pat <- as.data.frame(anot_patentes)

```

Essa etapa se mostrou 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.

#### **Etapa 5: Extração de pares verbo-substantivo de patentes e tarefas**

Nesta etapa, foram extraídos os pares verbo-substantivo de patentes e tarefas com base na estrutura sintática das sentenças, utilizando o parsing sintático fornecido pelo pacote *udpipe*.

```

extrair_pares <- function(df) {
  substantivos <- df %>% filter(upos == "NOUN")
  verbos <- df %>% filter(upos == "VERB")
  pares <- merge(substantivos, verbos,
    by = "sentence_id", suffixes = c("_sub", "_ver"))
  pares_filtrados <- pares %>%
    filter(head_token_id_ver == token_id_sub) %>%
    mutate(par = paste(token_ver, token_sub, sep = "_")) %>%
    select(sentence_id, par)
  return(pares_filtrados)
}

```

```

}
pares_cbo <- extrair_pares(df_cbo)
pares_pat <- extrair_pares(df_pat)

```

O *parsing* sintático (*syntactic parsing*) consiste em uma técnica do Processamento de Linguagem Natural (NLP) que atribui uma estrutura gramatical formal a uma dada sentença, viabilizando que seja analisado como as palavras se relacionam entre si dentro da frase. A partir desse processo, foi possível identificar quais substantivos estão conectados a quais verbos e qual função sintática cada palavra exerce — sujeito, objeto direto ou modificador. Essa representação estrutural, geralmente formalizada por meio de árvores sintáticas (*parse trees*), é utilizada para identificar diversas tarefas de análise linguística e semântica (Dan; Martin James, 2009).

Esta etapa que identifica os pares verbo-substantivo de patentes e tarefas baseia-se diretamente na metodologia original de Webb (2019), que em seu *paper* explora tais pares para capturar as tarefas concretas que podem ser automatizadas pela inteligência artificial.

## Etapa 6: Vetorização com o algoritmo GloVe

Para transformar os pares verbo-substantivos de patentes e tarefas em vetores numéricos dentro de um espaço vetorial contínuo, foi utilizada a técnica GloVe (Global Vectors for Word Representation), que captura relações semânticas entre palavras:

```

set.seed(42)

tokens_cbo <- str_split(pares_cbo$par, "_")
tokens_pat <- str_split(pares_pat$par, "_")
todos_tokens <- unique(unlist(c(tokens_cbo, tokens_pat)))

it <- itoken(todos_tokens, progressbar = FALSE)
vocab <- create_vocabulary(it)
vectorizer <- vocab_vectorizer(vocab)
dtm <- create_dtm(it, vectorizer)

glove <- GlobalVectors$new(rank = 300, x_max = 100)
wv_main <- glove$fit_transform(dtm, n_iter = 30)

glove <- GlobalVectors$new(rank = 100, x_max = 100)

```

```
wv_main <- glove$fit_transform(dtm, n_iter = 30)
```

Conforme salienta Pennington et al. (2014), o algoritmo GloVe é amplamente adotado na literatura de NLP por sua eficácia em capturar o significado contextual das palavras, sendo que por meio dele são construídas representações vetoriais das palavras de forma a refletir seu significado contextual, organizando-as em um espaço vetorial onde palavras semanticamente relacionadas ocupam posições próximas.

No âmbito do processamento de linguagem natural, essas representações vetoriais são conhecidas como *word embeddings*. De forma geral, *embeddings* consistem em representações numéricas densas das palavras, nas quais cada termo é associado a um vetor em um espaço vetorial de alta dimensão. Diferentemente de representações tradicionais baseadas apenas na frequência das palavras, os *embeddings* capturam padrões de coocorrência e relações semânticas presentes nos textos, permitindo que palavras utilizadas em contextos semelhantes apresentem vetores próximos entre si nesse espaço vetorial (Mikolov et al., 2013; Jurafsky; Martin, 2025).

Para garantir a reprodutibilidade dos resultados, foi incluída uma semente aleatória no início da etapa de vetorização semântica com o comando *set.seed(42)*. O modelo GloVe envolve procedimentos estocásticos em seu treinamento, motivo pelo qual, sem o controle da aleatoriedade a execução repetida do mesmo código pode gerar representações vetoriais diferentes e, conseqüentemente, variações nos escores de similaridade e no índice de exposição à IA. A definição de uma semente garante que os vetores gerados sejam consistentes entre execuções, logo, sua inserção no código é uma prática necessária para a reprodução dos resultados (Bouthillier et al., 2021).

Para construir os vetores semânticos com o modelo GloVe, foram definidos três parâmetros principais: *rank = 300*, *x\_max = 100* e *n\_iter = 30*.

A construção dos vetores semânticos partiu de uma matriz do tipo document-term matrix (DTM), que registra com que frequência os termos extraídos das tarefas ocupacionais e das patentes de inteligência artificial aparecem no corpus analisado. Para representar o significado das palavras de forma mais detalhada, foi adotada uma dimensão de 300 para os vetores (*rank = 300*).

Essa escolha se deve pelo fato de que quanto maior a dimensão do vetor, maior a capacidade do modelo de captar pequenas variações de sentido, contexto ou associação semântica no uso das palavras, o que é relevante para fins desta dissertação, pois o que se busca é a identificação de conexões mais finas entre as tarefas descritas nas ocupações e as tecnologias emergentes relacionadas à inteligência artificial. De acordo com Pennington et al. (2014), vetores com maior dimensionalidade tendem a oferecer melhor desempenho na representação semântica, embora os ganhos adicionais dimi-

nuam à medida que se aumentam as dimensões. De tal forma que a opção por 300 dimensões seguiu as recomendações metodológicas do próprio GloVe. (Pennington et al., 2014).

Já o  $x\_max = 100$  controla até que ponto a frequência de coocorrência entre palavras influencia o aprendizado dos vetores, evitando que termos muito comuns acabem tendo peso exagerado no modelo. Esse valor segue as práticas recomendadas por Pennington et al. (2014).

A combinação desses parâmetros buscou equilibrar profundidade semântica e robustez estatística, gerando representações vetoriais mais consistentes e coerentes com a complexidade dos dados analisados.

### **Etapa 7: Similaridade por cosseno**

Uma vez obtidas as representações vetoriais das palavras, a proximidade semântica entre os termos foi mensurada por meio de medidas de similaridade vetorial. Neste trabalho, a relação entre os pares extraídos das tarefas ocupacionais e das patentes de inteligência artificial foi avaliada por meio da similaridade cosseno, uma métrica amplamente utilizada em aplicações de PLN. Essa medida calcula o cosseno do ângulo entre dois vetores em um espaço vetorial, assumindo valores entre 0 e 1 em aplicações de processamento de linguagem natural, nas quais as representações vetoriais frequentemente derivam de frequências ou padrões de coocorrência não negativos. Quanto mais próximo de 1 for o valor obtido, maior é a proximidade semântica entre os termos representados, indicando que as palavras tendem a ocorrer em contextos semelhantes, o que faz com que a similaridade cosseno seja uma medida apta a avaliar o grau de relação semântica entre descrições de tarefas e tecnologias registradas em patentes (Jurafsky; Martin, 2025).

De acordo com Martin e Jurafsky (2009), a medida de similaridade por cosseno avalia a proximidade entre dois vetores com base na medição do cosseno do ângulo que se formam no espaço vetorial. Trata-se de técnica empregada em tarefas de comparação semântica em NLP, por considerar a direção dos vetores — e não sua magnitude — como principal critério de similaridade.

Conforme Martin e Jurafsky (2009) e Goldberg (2017), a equação matemática é dada por:

$$\text{Similaridade}(\vec{A}, \vec{B}) = \frac{\vec{A} \cdot \vec{B}}{|\vec{A}||\vec{B}|} = \frac{\sum_{i=1}^N A_i B_i}{\sqrt{\sum_{i=1}^N A_i^2} \sqrt{\sum_{i=1}^N B_i^2}} \quad (1.1)$$

Em que,

- $\vec{A}, \vec{B}$  são vetores representando os pares verbo-substantivo, gerados com base nos *embeddings*;
- $|\vec{A}|, |\vec{B}|$  são normas euclidianas dos vetores.

A escolha pela similaridade por cosseno justifica-se por sua simplicidade computacional, além de que compara representações vetoriais independentemente da magnitude dos vetores, focando na direção no espaço semântico, o que a torna adequada para capturar relações de similaridade semântica entre palavras ou sentenças (Martin; Jurafsky, 2009).

O código correspondente à implementação dessa etapa no software RStudio foi o seguinte:

```
dim_emb <- ncol(wv_main) # detecta automaticamente a dimensão

vetores_tokens <- as.data.frame(as.matrix(wv_main))
vetores_tokens$token <- rownames(wv_main)

vetor_medio <- function(par) {
  palavras <- unlist(strsplit(par, "_"))
  vetores <- lapply(palavras, function(p) {
    if (p %in% vetores_tokens$token) {
      return(as.matrix(vetores_tokens[vetores_tokens$token == p,
        1:dim_emb]))
    } else {
      return(matrix(0, nrow = 1, ncol = dim_emb))
    }
  })
  Reduce("+", vetores) / length(vetores)
}

todos_pares <- unique(c(pares_cbo$par, pares_pat$par))
vetores_pares <- map_dfr(todos_pares, ~{
  v <- vetor_medio(.x)
  tibble(par = .x, vetor = list(v))
})

vetores_cbo <- left_join(pares_cbo, vetores_pares, by = "par")
vetores_pat <- left_join(pares_pat, vetores_pares, by = "par")
```

```

mat_cbo <- do.call(rbind, vetores_cbo$vetor)
mat_pat <- do.call(rbind, vetores_pat$vetor)

sim_mat <- sim2(x = mat_cbo, y = mat_pat, method = "cosine", norm = "l2")
pares_cbo$score <- apply(sim_mat, 1, max)

```

Esse processo gera um escore de similaridade para cada par verbo-substantivo extraído das tarefas da CBO, com base no par mais semelhante encontrado entre os pares extraídos das patentes.

Esclarece-se que para facilitar o tratamento dos dados e tornar o processo reprodutível e mais ágil, foi criada uma tabela chamada `vetores_tokens`, onde ficaram armazenados os vetores gerados pelo modelo GloVe para cada palavra presente nos pares verbo-substantivo.

A ideia foi transformar a matriz de vetores (`wv_main`) em uma estrutura mais acessível, ligando diretamente cada vetor à sua palavra correspondente. Tal procedimento permite que, sempre que necessário, sejam reaproveitados os vetores já criados, sem precisar refazê-los a todo momento - o que poderia implicar em variações nos índices, por serem gerados novos vetores -, tornando a análise mais rápida e os resultados mais consistentes. Essa forma de organização está alinhada com as boas práticas recomendadas na área de processamento de linguagem natural, que orientam a manter os *embeddings* bem estruturados e reutilizáveis ao longo da manipulação dos dados (Martin; Jurafsky, 2009).

## **Etapas 8 a 9: Cálculo do índice e exportação dos resultados**

A última etapa da construção do índice de exposição ocupacional à inteligência artificial consistiu no cálculo do escore médio de similaridade por tarefa descrita nas ocupações da CBO. Para isso, os pares verbo-substantivo extraídos das patentes e das tarefas foram associados de volta às sentenças originais das tarefas, o que permitiu identificar a qual descrição cada par estava vinculado.

Em seguida, foi calculada a média dos escores de similaridade obtidos para todos os pares de cada descrição de tarefa.

```

df_sentences <- df_cbo %>%
  distinct(sentence_id, sentence) %>%
  mutate('Tarefa - DESCRIÇÃO SUMÁRIA' = descricoes_validas[sentence_id])

indice_ia_descricoes <- pares_cbo %>%

```

```

left_join(df_sentences, by = "sentence_id") %>%
group_by('Tarefa - DESCRIÇÃO SUMÁRIA') %>%
summarise('Índice de IA' = mean(score, na.rm = TRUE))
%>%
ungroup()

write_xlsx(df_final, "resultado.xlsx")
write_csv(df_final, "resultado.csv", row.names = FALSE)

```

Aqui, cada par verbo-substantivo anotado recebeu um escore de similaridade - calculado anteriormente via similaridade por cosseno -, e a média desses escores é então agregada por descrição sumária da tarefa.

Formalmente, o índice de IA de uma tarefa  $j$  pode ser expresso pela seguinte equação:

$$\text{Índice } IA_j = \frac{1}{n_j} \sum_{i=1}^{n_j} s_{ij} \quad (1.2)$$

Em que,

- Índice $_{IA_j}$  representa o índice de exposição à inteligência artificial da tarefa  $j$ ;
- $n_j$  é o número de pares verbo-substantivo extraídos da tarefa  $j$  e comparados com os pares extraídos das patentes;
- $s_{ij}$  representa o escore de similaridade do par  $i$  pertencente à tarefa  $j$ .

A obtenção da média aritmética simples dos escores de similaridade segue abordagem semelhante à de Webb (2020), que, ao construir o índice de exposição ocupacional à IA nos Estados Unidos, também agrega os escores extraídos dos pares verbo-substantivo por tarefa, ponderando-os conforme sua importância no O\*NET.

Para fins da presente dissertação, como as tarefas da CBO não possuem pesos, optou-se pela média simples, que será posteriormente ponderada pela quantidade de empregados do município vinculados à ocupação classificada por famílias dentro da CBO.

As etapas descritas nos tópicos anteriores proporcionaram a construção de um índice consistente, cujos resultados encontram-se descritos no corpo do artigo.