



UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO SOCIOECONÔMICO - CSE
DEPARTAMENTO DE ECONOMIA E RELAÇÕES INTERNACIONAIS - CNM
CURSO DE CIÊNCIAS ECONÔMICAS

Felipe Fin Fanfa

Exposição das Ocupações Brasileiras à Inteligência Artificial Generativa:
Revisão Metodológica e Projeto Piloto de Índice

Florianópolis
2026
Felipe Fin Fanfa

Exposição das Ocupações Brasileiras à Inteligência Artificial Generativa:
Revisão Metodológica e Projeto Piloto de Índice

Trabalho de conclusão de curso submetido ao curso de Ciências Econômicas do Centro Socioeconômico da Universidade Federal de Santa Catarina como requisito parcial para a obtenção do título de Bacharel em Ciências Econômicas.

Orientador: Dr. Guilherme de Oliveira Worm.

Florianópolis

2026

Fanfa, Felipe Fin

Exposição das Ocupações Brasileiras à Inteligência Artificial Generativa: : Revisão Metodológica e Projeto Piloto de Índice / Felipe Fin Fanfa ; orientador, Guilherme de Oliveira Worm, 2026.

44 p.

Trabalho de Conclusão de Curso (graduação) - Universidade Federal de Santa Catarina, Centro Socioeconômico, Graduação em Ciências Econômicas, Florianópolis, 2026.

Inclui referências.

1. Ciências Econômicas. 2. Inteligência Artificial Generativa. 3. Mercado de Trabalho. 4. Exposição Ocupacional. I. Worm, Guilherme de Oliveira. II. Universidade Federal de Santa Catarina. Graduação em Ciências Econômicas. III. Título.

Felipe Fin Fanfa

**Exposição das Ocupações Brasileiras à Inteligência Artificial Generativa:
Revisão Metodológica e Projeto Piloto de Índice**

Este Trabalho de Conclusão de Curso foi julgado adequado para obtenção do título de Bacharel e aprovado em sua forma final pelo Curso de Ciências Econômicas.

Florianópolis, 30 de março de 2026.

Prof. Guilherme de Oliveira Worm, Dr.
Orientador

Banca examinadora

Prof. Guilherme de Oliveira Worm, Dr.
Orientador Universidade Federal de Santa Catarina

Prof. Gilson Geraldino, Dr.
Instituição Universidade Federal de Santa Catarina

Matheus Ângelo de Sousa Vieira, Dr.
Instituição Universidade Federal de Santa Catarina

Florianópolis, 2026.

AGRADECIMENTOS

Agradeço, em primeiro lugar, ao professor Guilherme de Oliveira Worm, pela orientação cuidadosa ao longo deste trabalho, pela paciência, pela resiliência e pela generosidade em compartilhar sua experiência e seu conhecimento, fundamentais para o desenvolvimento desta pesquisa.

Agradeço também ao Igor Hüttl Marques e ao Pedro Henrique Ávila, colegas de faculdade, pelas conversas construtivas e pelas reflexões compartilhadas sobre a inteligência artificial no contexto brasileiro, que contribuíram para o amadurecimento das ideias aqui desenvolvidas.

Por fim, agradeço a Elizeu de Oliveira Neto e Rafael Soccol, colegas de faculdade e empreendedores, pela disponibilidade e pelo apoio ao cederem um espaço de trabalho no qual surgiram diversas discussões e ideias sobre os avanços tecnológicos, suas oportunidades e a importância de compreender e mensurar a exposição de indivíduos e ocupações a essas novas tecnologias.

RESUMO

Este trabalho tem como objetivo construir, em caráter exploratório, um índice piloto de exposição ocupacional à inteligência artificial generativa no contexto brasileiro, com base na Classificação Brasileira de Ocupações (CBO) e no uso de grandes modelos de linguagem como avaliadores de tarefas. A pesquisa adota uma abordagem centrada em tarefas, partindo do entendimento de que a exposição à IA não depende apenas do título ocupacional, mas do conteúdo efetivo das atividades desempenhadas. Para isso, foram selecionadas 30 ocupações e, para cada uma, cinco atividades descritas na CBO, que foram avaliadas quanto ao seu potencial de execução por LLMs. As avaliações foram realizadas em múltiplas rodadas e agregadas em um índice ocupacional padronizado entre zero e um, acompanhado de medida de dispersão. Em seguida, os resultados foram comparados, em caráter exploratório, com o benchmark internacional da Organização Internacional do Trabalho, com foco no ordenamento relativo das ocupações, e não na comparação direta entre magnitudes. Os resultados indicam que ocupações mais intensivas em processamento de informação, organização de dados, produção textual, apoio administrativo e funções analíticas tenderam a apresentar níveis mais elevados de exposição potencial, enquanto ocupações mais ligadas à execução manual, operação física e prestação presencial de serviços concentraram-se nas faixas inferiores do índice. A comparação com a referência internacional revelou convergência substantiva no padrão geral de ordenamento, ainda que com diferenças pontuais associadas à seleção de atividades, ao pareamento ocupacional e às limitações inerentes ao caráter piloto do estudo. Conclui-se que a metodologia testada apresenta utilidade como instrumento inicial de mensuração e oferece uma base promissora para o desenvolvimento de estudos mais amplos sobre inteligência artificial generativa e mercado de trabalho no Brasil.

Palavras-chave: inteligência artificial generativa; mercado de trabalho; ocupações; tarefas; CBO; exposição ocupacional.

ABSTRACT

This study aims to construct and test, on an exploratory basis, a pilot index of occupational exposure to generative artificial intelligence in the Brazilian context, using the Brazilian Classification of Occupations and large language models as task evaluators. The research adopts a task-based approach, based on the understanding that exposure to AI depends not only on occupational titles, but on the actual content of the activities performed. To this end, 30 occupations were selected and, for each of them, five activities described in the occupational classification were evaluated according to their potential for execution by LLMs. The assessments were carried out over multiple rounds and aggregated into a standardized occupational index ranging from zero to one, accompanied by a measure of dispersion. The results were then compared, on an exploratory basis, with the International Labour Organization benchmark, focusing on the relative ordering of occupations rather than on direct comparison of magnitudes. The findings indicate that occupations more intensive in information processing, data organization, text production, administrative support, and analytical functions tended to show higher levels of potential exposure, whereas occupations more closely associated with manual execution, physical operation, and in-person service provision were concentrated in the lower ranges of the index. The comparison with the international benchmark revealed substantial convergence in the overall ordering pattern, although with some differences related to task selection, occupational matching, and the limitations inherent in the pilot nature of the study. It is concluded that the tested methodology is useful as an initial measurement tool and provides a promising basis for broader studies on generative artificial intelligence and the labor market in Brazil.

Keywords: generative artificial intelligence; labor market; occupations; tasks; Brazilian Classification of Occupations; occupational exposure.

SUMÁRIO

1 INTRODUÇÃO.....	9
1.1 OBJETIVOS.....	11
1.1.1 Objetivo geral.....	11
1.1.2 Objetivos específicos.....	12
1.2 DELINEAMENTO DA PESQUISA.....	12
2 LITERATURA RELACIONADA.....	14
3 PROCEDIMENTOS METODOLÓGICOS.....	22
3.1 SELEÇÃO DAS OCUPAÇÕES E BENCHMARK COMPARATIVO.....	22
3.2 EXTRAÇÃO E SELEÇÃO DAS ATIVIDADES OCUPACIONAIS.....	23
3.3 AVALIAÇÃO DAS ATIVIDADES POR LLMS.....	23
3.4 DESENVOLVIMENTO DO PROMPT E TESTES DE ESTABILIDADE.....	24
3.5 AGREGAÇÃO DOS ESCORES E CONSTRUÇÃO DO ÍNDICE.....	25
4 RESULTADOS.....	27
4.1 DISTRIBUIÇÃO DOS ESCORES E ORDENAMENTO DAS OCUPAÇÕES.....	27
4.2 COMPARAÇÃO COM O BENCHMARK DA OIT.....	30
5 CONCLUSÃO.....	37
REFERÊNCIAS.....	40
ANEXO A – PROMPT UTILIZADO.....	42

1 INTRODUÇÃO

O avanço da inteligência artificial (IA)¹, em especial da inteligência artificial generativa (IAG), ampliou de forma significativa a fronteira das atividades que podem ser desempenhadas por máquinas². Diferentemente das ondas anteriores de automação, concentradas em tarefas rotineiras e repetitivas, a IAG é capaz de realizar, *mutatis mutandis*, algumas atividades de natureza cognitiva, como produção e síntese de textos, programação, tradução, elaboração de relatórios e análise de dados. Esse potencial coloca em debate uma questão central para o mercado de trabalho: quais ocupações estão mais expostas à adoção de IAG?

O interesse por essa temática tem crescido na literatura internacional, com o desenvolvimento de diferentes metodologias para mensurar a exposição ocupacional à IA. O trabalho de Frey e Osborne (2017) estima a probabilidade de informatização de 702 ocupações nos Estados Unidos. Para isso, especialistas classificaram inicialmente um conjunto de ocupações quanto à suscetibilidade à automação, e essas avaliações serviram para treinar um modelo estatístico que projetou as probabilidades para todas as demais. Os autores concluem que cerca de 47% dos empregos analisados apresentam alto risco de automação. Essa abordagem inaugurou uma linha de pesquisa importante, mas sofre críticas por tratar as ocupações como blocos homogêneos, sem considerar a granularidade das tarefas.

Como alternativa, estudos posteriores propuseram abordagens centradas em tarefas e habilidades. Acemoglu e Restrepo (2019) avançam ao distinguir entre tecnologias que substituem e que complementam tarefas humanas, destacando os mecanismos de “deslocamento” e “reinstalação”, que, respectivamente, correspondem à substituição de tarefas existentes por máquinas e à criação de novas

¹**A inteligência artificial (IA)** pode ser definida como o ramo da ciência da computação que busca desenvolver sistemas capazes de executar tarefas que, se realizadas por seres humanos, demandariam inteligência, como aprendizado, raciocínio, percepção e tomada de decisão. Esses sistemas operam por meio de algoritmos e modelos matemáticos capazes de identificar padrões em dados, adaptar-se a novas informações e agir de forma autônoma ou semiautônoma.

²Neste trabalho, o termo **máquinas** refere-se tanto a equipamentos físicos quanto a sistemas computacionais — englobando softwares e hardwares — capazes de executar tarefas tipicamente humanas.

tarefas que geram demanda adicional por trabalho. Essa perspectiva ganha força com os resultados encontrados pelos autores, que mostram que, entre 1947 e 1987, cerca de 50% do crescimento do emprego nos Estados Unidos decorreu da criação de novas tarefas, mesmo com perdas associadas ao deslocamento por automação. Isso evidencia que a tecnologia não impacta as ocupações de forma homogênea, mas redistribui tarefas dentro delas, mostrando a necessidade de medidas mais detalhadas de exposição, capazes de captar a heterogeneidade interna das ocupações.

Mais recentemente, Felten, Raj e Seamans (2021) desenvolveram o *Artificial Intelligence Occupational Exposure (AIOE)*³, um índice que conecta aplicações de IA documentadas na literatura de ciência da computação à habilidades do O*NET⁴, e destas às ocupações. A metodologia consiste em mapear quais capacidades tecnológicas descritas em artigos da área de IA são necessárias para desempenhar determinadas habilidades, e então verificar em que medida essas habilidades estão presentes em cada ocupação. Esse procedimento gera uma medida quantitativa de exposição que pode ser comparada entre ocupações, setores e ao longo do tempo.

Complementando esse esforço, Eloundou et al. (2023) propõem uma rubrica alternativa para mensurar o impacto potencial da inteligência artificial generativa sobre as tarefas ocupacionais. Em sua abordagem, cada tarefa é avaliada segundo a possibilidade de redução de pelo menos 50% no tempo de execução quando apoiada por modelos de linguagem, como o GPT-4, sem comprometer a qualidade do resultado. O método combina classificações de especialistas humanos e avaliações feitas pelos próprios modelos de IA, o que representa uma inovação metodológica robusta em relação a índices anteriores, mais baseados em inferências indiretas.

Um desenvolvimento recente nessa literatura é o trabalho de Colombo et al. (2024), que propõem o Task Exposure to AI Index (TEAI) e o Task Replacement by AI Index (TRAI) no estudo *Towards the Terminator Economy*. Nessa abordagem, as próprias LLMs⁵ avaliam sua capacidade de desempenhar tarefas descritas no O*NET, atribuindo escores de exposição e justificativas. Esse método, conhecido como LLM-

³**Índice de Exposição Ocupacional à Inteligência Artificial.** Tradução livre.

⁴**O Occupational Information Network (O*NET)** é um sistema norte-americano que descreve de forma detalhada as ocupações, suas tarefas, habilidades e requisitos. Mantido pelo Departamento do Trabalho dos Estados Unidos, substituiu o antigo *Dictionary of Occupational Titles* (DOT) e é amplamente utilizado em pesquisas sobre mercado de trabalho e tecnologia.

as-judge, representa uma inovação importante por permitir estimativas mais granulares e escaláveis de exposição ocupacional à IAG.

Embora esses avanços metodológicos ofereçam caminhos promissores, observa-se que ainda são raros estudos que adaptem tais abordagens para o contexto brasileiro. Enquanto o O*NET constitui a base de referência para os Estados Unidos, no Brasil a Classificação Brasileira de Ocupações (CBO) cumpre papel análogo, descrevendo atribuições e tarefas em nível ocupacional. Um exemplo é o trabalho de Adamczyk, Monasterio e Fochezatto (2020), que estima a probabilidade de automação das ocupações no Brasil a partir da adaptação da metodologia de Frey e Osborne (2017). Apesar de inovador, o estudo concentra-se em automação de forma ampla, não abordando especificamente a inteligência artificial generativa. A aplicação direta das metodologias recentes à CBO abre espaço para mensurações mais ajustadas à realidade nacional e pode gerar insumos relevantes para políticas de qualificação e planejamento do mercado de trabalho.

Dessa forma, o presente trabalho se insere, procurando responder o seguinte questionamento: É possível construir um índice exploratório de exposição ocupacional à inteligência artificial generativa no Brasil a partir da avaliação de atividades da CBO por modelos de linguagem?

1.1 OBJETIVOS

Diante do problema de pesquisa apresentado, esta seção organiza os objetivos do trabalho em duas partes: o objetivo geral, que orienta a investigação como um todo, e os objetivos específicos, que detalham as etapas necessárias para seu alcance.

1.1.1 Objetivo geral

Desenvolver, em caráter piloto, uma **metodologia automatizada** para mensurar a exposição das ocupações brasileiras à Inteligência Artificial Generativa

⁵**Large Language Models (LLMs)** são modelos de inteligência artificial treinados em grandes volumes de dados textuais, capazes de compreender e gerar linguagem natural em diferentes contextos.

(IAG), a partir da Classificação Brasileira de Ocupações (CBO), utilizando julgamentos de modelos de linguagem (LLMs).

1.1.2 Objetivos específicos

São objetivos específicos:

- I. Revisar as principais metodologias de mensuração de exposição ocupacional à IA e à IAG.
- II. Propor um modelo metodológico adaptado à CBO, baseado em julgamentos automatizados de LLMs.
- III. Aplicar a metodologia em uma amostra piloto de ocupações brasileiras para testar sua coerência e viabilidade.
- IV. Discutir as potencialidades, limitações e passos necessários para a expansão do índice em estudos futuros.

1.2 DELINEAMENTO DA PESQUISA

Este trabalho caracteriza-se como uma pesquisa aplicada de natureza exploratória, voltada à proposição e teste piloto de um modelo metodológico para mensurar a exposição ocupacional à IAG no contexto brasileiro.

O estudo combina análise qualitativa das metodologias internacionais e aplicação experimental limitada da abordagem proposta a uma amostra piloto de 30 ocupações da CBO, com vistas a validar o funcionamento do método e avaliar sua consistência interna.

O nível de complexidade da pesquisa é considerado intermediário, pois envolve tanto a sistematização da literatura internacional quanto a adaptação metodológica ao contexto brasileiro. O caráter da investigação é quantitativo e qualitativo: quantitativo na construção do indicador de exposição a partir da aplicação de julgamentos de modelos de linguagem (LLMs) às tarefas da CBO, e qualitativo na análise crítica das metodologias existentes, bem como na interpretação dos resultados obtidos.

A operacionalização do estudo se dá em etapas, refletidas na estrutura da monografia. A Seção 2 apresenta uma revisão da literatura sobre metodologias de mensuração da exposição ocupacional à IA e à IAG, destacando seus pressupostos, bases de dados e resultados. A Seção 3 detalha a metodologia da pesquisa, incluindo a descrição da base de dados da CBO, os procedimentos de coleta e organização das tarefas ocupacionais e o processo de construção do indicador proposto com apoio das LLMs. A Seção 4 apresenta os resultados da aplicação do índice piloto às ocupações brasileiras selecionadas, destacando o ordenamento das ocupações segundo seus níveis relativos de exposição à inteligência artificial generativa e sua comparação exploratória com o benchmark ocupacional da OIT. Por fim, a Seção 5 discute os resultados à luz da literatura revisada, aponta as principais limitações do estudo e sugere direções para pesquisas futuras. A seção também apresenta as conclusões do trabalho e delinea, em caráter preliminar, possíveis implicações para políticas públicas e para a gestão do trabalho no país.

2 LITERATURA RELACIONADA

O avanço tecnológico sempre desempenhou papel central na transformação das formas de produção e organização do trabalho. Desde a Revolução Industrial, cada nova onda de inovação — da mecanização ao computador pessoal — redefiniu o modo como as atividades econômicas são executadas e distribuiu de maneira desigual seus benefícios entre trabalhadores e setores (Schumpeter, 1961; Acemoglu; Restrepo, 2019; Filippucci et al., 2024). Nos últimos anos, a ascensão da inteligência artificial (IA), especialmente da inteligência artificial generativa (IAG), tem provocado uma reconfiguração ainda mais profunda, como mostram as evidências revisadas abaixo, atingindo não apenas tarefas operacionais, mas também atividades cognitivas, criativas e analíticas tradicionalmente associadas ao domínio humano.

De acordo com Eloundou et al. (2023), os modelos de linguagem de larga escala (LLMs) processam e geram diversos tipos de dados sequenciais — como código, sequências de proteínas e até registros de jogos —, ampliando substancialmente o conjunto de tarefas passíveis de automação parcial. Em contraste com tecnologias anteriores focadas em rotinas padronizadas, os modelos generativos interpretam linguagem natural, sintetizam informação complexa e produzem novos conteúdos, estendendo o impacto da automação a ocupações intensivas em comunicação, análise de dados, educação, design e produção de conhecimento (Eloundou et al., 2023; Gmyrek et al., 2025; Casas et al., 2026; Chen et al., 2025).

Essa transformação altera não apenas o que os trabalhadores fazem, mas como o fazem. Atividades antes baseadas em execução manual ou análise direta de dados passam a envolver interação com sistemas de IA que apoiam, ampliam ou, em alguns casos, substituem a atuação humana. A fronteira entre trabalho humano e trabalho algorítmico torna-se mais fluida, e novas competências — como a capacidade de interpretar, supervisionar e complementar a produção da IA — tornam-se cada vez mais importantes para a empregabilidade.

Nesse contexto, compreender a exposição das ocupações à IA é fundamental para antecipar os impactos sobre o emprego, a produtividade e a qualificação profissional. A literatura econômica tem se dedicado a desenvolver métodos para medir esse grau de exposição, buscando identificar quais atividades e setores estão

mais suscetíveis à automação e quais podem ser fortalecidos pela complementaridade homem-máquina (Filippucci et al., 2024; Brynjolfsson; Li; Raymond, 2023; Huang, 2025). Diversas abordagens surgiram ao longo da última década, combinando modelos estatísticos, bases de dados de tarefas e, mais recentemente, a própria inteligência artificial como ferramenta de avaliação. Nesse cenário, vale destacar o estudo de Mangoni (2025), que analisa a cocriação humano-IA no contexto da gestão e demonstra que a colaboração entre gestores e sistemas de IA generativa amplia a produtividade e favorece a aprendizagem contínua, através de entrevistas com gestores e da identificação de práticas de construção de prompts iterativos, validação crítica dos outputs da IA e redirecionamento de tarefas operacionais para atividades estratégicas, reforçando a ideia de complementaridade homem-máquina como eixo central da transformação tecnológica contemporânea.

Ao longo da última década, diversos estudos procuraram desenvolver métodos empíricos e índices comparativos para mensurar essa exposição, combinando dados sobre tarefas, habilidades e capacidades tecnológicas de forma progressivamente mais refinada. Essa evolução metodológica reflete não apenas o avanço da própria IA, mas também uma mudança conceitual: da noção de risco de substituição para a de exposição e complementaridade. A seguir, apresenta-se uma análise cronológica das principais contribuições que estruturam essa literatura, desde os modelos pioneiros de automação até as abordagens contemporâneas baseadas em inteligência artificial generativa.

O interesse sobre o impacto da tecnologia no emprego ganha força a partir da segunda década do século XXI, quando surgem as primeiras tentativas de mensurar quantitativamente o potencial de substituição das atividades humanas por sistemas automatizados. Por seu caráter pioneiro e por estabelecer os principais pressupostos que orientaram a literatura posterior, o estudo de Frey e Osborne (2017) recebe tratamento mais detalhado nesta revisão. O trabalho apresentou uma metodologia inovadora para estimar a probabilidade de automação de centenas de ocupações na economia norte-americana, com o objetivo central de identificar o grau de vulnerabilidade das ocupações à informatização e à robótica, refletindo o avanço de tecnologias como machine learning e sistemas de controle computacional.

A proposta metodológica de Frey e Osborne (2013) consistiu em combinar avaliações qualitativas de especialistas com modelagem probabilística. Em um primeiro momento, os autores reuniram engenheiros e pesquisadores em aprendizado de máquina para avaliar a viabilidade técnica de automatização de 70 ocupações específicas. Essas ocupações iniciais foram selecionadas como amostra de treinamento, representando diferentes tipos de tarefas e graus de complexidade cognitiva. Para cada uma delas, os especialistas classificaram se a automação seria “possível” ou “improvável” com base nas tecnologias emergentes à época, gerando uma variável binária de referência (automatizável = 1; não automatizável = 0).

Em seguida, essas classificações foram extrapoladas para o conjunto total de 702 ocupações listadas na base O*NET, a partir do uso de um classificador gaussiano (Gaussian Process Classifier). Esse modelo probabilístico aprendeu a relação entre as características das 70 ocupações avaliadas e um conjunto de variáveis explicativas extraídas da O*NET, como o grau de percepção, criatividade, manipulação manual e interação social exigidos por cada profissão. Com base nesse aprendizado, o modelo gerou, para as demais ocupações, probabilidades contínuas de automação, indicando o risco estimado de que cada uma pudesse ser executada por máquinas no futuro. Esse procedimento permitiu ordenar todas as ocupações segundo seu grau de suscetibilidade à computerização⁶, transformando as avaliações qualitativas iniciais em uma estimativa quantitativa abrangente.

Os resultados obtidos tiveram grande repercussão pública e acadêmica. Frey e Osborne estimaram que cerca de 47% dos empregos nos Estados Unidos apresentavam alto risco de automação nas décadas seguintes, destacando que os avanços tecnológicos da época poderiam afetar não apenas ocupações manuais ou operacionais, mas também atividades cognitivas de rotina, como tarefas administrativas, contábeis e de suporte de escritório. Essa ampliação do escopo da automação representou uma ruptura com a visão tradicional de que apenas o trabalho físico seria substituível por máquinas. Contudo, os autores ressaltaram que atividades

⁶O termo **computerização** é a tradução direta de *computerisation* (grafia britânica) utilizada por Frey e Osborne (2013; 2017) para designar o processo de incorporação de tecnologias digitais e sistemas computacionais às atividades humanas. Embora a forma “computadorização” apareça em alguns textos em português, a expressão **computerização** é a mais precisa e consagrada na literatura acadêmica internacional e nacional, especialmente nos estudos sobre automação e trabalho.

que exigem criatividade, empatia, negociação e julgamento humano permaneceriam, ao menos no horizonte previsível, menos suscetíveis à computerização. O estudo, ao correlacionar o risco de automação com o nível educacional e a faixa salarial, reforçou ainda que ocupações menos qualificadas e com tarefas padronizadas concentravam o maior potencial de substituição tecnológica.

Apesar de seu caráter inovador, o modelo de Frey e Osborne apresenta limitações conceituais e empíricas que se tornaram evidentes à medida que novas pesquisas aprofundaram a análise. Em primeiro lugar, a abordagem adota uma visão binária da automação, classificando tarefas como totalmente “automatizáveis” ou não, o que ignora a natureza gradativa e contextual da adoção tecnológica. Além disso, as avaliações de especialistas refletem percepções de um momento histórico específico, o que introduz certo grau de subjetividade e incerteza temporal. Outro ponto crítico é que o modelo assume um cenário de substituição direta entre capital e trabalho, sem considerar as possibilidades de complementaridade entre humanos e máquinas, isto é, a capacidade de a tecnologia ampliar a produtividade do trabalho em vez de simplesmente substituí-lo.

Essas limitações levaram parte da literatura posterior a revisar os pressupostos do estudo. Como destacam Acemoglu e Restrepo (2019), a automação deve ser compreendida não apenas como um processo de deslocamento de tarefas humanas (displacement effect), mas também como um mecanismo de criação de novas funções e conteúdos de trabalho (reinstatement effect). Os autores propõem um modelo de “novas tarefas”, segundo o qual o avanço tecnológico reconfigura a fronteira entre capital e trabalho, redefinindo o conteúdo das ocupações sem necessariamente reduzi-las.

Essa concepção dialoga com a tradição schumpeteriana do progresso técnico, na qual as inovações provocam transformações estruturais contínuas e exigem adaptação das empresas e dos trabalhadores às novas condições produtivas. Desde Schumpeter (1961), o desenvolvimento econômico é entendido como um processo de “destruição criadora”, no qual cada onda de inovação substitui antigas formas de produção e abre espaço para novas atividades e competências. Nesse sentido, a abordagem de Acemoglu e Restrepo representa um avanço sobre a de Frey

e Osborne, ao incorporar explicitamente essa dinâmica de recomposição produtiva e aprendizado econômico diante das inovações tecnológicas.

Mesmo com suas restrições, o trabalho de Frey e Osborne (2017) permanece como um marco fundador da mensuração do risco de automação, servindo de base para uma série de estudos aplicados em diferentes contextos nacionais. A partir de sua publicação, a agenda de pesquisa deslocou-se gradualmente do mapeamento estático do “risco” de substituição para a identificação dos mecanismos econômicos por meio dos quais a tecnologia afeta o emprego. Nesse sentido, Acemoglu e Restrepo (2019) mostram que a automação, ao reconfigurar o conteúdo das tarefas, produz simultaneamente um efeito de deslocamento — isto é, a substituição de tarefas anteriormente realizadas por trabalho humano — e um efeito de reinstalação, associado à criação de novas tarefas nas quais o trabalho volta a ser demandado. Quando o segundo não compensa o primeiro, os ganhos de produtividade decorrentes da automação não se traduzem em expansão proporcional do emprego e podem pressionar negativamente os salários relativos. Em síntese, a literatura avança da mera estimação de probabilidades de substituição para a análise dinâmica da reconfiguração das tarefas e dos retornos do trabalho, abrindo caminho para métricas de exposição e para o enfoque na complementaridade entre humanos e sistemas de IA.

É justamente essa mudança de perspectiva — do diagnóstico de risco à análise da complementaridade tecnológica — que marca o início da segunda fase dessa trajetória metodológica, na qual a automação passa a ser compreendida não apenas como substituição de tarefas, mas como processo de reconfiguração das relações produtivas. Essa nova abordagem, examinada a seguir, incorpora dimensões qualitativas do trabalho e reconhece que a tecnologia pode atuar tanto como fator de deslocamento quanto como instrumento de ampliação da produtividade e da cooperação homem–máquina.

Essa fase metodológica ganha densidade com a proposta de Felten, Raj e Seamans (2021), que substitui a pergunta “o que pode ser automatizado?” por “quem está mais exposto às capacidades atuais da IA?”. Para isso, os autores desenvolvem o AI Occupational Exposure (AIOE), métrica que conecta aplicações amplas de IA a habilidades e tarefas ocupacionais, permitindo derivar medidas agregadas por

indústria (AIE) e território (AIGE) e oferecendo um arcabouço replicável para comparação entre ocupações, setores e espaços geográficos. A contribuição é, sobretudo, metodológica e instrumental: ao quantificar a exposição de ocupações às capacidades da IA com base em correspondências sistemáticas entre tarefas e aplicações, o AIOE oferece uma métrica replicável e comparável, útil para estudos sobre o impacto da IA no trabalho e na estrutura produtiva.

Os resultados empíricos associados a essa abordagem evidenciam heterogeneidades marcantes entre ocupações e regiões, indicando que a exposição às capacidades da IA varia significativamente conforme o conteúdo das tarefas desempenhadas. Embora Felten, Raj e Seamans (2021) não investiguem diretamente os efeitos da exposição sobre desempenho, salários ou produtividade, o AIOE fornece uma base comparável para identificar quais ocupações concentram maior potencial de reconfiguração de tarefas diante da difusão da IA. Ao operacionalizar a exposição como correspondência entre capacidades tecnológicas e conteúdo ocupacional, a métrica permite distinguir setores e funções nos quais a adoção da IA tende a assumir caráter complementar, oferecendo subsídios analíticos para estudos aplicados sobre qualificação profissional, reorganização do trabalho e impactos distributivos (Felten; Raj; Seamans, 2021; Chen et al., 2025; Huang, 2025).

Neste trabalho, adota-se a distinção entre IA como categoria geral, IA generativa como sua vertente mais recente voltada à produção de conteúdo, e LLMs como a tecnologia central por meio da qual essa vertente se materializa empiricamente.

A inflexão para a IA generativa é explicitada por Eloundou, Manning, Mishkin e Rock (2023), que propõem uma rubrica de exposição a LLMs combinando juízo humano especializado e classificações do GPT-4 sobre o alinhamento entre tarefas e capacidades de modelos de linguagem. O desenho metodológico separa o efeito de LLMs isolados do efeito de software e ferramentas acopladas (“LLM-powered”)⁷, enfatizando que o objetivo não é prever a adoção dessas tecnologias, mas mensurar o potencial de afetação das tarefas a partir de capacidades já observáveis em geração

⁷ No estudo de Eloundou et al. (2023), “**LLM-powered software**” refere-se a aplicações que incorporam modelos de linguagem de grande escala (LLMs) como núcleo de funcionamento, mas que são acopladas a interfaces, bases de dados ou sistemas de automação complementares.

de texto e código, ampliando a granularidade das medidas de exposição no contexto da IA generativa (Eloundou et al., 2023; Casas et al., 2026).

Segundo Eloundou et al. (2023), cerca de 80% da força de trabalho dos EUA teria ao menos 10% de suas tarefas afetadas por LLMs, e aproximadamente 19% teriam $\geq 50\%$ das tarefas afetadas; com acesso direto ao LLM, cerca de 15% de todas as tarefas poderiam ser executadas significativamente mais rápido sem perda de qualidade, proporção que salta para 47–56% quando se consideram ferramentas e integrações (“LLM-powered”). Os autores concluem que LLMs exibem traços de tecnologia de uso geral, com efeitos difusos por faixas salariais e forte papel das complementaridades de software para escalar impactos. Esses resultados indicam que os impactos dos LLMs dependem criticamente do arranjo entre modelos, softwares e fluxos de trabalho, fornecendo uma base quantitativa para análises de reconfiguração de tarefas e ganhos potenciais de produtividade no contexto da IA generativa (Brynjolfsson; Li; Raymond, 2023; Filippucci et al., 2024; Johnston; Makridis, 2025).

Por fim, Gmyrek et al. (2025) dá um avanço relevante ao atualizar o índice global de exposição ocupacional à IAG em um desenho que combina amostra representativa de tarefas, survey com trabalhadores e rodadas Delphi com especialistas⁸, produzindo um repositório de conhecimento que alimenta um assistente de IA para prever pontuações no escopo do ISCO-08⁹. O resultado é um

⁸ O **desenho metodológico** do estudo de Gmyrek et al. (2025) articula três componentes complementares:

- Amostra representativa de tarefas: seleção estatisticamente balanceada de atividades ocupacionais, derivadas das classificações da *International Standard Classification of Occupations* (ISCO-08), de modo a refletir a diversidade de funções e níveis de qualificação em diferentes países.
- Survey com trabalhadores: coleta direta de dados junto a profissionais sobre o uso, a familiaridade e a percepção de impacto da IA generativa em suas tarefas cotidianas, permitindo capturar variações reais de exposição por ocupação.
- Rodadas Delphi com especialistas: técnica estruturada de consulta iterativa a especialistas (em IA, economia do trabalho e políticas públicas) utilizada para obter consenso qualificado sobre a probabilidade de determinadas tarefas serem afetadas pela IA.

⁹ **ISCO-08** (International Standard Classification of Occupations, 2008) é a classificação internacional de ocupações elaborada pela Organização Internacional do Trabalho (OIT).

índice refinado com quatro gradientes de exposição, sensível a avanços recentes da tecnologia e à maior familiaridade de uso, e comparável internacionalmente – o que possibilita diagnósticos transversais e adaptação metodológica em contextos nacionais.

As conclusões presentes no relatório de Gmyrek et al. (2025) reforçam que as ocupações clericais — de apoio administrativo e processamento de informação — permanecem entre as mais expostas, enquanto as ocupações fortemente digitalizadas ampliaram sua exposição. O estudo também evidencia que a tarefa deve constituir a unidade analítica central, e não apenas o cargo, reconhecendo a variação intra ocupacional e o papel das complementaridades que modulam os efeitos da IA sobre produtividade e emprego.

Em termos de política e de pesquisa aplicada, o índice de Gmyrek et al. (2025) representa um marco importante ao oferecer uma base global e comparável para análises de exposição ocupacional, útil para orientar prioridades de qualificação e transições no mercado de trabalho, além de servir como referência metodológica para futuras adaptações em contextos nacionais.

Encerrando este percurso conceitual, observa-se uma evolução clara nas formas de mensuração do impacto tecnológico: da ênfase no risco técnico, para a exposição mensurável, e, mais recentemente, para o mapeamento das complementaridades entre humanos e sistemas de IA generativa. Essa trajetória fundamenta o movimento da próxima seção, dedicada à metodologia, na qual se detalha o desenho empírico e as estratégias analíticas adotadas para estimar a exposição ocupacional a partir de modelos de linguagem de grande escala.

3 PROCEDIMENTOS METODOLÓGICOS

Este estudo adota uma abordagem exploratória e aplicada, com foco na construção de um índice piloto de exposição ocupacional à inteligência artificial generativa no contexto brasileiro. A proposta parte de uma abordagem centrada em tarefas, em linha com a literatura que trata a exposição tecnológica como resultado do conteúdo do trabalho, e não apenas da ocupação em sentido agregado. Em particular, Felten, Raj e Seamans (2021) constroem sua medida de exposição a partir de componentes micro do trabalho e a agregam posteriormente ao nível ocupacional, o que oferece a principal referência para a lógica adotada neste estudo.

O objetivo não é produzir uma medida definitiva para o conjunto do mercado de trabalho brasileiro, mas testar a viabilidade metodológica de um procedimento de mensuração aplicável à Classificação Brasileira de Ocupações (CBO). O índice construído deve, portanto, ser entendido como uma medida de exposição potencial a LLMs, e não como medida de automação observada, adoção efetiva ou substituição de trabalho humano. Essa distinção segue a formulação de Felten, Raj e Seamans (2021), para quem exposição não se confunde, necessariamente, com substituição, podendo também refletir complementaridade.

3.1 SELEÇÃO DAS OCUPAÇÕES E BENCHMARK COMPARATIVO

Foram selecionadas 30 ocupações para compor o projeto piloto. A seleção teve como referência ocupações presentes na literatura recente da OIT sobre exposição ocupacional à IA generativa, especialmente o índice refinado de exposição ocupacional proposto por Gmyrek et al. (2025), com o objetivo de construir um benchmark comparativo para os resultados obtidos no contexto brasileiro. Como não há correspondência perfeita entre a ISCO-08 e a CBO, a seleção foi feita por similaridade funcional e nominal entre ocupações das duas classificações, sem pretensão de equivalência estrita entre códigos ocupacionais.

A escolha das 30 ocupações buscou contemplar ocupações com baixa, média e alta exposição esperada, de modo a cobrir um gradiente amplo de conteúdos ocupacionais. Essa estratégia permite verificar se o procedimento proposto é capaz

de ordenar ocupações brasileiras de modo coerente com gradientes já identificados pela OIT, que também parte de escores em nível de tarefa para construir classificações em nível ocupacional.

3.2 EXTRAÇÃO E SELEÇÃO DAS ATIVIDADES OCUPACIONAIS

Após a definição das 30 ocupações, foram extraídas da CBO as descrições de atividades associadas a cada uma delas. Como a base da CBO não informa a importância relativa, a frequência ou o peso de cada atividade no interior da ocupação, não foi possível construir, nesta etapa, um índice ponderado por centralidade da tarefa. Diante dessa limitação, adotou-se um procedimento de amostragem aleatória simples de cinco atividades por ocupação, totalizando 150 atividades no projeto piloto.

A escolha de cinco atividades por ocupação teve caráter pragmático e exploratório. O objetivo foi captar parte da heterogeneidade do conteúdo do trabalho sem tornar a aplicação computacional excessivamente custosa.

3.3 AVALIAÇÃO DAS ATIVIDADES POR LLMS

A etapa central do procedimento consistiu na avaliação da exposição de cada atividade a modelos de linguagem de grande escala. Para isso, foi desenvolvido um prompt com instruções padronizadas para que o modelo avaliasse a atividade informada no contexto da ocupação correspondente, considerando apenas as capacidades técnicas atuais ou de curto prazo dos LLMS e desconsiderando fatores econômicos, regulatórios, institucionais e de adoção.

A estrutura do julgamento foi orientada por quatro critérios: capacidade técnica de execução, grau de padronização e codificabilidade, dependência de julgamento humano complexo e necessidade de interação humana complexa. A escolha desses critérios foi ancorada em duas referências centrais. De um lado, Frey e Osborne (2017) identificam criatividade, inteligência social e percepção/manipulação como gargalos relevantes à automatização. De outro, Eloundou et al. (2023) definem exposição em termos da capacidade de sistemas baseados em LLM de executar tarefas com redução substancial de tempo e qualidade

preservada, observando que isso se aproxima da execução da parte central da tarefa. Com base nessas referências, o protocolo adotado privilegiou a distinção entre núcleo da atividade, partes periféricas e necessidade de supervisão humana.

Cada atividade recebeu um escore ordinal de 0 a 4, em que 0 indica ausência de exposição relevante e 4 indica exposição muito alta à IA generativa baseada em linguagem. A escala foi definida para distinguir, de forma gradual, se o LLM não executa a atividade de modo útil, se executa apenas componentes periféricos, se realiza parte do processo sem executar diretamente seu núcleo, ou se executa utilmente o próprio núcleo da atividade. Na atribuição do escore, considerou-se ainda em que medida esse núcleo é padronizável e codificável, ou permanece dependente de julgamento humano complexo e de interação humana complexa.

3.4 DESENVOLVIMENTO DO PROMPT E TESTES DE ESTABILIDADE

Antes da aplicação final, foi realizada uma bateria de testes com diferentes versões de prompt, com o objetivo de reduzir ambiguidades interpretativas e aumentar a estabilidade das classificações. Ao longo desses testes, foram ajustadas as instruções, os critérios de julgamento e a formulação dos níveis da escala, até se chegar à versão final utilizada na coleta. Em particular, foram substituídos termos vagos ou excessivamente graduais por formulações mais observáveis, centradas na distinção entre núcleo da atividade, partes periféricas, necessidade de julgamento humano e necessidade de interação humana complexa.

A avaliação final foi realizada com dois modelos de linguagem distintos, claude-3-haiku-20240307 e gpt-4o-mini, e duas rodadas independentes por modelo, mantendo-se o mesmo prompt (disponível em ANEXO A – PROMPT UTILIZADO) em todas as execuções. Assim, cada atividade foi avaliada quatro vezes, o que gerou 600 avaliações no total, correspondentes a 150 atividades multiplicadas por dois modelos e duas rodadas.

Além do escore, cada avaliação retornou uma justificativa textual curta para a nota atribuída. Essas justificativas não foram usadas diretamente na construção do índice, mas serviram como apoio qualitativo para verificação de coerência das classificações.

3.5 AGREGAÇÃO DOS ESCORES E CONSTRUÇÃO DO ÍNDICE

A construção do índice ocorreu em duas etapas. Primeiro, para cada atividade, calculou-se a mediana das quatro avaliações recebidas. A mediana foi adotada como escore final da atividade por ser uma medida de tendência central mais robusta a discrepâncias entre modelos e rodadas, especialmente em uma escala ordinal curta. Segundo, para cada ocupação, calculou-se a média simples das medianas de suas cinco atividades.

Essa estratégia é consistente com a literatura recente de mensuração da exposição à IA, que constrói indicadores ocupacionais a partir da agregação de medidas em nível mais desagregado. Felten, Raj e Seamans (2021), por exemplo, agregam exposições no nível das habilidades para obter uma medida de exposição ocupacional à IA ponderando-as por sua importância e prevalência na ocupação e escalando o resultado para captar a exposição relativa. Em abordagem análoga no nível das tarefas, Colombo et al. (2024) agregam escores de tarefas para o nível ocupacional e normalizam o indicador final para fins de comparabilidade. Assim, embora a adoção da mediana como escore final da atividade constitua uma escolha metodológica deste estudo, a lógica de partir do nível da atividade e sintetizar os resultados em um índice ocupacional encontra respaldo na literatura.

Formalmente, seja $s_{oa}^{(r,m)}$ o escore atribuído à atividade a da ocupação o na rodada r pelo modelo m . O escore final da atividade foi definido como:

$$\widetilde{s}_{oa} = \text{median}\left(s_{oa}^{(1,1)}, s_{oa}^{(1,2)}, s_{oa}^{(2,1)}, s_{oa}^{(2,2)}\right) \quad (1).$$

Em seguida, o escore ocupacional bruto foi obtido pela média simples dos escores finais das cinco atividades da ocupação:

$$S_o = \frac{1}{5} \sum_{a=1}^5 \widetilde{s}_{oa} \quad (2).$$

Por fim, esse valor foi normalizado para o intervalo entre 0 e 1, por meio da divisão por 4, valor máximo da escala ordinal:

$$I_o = \frac{S_o}{4} \quad (3).$$

Desse modo, o índice final de exposição ocupacional a LLMs varia entre 0 e 1, preservando a lógica substantiva do gradiente ordinal de 0 a 4 no nível da atividade e permitindo comparabilidade sintética entre ocupações.

Além do índice final de exposição ocupacional, calculou-se também o desvio padrão dos escores finais das cinco atividades selecionadas em cada ocupação, com o objetivo de oferecer uma medida descritiva da dispersão interna dos resultados. Enquanto o índice sintetiza o nível médio de exposição potencial da ocupação a LLMs, o desvio padrão permite observar o grau de heterogeneidade entre as atividades que a compõem. Valores mais baixos indicam maior uniformidade entre os escores das atividades, ao passo que valores mais elevados sugerem maior variação interna no potencial de exposição.

4 RESULTADOS

Esta seção apresenta os resultados da aplicação piloto do índice de exposição ocupacional à inteligência artificial generativa para 30 ocupações da Classificação Brasileira de Ocupações (CBO). Como o índice foi construído a partir da agregação, em escala de 0 a 1, das avaliações atribuídas por LLMs a cinco atividades de cada ocupação, a análise a seguir privilegia sobretudo a identificação de padrões relativos de exposição e sua comparação com o benchmark ocupacional da OIT, sem pressupor equivalência estrita entre as duas medidas.

4.1 DISTRIBUIÇÃO DOS ESCORES E ORDENAMENTO DAS OCUPAÇÕES

Considerando o índice ocupacional final, os maiores escores concentraram-se em ocupações associadas a rotinas administrativas, financeiras, analíticas e intensivas em processamento de informação. Pode-se identificar na Tabela 1 que, no topo do ordenamento aparecem técnico de contabilidade (0,60), supervisor administrativo (0,50), administrador (0,475), escriturário de banco (0,475) e analista financeiro em instituições financeiras (0,475). Em seguida, também com valores relativamente elevados, figuram analista de logística, técnico de suporte ao usuário de tecnologia da informação, economista, assistente administrativo e analista de desenvolvimento de sistemas, todos com índice de 0,45. Na extremidade inferior da distribuição, os menores valores foram observados em encanador (0,275), pedreiro (0,30), advogado (0,30), técnico de enfermagem (0,325) e desenhista industrial gráfico (0,325).

O ordenamento obtido sugere uma distinção relativamente nítida entre ocupações mais ligadas à organização de informações, produção textual, análise, registro e apoio administrativo, de um lado, e ocupações mais dependentes de execução física, operação manual e intervenção técnica presencial, de outro. Em termos gerais, as primeiras tenderam a apresentar maior exposição relativa à IA generativa, enquanto as segundas se concentraram nas faixas inferiores do índice.

Tabela 1 – Ocupações da CBO e índice proposto em ordem decrescente

Ocupação	Índice 0-1	Desvio Padrão
Técnico de contabilidade	0,6	0,548
Supervisor administrativo	0,5	0,612
Administrador	0,475	0,224
Escriturário de banco	0,475	0,224
Analista financeiro (instituições financeiras)	0,475	0,224
Analista de logística	0,45	0,274
Técnico de suporte ao usuário de tecnologia da informação	0,45	0,274
Economista	0,45	0,447
Assistente administrativo	0,45	0,570
Analista de desenvolvimento de sistemas	0,45	0,758
Analista de pesquisa de mercado	0,425	0,274
Analista de planejamento e orçamento - apo	0,425	0,447
Corretor de imóveis	0,425	0,447
Jornalista	0,425	0,447
Analista de recursos humanos	0,4	0,548
Vendedor de comércio varejista	0,4	0,224
Eletricista de instalações	0,4	0,224
Cozinheiro geral	0,375	0,500
Operador de máquinas fixas, em geral	0,375	0,000
Motorista de caminhão (rotas regionais e internacionais)	0,375	0,000
Contador	0,375	0,500
Mecânico de manutenção de máquinas, em geral	0,375	0,000
Redator de publicidade	0,35	0,224
Enfermeiro	0,35	0,418
Professor de matemática no ensino médio	0,35	0,418
Desenhista industrial gráfico (designer gráfico)	0,325	0,447
Técnico de enfermagem	0,325	0,758
Advogado	0,3	0,570
Pedreiro	0,3	0,447
Encanador	0,275	0,224

Fonte: elaborado pelo autor.

Esse ordenamento está em linha com a literatura internacional recente sobre exposição ocupacional à IA generativa. Eloundou et al. (2023), por exemplo, mostram que a exposição a LLMs é positivamente associada a habilidades de escrita e programação, ao passo que tarefas manuais rotineiras e ocupações mais ligadas à robótica apresentam correlação negativa com esse tipo de exposição. De modo convergente, o estudo de Gmyrek et al. (2025) evidencia, em nível de tarefa, que atividades estruturadas, analíticas, documentais e comunicacionais tendem a apresentar maior potencial de apoio ou automação por IA generativa, enquanto tarefas que demandam manipulação física, destreza manual e intervenção presencial permanecem relativamente menos expostas.

A distribuição dos 600 escores atribuídos pelas IAs, disponibilizados em repositório público no GitHub¹⁰, também oferece evidências úteis sobre o comportamento da medida. A média geral foi de 1,61, com mediana e moda iguais a 2, em uma escala ordinal de 0 a 4. Além disso, nenhum julgamento atingiu o valor máximo da escala, o que sugere ausência de concentração em respostas extremas e indica que, mesmo nos casos de maior exposição, os modelos tenderam a adotar avaliações intermediárias.

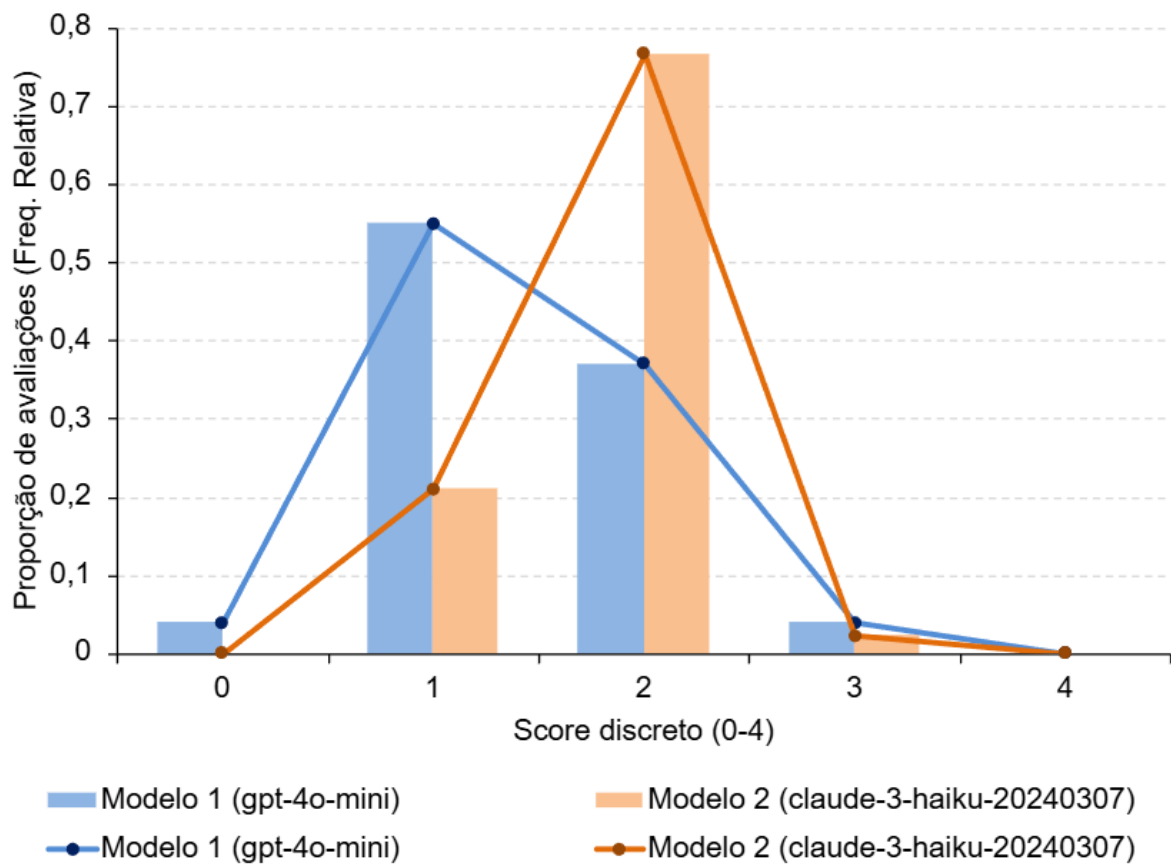
A comparação intra-modelo indica que os escores atribuídos apresentaram elevada estabilidade entre rodadas dentro de cada LLM. No Claude, a diferença absoluta média entre as duas rodadas foi de 0,013 e a correlação foi de 0,967; no GPT-4o-mini, a diferença absoluta média foi de 0,033 e a correlação foi de 0,959. Isso sugere que, para a maior parte das atividades, as rodadas 1 e 2 produziram o mesmo julgamento ou desvios muito pequenos. Ainda assim, o Claude mostrou maior consistência interna, com menor dispersão entre rodadas.

Já a comparação entre modelos revela um padrão distinto. A diferença média entre os escores foi de aproximadamente 0,40 ponto, com erro absoluto médio de 0,457, enquanto a correlação entre as médias dos modelos foi de 0,517. Em termos substantivos, isso sugere convergência apenas moderada entre as duas LLMs. Além disso, os resultados descritivos indicam que o Claude apresentou média de 1,813 e

¹⁰Repositório disponível em: https://github.com/felipefinfanfa/piloto_exposicao_ocupacional_iag. Acesso em: 18 mar. 2026.

mediana de 2,0, enquanto o GPT-4o-mini registrou média de 1,410 e mediana de 1,0. Também se observou maior dispersão no GPT-4o-mini, cuja amplitude variou de 0 a 3, ao passo que no Claude os escores oscilaram de 1 a 3. Essas observações são ilustradas na Figura 1.

Figura 1 – Distribuição dos 600 scores (0-4) emitidos pelos LLMs utilizados para avaliação.



Fonte: elaborado pelo autor.

4.2 COMPARAÇÃO COM O BENCHMARK DA OIT

A comparação entre o índice construído neste estudo e o benchmark ocupacional da OIT foi realizada em caráter exploratório, com o objetivo de verificar se o ordenamento das ocupações obtido a partir das atividades selecionadas na CBO se mostra compatível, em termos gerais, com a exposição esperada à inteligência artificial generativa sugerida pela classificação da OIT. Como os dois referenciais

foram construídos por procedimentos distintos, a análise não busca comparar magnitudes numéricas diretamente, mas observar a coerência do posicionamento relativo das ocupações.

Na proposta metodológica da OIT, as ocupações são distribuídas em um espectro ordinal de exposição à inteligência artificial generativa que parte das categorias Not Exposed e Minimal Exposure e avança por quatro gradientes crescentes de exposição (Gradient 1 a Gradient 4). Essa classificação é construída a partir da combinação entre a média dos escores das tarefas que compõem cada ocupação e a dispersão interna desses escores, de modo a captar não apenas o nível médio de exposição, mas também a heterogeneidade das tarefas ocupacionais. Assim, as categorias iniciais reúnem ocupações com baixa exposição geral, ao passo que os gradientes superiores concentram ocupações com exposição mais elevada e, em especial nos níveis mais altos, com maior consistência interna entre as tarefas avaliadas (Gmyrek et al., 2025).

De modo geral, os resultados indicam aderência substantiva entre o índice proposto e o padrão esperado a partir da OIT, como pode ser observado na Tabela 2. As ocupações que ocupam posições superiores no índice desenvolvido concentram-se, em sua maioria, nos gradientes mais altos de exposição da referência internacional, especialmente em funções administrativas, analíticas, financeiras e intensivas em processamento de informação. Em contrapartida, ocupações ligadas à execução manual, à operação física e à prestação presencial de serviços tendem a aparecer nos estratos de menor exposição esperada, aproximando-se das categorias Minimal Exposure ou Not Exposed.

Essa leitura também se sustenta quando as ocupações são observadas por gradiente da OIT. Nos grupos classificados como Gradient 2, Gradient 3 e Gradient 4, predominam ocupações que, no índice construído, aparecem relativamente acima das ocupações enquadradas como Minimal Exposure e Not Exposed. Ainda que essa ordenação não seja perfeitamente linear em todos os casos, o padrão geral é consistente com a expectativa teórica de que tarefas mais rotineiras de escritório, comunicação, registro, análise e organização da informação apresentem maior exposição à IA generativa do que tarefas fortemente dependentes de destreza manual, interação física com o ambiente ou execução presencial.

Tabela 2 – Comparação índice proposto e índice OIT

(continua)

Ocupação-CBO	Posição-CBO	Ocupação mais semelhante-OIT	Código-OIT	Gradiente Exposição-OIT	Posição-OIT
Técnico de contabilidade	1	Accounting Associate Professionals	3313	Gradient 2	11
Supervisor administrativo	2	Office Supervisors	3341	Gradient 2	15
Administrador	3	Business Services and Administration Managers Not Elsewhere Classified	1219	Gradient 2	16
Escriturário de banco	4	Bank Tellers and Related Clerks	4211	Gradient 3	3
Analista financeiro (instituições financeiras)	5	Financial Analysts	2413	Gradient 4	1
Analista de logística	6	Supply, Distribution and Related Managers	1324	Minimal Exposure	17
Técnico de suporte ao usuário de tecnologia da informação	7	Information and Communications Technology User Support Technicians	3512	Gradient 2	13
Economista	8	Economists	2631	Gradient 3	4
Assistente administrativo	9	General Office Clerks	4110	Gradient 4	2
Analista de desenvolvimento de sistemas	10	Software Developers	2512	Gradient 3	8
Analista de pesquisa de mercado	11	Advertising and Marketing Professionals	2431	Gradient 3	5
Analista de planejamento e orçamento - apo	12	Accountants	2411	Gradient 3	9
Corretor de imóveis	13	Real Estate Agents and Property Managers	3334	Minimal Exposure	20

Tabela 2 – Comparação índice proposto e índice OIT

(continua)

Ocupação-CBO	Posição-CBO	Ocupação mais semelhante-OIT	Código-OIT	Gradiente Exposição-OIT	Posição-OIT
Jornalista	14	Journalists	2642	Gradient 3	7
Analista de recursos humanos	15	Personnel and Careers Professionals	2423	Gradient 2	14
Vendedor de comércio varejista	16	Shop Sales Assistants	5223	Gradient 1	18
Eletricista de instalações	17	Building and Related Electricians	7411	Not Exposed	26
Cozinheiro geral	18	Cooks	5120	Not Exposed	27
Operador de máquinas fixas, em geral	19	Mineral and Stone Processing Plant Operators	8112	Not Exposed	25
Motorista de caminhão (rotas regionais e internacionais)	20	Heavy Truck and Lorry Drivers	8332	Minimal Exposure	23
Contador	21	Accountants	2411	Gradient 3	10
Mecânico de manutenção de máquinas, em geral	22	Agricultural and Industrial Machinery Mechanics and Repairers	7233	Not Exposed	29
Redator de publicidade	23	Advertising and Marketing Professionals	2431	Gradient 3	6
Enfermeiro	24	Nursing Professionals	2221	Not Exposed	22
Professor de matemática no ensino médio	25	Secondary Education Teachers	2330	Not Exposed	21
Desenhista industrial gráfico (designer gráfico)	26	Graphic and Multimedia Designer	2166	Gradient 2	12
Técnico de enfermagem	27	Nursing Associate Professionals	3221	Minimal Exposure	24
Advogado	28	Lawyers	2611	Minimal	19

				Exposure	
--	--	--	--	----------	--

Tabela 2 – Comparação índice proposto e índice OIT

(conclusão)

Ocupação-CBO	Posição-CBO	Ocupação mais semelhante-OIT	Código-OIT	Gradiente Exposição-OIT	Posição-OIT
Pedreiro	29	Bricklayers and Related Workers	7112	Not Exposed	30
Encanador	30	Plumbers and Pipe Fitters	7126	Not Exposed	28

Fonte: elaborado pelo autor

A comparação dos rankings reforça essa interpretação. Algumas ocupações apresentaram elevada convergência entre as duas classificações, como escriturário de banco, analista de recursos humanos e pedreiro, sugerindo que, nesses casos, o índice proposto capta de forma semelhante o nível de exposição esperado pelo benchmark da OIT. Em outros casos, surgem diferenças mais expressivas de posicionamento, como em redator de publicidade, desenhista industrial gráfico, supervisor administrativo e administrador. Essas discrepâncias (ilustradas na Figura 2) não invalidam o exercício comparativo; ao contrário, evidenciam limites esperados de uma aproximação entre medidas elaboradas com critérios distintos e dados diferentes, e sugerem que certas ocupações podem ser particularmente sensíveis à forma de seleção e agregação das tarefas.

Em conjunto, os resultados permitem afirmar que o índice proposto apresenta coerência externa satisfatória em relação ao benchmark da OIT. Mesmo sem equivalência métrica entre as duas medidas, o ordenamento obtido reproduz, em linhas gerais, a estrutura esperada de exposição ocupacional à IA generativa.

Figura 2 – Ranking das principais diferenças de posição por ocupação: posição no índice vs OIT



Fonte: elaborado pelo autor.

Os resultados obtidos nesta seção apresentam aderência substantiva à literatura internacional recente sobre exposição ocupacional à inteligência artificial generativa. Em GPTs are GPTs, Eloundou et al. (2023) mostram que a exposição tende a ser mais elevada em ocupações intensivas em linguagem, escrita, processamento de informação e apoio administrativo, além de identificarem maior incidência de exposição em diversas ocupações de maior qualificação. Esse padrão é compatível com o ordenamento encontrado neste estudo, no qual funções administrativas, analíticas, financeiras e informacionais ocupam posições relativamente superiores no índice, enquanto ocupações ligadas à execução manual e à operação física aparecem, em geral, entre as menos expostas. Também nesse sentido, Colombo et al. (2024), em *Towards the Terminator Economy*, observam que a exposição à IA está positivamente associada a habilidades cognitivas, de resolução

de problemas e de gestão, concentrando-se sobretudo em empregos de maior qualificação, o que reforça a coerência externa dos resultados aqui obtidos.

Em conjunto, essa convergência sugere que o índice proposto reproduz uma regularidade já observada na literatura recente: a IA generativa tende a afetar mais intensamente ocupações baseadas em processamento de informação, análise e produção textual, enquanto sua incidência é relativamente menor em funções marcadas pela execução física do trabalho. Assim, embora existam discrepâncias pontuais no posicionamento de algumas ocupações, o padrão geral encontrado mostra-se promissor tanto com o benchmark adotado quanto com evidências internacionais obtidas por metodologias distintas. Isso reforça a interpretação de que o índice desenvolvido capta, de forma plausível, a lógica contemporânea de exposição ocupacional à IA generativa.

5 CONCLUSÃO

À luz dos resultados apresentados, considera-se que o objetivo geral deste trabalho foi atingido, na medida em que se desenvolveu e aplicou, em caráter piloto, uma metodologia automatizada para mensurar a exposição das ocupações brasileiras à Inteligência Artificial Generativa com base na CBO e em julgamentos de modelos de linguagem. De forma consistente, os objetivos específicos também foram contemplados, incluindo a revisão da literatura, a proposição do modelo metodológico, sua aplicação empírica e a discussão de suas limitações e possibilidades de aprimoramento.

No plano empírico, desenvolveu-se e testou-se, em caráter piloto, uma metodologia automatizada para mensurar a exposição das ocupações brasileiras à Inteligência Artificial Generativa (IAG), a partir da Classificação Brasileira de Ocupações (CBO), utilizando julgamentos de modelos de linguagem (LLMs). Para isso, buscou-se articular uma revisão metodológica da literatura sobre automação, exposição ocupacional e inteligência artificial, com a construção de um procedimento aplicado ao contexto brasileiro, orientado pela seleção de atividades ocupacionais e por sua posterior avaliação em escala padronizada.

Os resultados obtidos sugerem que o procedimento proposto foi capaz de produzir um ordenamento ocupacional substantivamente plausível. Em linhas gerais, ocupações mais associadas a rotinas administrativas, financeiras, analíticas e intensivas em processamento de informação apresentaram níveis relativamente mais elevados de exposição, ao passo que ocupações marcadas por execução física, operação manual e intervenção técnica presencial tenderam a registrar valores mais baixos. Esse padrão mostrou-se compatível com a expectativa teórica de que ferramentas de IA generativa incidam com maior intensidade sobre tarefas codificáveis, textuais e informacionais.

A análise também indicou elevada estabilidade das avaliações entre rodadas dentro de um mesmo modelo, ao mesmo tempo em que revelou diferenças sistemáticas entre os modelos utilizados. Esse resultado recomenda cautela na leitura dos valores absolutos do índice, mas não compromete sua utilidade como instrumento exploratório de ordenamento relativo entre ocupações. De modo semelhante, a

comparação com o benchmark da OIT forneceu evidência favorável de coerência externa, na medida em que o índice desenvolvido reproduziu, em termos gerais, a distinção entre ocupações mais e menos expostas observada na referência internacional.

Esses achados devem, contudo, ser interpretados com cautela. O índice foi construído com base em apenas cinco atividades por ocupação, o que implica uma aproximação simplificada do conteúdo do trabalho. Além disso, a ausência de ponderação entre tarefas atribui o mesmo peso a atividades potencialmente muito distintas em relevância ocupacional. Como os escores foram atribuídos por LLMs, também permanece a possibilidade de vieses decorrentes de descrições parciais ou pouco contextualizadas das atividades. Por fim, a exposição estimada à IA generativa não equivale à sua adoção efetiva nem a efeitos observáveis imediatos no mercado de trabalho, já que sua incidência prática depende de fatores técnicos, organizacionais e institucionais que condicionam seu uso concreto (MASSENKOFF; McCRORY, 2026).

Ainda assim, essas limitações não anulam a contribuição do estudo. Ao contrário, reforçam seu caráter de teste metodológico aplicado a um tema em rápida transformação e ainda em consolidação na literatura. Nesse sentido, o trabalho contribui ao propor uma estratégia replicável, transparente e adaptável para mensurar exposição ocupacional à IA generativa no Brasil, oferecendo uma aproximação inicial para desenvolvimentos futuros. Entre os desdobramentos possíveis, destacam-se a ampliação do número de atividades por ocupação, o desenvolvimento de critérios de ponderação entre tarefas, o aprimoramento dos prompts de avaliação e a incorporação de formas adicionais de validação externa.

Em síntese, os resultados indicam que a metodologia testada permite uma aproximação exploratória das diferenças entre ocupações brasileiras quanto à exposição potencial à inteligência artificial generativa. O estudo não pretende oferecer uma medida definitiva, mas apenas examinar a viabilidade de construir, com base na CBO e com apoio de LLMs, um indicador inicial sensível ao conteúdo das tarefas e, em termos gerais, compatível com referências internacionais. Em um campo ainda marcado por incertezas conceituais e rápidas mudanças tecnológicas, os achados

devem ser lidos como evidência preliminar e como apoio modesto à agenda de pesquisa sobre inteligência artificial e mercado de trabalho no Brasil.

Como agenda para pesquisas futuras, seria relevante avançar no refinamento da mensuração do conteúdo efetivo das ocupações. Uma primeira frente consiste em desenvolver formas de atribuir pesos diferenciados às tarefas, de modo a aproximar o índice da importância relativa de cada atividade no interior de uma mesma ocupação, superando a limitação imposta pela ausência dessa informação na CBO. Também seria desejável analisar o conjunto total de tarefas por ocupação, reduzindo o risco de que a seleção de apenas cinco atividades produza uma representação parcial do trabalho desempenhado. Em paralelo, estudos posteriores podem explorar estratégias de enriquecimento das descrições ocupacionais, seja por meio da combinação da CBO com outras bases de dados, seja pela utilização de fontes complementares que permitam maior detalhamento das rotinas de trabalho, tornando as avaliações mais sensíveis à heterogeneidade intrínseca das ocupações.

Outra frente observável diz respeito ao próprio procedimento de avaliação por modelos de linguagem. Pesquisas futuras podem comparar sistematicamente diferentes modelos, prompts e protocolos de validação, buscando reduzir a sensibilidade dos resultados à formulação da instrução e às discrepâncias observadas entre modelos. Além disso, seria importante investigar formas de mitigar o possível viés de autoavaliação quando a própria LLM é utilizada para julgar sua capacidade técnica, por exemplo mediante validação cruzada com especialistas humanos. Por fim, trabalhos futuros podem aproximar a noção de exposição potencial de evidências empíricas de adoção e uso efetivo da IA generativa nas ocupações, distinguindo de forma mais precisa a capacidade técnica teórica da incidência observada no mundo do trabalho. Esse avanço permitiria conectar de maneira mais robusta a mensuração proposta aos efeitos concretos da difusão da inteligência artificial sobre a estrutura ocupacional brasileira.

REFERÊNCIAS

ACEMOGLU, Daron; RESTREPO, Pascual. Automation and new tasks: how technology displaces and reinstates labor. *Journal of Economic Perspectives*, v. 33, n. 2, p. 3-30, 2019.

ADAMCZYK, Willian Boschetti; MONASTERIO, Leonardo; FOCHEZATTO, Adelar. Automação e ocupações no Brasil: novas estimativas. In: **ENCONTRO NACIONAL DE ECONOMIA**, 48., 2020, Brasília. *Anais [...]* Brasília: ANPEC, 2020.

BRYNJOLFSSON, Erik; LI, Danielle; RAYMOND, Lindsey R. Generative AI at work. *NBER Working Paper Series*, Working Paper 31161. Cambridge, MA: National Bureau of Economic Research, 2023. Disponível em: https://www.nber.org/system/files/working_papers/w31161/w31161.pdf. Acesso em: 27 mar. 2026.

CASAS, Pablo; FERNÁNDEZ-MACÍAS, Enrique; MARTÍNEZ-PLUMED, Fernando; GÓMEZ, Emilia; GONZÁLEZ-VÁZQUEZ, Ignacio; SALOTTI, Simone. Revisiting the occupational impact of AI in the generative AI era. *JRC Working Papers Series on Labour, Education and Technology*, 2026/02. Luxembourg: European Commission, 2026. Disponível em: <https://publications.jrc.ec.europa.eu/repository/handle/JRC145832>. Acesso em: 27 mar. 2026.

CHEN, Qin; GE, Jinfeng; XIE, Huaqing; XU, Xingcheng; YANG, Yanqing. Large language models at work in China's labor market. *China Economic Review*, v. 92, 102413, 2025. DOI: 10.1016/j.chieco.2025.102413. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S1043951X25000719>. Acesso em: 27 mar. 2026.

COLOMBO, Emilio; MERCORIO, Fabio; MEZZANZANICA, Mario; SERINO, Antonio. Towards the Terminator Economy: assessing job exposure to AI through LLMs. *arXiv*, 2024. Disponível em: <https://arxiv.org/abs/2407.19204>. Acesso em: 19 mar. 2026.

ELOUNDOU, Tyna; MANNING, Sam; MISHKIN, Pamela; ROCK, Daniel. GPTs are GPTs: an early look at the labor market impact potential of large language models. *arXiv*, 2023. Disponível em: <https://arxiv.org/abs/2303.10130>. Acesso em: 19 mar. 2026.

FANFA, Felipe Fin. *Piloto Exposição Ocupacional*. GitHub, 2026. Disponível em: https://github.com/felipefinfanfa/piloto_exposicao_ocupacional_iag. Acesso em: 18 mar. 2026.

FELTEN, Edward; RAJ, Manav; SEAMANS, Robert. Occupational, industry, and geographic exposure to artificial intelligence: a novel dataset and its potential uses. *Strategic Management Journal*, v. 42, n. 12, p. 2195-2217, 2021.

FILIPPUCCI, Francesco et al. The impact of artificial intelligence on productivity, distribution and growth: key mechanisms, initial evidence and policy challenges.

OECD *Artificial Intelligence Papers*, n. 15. Paris: OECD Publishing, 2024. DOI: 10.1787/8d900037-en. Disponível em: https://www.oecd.org/en/publications/the-impact-of-artificial-intelligence-on-productivity-distribution-and-growth_8d900037-en.html. Acesso em: 27 mar. 2026.

FREY, Carl Benedikt; OSBORNE, Michael A. *The future of employment: how susceptible are jobs to computerisation?* Oxford: Oxford Martin School, 2013. Disponível em: https://www.oxfordmartin.ox.ac.uk/downloads/academic/The_Future_of_Employment.pdf. Acesso em: 19 mar. 2026.

FREY, Carl Benedikt; OSBORNE, Michael A. *The future of employment: how susceptible are jobs to computerisation? Technological Forecasting and Social Change*, v. 114, p. 254-280, 2017.

GMYREK, Paweł; BERG, Janine; KAMIŃSKI, Karol; KONOPCZYŃSKI, Filip; ŁADNA, Agnieszka; NAFRADI, Balint; ROSŁANIEC, Konrad; TROSZYŃSKI, Marek. Generative AI and jobs: a refined global index of occupational exposure. *ILO Working Paper*, n. 140. Geneva: International Labour Office, 2025. Disponível em: https://www.ilo.org/sites/default/files/2025-05/WP140_web.pdf. Acesso em: 19 mar. 2026.

HUANG, Xianguo. Labor market exposure to AI: from GenAI to future AGI. *AMRO Working Paper*, WP/25-12. Singapore: ASEAN+3 Macroeconomic Research Office, 2025. Disponível em: https://amro-asia.org/wp-content/uploads/2025/11/GenAI_Labour_Huang2025_20251107.pdf. Acesso em: 27 mar. 2026.

JOHNSTON, Andrew C.; MAKRIDIS, Christos. The labor market effects of generative AI: a difference-in-differences analysis of AI exposure. SSRN, 2025. DOI: 10.2139/ssrn.5375017. Disponível em: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=5375017. Acesso em: 27 mar. 2026.

MANGONI, Giovanna Karla. *Cocriação Humano-IA: o uso prático da IA generativa na rotina de gestores*. Florianópolis, 2025. Trabalho de Conclusão de Curso (Bacharelado em Administração) - Universidade Federal de Santa Catarina, Centro Socioeconômico, Curso de Administração, Florianópolis, 2025. Disponível em: <https://repositorio.ufsc.br/handle/123456789/266613>. Acesso em: 19 mar. 2026.

MASSENKOFF, Maxim; McCRORY, Peter. Labor market impacts of AI: a new measure and early evidence. [S. l.]: Anthropic, 2026. Disponível em: <https://www.anthropic.com/research/labor-market-impacts>. Acesso em: 19 mar. 2026.

SCHUMPETER, Joseph A. *Capitalismo, socialismo e democracia*. Rio de Janeiro: Fundo de Cultura, 1961.

ANEXO A – PROMPT UTILIZADO

"" Avalie a exposição da atividade abaixo à Inteligência Artificial generativa baseada em linguagem (LLMs).

REGRAS DE AVALIAÇÃO

- Considere apenas as capacidades técnicas atuais ou de curto prazo dos LLMs.
- Ignore fatores econômicos, regulatórios, institucionais, organizacionais e de adoção.
- Avalie apenas a atividade informada, no contexto da ocupação.
- Não avalie a ocupação inteira.
- Interprete a atividade em seu sentido mais típico e literal dentro da ocupação.

Contexto ocupacional:

{ocupacao}

Atividade:

{atividade}

CRITÉRIOS DE JULGAMENTO

1. Capacidade técnica de execução

Verifique se o LLM consegue executar a atividade de forma útil, integralmente ou em parte.

2. Padronização e codificabilidade

Verifique se a atividade pode ser descrita por instruções claras, replicáveis e baseadas em regras.

3. Dependência de julgamento humano complexo

Verifique se a atividade exige interpretação ambígua, discernimento subjetivo, criatividade ou decisão contextual não padronizada.

4. Necessidade de interação humana complexa

Verifique se a atividade exige negociação, persuasão, empatia, mediação, coordenação interpessoal ou contato humano como núcleo da ação.

REGRAS DE AVALIAÇÃO

1. Identifique primeiro o núcleo da atividade: a ação principal que define seu objetivo imediato no contexto da ocupação.

2. Identifique separadamente a parte periférica: apoio, preparação, organização, registro, busca de informação, síntese, documentação ou estruturação textual.
3. Avalie se o LLM executa de forma útil o núcleo da atividade.
4. Avalie se o LLM executa apenas alguma parte periférica da atividade.
5. Avalie se o núcleo depende de julgamento humano complexo.
6. Avalie se o núcleo depende de interação humana complexa.

ESCALA (0–4)

NÍVEL 0 - NÃO EXPOSTA

Use 0 quando:

- o LLM não executa a atividade de modo útil;
- a atividade não pode ser reduzida a instruções claras, estáveis e repetíveis;
- o núcleo da atividade exige julgamento humano contextual, tácito ou situado;
- o núcleo da atividade exige interação humana complexa, presença social ou percepção/manipulação do mundo físico.

NÍVEL 1 - EXPOSIÇÃO BAIXA

Use 1 quando:

- o LLM executa apenas partes periféricas ou preparatórias da atividade de forma útil;
- a atividade contém alguns elementos descritíveis, mas o núcleo não pode ser totalmente descrito por regras ou instruções;
- o núcleo da atividade exige julgamento humano para definir, interpretar ou decidir o resultado;
- a interação humana complexa ou o contexto situacional continuam sendo necessários para o núcleo da atividade.

NÍVEL 2 - EXPOSIÇÃO MODERADA

Use 2 quando:

- o LLM executa de forma útil parte do processo, mas não executa diretamente o núcleo da atividade;

- a atividade combina etapas que podem ser descritas por instruções com etapas que exigem contexto, integração ou interpretação;
- o núcleo da atividade exige julgamento humano para orientar, validar ou decidir o resultado;
- a interação humana complexa ou a adaptação ao contexto continuam sendo necessárias para o núcleo da atividade.

NÍVEL 3 - EXPOSIÇÃO ALTA

Use 3 quando:

- o LLM executa de forma útil o núcleo da atividade;
- a atividade pode ser descrita por instruções claras, repetíveis e baseadas em informação;
- o julgamento humano aparece principalmente como revisão, validação, supervisão ou decisão final;
- a interação humana não constitui o núcleo da atividade, embora ainda possa ser relevante em etapas específicas.

NÍVEL 4 - EXPOSIÇÃO MUITO ALTA

Use 4 quando:

- o LLM executa de forma útil a maior parte ou praticamente todo o núcleo da atividade;
- a atividade é padronizada, textual, informacional, classificatória ou baseada em regras claras e estáveis;
- o julgamento humano é limitado, acessório ou não decisivo para a execução;
- a interação humana é pouco necessária e não altera de forma decisiva o resultado.

FORMATO DE SAÍDA

Responda em exatamente duas linhas:

Linha 1: número inteiro de 0 a 4

Linha 2: justificativa curta, com no máximo 12 palavras""