

AUTOMAÇÃO E OCUPAÇÕES NO BRASIL: novas estimativas

Willian Boschetti Adamczyk¹

Leonardo Monasterio²

Adelar Fochezatto³

Resumo

Qual o efeito da automação no futuro das ocupações do setor privado no Brasil? Este estudo investiga as ocupações mais suscetíveis à automação com base em algoritmos de aprendizado de máquina e de processamento natural de linguagem. Inova-se ao aplicar um método objetivo para estimação de propensão à automação chamado *Bartik Occupational Tasks* – BOT, que evita o uso de classificações subjetivas ou *ad hoc*, como faz a literatura sobre o tema. Analisa-se 2.627 ocupações de 31,5 milhões de trabalhadores formais em tempo integral na base de dados da RAIS de 2018. Cerca de 11% dos trabalhadores brasileiros encontram-se nas ocupações de mais alta propensão à automação, e 45% até média-alta automação. Ocupações com menores níveis médios de escolaridade e menores remunerações são as mais propensas à automação. Na agropecuária, 79% dos trabalhadores formais são potencialmente automatizáveis, 68% no setor industrial e 33% no setor de serviços.

Palavras-chave: Automação; Mercado de trabalho; Aprendizado de máquina.

Abstract

What is the impact of automation on the future of private sector occupations in Brazil? Using machine learning and natural language processing algorithms, this study investigates the occupations' susceptibility to automation. We apply *Bartik Occupational Tasks* – BOT, an objective method to identify automation, avoiding subjective or *ad hoc* assessments. To that end, we analyze 2.627 occupations of 31,5 million fulltime workers in RAIS 2018 dataset. Around 11% of Brazilian workers find themselves in occupations with high susceptibility to automation, and 45% in high and middle-high automation. Occupations with lower levels of schooling and wages are most susceptible to automation. Automation can impact 79% of formal agricultural workers, 68% of industrial workers and 33% in the service sector.

Keywords: Automation; Job market; Machine Learning.

JEL: J24 - Human Capital • Skills • Occupational Choice • Labor Productivity.

Área temática: Área 13 – Economia do Trabalho.

¹ Doutorando em Economia no Programa de Pós-Graduação em Economia da Pontifícia Universidade Católica do Rio Grande do Sul – PPGE/PUCRS. O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001. E-mail: willianadamczyk@yahoo.com.br.

² Coordenador-geral de Ciência de Dados (ENAP) e professor do programa de pós-graduação em Economia do IDP-DF.

³ Doutor em Economia e Professor no Programa de Pós-Graduação em Economia – PPGE/PUCRS. Pesquisador no Conselho Nacional de Desenvolvimento Científico e Tecnológico - CNPq.

1 INTRODUÇÃO

As tecnologias de inteligência artificial e automação estão no centro de uma mudança de nos processos produtivos e no mercado de trabalho mundial. Já é consensual que essas novas tecnologias permitirão expressivos aumentos de produtividade e redução de custos (BRYNJOLFSSON; MCAFEE, 2014; WEF, 2016; FREY; OSBORNE, 2017).

A inovação tecnológica traz ganhos substanciais no longo prazo, mas, em períodos mais breves, as novas técnicas de automação impactar o desemprego. Nesse contexto, os bens de capital competem com o trabalho humano. Tensões sociais podem emergir com a eliminação de empregos por meio da substituição de trabalhadores por máquinas. Não há garantias de que novas ocupações serão repostas no mesmo ritmo em que são substituídas (GOLDIN; KATZ, 1998; AUTOR, 2015).

Dessa forma, a identificação das ocupações mais suscetíveis à automação pretende guiar a elaboração de políticas públicas com a finalidade de suavizar o processo de transição. Governos, empresas e universidades são responsáveis por desenvolver as habilidades e competências adequadas para uma força do trabalho do futuro que bem aproveite todo potencial humano e tecnológico.

As discussões acerca das consequências da automação têm crescido em popularidade após 2015, mas ainda contam com literatura incipiente no Brasil. Em geral, os estudos internacionais de previsão de ocupações automatizáveis (FREY; OSBORNE, 2017; ARNTZ; GREGORY; ZIERAHN, 2016, 2017) e estudos nacionais (ALBUQUERQUE *et al.*, 2019; KUBOTA; MACIENTE, 2019) baseiam-se na opinião de especialistas para classificar ocupações ou tarefas.

Este trabalho revisita o método *Bartik Occupational Tasks* (BOT), introduzido em Adamczyk, Monasterio e Fochezatto (2020), “Impacto da Automação no Futuro do Emprego do Setor Público: uma aplicação ao Executivo Federal brasileiro”, em uma aplicação ao mercado de trabalho privado no Brasil. O método BOT permite uma estimativa objetiva da trajetória ocupacional a partir de informações observadas no mercado de trabalho. Para isto, são construídos algoritmos preditivos de propensão à automação usando técnicas de *Natural Language Processing* e de *Machine Learning* para extrair informações quantitativas a partir dos textos que descrevem as tarefas de cada uma das 2.627 ocupações da CBO.

A fim de identificar o efeito da automação sobre as ocupações no mercado de trabalho brasileiro, os resultados da aplicação desta metodologia mostram que 11,3% dos trabalhadores desempenham ocupações classificadas em alta propensão à automação e 44,8% em situação de alta e média-alta propensão. Estima-se que nas próximas décadas a automação possa afetar 7 milhões de empregos no setor de serviços, 6 milhões na indústria e 1 milhão na agropecuária. Em geral, as ocupações mais propensas à automação são aquelas com menores níveis de escolaridade e remuneração.

Após essa introdução (1), faz-se a revisão da literatura (2), apresenta-se a metodologia e as fontes de dados (3). Na seção de resultados (4) estima-se a fronteira tecnológica, o efeito da automação sobre as ocupações do mercado de trabalho brasileiro e, apresentam-se as seções de discussão dos resultados (6) e considerações finais (7).

2 AUTOMAÇÃO E EMPREGO: UMA REVISÃO DA LITERATURA

2.1 TECNOLOGIAS E ESTUDOS DE AUTOMAÇÃO

Tecnologias de computerização e de inteligência artificial (IA) fomentam uma mudança de patamar tecnológico nos processos produtivos e no mercado de trabalho (BRYNJOLFSSON; MCAFEE, 2014; FREY; OSBORNE, 2017). A literatura de desemprego tecnológico oferece evidências de que a introdução de novas tecnologias de informação viabiliza automatizar tarefas executadas por trabalhadores (GOLDIN; KATZ, 1998; ACEMOGLU; AUTOR, 2011; FIRPO, FORTIN; LEMIEUX, 2011). Tais tecnologias oferecem vantagens por serem facilmente escaláveis, com alto poder de redução de custos e ganhos de eficiência produtiva (AUTOR, 2015; FREY; OSBORNE, 2017; WEF, 2016).

Pesquisas recentes trazem resultados conflitantes para a magnitude do impacto da automação na eliminação de postos de trabalho. As discordâncias podem ser contrastadas pela metodologia empregada

na estimação: *automação com base em ocupações* (FREY; OSBORNE, 2017) ou *automação com base em tarefas* (ARNTZ; GREGORY; ZIERAHN, 2016, 2017).

A *automação com base em ocupações* busca encontrar as profissões que tendem a desaparecer nas próximas décadas e o impacto do desemprego tecnológico sobre salários, desigualdade e polarização da renda. Nessa abordagem, Frey e Osborne (2017) e a pesquisa da McKinsey Global Institute (2017) estimaram que cerca de 47% dos empregos dos Estados Unidos possuem elevado risco de desaparecer em três décadas devido à automação.

A metodologia aplicada por Frey e Osborne (2017) atribuiu probabilidades de automatização das tarefas de cada profissão de acordo com a identificação dos gargalos tecnológicos (*bottlenecks*), realizando a classificação das atividades em baixo e alto risco. A fim de desenvolver os modelos preditivos, Frey e Osborne (2017) estimaram possíveis resultados de automação com base na opinião de um grupo de especialistas em aprendizado de máquina. As 70 ocupações em que os autores confiavam que todas as tarefas poderiam ser automatizáveis foram manualmente classificadas, servindo como informações para treinar o modelo. A partir desse treinamento, os autores inferiram as probabilidades de automatização para as demais 900 profissões da *Standard Occupational Classification* (SOC),

Em estudos para o mercado de trabalho formal brasileiro, Albuquerque *et al.* (2019) adaptaram a metodologia de Frey e Osborne (2017) confiando na avaliação de automação de 69 especialistas em inteligência artificial. Estimaram assim que 54,5% dos 45,9 milhões de postos de trabalho encontram-se em ocupações com alta ou muito alta probabilidade de automação. Com probabilidade alta foram consideradas as ocupações no terceiro quartil, enquanto muito alta as que se encontraram no quartil superior da distribuição da probabilidade de automação.

Críticas ao elevado percentual de trabalhadores em ocupações em alto risco de automação surgiram na literatura. Primeiro, Arntz, Gregory e Zierahn (2016) apontaram que a estimação com base em ocupações oferece superestimações de automação, pois mesmo naqueles empregos considerados de alto risco, trabalhadores podem realizar tarefas que são de difícil automação. O impacto da automação é heterogêneo e parcial sobre as ocupações, que são passíveis de serem remodeladas e assumirem um novo caráter, qualificação e denominação. Em segundo lugar, a classificação subjetiva pode incorrer em confusão entre o potencial para automação e as perdas no nível de emprego nas ocupações. Por vezes, a automação pode ser factível de um ponto de vista tecnológico, mas não ser economicamente viável (ARNTZ; GREGORY; ZIERAHN, 2016).

Como alternativa, Arntz, Gregory e Zierahn (2016, 2017) propuseram a estimação da probabilidade de automação *com base em tarefas* que compõe cada ocupação, em nível mais desagregado, o que permite incorporar heterogeneidades entre trabalhadores. Por essa abordagem, Arntz, Gregory e Zierahn (2016) estimaram que, na média dos países desenvolvidos selecionados, apenas 9% dos trabalhadores estão em ocupações com alto risco de desaparecer nas próximas duas décadas.

No contexto brasileiro, Kubota e Maciente (2019) estimaram que cerca de 56,5% dos empregos formais no país possuem ocupações vulneráveis à automação, considerando tecnologias consolidadas e passíveis de implementação dentro do marco regulatório em um prazo de cinco anos. Usando 19 mil tarefas descritas na base O*NET, Kubota e Maciente (2019) realizaram a construção de um dicionário de palavras-chave associadas à automação com base na classificação de atividades por seus requisitos de rotina e cognição propostos para a Alemanha em Spitz-Oener (2006).

Em comparação com os países desenvolvidos, a maior parte da mão-de-obra das ocupações brasileiras se encontra em atividades intensivas em habilidades rotineiras e de baixo nível cognitivo (ALBUQUERQUE *et al.*, 2019; MACIENTE; RAUEN; KUBOTA, 2019). A literatura indica que tarefas rotineiras de operação e controle e as dependentes de aptidões físicas tendem a perder espaço no mercado de trabalho frente as de maior qualificação.

2.2 EFEITOS DA AUTOMAÇÃO SOBRE O MERCADO DE TRABALHO

A classificação das tarefas ocupacionais de Autor, Levy e Murnane (2003) ajuda a compreender os efeitos da automação a partir de características das tarefas que definem cada ocupação. As ocupações são

formadas a partir de uma combinação de tarefas que variam em intensidade cognitiva, manual e rotineira. Tarefas cognitivas requerem elevado nível educacional com capacidade analítica para lidar com problemas abstratos. Tarefas manuais são desempenhadas por meio de interações pessoais, necessitando de reconhecimento visual, de linguagem e adaptação a diferentes situações. Ainda, tanto as tarefas cognitivas quanto manuais podem ser classificadas como rotineiras ou não-rotineiras. Tarefas rotineiras são executadas de maneira repetitiva em ambientes estruturados, com baixo nível de improvisação. Autor (2015) destaca que as tarefas rotineiras são mais fáceis de serem codificadas e, portanto, automatizáveis. Por outro lado, tarefas cognitivas e manuais não-rotineiras apresentam maior resistência à automação.

Assim, o avanço da automação sobre as tarefas rotineiras pode impactar o mercado de trabalho por meio do aumento da desigualdade e polarização dos rendimentos do emprego. Autor (2015) mostra que a tradução dos efeitos da automação sobre a polarização de rendimentos depende da interação entre três forças de mercado: *complementaridade, elasticidade da demanda e oferta de trabalho*.

A complementaridade aumenta a produtividade de trabalhadores em ocupações que se beneficiam da interação com tecnologias de automação. Um médico, por exemplo, pode se utilizar de tecnologias de inteligência artificial que, a partir de um conjunto de sintomas, aponte para hipóteses diagnósticas cada vez mais precisas (LOBO, 2017). O estudo seminal de Tinbergen (1964) mostra que o progresso tecnológico complementa e eleva a demanda por trabalhadores mais educados. Por sua vez, a demanda por serviços médicos é inelástica, já que, em caso de necessidade, o paciente não encontra substitutos próximos. Ainda, a oferta de médicos é considerada inelástica. O tempo e o nível de qualificação necessários para a formação dificultam a entrada de novos profissionais nesse mercado. Forças semelhantes podem ser vistas sobre ocupações de juristas, finanças, engenharia, pesquisa e design (AUTOR, 2015). Assim, cria-se um ciclo de reforço gerando aumentos nos ganhos salariais de profissionais que desfrutam de complementaridades e inelasticidade de oferta e demanda. A regulamentação e responsabilidades legais também desempenham papéis para a importância dessas profissões (AUTOR, 2015).

Por outro lado, ocupações na parte de baixo da distribuição de salários, mesmo sendo menos sujeitas à automação, podem sofrer efeitos de compressão nos rendimentos. Ocupações intensivas em tarefas manuais, que não envolvem rotinas, são mais difíceis de terem seus procedimentos codificados (FREY; OSBORNE, 2017). Exemplos podem ser vistos nas ocupações de zeladores, faxineiros, motoristas, atendentes dos serviços de alimentação e saúde. O menor rendimento dessas profissões pode não justificar os custos da implementação de tecnologias de automação. Com baixas barreiras de qualificação, trabalhadores deslocados de ocupações codificáveis podem desempenhar essas ocupações, tornando a sua oferta mais elástica e diminuindo os seus ganhos.

No Brasil, Sulzbach (2020) observa um aumento no retorno salarial de tarefas cognitivas e tarefas manuais entre 2002 e 2014. O retorno de tarefas rotineiras não acompanhou o aumento das demais no mesmo período. Mensurando o preço das tarefas em cada ocupação, Sulzbach (2020) conclui que existe um processo de polarização do emprego e dos rendimentos no país, em linha com as tendências internacionais. Detoni, Freguglia e Corseuil (2020) também encontraram retornos salariais crescentes para ocupações intensivas em tarefas não rotineiras, analíticas e interativas, com perdas salariais em ocupações rotineiras.

No longo prazo, as forças de polarização podem ceder lugar a um aumento persistente da desigualdade de renda. Além da globalização do comércio e produção, as tecnologias de informação são centrais para o aumento da desigualdade. Autor *et. al* (2020) expõe a concentração de mercado em empresas *superstars* (como Alphabet, Amazon e Facebook) que auferem maiores margens de lucro, reduzindo a parcela dos salários destinados aos trabalhadores. Contrariando o fato estilizado de estabilidade na parcela de salários (KALDOR, 1961), Autor *et. al* (2020) mostram a queda da participação dos salários na renda nacional para os países da OCDE a partir da década de 1980. Piketty (2014) aponta o aumento do retorno do capital em relação ao trabalho como um dos principais elementos de concentração de renda no longo prazo.

Por fim, considera-se que as tarefas rotineiras não são as únicas automatizáveis. Inovações tecnológicas progressivamente avançam na substituição das tarefas mais simples até as mais abstratas, em uma questão de décadas (FREY; OSBORNE, 2017). Nesse contexto, considera-se que uma profissão tende

a ser eliminada quando grande parte de suas atividades são substituídas. Assim, a profissão transforma-se em outra, agregando diferentes tarefas sob uma nova denominação. Segundo Autor (2015), a história registra pensadores influentes superestimando o potencial de substituição do trabalho humano, enquanto minimizavam o potencial de complementaridade e necessidade de novas ocupações. Identificar as oportunidades de novas ocupações a partir da automação é tarefa não trivial e ainda não possui literatura e metodologia consolidadas.

Nesse contexto, visando contribuir para o debate sobre o tema, a seção seguinte apresenta a construção de algoritmos preditivos da propensão à automação com uma abordagem empírica, sem o uso de classificações *ad hoc*. A partir das estimativas de propensão à automação é possível realizar a análise quantitativa por setores da economia, mostrando um perfil detalhado dos potenciais efeitos das tecnologias de automação sobre o mercado de trabalho brasileiro.

3 METODOLOGIA

3.1 ESTIMAÇÃO DA FRONTEIRA TECNOLÓGICA DE AUTOMAÇÃO

O estudo realiza uma nova aplicação da metodologia *Bartik Occupational Tasks*⁴ (BOT) discutida em detalhes em Adamczyk, Monasterio e Fochezatto (2020). O BOT representa um método objetivo para estimação da fronteira tecnológica com o intuito de obter as tendências de automação no mercado de trabalho nacional. Esta fronteira será construída para o Estado de São Paulo, por ser o maior e mais vibrante centro econômico do país e, por suposição, o local onde as mudanças tecnológicas são implementadas primeiro, difundindo-se posteriormente para outros locais do país. Essa fronteira representa o efeito diferencial de alterações na distribuição dos empregos entre as ocupações após remover os efeitos de crescimento total e crescimento de cada um dos setores. A mudança na composição dos empregos dentro dos setores é atribuída às alterações nas tecnologias de produção, ao reestruturar as relações de substituição (ou complementaridade) entre capital e trabalho, decorrentes da introdução de tecnologias de automação.

Assim, a fronteira tecnológica é calculada para o período entre 2010 e 2018. Com as estimativas de automação para a fronteira tecnológica, parte-se para a atribuição das mudanças às tarefas das ocupações e à generalização para as demais ocupações. Em resumo, a RAIS de São Paulo é usada para encontrar o efeito diferencial por meio da modificação ocupacional do método *Shift-Share*, enquanto que a Matriz de Atividades da CBO passa pela análise TF-IDF. Os resultados de efeito diferencial e TF-IDF se unem para a classificação com o método BOT, que tem sua construção detalhada na próxima seção. O modelo é então usado para encontrar o efeito da automação sobre as ocupações na RAIS.

3.2 PREDIÇÃO DA PROPENSÃO À AUTOMAÇÃO

O objetivo não é estimar o impacto da automação diretamente sobre as ocupações, mas sim, nas tarefas envolvidas em cada uma das ocupações. Para isso, utiliza-se os resultados da etapa anterior para a construção do *Bartik Occupational Tasks* (BOT), método que tem o objetivo de realizar a predição da propensão à automação com base nas tarefas de cada ocupação.

Para obter a informação das tarefas inerentes a cada ocupação utilizou-se a Matriz de Atividades da CBO 2002. A matriz de atividades mostra as tarefas envolvidas em cada ocupação. Por exemplo, a ocupação Administrador (252105) traz as atividades “Administrar organizações”, “Elaborar planejamento organizacional”, “Implementar programas e projetos”, entre outras.

Algoritmos de *Natural Language Processing* (NLP) permitem ponderar os termos das atividades que constituem cada ocupação e identificar a sua contribuição para o efeito diferencial de automação estimado na etapa anterior. Com isso, pôde-se generalizar a propensão à automação para as demais

⁴ Por limitações de espaço, remete-se o leitor interessado nos detalhes da construção do BOT para Adamczyk, Monasterio e Fochezatto (2020), “Impacto da Automação no Futuro do Emprego do Setor Público: uma aplicação ao Executivo Federal brasileiro”.

ocupações com base no peso relativo das tarefas. Para identificar o peso relativo das tarefas emprega-se a técnica *Term Frequency–Inverse Document Frequency* (TF-IDF). O valor do TF-IDF aumenta proporcionalmente à frequência em que uma palavra aparece em um extrato de texto em relação ao número de textos que contém essa palavra. Na formulação de Ramos (2003), dada uma coleção de documentos D , um termo w , e um documento único $d \in D$, calcula-se:

$$w_d = f_{w,d} * \log(|D| / f_{w,D}) \quad (2)$$

em que $f_{w,d}$ é o número de vezes que w aparece em d , $|D|$ é o tamanho do conjunto de textos (*corpus*), e $f_{w,D}$ o número de documentos em que w aparece em D . Termos com elevado w_d implicam que w é uma palavra importante em d , mas não é comum em D . Portanto, o termo w apresenta poder discriminatório em relação ao conjunto de todos os textos (RAMOS, 2003).

O método TF-IDF tem como principal limitação a impossibilidade de identificar flexões gramaticais de um mesmo termo (QAISER; ALI, 2018). Nesse caso, atividades com a grafia “analisar”, “análise” ou [*sic*] “análise” seriam vistas como diferentes. Por esse motivo, anterior ao TF-IDF faz-se um procedimento de *stemming*, que traz variações de termos para uma raiz comum. Aplica-se também um procedimento de remoção de *stopwords* para descartar conectores frasais como artigos, conjunções, números e caracteres especiais que não retêm valor semântico para a análise.

Assim, a análise TF-IDF da Matriz de Atividades da CBO oferece uma ponderação que permite descontar a importância de termos que são comuns às tarefas de outras ocupações, colocando maior ênfase nas tarefas únicas que as diferenciam. Assim, D é o conjunto de 20.003 descrições de atividades de 2.601 ocupações, resultando em 47 milhões de palavras. Por fim, a medida da importância das tarefas dentro de cada ocupação é calculada pela soma dos pesos relativos w_d obtidos. A matriz resultante possui 2.341 termos ponderados para 2.601 ocupações.

O *Bartik Occupational Tasks* (BOT) é então construído a partir da união dos resultados do TF-IDF com o efeito diferencial. O BOT considera a importância relativa da tarefa em cada ocupação como variável explicativa da propensão à automação obtida do efeito diferencial da fronteira tecnológica. Considera-se o modelo em (3) para realizar a atribuição do efeito diferencial diretamente aos termos constituintes das tarefas de cada ocupação:

$$BOT = f(w_{d_{111}} termo_{111}, \dots, w_{d_{ijk}} termo_{ijk}) \quad (3)$$

em que o BOT atribui o efeito diferencial de automação estimado para a fronteira tecnológica aos w_d pesos encontrados para cada termo i , que constituem as tarefas j de cada ocupação k extraídos na aplicação do método TF-IDF.

A fim de encontrar o melhor método para predição e seguindo as práticas da área de *machine learning*, subdivide-se a amostra de 2.601 ocupações em subamostras aleatórias de 70% do tamanho inicial, em um conjunto de treino e um conjunto de teste. Constrói-se os modelos com dados do conjunto de treino, atribuindo um valor de importância relativa a cada uma das variáveis explicadas, e avalia-se o desempenho dos modelos frente ao conjunto de teste. O modelo selecionado é então usado para generalizar a importância relativa a todas ocupações da base de dados da CBO, com base na importância das tarefas.

Foram tentados diferentes métodos econométricos e de *machine learning* para avaliar aquele que apresentava o melhor desempenho preditivo geral nos dados de teste. O método *Random Forest Regression* (BREIMAN, 2001) foi selecionado a partir de avaliações de acurácia e poder preditivo quando confrontado com modelos de regressão linear, modelos logísticos, e demais métodos de *machine learning*, como *Support Vector Machines* (SVM), *Support Vector Regression* (SVR) e *Decision Trees*.

Métodos Random Forest têm se tornado populares por oferecerem bom desempenho preditivo, especialmente em contextos de estimação em matriz esparsa (*sparsity*) (ATHEY; IMBENS, 2019). Ao transformar as tarefas pela análise TF-IDF, a matriz resultante é esparsa, com o número de variáveis regressoras superior ao número de observações. Nesse contexto, o desempenho do *Random Forest*

Regression mostrou-se superior aos demais métodos com uma capacidade de acertos na predição acima de 95%, considerando uma validação cruzada em 100 subamostras aleatórias.

A partir desse procedimento, obtém-se as estimativas de propensão à automação para todas as ocupações da CBO. Esse número foi padronizado entre 1 (maior propensão à automação) e 0 (menor propensão). Deve-se realizar a leitura deste resultado em termos ordinais com o objetivo de ranquear as ocupações da mais à menos provável de ser automatizada. A classificação em relação à propensão à automação de cada ocupação depende do quartil da distribuição de propensão estimada na qual se encontra. Como em Albuquerque *et al.* (2019), classifica-se como “alta propensão à automação” as ocupações acima do 75º percentil; “média-alta propensão à automação” aquelas ocupações entre o 50º e 75º percentil; “média-baixa” entre 25º e 50º percentil; e “baixa” abaixo do 25º percentil. Ainda seguindo a literatura, considera-se que esses pontos de corte não devem ser vistos como estáticos, mas como uma classificação que depende do horizonte temporal. A literatura de automação reconhece que as tecnologias avançam sobre as ocupações ao deslocar-se o foco para uma, duas, ou três décadas à frente (FREY; OSBORNE, 2017).

4 RESULTADOS DE AUTOMAÇÃO

4.1 A FRONTEIRA TECNOLÓGICA DE AUTOMAÇÃO

A fim de justificar a mudança tecnológica a partir de tendências verificadas no passado recente, observou-se as mudanças ocorridas nas ocupações do setor privado do Estado de São Paulo, no período de 2010 e 2018.

Considera-se São Paulo como a fronteira tecnológica brasileira⁵, por possuir a segunda maior renda média entre os estados (IBGE, 2019), atuar como *hub* de contato internacional com elevado número de empresas multinacionais; concentrar 69,5% do total investido pelos estados brasileiros em pesquisa e desenvolvimento (INVESTESP, 2020); e por ter 42,9% do total de trabalhadores das áreas de *hardware*, *software*, serviços, nuvem e produção de tecnologia da informação (VALOR, 2018).

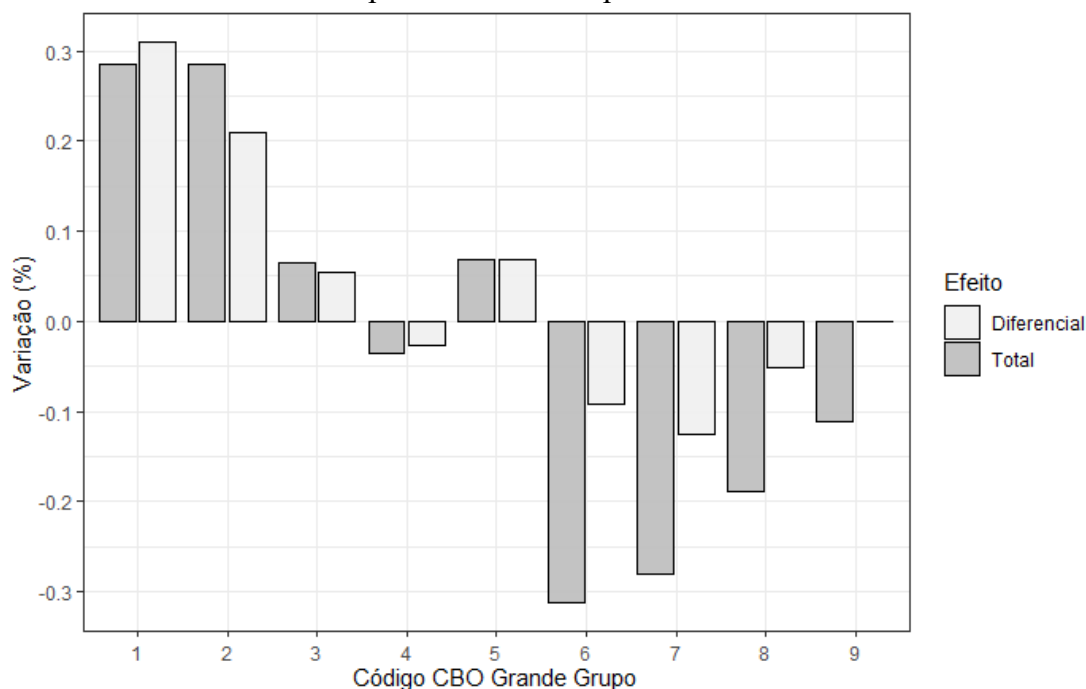
Com base na RAIS, o Estado de São Paulo apresentou 18,5 milhões de vínculos empregatícios em 2010 e 17 milhões em 2018, uma variação de -5,6%. Tal decréscimo no número de empregos pode estar relacionado tanto ao progresso técnico quanto à conjuntura econômica desfavorável. Os resultados da Pesquisa Mensal do Emprego (IBGE, 2019) também mostraram uma tendência de aumento no desemprego no período. Como as variações no nível de emprego não afetam de maneira homogênea os diferentes setores da economia e suas ocupações, busca-se extrair o efeito diferencial para entender a mudança na composição dos empregos dentro dos setores, atribuída à introdução de tecnologias de produção automatizáveis.

A Figura 1 contrasta o crescimento do emprego verificado em cada setor (Efeito Total) com o crescimento no emprego devido ao Efeito Diferencial. Este foi estimado pelo método BOT exposto na subseção 3.1 da Metodologia e Dados. Os resultados estão agregados por Grande Grupo da CBO, que considera 10 categorias de ocupações. O grupo 0, que contém forças armadas, policiais e bombeiros militares foi removido, já que a construção do efeito diferencial da fronteira tecnológica considera apenas os trabalhadores do setor privado.

A Figura 1 mostra que o grupo de membros superiores do poder público, dirigentes de organizações de interesse público e de empresas e gerentes (+28,6%) foi o que mais cresceu em número total de empregos, seguido de profissionais das ciências e das artes (+28,5%) e trabalhadores dos serviços, vendedores do comércio em lojas e mercados (+6,9%). Os grupos que mostraram maior retração são os trabalhadores agropecuários, florestais e da pesca (-31,3%) e trabalhadores da produção de bens e serviços industriais, tanto de processos discretos (-28%) quanto de processos contínuos (-18,9%).

⁵ O treinamento do modelo foi testado considerando outros estados da federação como fronteira. A classificação de propensão à automação se mostrou estável por meio de forte correlação de resultados entre São Paulo e: Rio de Janeiro (0,80), Minas Gerais (0,76) e Rio Grande do Sul (0,68).

Figura 1 – Efeito total e diferencial por CBO no setor privado de São Paulo - 2010 a 2018.



Legenda – Códigos e Títulos CBO 2002 - Grande Grupo:

- 1 Membros superiores do poder público, dirigentes de organizações (...) de empresas e gerentes
- 2 Profissionais das ciências e das artes
- 3 Técnicos de nível médio
- 4 Trabalhadores de serviços administrativos
- 5 Trabalhadores dos serviços, vendedores do comércio em lojas e mercados
- 6 Trabalhadores agropecuários, florestais e da pesca
- 7 Trabalhadores da produção de bens e serviços industriais (processos discretos)
- 8 Trabalhadores da produção de bens e serviços industriais (processos contínuos)
- 9 Trabalhadores em serviços de reparação e manutenção

Fonte: elaboração própria.

Em termos diferenciais, o grupo de membros superiores do poder público, dirigentes de organizações de interesse público e de empresas e gerentes mostrou maior crescimento (+31%), seguido dos profissionais das ciências e das artes (+21%) e trabalhadores dos serviços, vendedores do comércio em lojas e mercados (+6,8%). Os grupos com maior retração diferencial foram os trabalhadores da produção de bens e serviços industriais (processos discretos) (-12,6%), trabalhadores agropecuários, florestais e da pesca (-9,2%) e trabalhadores da produção de bens e serviços industriais (processos contínuos) (-5,2%).

Em linha com a literatura, os grupos de ocupações que estão mais sujeitos à automação agregam trabalhadores de menor qualificação e menor remuneração, com tarefas que possuem maior possibilidade de serem padronizadas e codificadas em algoritmos (FREY; OSBORNE, 2017). Tais ocupações são mais comuns na produção de bens e serviços industriais, tanto em processos contínuos e discretos, assim como em atividades agropecuárias, florestais e da pesca. Por outro lado, ocupações que requerem o uso de criatividade na solução de problemas e inteligência social para comunicação e interação com equipes, são apontadas como menos propensas à automação (FREY; OSBORNE, 2017). Essa tendência se reflete no crescimento diferencial verificado nos grupos que incluem os membros superiores do poder público, dirigentes e gerentes de organizações em geral, assim como profissionais da ciência e das artes.

As características das ocupações automatizáveis encontradas com o método BOT condizem com os efeitos de automação apontados por estudos realizados para os Estados Unidos e países da OCDE, mesmo que tais estudos tenham sido baseados na opinião de especialistas (FREY; OSBORNE, 2017; ARNTZ; GREGORY; ZIERAHN, 2016). Sendo um método objetivo e replicável, construído dentro do contexto brasileiro, o BOT classifica as ocupações mais propensas à automação, atribuindo o efeito diferencial às

tarefas exercidas em cada uma das ocupações. O efeito diferencial é calculado usando-se 49 subgrupos principais de ocupações, de acordo com a desagregação dada pela categorização de dois dígitos da CBO 2002.

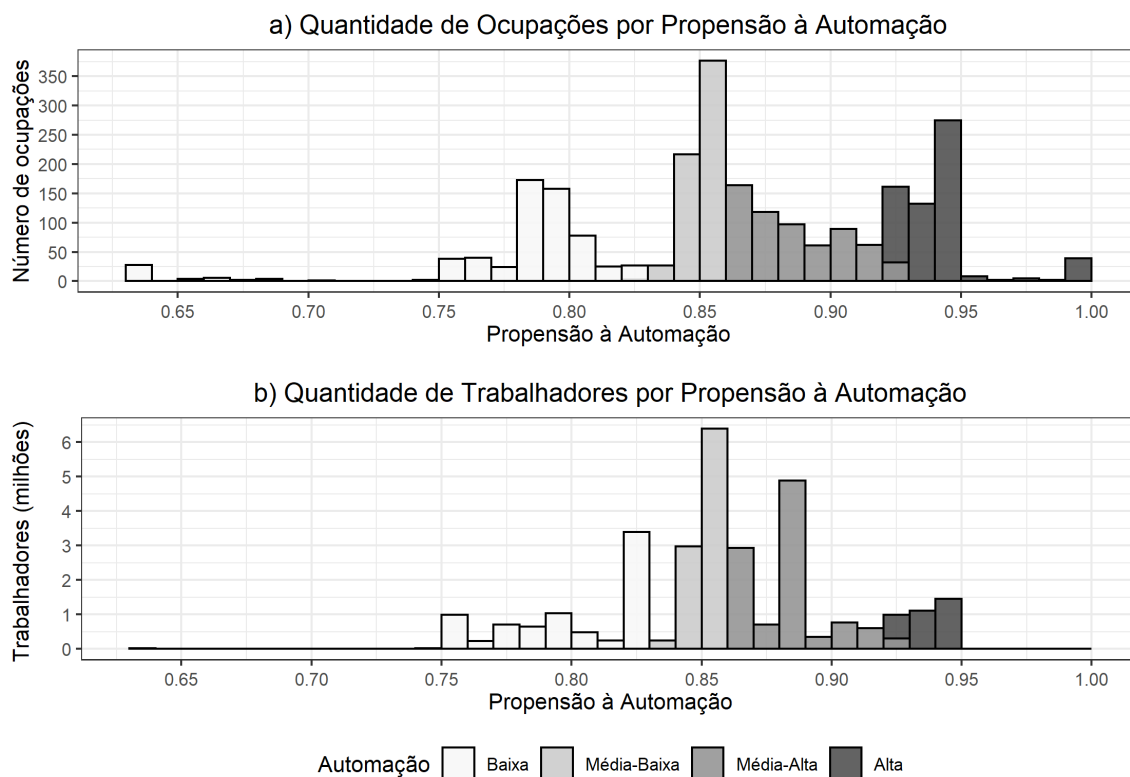
A partir das estimativas para a propensão à automação obtidas considerando a fronteira tecnológica de automação, avalia-se o impacto quantitativo da automação sobre as ocupações do mercado de trabalho brasileiro. Atribui-se os rótulos de “alta propensão à automação” às ocupações no quartil superior da distribuição de ocupações; “média-alta” às ocupações no terceiro quartil; “média-baixa” ao segundo quartil e “baixa” ao quartil menos propenso à automação.

O resultado deve ser lido como uma escala ordinal, e não cardinal. Assim, a propensão à automação não representa a probabilidade em si, mas ordena as ocupações da maior à menor propensão à automação. Em caso de empate, considerou-se a maior escolaridade média das ocupações para diferenciá-las, com base no relato de outros autores, em que a automação tende a impactar mais as profissões de menor qualificação (FREY; OSBORNE, 2017; ARNTZ; GREGORY; ZIERAHN, 2016).

A Figura 2.a) mostra a distribuição de ocupações em relação à propensão de automação, ou seja, representa o número de ocupações situadas em cada faixa. No total, são 2.496 ocupações selecionadas por apresentarem trabalhadores privados. Para fins de visualização, omitiu-se 14 ocupações dispersas abaixo de 0,6, contendo menos de 0,06% dos trabalhadores. As ocupações no tom mais escuro, com uma propensão acima de 0,92 representam as 624 ocupações em alta propensão à automação.

A Figura 2.b) mostra a distribuição do número de trabalhadores em cada ocupação ordenados pela propensão à automação. Do total de 31,5 milhões de trabalhadores analisados em 2018, 3,57 milhões são classificados em alta propensão à automação (11,3% do total). Em média-alta propensão encontram-se 10,55 milhões de trabalhadores (33,4% do total). Se estendermos o horizonte temporal de análise, pode-se considerar os grupos de alta e média-alta propensão como automatizáveis, obtendo um total de 44,8% do emprego.

Figura 2 – Distribuição de ocupações e trabalhadores por propensão à automação.



Fonte: elaboração própria.

Apesar das diferentes metodologias, o resultado de 44,8% dos empregos estarem em alta e média-alta propensão à automação é inferior, mas não se distancia muito do que foi encontrado em outros estudos aplicados ao Brasil. Albuquerque *et al.* (2019) concluíram que até 55% de todos os trabalhadores formais de 2017 desempenhavam ocupações com risco de automação elevado ou muito elevado. Kubota e Maciente (2019) estimaram que cerca de 56,5% dos empregos formais no país possuem ocupações com alto ou médio-alto percentual de tarefas automatizáveis. Ambos estudos utilizam a mesma classificação de ocupações automatizáveis baseada em opiniões subjetivas de especialistas, construída por Albuquerque *et al.* (2019).

4.2 OCUPAÇÕES PROPENSAS À AUTOMAÇÃO

Após análise da distribuição de trabalhadores e ocupações de acordo com a classificação por automação, é importante detalhar as ocupações responsáveis pelos resultados encontrados. A seção agrupa as 2.627 ocupações em 489 famílias de ocupações, de acordo com a média da propensão à automação estimada. A agregação facilita a análise ao passo que agrupa dentro de uma mesma família as ocupações que exercem tarefas e possuem propensão à automação semelhantes.

A Tabela 1 mostra as ocupações com mais de mil trabalhadores ordenadas de forma decrescente, a partir da mais propensa à automação. Considera-se a quantidade de trabalhadores acima de mil, deixando de fora da visualização as ocupações menos relevantes para análise. A tabela inclui a quantidade de trabalhadores em cada ocupação, os anos médios de estudo e a remuneração média.

As ocupações com maior propensão à automação são as de produtores agropecuários e agrícolas. Dentre as tarefas realizadas por essas ocupações destacam-se: plantar culturas, beneficiar produtos de origem vegetal e animal, planejar alimentação e controlar sanidade e manejo de rebanho, comercializar produção agropecuária, administrar e montar infraestrutura da propriedade (CBO, 2002). Em geral, são atividades executadas como rotinas com baixo grau de abstração e baixa necessidade de qualificação. Essas ocupações possuem uma média entre 6 e 8 anos de escolaridade, equivalentes ao ensino fundamental.

Tabela 1 – Famílias de ocupações ordenadas por propensão à automação – decrescente*.

Posição	Título da ocupação	Código CBO	Prop. auto- mação	Quan- tidade	Anos de estudo	Remu- neração média
1	Produtores em pecuária de animais de grande porte	6131	0,9969	1.260	7,07	1.503
2	Produtores agropecuários em geral	6110	0,9565	2.650	7,26	1.377
3	Trabalhadores de beneficiamento de minérios	7121	0,9505	6.976	7,97	2.280
4	Produtores agrícolas polivalentes	6120	0,9499	2.619	6,69	1.499
5	Trabalhadores de montagem de estruturas [...] em obras civis	7155	0,9497	98.309	7,35	2.002
6	Supervisores da construção civil	7102	0,9495	85.677	8,67	3.614
7	Aplicadores de materiais isolantes	7157	0,9490	12.236	8,89	2.036
8	Trabalhadores de beneficiamento de pedras ornamentais	7122	0,9487	21.429	8,53	1.825
9	Trabalhadores na operação de máquinas de terraplenagem [...]	7151	0,9487	113.151	8,02	2.475
10	Aplicadores de revestimentos cerâmicos, pastilhas, pedras [...]	7165	0,9486	20.293	8,68	1.880

Fonte: elaboração própria.

Nota: *Famílias de ocupações com mais de mil trabalhadores.

Na sequência estão os trabalhadores de beneficiamento de minérios e trabalhadores da indústria da construção civil, como montadores de estruturas, de concreto armado e alvenaria, aplicadores de materiais isolantes, revestimentos e operadores de máquinas de terraplanagem (CBO, 2002). Essas ocupações têm

em comum as atividades de operação, inspeção e manutenção básica de máquinas pesadas. Ainda, trabalhadores da construção realizam o corte, montagem e aplicação de ferragens e armações. A escolaridade desses grupos varia entre 7 e 9 anos de estudo.

Entre as quinze ocupações mais propensas à automação encontram-se ainda os trabalhadores das indústrias gráficas e têxteis. Trabalhadores da impressão gráfica são responsáveis por planejar a impressão, ajustar máquinas e realizar a impressão por meio de variadas técnicas. Os trabalhadores têxteis fazem a confecção de fios, operação de teares manuais ou automatizados, além da comercialização de produtos para os trabalhadores de tecelagem manual (CBO, 2002). Assim, a escolaridade desses trabalhadores varia entre ensino fundamental e ensino médio, com uma média de anos de estudo próxima a 9 anos.

Em geral, os trabalhadores mais propensos à automação desempenham ocupações com baixa necessidade de qualificação e remuneração. A escolaridade equivale ao ensino fundamental e médio, com uma remuneração inferior à média nacional, calculada em R\$ 2.818 para trabalhadores em tempo integral (em valores de 2018). Assim, essa conclusão está em linha com outras pesquisas de automação que consideram um maior impacto da automação sobre as profissões de menor qualificação e menor nível salarial (ARNTZ; GREGORY; ZIERAHN, 2016; FREY; OSBORNE, 2017, ALBUQUERQUE *et al.*, 2019). Por sua vez, a Tabela 2 mostra as ocupações no extremo oposto da classificação de automação, ou seja, ordenadas a partir das famílias menos propensas à automação que contêm mais de mil trabalhadores.

Os profissionais menos propensos à automação são os chefes e tecnólogos de cozinha. Dentre suas principais atividades estão a criação de pratos e cardápios, planejamento de rotinas de trabalho, gerenciamento e capacitação de funcionários, gestão de estoques e preparação de alimentos (CBO, 2002). Em seguida, aparecem os artesãos em geral. Os artesãos fazem a criação, confecção, finalização e comércio de produtos artesanais, aquisição e preparação de matéria prima e gerenciamento do próprio negócio. As tarefas de ambas ocupações requerem habilidades de difícil automação: a criatividade para criação de novos produtos e relacionamento interpessoal para gestão de equipes, do próprio negócio e comercialização dos produtos (CBO, 2002).

Tabela 2 – Ocupações ordenadas por propensão à automação – crescente*.

Posição	Título da ocupação	Código CBO	Prop. automação	Quantidade	Anos de estudo	Remuneração média
1	Chefes de cozinha e afins	2711	0,0044	17.641	10,41	2.624
2	Artesãos	7911	0,2188	1.028	9,48	1.491
3	Pesquisadores das ciências biológicas	2030	0,6310	1.048	16,33	8.950
4	Pesquisadores de engenharia e tecnologia	2032	0,6316	11.856	15,28	10.858
5	Pesquisadores das ciências da saúde	2033	0,6319	1.935	15,45	8.993
6	Pesquisadores das ciências sociais e humanas	2035	0,6342	1.918	15,40	7.751
7	Pesquisadores das ciências da agricultura	2034	0,6366	1.322	16,89	11.046
8	Engenheiros de controle e automação, engenheiros mecatrônicos e afins	2021	0,6693	2.665	15,05	9.023
9	Pesquisadores das ciências naturais e exatas	2031	0,7200	1.741	15,79	8.380
10	Gerentes de manutenção e afins	1427	0,7477	22.914	13,00	9.210

Fonte: elaboração própria.

Nota: *Famílias de ocupações com mais de mil trabalhadores.

Em seguida, verifica-se ocupações de alta escolaridade e elevada remuneração, como pesquisadores de áreas diversas, engenheiros e cargos gerenciais. As atividades mais comuns entre os pesquisadores são as que envolvem desenvolvimento de novos materiais, produtos, processos e métodos. Além disso, há atividades de identificação de oportunidades, execução de projetos de pesquisa e prestação de consultoria técnica. Essas atividades estão na fronteira do conhecimento e longe de possibilitarem uma padronização

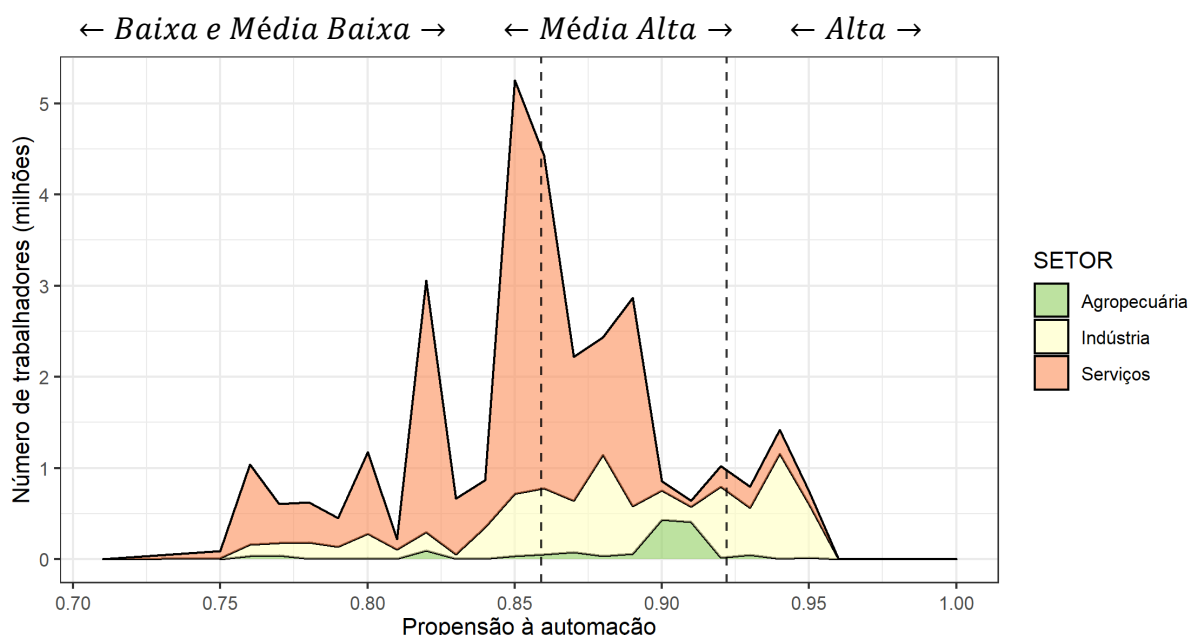
em seus processos, dada a elevada complexidade das tarefas e necessidade de criatividade e inovação. Atividades de disseminação de conhecimento também são centrais às atividades de pesquisadores, ao orientar trabalhos de pesquisa, coordenar seminários, congressos e cursos, e capacitar equipes de futuros pesquisadores.

Ainda, entre as ocupações com mais baixa propensão à automação estão profissionais de engenharia, gestão e comunicação. Essas ocupações desempenham atividades centrais para o desenvolvimento das próprias tecnologias de automação, que ao ganharem espaço e importância no mercado de trabalho, poderão demandar mais esforços e investimentos para a continuidade da sua evolução e disseminação pela sociedade.

4.3 CONSEQUÊNCIAS SETORIAIS DA AUTOMAÇÃO

A partir da classificação das ocupações por propensão à automação é possível visualizar os efeitos sobre cada setor da economia brasileira. A Figura 3 exibe a relação entre automação e emprego nos setores de serviços, indústria e agropecuária⁶. Do total de 31,5 milhões de vínculos privados em tempo integral registrados na RAIS de 2018, 68% estão no setor de serviços, 27,5% nos setores industriais e 4,5% na agropecuária.

Figura 3 – Distribuição do emprego por propensão à automação e setores.



Fonte: elaboração própria.

Estima-se que 11,3% dos trabalhadores desempenham ocupações classificadas em alta propensão à automação, 33,4% em média-alta, e os 55,3% restantes em baixa e média-baixa propensão à automação. Um total de 3,6 milhões de trabalhadores encontram-se na região de alta propensão à automação e 10,6 milhões ao incorporar alta e média-alta automação.

⁶ A agropecuária inclui as divisões da CNAE 01 à 03 (Agricultura, pecuária, produção florestal, pesca e aquicultura). A indústria inclui as divisões da CNAE 05 à 43 (indústrias extrativas; indústrias de transformação; eletricidade e gás; água, esgoto, atividades de gestão de resíduos e descontaminação; e construção). O setor de serviços inclui as divisões da CNAE 45 à 99 (comércio; reparação de veículos automotores e motocicletas; transporte, armazenagem e correio; alojamento e alimentação; informação e comunicação; atividades financeiras, de seguros e serviços relacionados; atividades imobiliárias; atividades profissionais, científicas e técnicas; atividades administrativas e serviços complementares; administração pública, defesa e seguridade social; educação; saúde humana e serviços sociais; artes, cultura, esporte e recreação; outras atividades de serviços; serviços domésticos; organismos internacionais e outras instituições extraterritoriais).

Proporcionalmente, o setor da indústria é o mais afetado pela automação. Entre os empregos classificados em maior propensão, 75% são da indústria, o que representa 2,7 milhões de trabalhadores. O setor de serviços corresponde a cerca de 21% e a agropecuária a 4%. A Tabela 3 complementa a visualização com os resultados do emprego desagregado em cada seção de atividade.

No setor agropecuário, 7% dos trabalhadores estão nas ocupações de alta propensão, mas o percentual se eleva para 79,3% ao se considerar as ocupações de média-alta propensão à automação. Entre as ocupações com maior número de trabalhadores em alta propensão à automação no setor estão os produtores agrícolas e da pecuária, trabalhadores e ajudantes de obras, além de ocupações extrativistas vegetais e minerais. Entre as ocupações com baixa propensão, destacam-se trabalhadores da mecanização agropecuária e florestal, gerentes de produção e operações, agrônomos, biólogos e pesquisadores em geral.

Na indústria, incluindo construção civil, 31,4% do emprego está em alta propensão à automação. Neste grupo encontram-se trabalhadores de obras, trabalhadores de confecção de roupas e de calçados, condutores de veículos, operadores de movimentação de cargas, e assistentes administrativos em geral. Entre os menos automatizáveis estão os cargos de direção e organização de empresas, engenheiros, arquitetos e afins, técnicos em operações industriais e vendedores e demonstradores.

Tabela 3 – Efeitos da automação sobre o emprego por setor e seção CNAE.

Setor	Seção CNAE	Denominação CNAE	Emprego em alta auto.	Emprego em alta e média-alta auto.	Trab. em alta auto. (mil)	Trab. em alta e média-alta auto. (mil)	Total de Trab. (mil)
Agrop.	A	Agricultura, pecuária, produção florestal, pesca e aquicultura	7,0%	79,3%	99,4	1.132,6	1.427,8
Indústria			31,4%	68,1%	2.720,0	5.907,2	8.674,4
	B	Indústrias extrativas	26,3%	59,6%	41,5	93,9	157,5
	C	Indústrias de transformação	23,8%	66,3%	1.499,1	4.178,4	6.302,4
	D	Eletricidade e gás	23,0%	45,3%	24,6	48,3	106,6
	E	Água, esgoto, atividades (...)	14,1%	46,0%	39,3	127,7	277,5
	F	Construção	60,9%	79,7%	1.115,5	1.458,9	1.830,4
Serviços			3,5%	33,0%	754,7	7.084,8	21.443,1
	G	Comércio; rep. de veículos (...)	3,7%	29,5%	316,5	2.528,2	8.556,4
	H	Transporte, armazenagem (...)	2,2%	66,5%	46,2	1.370,5	2.061,9
	I	Alojamento e alimentação	1,0%	8,3%	17,1	141,7	1.715,2
	J	Informação e comunicação	7,8%	36,5%	53,8	251,1	688,2
	K	Atividades financeiras (...)	0,5%	34,7%	2,9	200,6	577,9
	L	Atividades imobiliárias	9,7%	52,9%	13,2	72,2	136,5
	M	Atividades profissionais, (...)	7,3%	50,6%	68,4	471,5	931,9
	N	Atividades administrativas (...)	3,9%	23,6%	135,7	828,1	3.515,6
	O	Adm. pública, defesa (...)	4,2%	40,3%	1,9	18,3	45,4
	P	Educação	2,7%	29,2%	25,5	278,7	956,0
	Q	Saúde humana e serviços sociais	1,3%	41,4%	16,0	528,0	1.275,9
	R	Artes, cultura, esporte e recr.	10,2%	31,2%	18,4	56,5	181,0
	S	Outras atividades de serviços	4,9%	42,3%	39,0	337,8	798,4
	T	Serviços domésticos	6,7%	51,1%	0,2	1,2	2,4
	U	Organismos internacionais (...)	7,2%	51,5%	0,0	0,2	0,5
		Totais	11,3%	44,8%	3.574,1	14.124,6	31.545,3

Fonte: elaboração própria.


No setor de serviços, apenas 3,5% dos trabalhadores estão em alta automação e 33% se for considerada a média-alta propensão. Ocupam elevado número de empregos em alta propensão à automação os ajudantes construção, obras e acabamentos, de instalação, manutenção e montagem de estruturas e equipamentos diversos. Escriturários, assistentes e auxiliares administrativos em geral também estão em alta automação. Entre as ocupações com menos automatizáveis estão os trabalhadores em serviços de alimentação e hotelaria, vendedores e demonstradores e demais atividades comerciais. Diretores de empresas, engenheiros, profissionais da medicina, cientistas sociais e pesquisadores são as ocupações com menor propensão à automação.

Dessa forma, os resultados estão de acordo com as tendências de automação em ocupações de menor complexidade, intensas em tarefas manuais e de rotina. A indústria, que se utiliza de processos produtivos mais estruturados e padronizados em relação aos demais setores, está mais exposta a transformações por automatização. Já o setor de serviços, com ocupações de maior intensidade de tarefas não repetitivas, complexas e com necessidade de contato interpessoal apresenta o menor efeito da automação sobre o emprego. A seção seguinte aprofunda a discussão sobre fatores e tendências de automação.

5 DISCUSSÃO DOS RESULTADOS

De acordo com a RAIS, o número de trabalhadores no mercado de trabalho formal brasileiro apresentou um crescimento de 112% desde a década de 1980. Em 1986, existiam 18,2 empregos formais em tempo integral. Em 2018, este número aumentou para 38,5 milhões de trabalhadores. As ocupações que mais cresceram estão nas áreas administrativas e de comércio, enquanto dirigentes, profissionais e técnicos de nível médio mostraram relativa retração. A Figura 4 apresenta a evolução na participação das ocupações no emprego formal.

Figura 4 – Participação dos grupos de ocupações no emprego formal no Brasil – 1986 a 2018.



Fonte: elaboração própria.

Ao analisar-se os trabalhadores agropecuários, considera-se que estão inseridos em processos de intensa mecanização, tendo perdido participação no emprego ao longo das últimas décadas. Em 2018, o setor agropecuário representava ainda 4,5% dos empregos formais, pouco abaixo dos 4,9% registrados no início da década de 2000. Nos Estados Unidos, que possuem uma agricultura mais intensiva em capital, Katz e Margo (2014) mostram que o emprego agropecuário reduziu sua participação, caindo de 35,3% do total do emprego em 1900 para menos de 1% nos anos 2000.

A maior participação do emprego agropecuário no Brasil, em relação à economia norteamericana, é indício de que há espaço para o avanço da automação. De acordo com os resultados deste estudo,

analisados na seção anterior, 79,3% dos trabalhadores dos setores da agricultura e pecuária desempenham ocupações classificadas como alta e média-alta propensão à automação. Portanto, o efeito da automação pode atingir 1,1 milhão de trabalhadores formais no setor. Porém, o número total de trabalhadores automatizáveis pode ser ainda maior, já que a informalidade na agricultura familiar e trabalhadores sazonais (boias-frias) não é capturada pela RAIS. Segundo o DIEESE (2014), a informalidade atinge 59,4% dos trabalhadores rurais.

A RAIS (2018) revela relativa estabilidade na participação de trabalhadores industriais, mas com expressiva queda no emprego a partir de 2010. Grande parte dos estudos de automação se concentram em analisar os efeitos sobre a indústria e têm encontrado evidências de destruição de empregos (ACEMOGLU; LELARGE; RESTREPO, 2020). No Brasil, Stemmler (2020) mostra que o aumento no uso de robôs faz com que o emprego se desloque para atividades produtivas de menor valor agregado. As regiões mais expostas a tecnologias estrangeiras apresentaram aumento no emprego de mineração, mas quedas no emprego da manufatura.

O emprego industrial é sujeito à automação por desempenhar atividades manuais e rotineiras em ambientes controlados. A previsibilidade do trabalho facilita a introdução de robôs e algoritmos de organização da produção (FREY; OSBORNE, 2017). Os resultados da pesquisa mostram que, entre os empregos classificados em maior propensão a automação, 75% são da indústria, o que representa 2,7 milhões de trabalhadores. No total, dos 8,7 milhões de trabalhadores industriais, 68,1% estão em alta e média-alta propensão.

Em análise sobre a introdução de robôs na indústria francesa entre 2010 e 2015, Acemoglu, Lelarge e Restrepo (2020) encontram um efeito líquido de diminuição no emprego do setor, em que um aumento de 20 p.p. na adoção de robôs está associada a uma queda de 3,2% no emprego industrial. Há um efeito concorrencial entre empresas que induz a adoção de tecnologias de automação. Segundo a pesquisa, as firmas que adotam robôs reduzem seus custos e crescem em relação as suas concorrentes. Por outro lado, firmas em que os competidores adotaram robôs sofreram perdas de participação no valor adicionado e no emprego (ACEMOGLU; LELARGE; RESTREPO, 2020).

A automação pode redesenhar a distribuição dos empregos dentro e entre os países, afetando a competitividade internacional. As principais forças por trás da movimentação internacional de mão de obra se encontram no aumento da competição de importações de países em desenvolvimento e na substituição de tarefas por *offshoring*. O *offshoring* consiste na transferência de ocupações realizadas a um custo menor em outros países (BLINDER, 2009). A crescente inserção da China nas cadeias produtivas globais gerou efeitos negativos sobre o emprego e salários na manufatura no Estados Unidos (AUTOR; DORN; HANSON, 2013, 2016).

A automação pode viabilizar a reversão de tendência de *offshoring* por meio de um movimento de *reshoring*. Backer (2016) define o *reshoring*⁷ como a volta de atividades produtivas ao país original ou em sua proximidade. O avanço da robótica torna os processos produtivos mais baratos em países desenvolvidos, favorecendo a produção local e acelerando a desindustrialização em países emergentes. Ao produzir no mercado local, as empresas têm redução em custos de transporte e tiram proveito da proximidade à mão de obra qualificada e abundante, considerada escassa em países emergentes. Segundo a CNI (2020), metade das indústrias no Brasil encontram dificuldades na contratação de mão de obra com a qualificação necessária.

A economia brasileira, por sua vez, é considerada por Ehrl (2017) como *onshoring*, que possui vantagens comparativas na atração de tarefas de média complexidade e intensivas em rotinas manuais.

⁷ A literatura ainda diferencia o *reshoring* entre *backshoring* e *nearshoring*. *Backshoring* é a volta das atividades para o próprio país de origem. *Nearshoring* é o retorno das atividades para um país próximo ou vizinho. Fratocchi *et al.* (2015) aponta o *backshoring* como o fenômeno mais comum nos Estados Unidos e na Europa. Em anos recentes, cresceu o número de casos de empresas multinacionais repatriando seus processos produtivos, mas faltam estudos para afirmar a real relevância desses movimentos (BACKER *et al.*, 2016). As evidências são discutidas por Backer *et al.* (2016), Fratocchi *et al.* (2015) e Delis *et al.* (2019).

Assim, o avanço da automação nos países desenvolvidos pode implicar em redução do emprego industrial brasileiro e dos setores correlatos. Deve-se levar em conta que a indústria tem forte efeito multiplicador sobre os empregos dos outros setores. Macedo e Monastério (2016) mostram que, para cada emprego criado nos setores industriais, 4 novos empregos são criados nos setores de serviços. Nas indústrias de alta intensidade tecnológica, cada emprego criado gera 7 empregos adicionais no setor de serviços.

Ainda assim, seria superficial a interpretação de que todos 8,7 milhões de empregos industriais automatizáveis simplesmente viriam a desaparecer. A análise histórica mostra que, na revolução industrial do século XIX, teares mecânicos possibilitaram a automação de 98% do trabalho manual necessário para a fabricação de tecidos, mas ainda assim, o número de empregos fabris de tecelagem aumentou no período (BESSEN, 2015). Em mercados competitivos, a queda nos custos com trabalho permitiu a redução de preços e aumento da demanda por tecidos. Trabalhadores com habilidades não automatizáveis se tornaram cada vez mais necessários em outras atividades, como a coordenação da produção entre múltiplos teares. O emprego remanescente tornou-se cada vez mais valioso, observando aumentos nos seus rendimentos (BESSEN, 2015). Essa tendência resultou no aumento contínuo na parcela de ocupações de altas habilidades, como profissionais, técnicos e gerenciais, a partir de meados do século XIX e XX (KATZ; MARGO, 2014).

Efeito semelhante pôde ser visto na automatização dos serviços bancários nos Estados Unidos a partir dos anos 1990. Com a introdução de terminais informatizados de autoatendimento (ATMs), o número de agências se multiplicou pelo país, com a valorização das tarefas de relacionamento com os clientes e personalização de produtos financeiros mais lucrativos (BESSEN, 2015).

A análise de automação mostrou que o setor de serviços, responsável por 21,4 milhões de empregos, apresenta 3,5% dos seus empregos na região de alta propensão e 33% em alta e média-alta propensão à automação. As ocupações do setor de serviços impõem maior resistência à automação por dependerem mais do contato interpessoal. As tarefas são realizadas em ambientes menos estruturados que nos setores agropecuário e industrial, com maior importância relativa de tarefas não rotineiras e cognitivas.

O avanço tecnológico tende a gerar no setor de serviços o maior número de novas ocupações. Autor e Salomons (2019) mostram que a automação avança das tarefas rotineiras mais simples em direção às mais complexas, restando aquelas tarefas marginais com maior dificuldade de codificação. Ocupações de fronteira surgem com a finalidade de desenvolver e implementar novas tecnologias (*frontier work*), oferecer serviços personalizados, de luxo e bem-estar pessoal (*wealth work*) e conduzir tarefas ainda não automatizáveis (*last-mile work*) (AUTOR; SALOMONS, 2019).

Todavia, os trabalhadores beneficiados pelas novas ocupações raramente são os mesmos afetados pela automação. Feigenbaum e Gross (2020) apontam que operadores telefônicos manuais substituídos por sistemas automatizados de discagem entre 1920 e 1940, se deslocaram para ocupações de menores salários ou deixaram a força de trabalho. Essas evidências suscitam o debate da polarização e os desafios para a requalificação de trabalhadores afetados negativamente pela automação.

A polarização do emprego tem sido reportada nos países desenvolvidos como o crescimento das ocupações nos extremos da distribuição de rendimentos. A polarização é considerada um efeito imediato da adoção de tecnologias de automação (GOOS; MANNING, 2007; MANNING; SALOMONS, 2014). Ocupações de maior qualificação, com tarefas cognitivas complexas, e ocupações de menor qualificação, com salários abaixo do custo de automatização, atraem um maior número de trabalhadores, com um esvaziamento nas ocupações intermediárias.

Sulzbach (2020) encontra indícios de polarização no emprego brasileiro com o crescimento no número de trabalhadores nos quintis inferiores e superiores da distribuição de rendimentos, entre 1994 e 2017. Em termos salariais, porém, a polarização não se verificou. Observou-se expressivo crescimento nos salários dos grupos de menor qualificação. Esse efeito pode ser explicado pelas políticas de valorização do salário mínimo que ocorreram no período (SULZBACH, 2020). Entre a implantação do Plano Real em 1994 e o final de 2017, o salário mínimo passou por uma valorização real de 197% (IPEADATA, 2021).

Sem políticas públicas ativas na suavização dos efeitos de transição no mercado de trabalho, as tendências de automação tendem a agravar os efeitos da polarização de rendimentos e desigualdade. Até o momento, são insuficientes os estudos que apontem quais serão as novas ocupações a surgir, mas fica cada

vez mais claro que, para aproveitar todo potencial produtivo das tecnologias de automação, demanda-se habilidades complexas e de alta qualificação. Assim, o papel da educação é de suma importância para preparar a força de trabalho para o futuro.

6 CONSIDERAÇÕES FINAIS

O objetivo geral deste estudo foi estimar os possíveis impactos da automação no mercado de trabalho brasileiro. Para isso aplicou-se um método novo, denominado de *Bartik Occupational Tasks* (BOT). Por meio deste método, realizou-se uma estimação objetiva da trajetória das ocupações brasileiras em um contexto de crescente automação. A partir de informações observadas no mercado de trabalho, construiu-se algoritmos preditivos da propensão à automação usando técnicas de *Natural Language Processing* e de *Machine Learning* para extrair informações quantitativas a partir dos textos que descrevem as tarefas de cada uma das 2.627 ocupações da Classificação Brasileira de Ocupações.

Os resultados possibilitaram traçar um perfil detalhado do potencial efeito das tecnologias de automação sobre as ocupações. Mostrou-se que cerca de 11,3% dos trabalhadores desempenham ocupações classificadas em alta propensão à automação e 44,8% em situação de alta e média-alta propensão. Estimou-se que, nas próximas décadas, a automação possa afetar 7 milhões de empregos no setor de serviços, 6 milhões na indústria e 1 milhão na agropecuária. Em geral, as ocupações mais propensas à automação apresentam menores níveis de escolaridade e remuneração.

As tendências aqui discutidas, como polarização do emprego, aumento da desigualdade e *reshoring* se baseiam em evidências ainda incipientes, mas apresentam fronteiras de pesquisa promissoras. Se verificadas, as consequências negativas do avanço da automação exigirão políticas públicas de redução de desigualdades no mercado de trabalho; de formação e treinamento de trabalhadores; e de desenvolvimento de novas habilidades e competências para o mercado de trabalho do futuro.

REFERÊNCIAS

ACEMOGLU, D.; AUTOR, D. Skills, tasks and technologies: Implications for employment and earnings. In: **Handbook of Labor Economics** (Vol. 4), 2011.

ACEMOGLU, D.; LELARGE, C.; RESTREPO, P. Competing with Robots: Firm-Level Evidence from France. **AEA Papers Proceedings**, v. 110, p. 383–388, 2020.

ADAMCZYK, W. B.; MONASTERIO, L.; FOCHEZATTO, A. Impacto da Automação no Futuro do Emprego do Setor Público: uma aplicação ao Executivo Federal brasileiro. In: 48º Encontro Nacional de Economia, 2020, Brasília. **Anais do 48º Encontro Nacional de Economia**, 2020.

ALBUQUERQUE, P. H. M.; SAAVEDRA, C. A. P. B.; MORAIS, R. L.; PENG, Y. The Robot from Ipanema goes Working: Estimating the Probability of Jobs Automation in Brazil, **Latin American Business Review**, 20:3, 227-248, 2019.

ARNTZ, M.; GREGORY, T.; ZIERAHN, U. The risk of automation for jobs in OECD countries. **OECD Social, Employment and Migration Working Papers**, No. 189. Paris: OECD Publishing, 2016.

ARNTZ, M.; GREGORY, T.; ZIERAHN, U. Revisiting the risk of automation. **Economics Letters**, v. 159, p. 157-160, 2017.

ATHEY, S.; IMBENS, G. W. Machine learning methods that economists should know about. **Annual Review of Economics**, v. 11, p. 685-725, 2019.

AUTOR, D.; DORN, D.; HANSON, G. The China Shock: Learning from labor-market adjustment to large changes in trade. **Annual Review of Economics**, v. 8, p. 205-240, 2016.

- AUTOR, D.; DORN, D.; HANSON, G. The China Syndrome: Local labor market effects of import competition in the United States. **American Economic Review**, v. 103, n. 6, p. 2121-68, 2013.
- AUTOR, D., DORN, D., KATZ, L.F., PATTERSON, C., VAN REENEN, J. The Fall of the Labor Share and the Rise of Superstar Firms. **The Quarterly Journal of Economics**, v. 135, n. 2, p. 645–709, 2020.
- AUTOR, D.; LEVY, F.; MURNANE, R. The skill content of recent technological change: An empirical exploration. **The Quarterly Journal of Economics**, v. 118, n. 4, p. 1279-1333, 2003.
- AUTOR, D.; SALOMONS, A. New Frontiers: The Evolving Content and Geography of New Work in the 20th Century. **MIT Working Papers**, 2019.
- AUTOR, D. Why Are There Still So Many Jobs? The History and Future of Workplace Automation. **Journal of Economic Perspectives**, v. 29, n. 3, p. 3-30, 2015.
- BACKER, K.; MENON, C.; DESNOYERS-JAMES, I.; MOUSSIEGT, L. Reshoring: Myth or Reality? **OECD Science, Technology and Industry Policy Papers**, n. 27, Paris: OECD Publishing, 2016.
- BARTIK, T. J. **Who Benefits from State and Local Economic Development Policies?** Kalamazoo, Michigan: W. E. Upjohn Institute for Employment Research, 1991.
- BESSEN, J. Toil and Technology. *Finance and Development*, v. 52, n. 1, 2015.
- BLANCHARD, O. J; KATZ, L. F. Regional Evolutions. **Brookings Papers on Economic Activity**, v. 1, p. 1-75, 1992.
- BLINDER, A. S. How many US jobs might be offshorable? **World Economics**, v. 10, n. 2, p. 41-78, 2009.
- BRASIL, MINISTÉRIO DO TRABALHO E DO EMPREGO. **Classificação Brasileira de Ocupações (CBO)**. Portal Emprega Brasil, 2019. Disponível em: <https://empregabrasil.mte.gov.br/76/cbo/>. Acesso em: 20 de jun. 2020.
- BREIMAN, L. Random Forests. **Machine Learning**, v. 45(1), p. 5-32, 2001.
- BRYNJOLFSSON, E.; McAFEE, A. **The second machine age: Work, progress, and prosperity in a time of brilliant technologies**. WW Norton & Company, 2014.
- CNI – Confederação Nacional da Indústria. **Falta de Trabalhador Qualificado**. Sondagem Especial, v. 20, n. 76. Brasília: CNI, 2020.
- CONCLA – Comissão Nacional de Classificação. **Classificação Brasileira de Ocupações – CBO**. Instituto Brasileiro de Geografia e Estatística, 2019. Disponível em: <https://concla.ibge.gov.br/classificacoes/portema/ocupacao/classificacao-brasileira-de-ocupacoes.html> . Acesso em: 22 de jun. 2020.
- DELIS, A.; DRIFFIELD, N.; TEMOURI, Y. The global recession and the shift to re-shoring: myth or reality? **Journal of Business Research**, v. 103, p. 632-643, 2019.
- DETONI, O. F.; FREGUGLIA, R.; CORSEUIL, C. H. Prêmio salarial associado às competências dos trabalhadores no Brasil. **Anais do 48º Encontro Nacional de Economia**. Brasília, 2020.
- DIEESE - Departamento Intersindical de Estatística e Estudos Socioeconômicos. **O Mercado de Trabalho Assalariado Rural Brasileiro**. Estudos e Pesquisas, n. 74, 2014.

- EHRL, P. Task Trade and Employment Patterns: The Offshoring and Onshoring of Brazilian Firms. **Journal of International Trade and Economic Development**, n. 27, v. 3, p. 235–66, 2017.
- FEIGENBAUM, J.; GROSS, D. Automation and the Fate of Young Workers: Evidence from Telephone Operation in the Early 20th Century. **National Bureau of Economic Research**, n. w28061, 2020.
- FIRPO, S.; FORTIN, N. M.; LEMIEUX, T. Occupational tasks and changes in the wage structure. **IZA Discussion Paper**, n. 5542, 2011.
- FRATOCCHI, L.; BARBIERI, P.; ANCARANI, A.; DI MAURO, C.; TROIANO, A.; VIGNOLI, M.; ZANONI, A. Manufacturing Back- and Near-Reshoring: A Comparison of European and North American Evidence. In: STENTOFT, J.; PAULRAI A.; VASTAG G. (org.) **Research in the Decision Sciences for Global Supply Chain Network Innovations**. Pearson, p. 107-128, 2015.
- FREY, C.; OSBORNE, M. The Future of Employment: how susceptible are jobs to computerisation? **Technological forecasting and social change**, v. 114, p. 254-280, 2017.
- GOLDIN, C.; KATZ, L. F. The Origins of Technology-Skill Complementarity. **The Quarterly Journal of Economics**, 113(3), 693–732, 1998.
- GOLDSMITH-PINKHAM, P.; SORKIN, I.; SWIFT, H. Bartik instruments: What, when, why, and how. **National Bureau of Economic Research**, 2018.
- GOOS, M.; MANNING, A. Lousy and Lovely Jobs: The Rising Polarization of Work in Britain. **Review of Economics and Statistics** 89(1): 118–33. 2007.
- GOOS, M., MANNING, A.; SALOMONS, A. Explaining Job Polarization: Routine-Biased Technological Change and Offshoring. **American Economic Review**, 104(8): 2509–26. 2014.
- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA – IBGE. **Pesquisa Nacional por Amostra de Domicílios Contínua – PNAD 2019**. Rio de Janeiro: IBGE, 2019. Disponível em: <https://www.ibge.gov.br/estatisticas/sociais/trabalho/17270-pnad-continua.html>. Acesso em: jun. 2020.
- INVESTESP. Por que SP. Disponível em: <https://www.investe.sp.gov.br/por-que-sp/>. Acesso em: 15 de jun. de 2020.
- IPEADATA. Salário mínimo real – Frequência mensal de 1940.07 até 2020.12. Instituto de Pesquisa Econômica Aplicada, 2021. Disponível em: <http://www.ipeadata.gov.br/ExibeSerie.aspx?serid=37667> . Acesso em: 08 de jan. de 2021.
- JAIMOVICH, N.; SIU, H. E. Job polarization and jobless recoveries. Technical Report, NBER Working Paper No. 18334. **National Bureau of Economic Research**, 2012.
- KATZ, L. F., MARGO, R. A. Technical Change and the Relative Demand for Skilled Labor: The United States in historical perspective. In: BOUSTAN, L.P.; FRYDMAN, C.; MARGO, R.A. **Human Capital in History: The American Record**. University of Chicago Press, 2014.
- KUBOTA, L. C.; MACIENTE, A. N. Propensão à automação das tarefas ocupacionais no Brasil. **Radar: tecnologia, produção e comércio exterior**, v. 61. Brasília: IPEA, 2019.
- LOBO, L. C. Inteligência Artificial e Medicina. **Revista Brasileira de Educação Médica**, v. 41, n. 2, p. 185-193, 2017.

MACEDO, G.; MONASTERIO, L. Local multiplier of industrial employment: Brazilian mesoregions (2000-2010). **Brazilian Journal of Political Economy**, 36(4), 827-839, 2016.

MACIENTE, A. N.; RAUEN, C. V.; KUBOTA, L. C. Tecnologias digitais, habilidades ocupacionais e emprego formal no Brasil entre 2003 e 2017. **Mercado de Trabalho: conjuntura e análise**, v. 66. Brasília: IPEA, 2019.

MCKINSEY GLOBAL INSTITUTE. **A Future That Works: automation, employment, and productivity**. McKinsey & Company, 2017.

Mercado de tecnologia movimentou R\$ 467,8 bilhões no Brasil em 2017. **Valor Econômico**, 20 de abril de 2018. Disponível em: <https://valor.globo.com/empresas/noticia/2018/04/20/mercado-de-tecnologia-movimentou-r-4678-bilhoes-no-brasil-em-2017.ghtml>. Acesso em: 15 de jun. 2020.

O*NET. **Content Model Reference**. O*NET Resource Center. 2019. [<https://www.onetcenter.org/content.html>]

QAISER, S.; ALI, R. Text mining: use of TF-IDF to examine the relevance of words to documents. **International Journal of Computer Applications**, v. 181, n. 1, p. 25-29, 2018.

RAIS – Relação Anual de Informações Sociais. **Manual de Orientação da RAIS – ano-base 2018**. Brasília: MTb, SPES, 2019.

RAMOS, J. Using TF-IDF to determine word relevance in document queries. **Proceedings of the first instructional conference on machine learning**, v. 242, p. 133-142, 2003.

SCHWAB, K. **The fourth industrial revolution**. Nova York: Crown Business, 2017.

SPITZ-OENER, A. Technical change, job tasks, and rising educational demands: looking outside the wage structure. **Journal of Labor Economics**, v. 24, n. 2, p. 235-270, 2006.

STEMMLER, H. Automated Deindustrialization: How Global Robotization Affects Emerging Economies - Evidence from Brazil. **CEGE Discussion Papers**, n. 382, 2020.

SULZBACH, V. N. **Essays on job polarization in the Brazilian labor market**. 2020. 112 f. Tese (Doutorado) – Universidade Federal do Rio Grande do Sul, Faculdade de Ciências Econômicas, Programa de Pós-Graduação em Economia, Porto Alegre, 2020.

TINBERGEN, J. Substitution of Graduate by Other Labour. **Kyklos**, v. 27, 217–226, 1974.

WEF – WORLD ECONOMIC FORUM. **The Future of Jobs: Employment, Skills and Workforce Strategy for the Fourth Industrial Revolution**, 2016.