

IMPACTO DA AUTOMAÇÃO NO FUTURO DO EMPREGO DO SETOR PÚBLICO: uma aplicação ao Executivo Federal brasileiro

Willian Boschetti Adamczyk¹

Leonardo Monasterio²

Adelar Fochezatto³

Resumo

Qual o impacto da automação no futuro do emprego do setor público? Com foco no Executivo Federal brasileiro, este estudo estima as ocupações e órgãos mais suscetíveis à automação com base em algoritmos de aprendizado de máquina e de processamento natural de linguagem. Inova-se ao apresentar um método objetivo para estimação de propensão à automação chamado BOT (*Bartik Occupational Tasks*), que evita o uso de classificações subjetivas ou *ad hoc*, como faz a literatura sobre o tema. Mostra-se que por volta de 20% dos servidores encontram-se em ocupações com elevado potencial a terem suas tarefas atribuídas a sistemas automatizados nas próximas décadas. Ocupações públicas com menores níveis médios de escolaridade e menores remunerações são as mais propensas à automação.

Palavras-chave: Automação; Aprendizado de máquina; Poder Executivo Federal.

Abstract

What is the impact of automation on public sector employment? Using machine learning and natural language processing algorithms, the study estimates which occupations and agencies of the Brazilian Federal Government are most susceptible to automation. We contribute to the literature by introducing BOT (*Bartik Occupational Tasks*), an objective method for estimation of automation propensity that avoids subjective or ad hoc classifications. We show that around 20% of Brazilian civil servants work on jobs with high risk of automation in the coming decades. Government occupations with lower levels of schooling and lower wages have higher propensities of automation.

Keywords: Automation; Machine Learning; Executive Government.

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 e Professor na FATENP. Agradecemos à Escola Nacional de Administração Pública – ENAP pelo apoio na realização da pesquisa “Impactos da Automação no Executivo Federal no Brasil”. E-mail: willianadamczyk@yahoo.com.br.

² Doutor em Economia, Coordenador-geral de Ciências de Dados na Escola Nacional de Administração Pública – ENAP e professor do Mestrado Profissional em Economia – IDP-Brasília. Agradeço o apoio da FAP-DF (Edital 04/2017).

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

Estudos sobre tecnologias de automação discutem mudanças futuras no mercado de trabalho, refletindo a preocupação geral com o risco de desemprego causado pela substituição de trabalhadores humanos por máquinas (ACEMOGLU; AUTOR, 2011; FREY; OSBORNE, 2017).

Apesar do volume e qualidade dessa literatura, não há registro de estudos que atentem para a distinção entre as ocupações no setor privado e as do setor público. Enquanto o setor privado possui flexibilidade para ajustar-se às mudanças tecnológicas por meio de contratações, demissões e realocação de funcionários, contando com o mecanismo de preços como sinalizador, o setor público possui maior rigidez para ajustar sua força de trabalho frente às mudanças tecnológicas. Na ausência de um mecanismo de mercado, a alocação dos trabalhadores dá-se por decisões planejadas pelo gestor público. Os conhecidos e persistentes problemas do Estado brasileiro⁴ reduzem o ritmo da incorporação das tecnologias de automação, contribuindo para a defasagem da produtividade do setor público em relação ao setor privado.

A presente pesquisa visa identificar as ocupações em que tecnologias de automação podem ser introduzidas para aumento de produtividade e redução de custos no serviço público. Para isso, apresenta a construção de algoritmos preditivos da propensão à automação das ocupações do Poder Executivo Federal no Brasil, possibilitando a análise do impacto quantitativo da automação por órgãos do funcionalismo público.

A literatura internacional (FREY; OSBORNE, 2017; ARNTZ; GREGORY; ZIERAHN, 2016, 2017) e nacional (ALBUQUERQUE *et al.*, 2019a, 2019b; KUBOTA; MACIENTE, 2019) de previsão de automação baseia-se na opinião de especialistas na área. Este trabalho inova ao aplicar um método objetivo, inspirado no *Bartik Instrument*, que permite estimar a trajetória ocupacional a partir de informações observadas do mercado de trabalho. O método aqui proposto – nomeado BOT (Bartik Occupational Tasks) – pode ser útil não só para o governo federal, mas também para outros entes federativos nacionais ou internacionais.

Algoritmos de *Natural Language Processing* (NLP) e de *Machine Learning* permitiram sintetizar e extrair informações quantitativas a partir dos textos que listam as tarefas envolvidas em cada uma das 2.627 ocupações da CBO. Esse foi o ponto de partida para a estimação da propensão à automação para as 389 ocupações do setor público. Acesso a microdados completos dos mais de 520 mil servidores registrados no SIAPE em dezembro de 2017, combinados com os textos de descrição das ocupações da Classificação Brasileira de Ocupações e informações da RAIS identificada formam a base de dados deste trabalho.

As principais contribuições do artigo expõem, em termos empíricos, um perfil detalhado, do impacto potencial da automação. Mostra-se que 20% dos servidores desempenham ocupações classificadas em alta propensão à automação. Essas ocupações costumam apresentar menores níveis de escolaridade e remuneração.

2 AUTOMAÇÃO E EMPREGO: REVISÃO DA LITERATURA

Apesar dos ganhos inegáveis de longo prazo da inovação, em breves intervalos de tempo, a introdução de tecnologias de automação pode gerar desemprego e outras tensões sociais. Assim, o desemprego tecnológico é definido como a eliminação de empregos por meio da substituição de trabalhadores por máquinas. Nesse contexto, os bens de capital podem se mostrar mais substitutos para o trabalho humano do que como seu complemento. Não há garantias, portanto, de que novas ocupações serão repostas no mesmo ritmo ou que

⁴ Ver Banco Mundial (2019).

esse ajuste será indolor (GOLDIN; KATZ, 1998). Mais recentemente, por trás da mudança de patamar tecnológico nos processos produtivos e no mercado de trabalho estão as tecnologias de computerização e de Inteligência Artificial (IA) (BRYNJOLFSSON; MCAFEE, 2014; FREY; OSBORNE, 2017).

O conceito de Inteligência Artificial é amplo e de variadas definições. A IA pode ser compreendida como "*a system's ability to interpret external data correctly, to learn from such data, and to use those learnings to achieve specific goals and tasks through flexible adaptation*" (KAPLAN; HAENLEIN, 2020, p. 4)⁵. As tecnologias que constituem a IA incluem *machine learning, reinforcement learning, artificial neural networks, deep learning, computer vision* e outras em rápido desenvolvimento (BRYNJOLFSSON; MCAFEE, 2014).

O desenvolvimento das tecnologias de inteligência artificial permite a sua extensão para o mercado de trabalho. A literatura de desemprego tecnológico⁶ oferece evidências de que a introdução de novas tecnologias de informação viabiliza automatizar tarefas executadas por trabalhadores. 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).

O horizonte das tarefas que podem ser automatizadas é difuso e se desloca progressivamente em direção às tarefas de maior complexidade. As tarefas que hoje são consideradas rotineiras não são limitantes para o avanço da tecnologia, que possuem potencial de progressão 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.

A identificação de ocupações automatizáveis em um cenário de constante evolução tecnológica é acompanhada de apreensão por parte da sociedade. Segundo Autor (2015), jornalistas e a mídia em geral tendem a superestimar o alcance da substituição de trabalho humano por máquinas e ignorar a forte complementaridade entre automação e trabalho que aumenta a produtividade, eleva salários, e incrementa a demanda por trabalho. Identificar as ocupações mais afetadas pela automação e seus impactos sobre o mercado de trabalho não é tarefa trivial e ainda não conta com literatura e metodologias consolidadas.

Pesquisas recentes trazem resultados conflitantes para a profundidade das transformações que as tecnologias podem causar como impacto 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 automatização das profissões.

⁵ "A habilidade de um sistema de interpretar dados externos corretamente, aprender com tais dados, e usar esse aprendizado para atingir objetivos específicos e tarefas por meio de flexível adaptação" (KAPLAN; HAENLEIN, 2020, p. 4). Tradução nossa.

⁶ Discussões transversais ao desemprego tecnológico e automação, mas que não são questões centrais deste estudo são as de retorno da educação e mudança tecnológica por habilidades (GRILICHES, 1969; GOLDIN; KATZ, 1998; ACEMOGLU; AUTOR, 2011; FIRPO, FORTIN; LEMIEUX, 2011), *offshorability* (BLINDER, 2009; JENSEN; KLETZER, 2010), desigualdade e polarização no mercado de trabalho (AUTOR, 2010; AUTOR; KATZ; KEARNEY, 2006; GOOS; MANNING, 2007; JAIMOVICH; SIU, 2012; GOOS; MANNING; SALOMONS, 2014).

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 o treino do 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.* (2019a, 2019b) 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 estimativa com base em ocupações oferece superestimativas 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.

Segundo, 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 estimativa 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.

Para o Brasil, Kubota e Maciente (2019) estimaram que cerca de 56,5% dos empregos formais no país possuem ocupações vulneráveis à automação, considerando tecnologias consolidadas e possíveis de implementação dentro do marco regulatório em um prazo de cinco anos. Usando 19 mil tarefas descritas na base O*NET, foi realizada 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 Maciente, Rauen e Kubota (2019) mostrou-se que, 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. A literatura indica que tarefas rotineiras de operação e controle, e dependentes de aptidões físicas tendem a perder espaço no mercado de trabalho frente as de maior qualificação. Empregando as probabilidades de automação de Albuquerque *et al.* (2019a), Maciente, Rauen e Kubota (2019) consideraram que ocupações com alta probabilidade de automação representam 29% do emprego no Brasil.

Como se vê, as estimativas existentes são discordantes para o potencial de automação no Brasil. Analisando o mercado de trabalho como um todo, os estudos não consideram as dinâmicas e especificidades diversas das ocupações do setor público em relação às ocupações

privadas. Além disso, confiam na atribuição de automação a classificações *ad hoc* ou subjetivas.

3 METODOLOGIA

3.1 Estimação da fronteira tecnológica de automação

O objetivo da estimação da fronteira tecnológica é encontrar tendências de automação no setor privado que possam ser replicadas no setor público, adotando como diferencial metodológico uma abordagem empírica de classificação das ocupações que podem ser automatizadas.

A intuição do novo método é a seguinte: parte-se da suposição de que a automação do setor público já está defasada em relação à fronteira tecnológica relevante. Mantida essa defasagem, ao menos em termos potenciais, o futuro do setor público reproduzirá as tendências recentes da fronteira relevante. A fronteira escolhida foi o estado de São Paulo entre 2010 e 2018. Porém, não basta atentar para quais ocupações apresentaram variação do nível de emprego, pois outros motivos além da automação poderiam levar a esse resultado.

Nesse sentido, emprega-se uma construção semelhante ao *Bartik Instrument*, também conhecido como *Shift-Share Instrument*. A análise *Shift-Share* permite a decomposição do crescimento do emprego local em três efeitos: nacional, estrutural e diferencial. Apesar de ser um método tradicional na área de Economia Regional (DUNN, 1960), a técnica renasceu partir dos trabalhos de Bartik (1991) e Blanchard e Katz (1992), os quais utilizam um de seus componentes como variável instrumental⁷. A decomposição do crescimento local (regional) pode ser vista como:

$$\text{Crescimento Local} = \text{Efeito Nacional} + \text{Efeito Estrutural} + \text{Efeito Diferencial} \quad (1)$$

No método *Shift-Share* regional, o efeito nacional representa a parcela do crescimento do emprego local devido ao crescimento do emprego no país como um todo. O efeito estrutural representa a mudança no emprego local resultante do crescimento do emprego a nível nacional. O efeito diferencial representa a variação no emprego por fatores internos aos locais que não são explicados pelos efeitos nacional e estrutural. No contexto de automação de ocupações, busca-se encontrar o efeito de variação do emprego nas ocupações que não é explicado pelo crescimento nacional e setorial. Esse efeito será usado como variável dependente no treino da predição de propensão à automação, condicionado às tarefas das ocupações, conforme detalhado na subseção 3.2.

Para encontrar o efeito diferencial de automação, adapta-se o método *Shift-Share* para controlar efeitos de crescimento do emprego *setorial* ao em vez de crescimento regional. A Tabela 1 representa a modificação do método *Shift-Share* regional para ocupacional devido à introdução de informações sobre setores e ocupações.

⁷ Para uma crítica ao uso do *Bartik Instrument* ver Goldsmith-Pinkham *et al.* (2018) e Jaeger *et al.* (2018). Para o caso brasileiro, o *Bartik Instrument* foi aplicado à RAIS por Dix-Carneiro (2014); Dix-Carneiro, Soares e Ulyseia (2018); Macedo e Monasterio (2016), entre outros.

Tabela 1 – Modificação do método *Shift-Share* regional para ocupacional.

a) <i>Shift-Share</i> Regional			b) <i>Shift-Share</i> Ocupacional		
	Setor 1	Setor j		Ocupação 1	Ocupação j
Região 1	a_{11}	a_{1j}	Setor 1	b_{11}	b_{1j}
Região i	a_{i1}	a_{ij}	Setor i	b_{i1}	b_{ij}

Fonte: Elaboração própria.

em que a_{ij} indica o emprego da Região i no Setor j . Em contraste, o método modificado substitui Região por Setor, e considera a categoria de Ocupação onde antes havia Setor. Assim, b_{ij} indica o emprego da Ocupação j no Setor i .

Essa mudança implica que: o *efeito nacional* passa a representar o crescimento do emprego como um todo; o *efeito estrutural*, a mudança no emprego setorial como um resultado do crescimento do setor do emprego nacional; o *efeito diferencial* representa a variação no emprego setorial devida a mudanças internas às ocupações.

Em particular, o efeito diferencial mostra alterações na distribuição dos empregos entre as ocupações após remover os efeitos de crescimento total e crescimento de cada um dos setores. Essa 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 no mercado de trabalho.

Com as estimativas de automação para a fronteira tecnológica, parte-se para a atribuição das mudanças às tarefas das ocupações e a generalização para as ocupações do Poder Executivo Federal.

3.2 Predição da propensão à automação

A abordagem adotada é atribuir o impacto da automação às tarefas que compõem cada ocupação, e não diretamente à ocupação. 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 que constituem aquela 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 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*] “analise” 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 2601 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 2341 termos ponderados para 2601 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 2601 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 diversos 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, incluindo setor privado e público. 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.* (2019a), 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).

3.3 Fontes de dados

Dentre as bases de dados relevantes para a execução do estudo destaca-se a Classificação Brasileira de Ocupações (2002), a Relação Anual de Informações Sociais (RAIS), de responsabilidade do Ministério da Economia do Brasil, e a base de dados do Sistema Integrado de Administração de Pessoal (SIAPE).

O Sistema Integrado de Administração de Pessoal (SIAPE) centraliza o processamento da folha de pagamentos dos órgãos das administrações direta, fundacional e autárquica do poder executivo que dependem do Tesouro Nacional para as suas despesas de pessoal. O SIAPE é responsável por processar o pagamento de servidores, regidos pelo Regime Jurídico Único Federal (Lei 8.112/90), pela Consolidação das Leis do Trabalho (CLT) e regimes de contratos temporários, estágios, residência médica, entre outros. A base de dados contém informação de servidores ativos, além de aposentados e pensionistas, alocados em órgãos públicos federais em todo o território brasileiro (SIAPENET, 2020).

No presente estudo considera-se apenas os servidores civis ativos, de acordo com seu vínculo principal, de carga horária igual ou superior a 40 horas semanais em dezembro de 2017. Com esse filtro, trabalha-se com as informações de 521.701 servidores, de um total de 627.284 vínculos registrados no SIAPE.

Uma dificuldade inicial foi a de compatibilizar a nomenclatura dos cargos do SIAPE, que não seguem uma padronização em termos de código, descrição ou ortografia, resultando em 1155 variações de cargos. A fim de obter um padrão, atribui-se aos cargos do Executivo Federal os códigos e títulos da Classificação Brasileira de Ocupações (2002), por meio da correspondência entre o CPF do servidor no SIAPE e na RAIS Identificada de 2017. Refina-se os resultados considerando o CBO modal para cada cargo do SIAPE⁸, seguido de uma inspeção visual da correspondência entre a descrição das atividades das ocupações na CBO e descrição das atividades dos cargos. A compatibilização resulta em 389 ocupações públicas distintas.

A Classificação Brasileira de Ocupações descreve e ordena as ocupações dentro de uma estrutura hierárquica, possibilitando que a sistematização de informações referentes à força de trabalho, de acordo com suas características ocupacionais e a natureza e conteúdo do trabalho. Descreve as funções, obrigações e tarefas que constituem cada ocupação, trazendo também o conteúdo do trabalho em termos do conjunto de conhecimentos, habilidades e requisitos exigidos para o exercício de cada ocupação (CONCLA, 2019).

⁸ Agradecemos a Danilo Cardoso, Flávio da Vitoria e Pedro Masson, da coordenação geral de Ciência de Dados da ENAP, pelo apoio no acesso e na compreensão da base identificada do SIAPE.

Para a estimação da fronteira tecnológica de automação empregou-se os dados da Relação Anual de Informações Sociais (RAIS). A RAIS é reconhecida como uma das fontes estatísticas mais confiáveis sobre o mercado de trabalho formal no Brasil (DIX-CARNEIRO, 2014). Os microdados constituem um registro administrativo que pode ser visto como um censo do mercado de trabalho formal (RAIS, 2019).

A seção seguinte expõe os resultados encontrados para a estimação da fronteira tecnológica de automação, que serve para a construção da medida de propensão à automação com base nas tarefas das ocupações.

4 ESTIMAÇÃO DA 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, entre 2010 e 2018.

Considera-se São Paulo como a fronteira tecnológica brasileira, por possuir segunda maior renda média entre os estados (IBGE, 2019), atuar como *hub* de contato internacional com elevado número de empresas multinacionais e do setor de tecnologia, ao concentrar 69,5% do total investido pelos estados brasileiros em pesquisa e desenvolvimento (INVESTESP, 2020) e 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 em 2010, e 17 milhões de vínculos em 2018, uma variação de -5,6%. Tal decréscimo no número de empregos pode estar relacionado à elevação da taxa de desocupação em relação ao ano inicial, de acordo com tendências crescentes no desemprego observados na Pesquisa Mensal do Emprego (PME) e (IBGE, 2019).

As variações no nível de emprego não afetam de maneira homogênea os diferentes setores da economia e suas ocupações. Assim, 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.

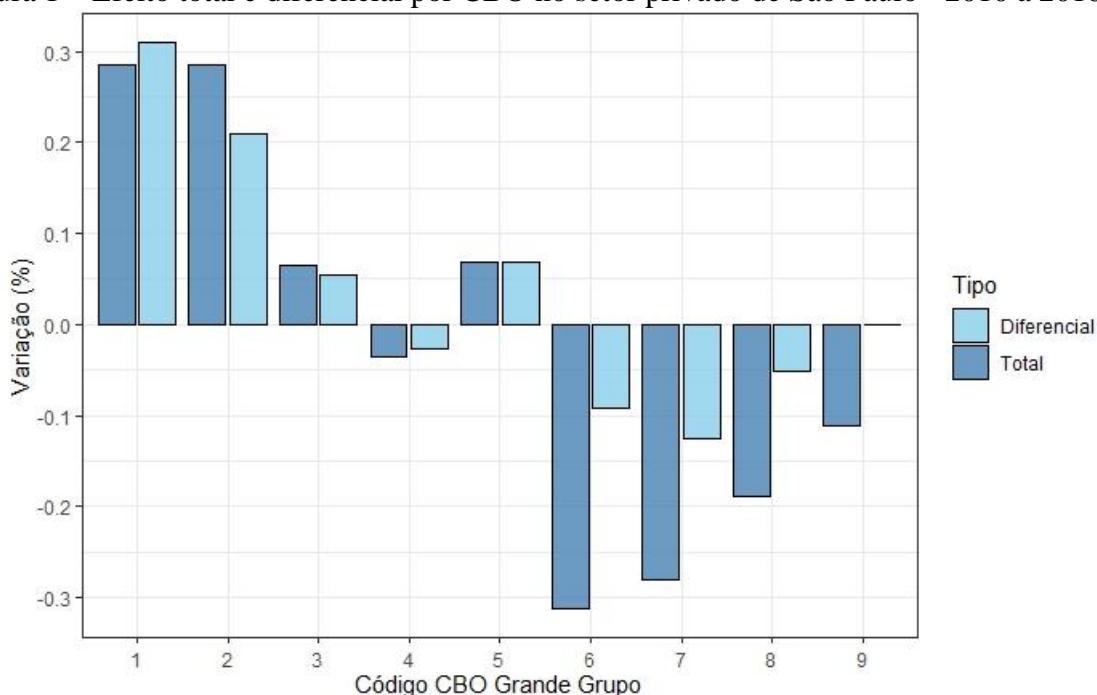
A Figura 1 contrasta o crescimento do emprego verificado em cada setor (Efeito Total) com o crescimento no emprego independentemente do crescimento setorial (Efeito Diferencial). A variação diferencial foi estimada pelo método BOT exposto na subseção 3.1 da Metodologia e Dados.

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%).

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%).

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.

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.

Considera-se que os resultados obtidos com o método BOT condizem com os efeitos de automação apontados por estudos realizados para os Estados Unidos e países da OCDE e baseados na opinião de especialistas. Dessa forma, usa-se o efeito diferencial estimado para classificar as ocupações mais propensas à automação, atribuindo esse efeito às diferentes

tarefas exercidas em cada uma das ocupações. Para isso, calcula-se o efeito diferencial para 49 subgrupos principais de ocupações, de acordo com a desagregação dada pela categorização de dois dígitos da CBO 2002. A Figura 2 esquematiza os procedimentos de estimação do estudo:

Figura 2 – Etapas de estimação da propensão à automação no Executivo Federal.



Fonte: Elaboração própria.

Em resumo, a RAIS de São Paulo é usada para encontrar o efeito diferencial por meio da modificação ocupacional do método *Shift-Share*, enquanto a Matriz de Atividades da CBO passa pela análise TF-IDF. Os resultados de efeito diferencial e TF-IDF se unem para a construção do método BOT, que estima a propensão à automação por meio de *Random Forest Regression*. O modelo é então usado para encontrar o impacto da automação sobre as ocupações do Executivo Federal, cujas informações provêm da base de dados do SIAPE. Nessa etapa, investiga-se o impacto sobre a qualificação e quantidade de servidores em cada ocupação e sua distribuição nos diferentes órgãos.

5 RESULTADOS DE AUTOMAÇÃO PARA OCUPAÇÕES DO EXECUTIVO FEDERAL

Na presente seção analisa-se a propensão à automação estimada nas seções anteriores, mostrando as estatísticas descritivas das ocupações no Executivo Federal (5.1), o impacto geral da automação sobre as ocupações (5.2) e o impacto da automação por órgão superior (5.3).

5.1 Estatísticas descritivas das ocupações do Executivo Federal

A Tabela 1 apresenta as estatísticas descritivas das variáveis quantitativas e qualitativas dos servidores analisados na pesquisa. Nota-se que a média de estudo é de 15,3 anos, com um mínimo de 8 anos (ensino fundamental completo) a um máximo de 21 anos (doutorado). A variável de escolaridade descreve as categorias da maior titulação declarada pelo servidor. A maior parte dos servidores possui ensino superior completo (36%), seguido de ensino médio (20%), doutorado (19%) e mestrado/MBA (19%), e ensino fundamental (5%).

A idade média dos servidores é de 46,7 anos, variando entre 18 e 90 anos, com um desvio padrão de 11,65 anos. Entre 30 e 50 anos estão 49,7% dos servidores, com 41,9% entre 50 e 70 anos, 8,1% entre 18 e 30 anos, e apenas 0,4% acima de 70 anos.

Tabela 1 – Estatísticas descritivas dos servidores na base do SIAPE – dezembro de 2017.

Variável	Mínima	Mediana	Média	Máxima	Desvio Padrão
Anos de Estudo	8,00	15,00	15,35	21,00	3,68
Idade	18,00	47,00	46,70	90,00	11,65
Remuneração Mensal (R\$)	0,00	8.078	9.913	50.299	6.202

Escolaridade	Quant.	%	Idade	Quant.	%	Remuneração (em mil R\$)	Quant.	%
Fundamental	28.396	5,4	18 --- 30	42.043	8,1	0 --- 10	314.593	60,3
Médio	106.141	20,3	30 --- 50	259.273	49,7	10 --- 20	162.438	31,1
Superior	187.932	36,0	50 --- 70	218.346	41,9	20 --- 30	43.295	8,3
Mestrado ou MBA	97.937	18,8	70 --- 90	2.039	0,4	30 --- 40	1.358	0,3
Doutorado	101.295	19,4				40 --- 50	17	0,003
Total	521.701	100		521.701	100		521.701	100

Fonte: Elaboração própria.

A remuneração média mensal é de R\$ 9.913, com uma mediana de R\$ 8.078 e desvio padrão de R\$ 6.202. A maior parte dos servidores, 60,3% recebem até R\$ 10 mil, 31,1% entre R\$ 10 mil e R\$ 20 mil, 8,3% entre R\$ 20 mil e 30 mil, 0,3% entre R\$ 30 mil e R\$ 40 mil, e 0,003% acima de R\$ 40 mil. Dentre as maiores remunerações, 17 servidores receberam acima de R\$ 40 mil, nas ocupações de ministros, delegados e médicos.⁹

5.2 Impacto da automação sobre as ocupações do Executivo Federal¹⁰

Avalia-se então o impacto quantitativo da automação sobre as ocupações do Executivo Federal a partir das estimativas para a propensão à automação obtidas considerando a fronteira tecnológica de automação. Atribui-se o rótulo de “alta propensão à automação” às ocupações no quartil superior da distribuição de ocupações públicas, ou seja, 96 das 389 ocupações.

De maneira desagregada, apresenta-se as ocupações da maior à menor propensão, bem como a quantidade e características de escolaridade e remuneração dos servidores. O resultado de propensão à automação estimado para as ocupações do Executivo Federal 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 3.a) mostra a distribuição de ocupações em relação à propensão de automação, ou seja, representa o número de ocupações situadas em cada faixa. As ocupações na cor azul escuro, acima de 0,87 representam as 96 ocupações em alta propensão à automação. Para fins de visualização, omitiu-se as 12 ocupações dispersas abaixo de 0,6.

A Figura 3.b) mostra a distribuição do número de servidores ao longo da propensão à automação. Do total de 521.701 servidores analisados, considera-se que 104.670, ou seja, 20% do total de servidores encontram-se em ocupações consideradas de alta propensão à automação, representados na porção azul mais escura do gráfico.

⁹ Há 6.877 registros que apresentam salários zerados, mas que se referem a servidores que recebem seus pagamentos por sistemas alternativos ao SIAPE, por exemplo médicos residentes e integrantes do programa Mais Médicos.

¹⁰ A relação completa de Propensão à Automação das Ocupações do Executivo Federal pode ser consultada em: https://willba.shinyapps.io/view_auto/.

Figura 3 – Distribuição de ocupações e servidores por propensão à automação.



Fonte: Elaboração própria.

Analisando-se a distribuição dos servidores nas ocupações, com uma propensão à automação calculada entre 0,87 a 0,88 há 90.696 servidores, em 15 ocupações. Nessa faixa, encontram-se ocupações com grande quantidade de servidores, como assistente administrativo (73.208 servidores), auxiliar de escritório (8.022) e datilógrafo (4.559). Isso explica o pico observado no gráfico de distribuição da quantidade (2.b). Para as ocupações entre 0,87 e 0,88 os anos médios de estudo são de 13,77, com remuneração média de R\$ 5.724.

De 0,88 a 0,95 são 34 ocupações, que somam 9.063 servidores. Destaca-se nessa faixa as ocupações de motorista de furgão ou veículo similar (4.703), trabalhador agropecuário em geral (1.511) e auxiliar de biblioteca (1.123). Na faixa mais elevada, a partir de 0,95, são 41 ocupações, com um total de 3.932 servidores. A escolaridade nessa faixa é de 10,82 anos de estudo, com remuneração média de R\$ 5.275. Destaca-se as ocupações de carpinteiro (687), servente de obras (441) e pedreiro (306). A escolaridade nessa faixa é de 11,67 anos, com uma remuneração média de R\$ 5.452.

Assim, ao realizar-se a comparação entre o grupo de ocupações consideradas em alta propensão com as demais, a média de escolaridade para as de alta é de 13,42 anos, em relação a 15,83 para as demais. Em relação a remuneração, a média é de R\$ 5.683 para as ocupações de alta, comparadas à R\$ 10.975 para as demais. Dessa forma, mostra-se que as ocupações em alta propensão à automação são as que possuem menor nível de escolaridade e menor média salarial.

A Tabela 2 traz as ocupações com mais de 50 trabalhadores ordenadas de forma decrescente, a partir da mais propensa à automação. Considera-se a quantidade de servidores acima de 50 pois há diversas ocupações com um baixo número de servidores não relevantes para análise. Mostra-se ainda a quantidade de servidores do Executivo Federal em cada ocupação, os anos médios de estudo e a remuneração média desses servidores.

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

Título da Ocupação	Código CBO	Propensão Automação	Quantidade	Anos de Estudo	Remuneração Média
Técnico de sistemas audiovisuais	373130	0,9845	58	10,78	4.991
Assistente de operações audiovisuais	373145	0,9845	88	11,28	5.941
Operador de mídia audiovisual	373105	0,9845	51	12,78	4.630
Cenotécnico (cinema, vídeo, televisão, teatro e espetáculos)	374205	0,9814	89	13,76	7.546
Técnico em programação visual	371305	0,9780	291	16,35	7.346
Técnico gráfico	371310	0,9757	267	13,08	6.083
Armador de estrutura de concreto armado	715315	0,9736	285	12,29	7.830
Pedreiro	715210	0,9732	306	9,91	4.189
Pintor de obras	716610	0,9731	223	10,06	4.344
Carpinteiro	715505	0,9727	687	10,37	5.697

*Ocupações com número de servidores acima de 50.

Fonte: Elaboração própria.

Observa-se a predominância de ocupações técnicas de sistemas audiovisuais e gráfica, além de servidores da construção civil, como armador, pedreiro, pintor e carpinteiro. Em geral, são ocupações de baixa escolaridade e todas com remuneração abaixo da média de R\$ 9.913 para o total de ocupações. Essa tendência está em linha com a conclusão de outras pesquisas 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.*, 2019a).

A Tabela 3 traz as ocupações com mais de 50 trabalhadores ordenadas de forma crescente, a partir da menos propensa à automação, com as respectivas quantidades de trabalhadores do Executivo Federal em cada ocupação, os anos médios de estudo, a remuneração média desses servidores.

Tabela 3 – Ocupações ordenadas por propensão à automação – crescente*.

Título da Ocupação	Código CBO	Propensão Automação	Quantidade	Anos de Estudo	Remuneração Média
Pesquisador de engenharia elétrica e eletrônica	203215	0,3966	453	18,99	14.454
Pesquisador de engenharia e tecnologia (outras áreas da engenharia)	203210	0,3966	198	17,04	11.750
Pesquisador em saúde coletiva	203320	0,4009	2675	19,23	16.253
Pesquisador em ciências sociais e humanas	203505	0,4060	4478	18,61	15.277
Pesquisador em ciências da educação	203515	0,4060	252	17,52	11.469
Pesquisador em metrologia	201205	0,4184	518	17,95	15.709
Perito criminal	204105	0,5590	1089	15,02	27.112
Biólogo	221105	0,6341	438	17,68	10.516
Gerente de serviços de saúde	131210	0,6638	800	17,38	13.582
Psicólogo clínico	251510	0,6704	1784	16,53	8.660

*Ocupações com número de servidores acima de 50.

Fonte: Elaboração própria.

Verifica-se dentre as ocupações com menor propensão à automação profissionais de alta escolaridade e elevada remuneração, como pesquisadores de áreas diversas, perito criminal, gerência de serviços de saúde e psicólogo clínico.

As atividades mais comuns entre os pesquisadores são as que envolvem desenvolvimento de novos materiais, produtos, processos e métodos, conforme descrição da CBO 2002. 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 elementos de criatividade e inovação para que sejam executados. Atividades de disseminação de conhecimento também são centrais às atividades de pesquisadores, ao orientar trabalhos de pesquisa, coordenar seminários, congressos e cursos em geral para capacitar equipes e futuros pesquisadores.

Ainda, entre as ocupações com mais baixa propensão à automação estão profissionais do conhecimento relacionados às ciências sociais e da saúde, como economistas, sociólogos, geógrafos, biólogos, psicólogos e antropólogos. Profissionais de engenharia, gestão e comunicação como gerentes de produção e de serviços de saúde, relações públicas, publicitários e redatores. 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.

5.3 Impacto da automação por órgão superior

Após a investigação das ocupações em nível desagregado, é de interesse analisar a distribuição dos impactos da automação por órgão superior do Executivo Federal. Dadas as diferenças na demanda por profissionais dentro de cada órgão, como foco em diferentes áreas como educação, saúde ou segurança, o impacto da automação é heterogêneo entre os órgãos.

O SIAPE apresenta informações para 27 órgãos superiores aos quais estão vinculados 208 órgãos que incluem: universidades e institutos federais, previdência e seguridade social, agências de inteligência e polícia, agências de controle, regulação e fiscalização, fundações e instituições de pesquisa e fomento, entre outros órgãos da administração pública. Exclui-se da análise os militares e sociedades empresárias.

Ressalva-se a presença de ministérios e ocupações remodeladas em anos posteriores à base de dados do SIAPE, de dezembro de 2017. A exemplo de datilógrafo, ocupação com elevado número de servidores, mas cujos cargos vagos e que vierem a vagar ficaram extintos, com vedação de abertura de novo concurso público, a partir do Decreto nº 9.262/2018 (BRASIL, 2018).

A Tabela 4 traz o resumo dos impactos de automação nos cinco órgãos superiores com maior número de servidores no Executivo Federal. A última linha da Tabela 4 traz o resultado para o conjunto de todos os servidores, em que 104.670 dos 521.701 servidores analisados estão em ocupações com alta propensão à automação, ou seja, 20,1%. Em termos da remuneração em dezembro de 2017, os servidores em alta automação representam R\$ 595 milhões do total de R\$ 5.172 milhões, ou seja, 11,5% da remuneração total do Executivo Federal.

Identifica-se o Ministério da Educação (MEC) como o órgão superior com o maior número de servidores, assim como o maior número em ocupações com alta propensão à automação: 78 de 272 ocupações que compõe o órgão. Nessas ocupações estão 47.296 do total de 252.272 servidores, ou seja, 18,8%. Em termos salariais, são 9,5% do total da remuneração em ocupações em alta propensão.

Tabela 4 – Impacto da automação por órgão superior do Executivo Federal.

Órgão Superior	Quantidade Automação	Quantidade Total	Percentual Automação	Massa Salarial Automatizada (milhões R\$)	Massa Salarial (milhões R\$)	Percentual Automatizada
Ministério da Educação	47.296	252.272	18,8%	222	2.337	9,5%
Ministério da Saúde	11.904	66.465	17,9%	72	474	15,3%
Min. do Desen. Social	1.727	32.358	5,3%	17	331	5,1%
Ministério da Fazenda	5.295	29.815	17,8%	30	489	6,1%
Ministério da Justiça	3.816	29.273	13,0%	23	400	5,7%
Outros (22)	34.632	111.518	31,1%	231	1.141	20,2%
TOTAL	104.670	521.701	20,1%	595	5.172	11,5%

Fonte: Elaboração própria.

Dentre as ocupações do Ministério da Educação classificadas como em alta propensão à automação estão: assistente administrativo (33.418), auxiliar de escritório (6.189), auxiliar de biblioteca (1.112), trabalhador agropecuário em geral (906), motorista de furgão ou veículo similar (701) e outras 73 ocupações que contém 4.970 servidores. Os servidores nos cargos de assistente administrativo, auxiliar de escritório e motorista de furgão ou veículo similar ocupam posições de destaque entre as com maiores quantidades de servidores em alta propensão à automação nos demais Ministérios.

O Ministério da Saúde (MS) contém 26 das 129 ocupações em alta propensão à automação, o que representa 11.904 do total de 66.465 servidores, ou seja, 17,9%. É seguido na quantidade total de servidores por Ministério do Desenvolvimento Social (MDS), com 1.727 do total de 32.358 servidores, 5,3%, do Ministério da Fazenda (MF), com 5.295 do total de 29.815 servidores, 17,8% e do Ministério da Justiça (MJ), com 3.816 do total de 29.273 servidores, 13%.

Em geral, a ênfase no impacto quantitativo revela as ocupações mais propensas à automação com maior quantidade de servidores. As ocupações classificadas em alta propensão à automação estão abaixo da média de escolaridade e abaixo da média de remuneração do Executivo Federal como um todo: 15,4 anos e R\$ 9.913. Essa análise vai ao encontro da literatura de automação, mostrando que as ocupações no serviço público com menores níveis médios de escolaridade e menores remunerações são mais propensas à automação.

6 CONSIDERAÇÕES FINAIS

A presente pesquisa estimou a propensão à automação das ocupações do Poder Executivo Federal no Brasil, permitindo a análise do impacto da automação por ocupações e órgãos do funcionalismo público. Trata-se do primeiro estudo sobre automação de que se tem notícia em que o foco foi o emprego público. Vale notar que a metodologia aqui desenvolvida pode ser aplicada a outras esferas e poderes do setor público brasileiro ou mesmo de outros países.

Além dos resultados obtidos, este estudo inova ao apresentar um método de estimação, intitulado *Bartik Occupational Tasks* – BOT, que permite estimar a propensão a automação sem contar com critérios subjetivos. O pressuposto do método é que o setor público segue, com defasagem, as tendências de automação do setor privado na fronteira tecnológica do país.

A partir das tendências de automação encontradas para as ocupações no setor privado, mostrou-se que mais de cem mil dos 521.701 servidores do Executivo Federal estudados desempenham ocupações em alta propensão à automação. Assim, 20% do total de servidores

encontram-se em ocupações com elevado potencial a terem suas tarefas atribuídas à sistemas automatizados no futuro próximo.

As ocupações com maior propensão à automação são ocupações técnicas de sistemas audiovisuais e gráfica, além de servidores da construção civil, como armador, pedreiro, pintor e carpinteiro. Em geral, essas ocupações possuem baixa escolaridade e remuneração abaixo da média, de R\$ 9.913. Essa conclusão está em linha com a literatura que considera 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.*, 2019a).

As ocupações com baixa propensão à automação são aquelas que, em geral, exigem alta intensidade de tarefas analíticas ou pouco repetitivas. Entre elas estão as constituídas por pesquisadores e profissionais relacionados às ciências naturais, sociais e da saúde, como engenheiros, economistas, sociólogos, geógrafos, biólogos, psicólogos e antropólogos. Ainda, há profissionais de gestão e comunicação como gerentes de produção e de serviços de saúde, relações públicas, publicitários e redatores. Essas ocupações são consideradas de alta qualificação e alta remuneração.

O impacto quantitativo da automação no setor público mostrou-se expressivo devido ao elevado número de profissionais em ocupações de alta propensão à automação, como assistentes administrativos, auxiliares de escritório, de biblioteca e motoristas. Em termos orçamentários, relativo a dezembro de 2017, os servidores em alta automação receberam uma massa salarial de R\$ 594 milhões do total de R\$ 5,2 bilhões da folha mensal do Executivo Federal, ou seja, 11,5% do total.

REFERÊNCIAS

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

ALBUQUERQUE, P. H. M.; SAAVEDRA, C. A. P. B.; MORAIS, R. L. de; ALVES, P. F.; PENG, Yaohao. Na era das máquinas, o emprego é de quem? Estimativa da probabilidade de automação de ocupações no Brasil. **Texto para Discussão 2457**. Instituto de Pesquisa Econômica Aplicada – IPEA, 2019b.

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

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

ARNTZ, Melanie; GREGORY, Terry; ZIERAHN, Ulrich. 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., KATZ, L. F.; KEARNEY, M. S. The polarization of the US labor market. **The American economic review**, v. 96, n. 2, p. 189-194, 2006.

- AUTOR, D. The polarization of job opportunities in the US labor market: Implications for employment and earnings. **Center for American Progress and The Hamilton Project** 6, p. 11-19, 2010.
- 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.
- BARTIK, T. J. **Who Benefits from State and Local Economic Development Policies?** Kalamazoo, Michigan: W. E. Upjohn Institute for Employment Research, 1991.
- BANCO MUNDIAL. **Gestão de Pessoas e Folha de Pagamentos no Setor Público Brasileiro: o Que Os Dados Dizem**. Brasília: Banco Mundial, 2019
- 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. **Decreto nº 9.262, de 9 de janeiro de 2018**. Extingue cargos efetivos vagos e que vierem a vagar dos quadros de pessoal da administração pública federal, e veda abertura de concurso público e provimento de vagas adicionais para os cargos que especifica. Diário Oficial da União, v. 7, p. 5-42, 2018.
- 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.
- 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/por-tema/ocupacao/classificacao-brasileira-de-ocupacoes.html> . Acesso em: 22 de jun. 2020.
- DIX-CARNEIRO, R. Trade liberalization and labor market dynamics. **Econometrica**, v. 82, n. 3, p. 825-885, 2014.
- DIX-CARNEIRO, Rafael; SOARES, Rodrigo R.; ULYSSEA, Gabriel. Economic shocks and crime: Evidence from the brazilian trade liberalization. **American Economic Journal: Applied Economics**, v. 10, n. 4, p. 158-95, 2018.
- DUNN, E. S. A statistical and analytical technique for regional analysis. **Papers in Regional Science**, v. 6, n. 1, p. 97-112, 1960.
- FIRPO, S.; FORTIN, N. M.; LEMIEUX, T. Occupational tasks and changes in the wage structure. **IZA Discussion Paper**, n. 5542, 2011.

FREY, Carl B.; OSBORNE, Michael A. 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.

GRILICHES, Z. Capital-Skill Complementarity. **The Review of Economics and Statistics**, 51(4), 465–468, 1969.

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.

JAEGER, D. A.; RUIST, J.; STUHLER, J. Shift-share instruments and the impact of immigration. **National Bureau of Economic Research**, 2018.

JAIMOVICH, N.; SIU, H. E. Job polarization and jobless recoveries. Technical Report, NBER Working Paper No. 18334. **National Bureau of Economic Research**, 2012.

JENSEN, J. B.; KLETZER, L. G. Measuring the task content of offshorable services jobs, tradable services and job loss. **Labor in the New Economy**, p. 309-335, 2010.

KAHNEMAN, D. **Thinking, fast and slow**. Macmillan, 2011.

KAPLAN, A.; HAENLEIN, M. Rulers of the world, unite! The challenges and opportunities of artificial intelligence. **Business Horizons**, 63(1), p. 37-50, 2020.

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.

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.

SIAPENET. **Portal Siapenet**. Apresentação. Disponível em:

www.siapenet.gov.br/portal/servico/Apresentacao.asp. Acesso em: 13 maio 2020.

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.

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