

Os efeitos do Programa Bolsa Família (PBF) no mercado de trabalho: uma análise com *Causal Forest*

Renilson Rodrigues da SILVA¹

renilsonsilva@ufsj.edu.br |  ORCID: <https://orcid.org/0000-0003-1013-0231>

Resumo

Este estudo investiga o impacto do Programa Bolsa Família (PBF) em três desfechos: a probabilidade de estar empregado, a probabilidade de ter carteira de trabalho assinada e a quantidade de horas trabalhadas. Utilizando o método *Causal Forest* e dados do segundo trimestre de 2023 da PNAD Contínua, os resultados mostram que beneficiários do PBF têm menor probabilidade de estar empregados, especialmente em empregos formais, e trabalham menos horas semanalmente. Os efeitos variam entre grupos. Mulheres, indivíduos com 30 anos ou mais e residentes urbanos são os mais afetados, com maiores reduções na formalização e nas horas trabalhadas.

Palavras-chave

Programa Bolsa Família (PBF), *Causal Forest*, Heterogeneidade dos efeitos.

The effects of the Bolsa Família Program (PBF) on the labor market: an analysis using *Causal Forest*

Abstract

This study examines the impact of the Bolsa Família Program (PBF) on three outcomes: the likelihood of employment, the probability of holding a formal employment contract, and the number of hours worked. Using the *Causal Forest* method and data from the second quarter of 2023 of the PNAD Contínua, the results indicate that PBF beneficiaries are less likely to be employed, particularly in formal jobs, and tend to work fewer hours per week. The effects vary across demographic groups, with women, individuals aged 30 or older, and urban residents experiencing the most significant reductions in formal employment and hours worked.

Keywords

Bolsa Família Program (PBF), *Causal Forest*, Heterogeneity of effects.

JEL Classification

I38. J01. C21.

¹ Universidade Federal de São José del-Rei(UFSJ), Departamento de Ciências Econômicas, São José del-Rei, MG, Brasil.

Recebido: 12/02/2025.

Revisado: 31/10/2025.

Aceito: 12/03/2026.

DOI: <https://doi.org/10.1590/1980-53575625rrs>



This Article is Distributed Under the Terms of the Creative Commons Attribution 4.0 International License.

1. Introdução

Os Programas de Transferência Condicional de Renda (TCR) emergem como pilares fundamentais no combate à pobreza e à desigualdade social, proporcionando suporte financeiro a famílias vulneráveis globalmente (World Bank 2009). No Brasil, o Programa Bolsa Família (PBF), implementado em 2004, tem se consolidado como uma das políticas sociais mais abrangentes, impactando milhões de indivíduos. Sua relevância vai além do auxílio financeiro, ao atuar também como uma rede de proteção social que fomenta o desenvolvimento humano e a inclusão. Contudo, a literatura acerca dos impactos desses programas no mercado de trabalho é notavelmente diversificada. Muitas vezes, essa literatura é polarizada pela controvérsia do ‘efeito preguiça’ – a ideia de que a assistência financeira poderia desencorajar a procura por emprego ou a formalização laboral.

Embora existam diversos estudos nacionais e internacionais que investigam a relação entre o PBF e o mercado de trabalho, não há consenso claro na literatura sobre seus efeitos, e os resultados permanecem objeto de debate. A discussão permanece incerta e sem um acordo claro entre os estudiosos. Algumas pesquisas sugerem que o programa não afeta negativamente a participação na força de trabalho ou até mesmo promove o emprego formal, como mostram Soares, Ribas e Osario (2010) e Gerard, Naritomi e Silva (2021). De outro lado, há pesquisas que apontam para uma redução na oferta de trabalho – especialmente em setores formais – e um aumento da informalidade, conforme Vidigal (2026) e Ribas e Soares (2011).

Essa heterogeneidade de resultados reflete a complexidade dos efeitos dos programas de transferência condicionada de renda sobre o mercado de trabalho. Também evidencia os desafios metodológicos envolvidos em identificar variações desses efeitos entre diferentes subgrupos populacionais. Além disso, permanece uma lacuna na avaliação dos impactos do PBF no contexto pós-pandemia da COVID-19, período marcado por transformações relevantes no mercado de trabalho.

Este estudo busca preencher essa lacuna crítica, investigando os efeitos heterogêneos do Programa Bolsa Família no mercado de trabalho brasileiro. A ênfase está no contexto de recuperação econômica pós-pandemia. Para tanto, emprega-se a metodologia *Causal Forest*, uma técnica sofisticada de *machine learning*. O *Causal Forest* destaca-se pela sua capacidade de identificar e estimar com precisão os efeitos causais de tratamento em

diferentes subgrupos. Essa abordagem supera as limitações dos métodos tradicionais na modelagem da heterogeneidade. Os dados utilizados referem-se ao segundo trimestre de 2023 da PNAD Contínua (IBGE). Este é o suplemento mais recente com informações detalhadas sobre benefícios sociais e condições domiciliares.

O foco do presente artigo recai sobre três desfechos principais: a probabilidade de estar empregado, a probabilidade de possuir carteira de trabalho assinada e a quantidade de horas trabalhadas. Os resultados mostram impactos heterogêneos no mercado de trabalho, variando conforme o valor do benefício e características demográficas. Dessa forma, eles podem auxiliar no desenho de políticas públicas mais eficazes, capazes de conciliar a proteção social com o incentivo à inclusão produtiva e à formalização do emprego, especialmente para os grupos mais vulneráveis.

O restante do artigo está organizado da seguinte forma: a seção subsequente apresenta a revisão de literatura pertinente. Em seguida, detalhamos a metodologia empregada, incluindo a base de dados e a aplicação do método *Causal Forest*. A seção de resultados discute os achados empíricos, e, por fim, as considerações finais sintetizam as principais conclusões e suas implicações para a política econômica.

2. Revisão de literatura

Os programas de transferência condicional de renda (TCR) são uma estratégia globalmente reconhecida para mitigar a pobreza e promover o desenvolvimento humano. No Brasil, o Programa Bolsa Família (PBF) se destaca como uma das maiores e mais impactantes políticas sociais. Contudo, o recebimento desses auxílios financeiros é frequentemente objeto de intenso debate. A crítica mais comum refere-se ao argumento de que tais auxílios desestimulam o trabalho, um fenômeno conhecido como “efeito preguiça”. A teoria econômica clássica, conforme apontado por Borjas (2016), indica que o aumento da renda não laboral pode, efetivamente, reduzir a oferta de trabalho. Isso acontece porque os indivíduos tendem a maximizar sua utilidade alocando seu tempo entre trabalho e lazer.

2.1. O debate sobre os efeitos dos programas de transferência de renda no mercado de trabalho: oferta de trabalho e “efeito preguiça”

A literatura empírica sobre os impactos dos TCRs no mercado de trabalho é vasta e, de fato, carece de consenso, refletindo a complexidade de se isolar e medir esses efeitos.

Por um lado, há diversos estudos indicando que os programas de transferência de renda não geram um desincentivo significativo à participação na força de trabalho. Em alguns casos, podem até mesmo apresentar impactos positivos. Soares, Ribas e Osario (2010) argumentam que o PBF não tem impacto negativo na participação laboral. Essa perspectiva é corroborada por Foguel e Barros (2010), que analisam dados de 2001 a 2005. Os autores constataam que as TCRs no Brasil não alteram a média de horas trabalhadas pelos homens, embora possam diminuir as horas trabalhadas das mulheres, sem afetar sua taxa de participação geral. Em uma perspectiva mais ampla, Gerard, Naritomi e Silva (2021) propõem que o Bolsa Família pode fomentar economias locais, além de incentivar a geração de empregos formais. Isso se deve aos efeitos multiplicadores que, por muitas vezes, superam possíveis desincentivos individuais. Adicionalmente, Fruttero, Leichsenring e Paiva (2020), assim como Barbosa e Corseuil (2014), identificam evidências de que o programa pode ter impacto positivo na entrada no mercado de trabalho formal. Esse efeito é especialmente significativo para jovens, sem influenciar a escolha ocupacional entre os setores formal e informal. Mais recentemente, Nazareno e De Castro Galvao (2023) destacam que programas como o PBF podem manter ou até aumentar a participação na força de trabalho durante crises.

Por outro lado, uma corrente de estudos identifica efeitos negativos ou ambíguos dos TCRs sobre o mercado de trabalho, particularmente no que tange à formalização e à intensidade do trabalho. Vidigal (2026) destaca que a participação no PBF eleva a oferta de trabalho na margem extensiva, com um maior número de pessoas em busca de emprego. Entretanto, ocorre uma diminuição na margem intensiva, refletindo em menos horas trabalhadas e um crescimento do emprego informal, principalmente entre mulheres. Ribas e Soares (2011) corroboram que, em áreas metropolitanas, o PBF pode diminuir a participação na oferta de trabalho da principal fonte de renda, sugerindo um potencial dependência. Brauw *et al.* (2015) apontam para uma realocação substancial de horas do trabalho formal para o informal em áreas urbanas. Essas tendências não são exclusivas do

Brasil, com achados semelhantes em países como Quênia, Malawi, México, Nicarágua, Paquistão e Uruguai, conforme revisado por Alzúa, Cruces e Ripani (2013) Salud y Alimentación (PROGRESA, Asfaw *et al.* (2014), Amarante *et al.* (2011), Hasan (2010), Géron (2022), Covarrubias, Davis e Winters (2012).

Essa polaridade de resultados na literatura evidencia que os impactos dos TCRs não são lineares ou universais. Esses impactos variam conforme uma série de fatores contextuais e as características individuais dos beneficiários. É evidente a necessidade de ampliar a compreensão acerca da interação desses programas com as realidades socioeconômicas específicas. Ademais, é fundamental analisar como seus efeitos se manifestam de forma diferenciada entre os diversos grupos populacionais.

2.2. Evidências empíricas, heterogeneidade dos efeitos e lacuna de pesquisa

Tradicionalmente, a avaliação de impacto de programas sociais, incluindo o PBF, tem-se valido de métodos como o *Propensity Score Matching* (PSM). O PSM, conforme demonstrado por Cedeplar, SAGI e MDS (2007) e diversos trabalhos subsequentes como Duarte, Sampaio e Sampaio (2009) esses programas visam aliviar os problemas decorrentes da situação de pobreza, sendo que, no longo prazo, o objetivo é investir no capital humano, quebrando o ciclo intergeracional da pobreza. Estudos têm sido realizados para avaliar os impactos desses programas sobre variáveis como frequência escolar, trabalho infantil, gastos com alimentação, entre outros. Este trabalho avalia o impacto da transferência de renda do Programa Bolsa Família sobre os gastos com alimentos de famílias rurais. As estimações foram feitas com base no método de Propensity Score Matching (PSM, Foguel e Barros (2010), Ribas e Soares (2011), Barbosa e Corseuil (2014), Brauw *et al.* (2015), Olson *et al.* (2019), Fruttero *et al.* (2020), Araújo *et al.* (2021), Marx (2023) e Silva (2023), busca equilibrar grupos de tratamento e controle para estimar o efeito médio do tratamento. Contudo, uma limitação dessa abordagem, assim como em outros modelos paramétricos tradicionais, é a dificuldade em capturar a heterogeneidade dos efeitos do tratamento. Essa questão pode comprometer os resultados e as conclusões obtidas a partir da análise. Esses métodos, frequentemente, presumem que o impacto do programa é homogêneo. Além disso, acreditam que suas variações podem ser explicadas por um

conjunto restrito de interações pré-especificadas. Essa abordagem pode ocultar padrões complexos e não lineares de resposta entre diferentes sub-grupos populacionais.

Nesse contexto, a aplicação de técnicas de *Machine Learning* (ML) tem expandido significativamente as capacidades de análise. Banerjee et al. (2017) utilizam ML em uma meta-análise de ensaios controlados randomizados. Eles não encontram evidências consistentes de que os programas de transferência de renda desencorajem o trabalho. Chen (2018), ao analisar o programa Progres a Oportunidades do México com *Random Forest*, demonstra que métodos de ML oferecem maior precisão na identificação de regiões e subgrupos beneficiados.

Mais recentemente, o método *Causal Forest*, desenvolvido por Athey e Imbens (2016) e Athey e Wager (2019), tem se mostrado particularmente promissor. Essa técnica fundamenta-se nos princípios do *Random Forest*. Contudo, é adaptada para estimativas causais em dados observacionais complexos. Essa adaptação viabiliza a identificação robusta da heterogeneidade do efeito do tratamento. Além disso, não depende de suposições rígidas sobre o modelo nem exige a pré-especificação de interações. Zheng e Yin (2023) e Rehill e Biddle (2024) destacam a capacidade do *Causal Forest* de lidar com múltiplos moderadores e estimar a heterogeneidade dos efeitos do tratamento em ciências sociais. No Brasil, até o momento, o estudo de Silva (2023) é um dos poucos trabalhos que aplicam essa técnica. Ele analisa os efeitos heterogêneos do Bolsa Família no mercado de trabalho, utilizando dados de 2012. Além disso, evidencia a eficácia do método em identificar corretamente a heterogeneidade e em gerar estratos precisos da população.

A literatura revisada indica que os impactos do PBF no mercado de trabalho são amplamente estudados. No entanto, há uma evidente ausência de consenso quanto à magnitude e direção desses efeitos. Isso é especialmente verdadeiro em relação à formalização do emprego e à carga horária. É crucial observar que existe uma lacuna considerável na análise sobre como esses impactos se distinguem entre diversos subgrupos populacionais em um contexto pós-pandemia da COVID-19. A maioria dos estudos anteriores, ao empregar métodos mais tradicionais como o PSM, pode não ter capturado adequadamente a complexidade e a heterogeneidade inerente às respostas dos beneficiários.

Diante disso, o presente estudo busca preencher essas lacunas. Para tanto, utiliza-se o método *Causal Forest*, aplicando dados da PNAD Contínua do segundo trimestre de 2023. A metodologia inovadora utilizada, juntamente com a análise de um período crítico pós-pandemia, permite uma investigação mais acurada dos impactos do Programa Bolsa Família (PBF). Isso é especialmente relevante na identificação dos subgrupos populacionais que enfrentaram as maiores consequências. Além disso, é importante observar as particularidades dos efeitos sobre a probabilidade de emprego, a obtenção da carteira de trabalho assinada e a quantidade de horas trabalhadas. Ao efetuar essa ação, a presente pesquisa oferece uma contribuição relevante para o debate sobre os efeitos dos TCRs, propiciando entendimentos mais detalhados para o aperfeiçoamento das políticas públicas.

3. Metodologia

Nesta pesquisa, o método *Causal Forest* é adotado para analisar o impacto do Programa Bolsa Família (PBF) em indicadores do mercado de trabalho. A seguir, são detalhadas essa abordagem e as etapas de tratamento dos dados utilizados.

3.1. Base de dados

A pesquisa utilizou microdados da PNAD Contínua (IBGE 2024). Especificamente, dados do segundo trimestre de 2023, que até então era o suplemento mais recente disponível, com informações sobre benefícios sociais e condições do domicílio. A amostra é constituída por indivíduos com idades entre 16 a 65 anos, em decorrência das faixas etárias estabelecidas pela legislação brasileira referente ao emprego formal e à aposentadoria (Brasil 1988, 1991). Todas as variáveis utilizadas nos modelos estão listadas a seguir (Tabela 1).

Tabela 1 - Variáveis utilizadas nos modelos

Variável	Descrição	$\hat{W}$	$\hat{Y}$ e Modelos		
			1	2	3
pbf	<i>Dummy</i> que indica que o indivíduo recebe o PBF	x			
val_pbf	Valor recebido do PBF	x	x	x	x
trabalha	<i>Dummy</i> que indica que o indivíduo trabalha (formal ou informalmente)		x		
carteira	<i>Dummy</i> que indica que o indivíduo trabalha formalmente			x	
horas	Horas trabalhadas semanalmente				x
mulher	<i>Dummy</i> que indica que o indivíduo é do sexo feminino	x	x	x	x
idade	Idade do indivíduo	x	x	x	x
branca	<i>Dummy</i> que indica que o indivíduo é branco ou amarelo	x	x	x	x
rend_dom_pc	Rendimento domiciliar per capita	x	x		
estudo	Anos de estudo	x			
e1:e3	<i>Dummies</i> que indicam o nível educacional completo do indivíduo: e1 - ensino fundamental, e2 - ensino médio e e3 - ensino superior. A categoria de referência são os indivíduos sem instrução ou com menos de 1 ano de escolaridade.		x	x	x
criança	<i>Dummy</i> para residente de um domicílio com criança	x	x	x	x
cd1	<i>Dummy</i> que indica que o indivíduo é o responsável pelo domicílio	x	x	x	x
sa1:sa9	<i>Dummies</i> que indicam o setor de atividade em que o indivíduo trabalha. Os setores representados são, respectivamente: s1- Agricultura, pecuária, produção florestal, pesca e aquicultura; s2- Construção; s3 - Comércio, reparação de veículos automotores e motocicletas; s4 - Transporte, armazenagem e correio; s5 - Alojamento e alimentação; s6 - Informação, comunicação e atividades financeiras, imobiliárias, profissionais e administrativas; s7 - Educação, saúde humana e serviços sociais; s8 - Outros Serviços; e s9 - Serviços domésticos. A categoria de referência é composta por indivíduos que trabalham na indústria geral.			x	x
próprio	<i>Dummy</i> para residente de um domicílio próprio	x			
casa_apartamento	<i>Dummy</i> para residente de uma casa ou apartamento	x			
domicilio_alvenaria	<i>Dummy</i> para residente de um domicílio de alvenaria	x			
abastecimento_geral	<i>Dummy</i> para residente de um domicílio com abastecimento geral	x			
eletricidade	<i>Dummy</i> para residente de um domicílio com eletricidade	x			
esgoto_rede	<i>Dummy</i> para residente de um domicílio com esgoto ligado à rede	x			
coleta_lixo	<i>Dummy</i> para residente de um domicílio com coleta de lixo	x			
reg_metr	<i>Dummy</i> para residente de região metropolitana	x	x	x	x
urb	<i>Dummy</i> para residente de em área urbana	x	x	x	x
norte	<i>Dummy</i> para residente da região Norte do Brasil	x			
nordeste	<i>Dummy</i> para residente da região Nordeste do Brasil	x	x	x	x
centro_oeste	<i>Dummy</i> para residente da região Centro-Oeste do Brasil	x	x	x	x
sul	<i>Dummy</i> para residente da região Sul do Brasil	x	x	x	x
sudeste	<i>Dummy</i> para residente da região Sudeste do Brasil	x	x	x	x

Fonte: Elaboração própria.

Para avaliar os efeitos do benefício do PBF na inserção e nas condições no mercado de trabalho, foram analisados três desfechos principais, representados em três modelos. No modelo 1, examina-se se o recebimento do PBF impacta a probabilidade de estar empregado. Os outros dois modelos são aplicados aos dados de indivíduos que estão trabalhando: o modelo 2 permite investigar o impacto do PBF sobre a probabilidade de possuir carteira de trabalho assinada; e o modelo 3 trata-se do efeito do PBF sobre a quantidade de horas trabalhadas.

Para realizar as análises, as variáveis foram subdivididas em duas categorias: aquelas que afetam a probabilidade de receber o PBF, ou valor recebido do PBF ($\hat{W}$) e aquelas que influenciam os desfechos de interesse (e Modelos). O método *Causal Forest* utiliza o primeiro conjunto para corrigir o viés de seleção no recebimento do benefício, enquanto o segundo é destinado a avaliar o efeito causal do PBF sobre os resultados. Assim, o método controla fatores que podem distorcer a relação entre o recebimento do benefício e os resultados observados no mercado de trabalho.

Destaca-se que tanto o modelo quanto as estatísticas descritivas foram ajustados no *software* RStudio (2024), respeitando o desenho amostral da PNADC.

3.2. Estratégia empírica

Considerando um conjunto de N unidades, denotamos o desfecho observado da unidade i como Y_i e suas características observáveis como X_i . A presença do tratamento é indicada pela variável binária W_i , onde $W_i = 1$ indica que a unidade recebeu o tratamento (ou intervenção) e $W_i = 0$ indica que não recebeu. Os resultados potenciais representam os dois cenários possíveis: o desfecho da unidade i *caso receba* o tratamento e *caso não receba* (Athey e Imbens 2016). No entanto, observamos apenas um desses desfechos, e a comparação entre os dois define o efeito causal (ou efeito do tratamento).

O efeito causal para a unidade i ($\tau_i = Y_i(1) - Y_i(0)$) não é diretamente observável, mas podemos estimar o Efeito Médio do Tratamento (*Average Treatment Effect* - ATE) da intervenção, desde que: i) a atribuição do tratamento seja independente dos resultados potenciais, ou seja, $W_i \perp (Y_i(1), Y_i(0)) | X_i$; ii) desde que a Suposição de Valor de Tratamento de Unidade Estável (*Stable Unit Treatment Value Assumption* - SUTVA)

seja válida. Conforme Athey; Imbens (2016), a SUTVA implica que: (i) o tratamento é uniforme entre as unidades; (ii) o tratamento de uma unidade não afeta o resultado potencial de outra unidade e; (iii) os potenciais resultados ($Y_i(1)$ e $Y_i(0)$) dependem apenas do tratamento recebido (W_i). Sob essas suposições, temos que o ATE é $E(\tau_i) = E(Y_i(1) - Y_i(0))$.

Em estudos observacionais, estima-se o efeito do tratamento condicionado a um conjunto de covariáveis, conhecido como ATE condicional (*Conditional Average Treatment Effect* - CATE). Neste estudo, foram analisados dois tipos de tratamento: um binário, indicando o recebimento, ou não do PBF, e um contínuo, representando o valor recebido.

Quando o tratamento é binário ($W \in \{0, 1\}$), o CATE mede a diferença média nos resultados esperados entre as unidades tratadas ($W = 1$) e não tratadas ($W = 0$), condicionado a um conjunto de covariáveis X . Assim, seguindo Imbens e Rubin (2015), a equação do tratamento binário é a seguinte:

$$\tau(x) = E(Y_i(1) - Y_i(0) | X_i = x), \quad (1)$$

em que $Y_i(1)$ é o resultado potencial sob tratamento ($W = 1$), $Y_i(0)$ é o resultado potencial sem tratamento ($W = 0$) e $X_i = x$ são as covariáveis condicionantes.

Quando o tratamento é contínuo, $W \in \mathbb{R}$, o CATE reflete a variação média do resultado esperado para um nível específico do tratamento contínuo d , comparado a não receber o tratamento ($d = 0$), condicionado a um conjunto de covariáveis X . Nesse caso, conforme mostra Imbens e Rubin (2015), a equação é:

$$\tau(x, d) = E(Y_i(d) - Y_i(0) | X_i = x), \quad (2)$$

onde $Y_i(d)$ é o resultado potencial sob o nível de tratamento d .

A utilização do PBF como um tratamento contínuo permite captar variações nos impactos que não seriam visíveis com uma abordagem binária. Como o valor do benefício recebido varia entre famílias, essa abordagem permite entender como diferentes níveis de apoio influenciam os resultados de forma incremental, revelando efeitos marginais e padrões não lineares que seriam perdidos na simplificação binária.

Para identificar o CATE, foram assumidas duas hipóteses: não confundimento, que garante que $W_i \perp (Y_i(1) - Y_i(0)) \mid X_i$; ii) e de sobreposição, que assegura que existam unidades em ambos os grupos para cada valor de X_i , ou seja, que existe um $v > 0$ tal que $v < e(X_i) 1 - v$, sendo $e(X_i)$ o escore de propensão (Imbens e Rubin 2015).

A validade da inferência causal está condicionada à hipótese de sobreposição. Ela requer que, para cada valor das covariáveis, existam indivíduos correspondentes, tanto no grupo de tratamento quanto no grupo de controle. Entretanto, em programas sociais como o PBF, a elegibilidade é definida por critérios restritivos, como a renda *per capita* e a presença de crianças. Isso pode, potencialmente, gerar propensões extremas em certos subgrupos da população.

Para verificar a aderência a esta hipótese, realizou-se um diagnóstico empírico detalhado, analisando a distribuição dos escores de propensão entre os grupos de beneficiários e não beneficiários. Seguindo Imbens e Rubin (2015), a sobreposição foi verificada, confirmando uma área comum razoável entre os grupos, ainda que com algumas regiões de baixa densidade de observações. Para mitigar o impacto dessas áreas e garantir a representatividade adequada dos grupos, foram aplicados pesos amostrais robustos, conforme Hirano et al. (2003), assegurando que a comparação entre as unidades tratadas e de controle fosse metodologicamente válida e que as estimativas se mantivessem robustas mesmo diante de heterogeneidade na densidade dos dados.

3.2.1. O método Causal Forest

O efeito heterogêneo do tratamento foi estimado por meio do *Causal Forest*, uma técnica avançada projetada para capturar variações nos efeitos do tratamento entre subgrupos de indivíduos com características distintas (Athey e Wager 2019). Primeiramente, foram utilizadas florestas de regressão para calcular os parâmetros de *nuisance* $\hat{W}$ (probabilidade de tratamento condicional) e $\hat{Y}$ (média condicional dos resultados). As variáveis empregadas para estimar $\hat{W}$ são aquelas que influenciam a probabilidade de participação no PBF, listadas na coluna " $\hat{W}$ " da Tabela 1. As variáveis utilizadas para estimar $\hat{Y}$ correspondem àquelas que capturam diferentes desfechos no mercado de trabalho, listadas na coluna " $\hat{Y}$ e Modelos" da mesma tabela.

Após calcular os parâmetros $\hat{W}$ e $\hat{Y}$, esses valores foram incorporados ao modelo *Causal Forest* “Piloto”. Esse modelo também incluiu o desfecho Y , todas as variáveis X listadas na coluna “ $\hat{Y}$ e Modelos” como potenciais modificadores de efeito para cada desfecho, além da variável de tratamento W . Conforme a abordagem proposta por Basu *et al.* (2018), utilizou-se os resultados dessa floresta inicial para classificar as variáveis X com base em sua importância, medida pela frequência de divisões em cada variável. Em seguida, ajustou-se uma segunda floresta causal, que leva em consideração apenas as variáveis cuja importância ultrapassa 20% da média geral de importância. Essa estratégia tem como objetivo reduzir o impacto de divisões causadas por ruído, garantindo maior clareza nos resultados (Athey e Wager 2019). A equação básica do modelo é apresentada a seguir, em consonância com Jawadekar *et al.* (2023):

$$\hat{\tau}(X_i) = \frac{1}{B} \sum_{b=1}^B \hat{\tau}_{best}(X), \quad (3)$$

Nesta equação, $\hat{\tau}$ é o CATE estimado para indivíduos com covariáveis x , calculado pela média dos CATEs específicos de cada ($\hat{\tau}_{best}$) em B árvores causais honestas. Cada árvore é construída a partir de uma amostra *bootstrap*, e apenas aquelas que não contêm os indivíduos no conjunto de treinamento são utilizadas na estimativa, garantindo a integridade do processo.

A aplicação do *Causal Forest* requer uma separação estratégica dos dados, onde uma porção da amostra é destinada ao treinamento do modelo (para determinar a estrutura das árvores), enquanto outra é utilizada para a estimação dos efeitos (nas folhas das árvores). Este procedimento - conhecido como estimação honesta - é fundamental para evitar o *overfitting* e para garantir a robustez e a imparcialidade das estimativas obtidas, bem como a validade das inferências (Athey e Wager 2019). Em linha com práticas estabelecidas e recomendações comuns em *machine learning* para a avaliação de modelos, a amostra total foi dividida aleatoriamente. Desse modo, 70% dos dados são alocados para o conjunto de treinamento, e os 30% restantes formam o conjunto de estimação, assegurando a validade externa das previsões e inferências (e.g. Géron 2022; Kuhn e Johnson 2013).

Na implementação empírica, o ajuste dos parâmetros e a subsequente geração das previsões foram realizados utilizando uma floresta com 2.000 árvores, com a ativação do parâmetro `tune.parameters = “all”` nas funções `regression_forest()` e `causal_forest()` do pacote *grf*. Este ajuste otimizou todos os parâmetros configuráveis do modelo por meio de validação cruzada,

incluindo a fração da amostra utilizada, o número de variáveis consideradas em cada divisão da árvore, e o número mínimo de observações por folha. Esse processo melhora o desempenho do modelo, tornando-o mais robusto e adaptado aos dados, evitando problemas de *underfitting* ou *overfitting*.

Após a estimação do modelo, dois métodos complementares foram aplicados para detectar a heterogeneidade nos efeitos do tratamento. O primeiro compara o ATE entre grupos classificados por altos e baixos valores estimados de CATEs, investigando se os subgrupos com altos CATEs exibem efeitos significativamente maiores em relação aos com baixos CATEs, o que sugere possíveis padrões de heterogeneidade. Adicionalmente, foram aplicado um teste formal de calibração, conforme proposto por Chernozhukov *et al.* (2018), disponível no pacote *grf*. Esse teste verifica a hipótese nula de que não há heterogeneidade nos efeitos do tratamento capturada pela estimativa $\hat{\tau}(X_i)$. Caso a hipótese nula seja rejeitada, isso indica a presença de heterogeneidade significativa. Com base nesse resultado, novas análises são conduzidas, explorando as características que demonstraram maior relevância no modelo. Essa relevância é medida pela frequência com que cada variável foi selecionada nas divisões das árvores, destacando os fatores que mais influenciam a variação nos efeitos do tratamento.

3.3. Validação dos resultados

Para avaliar a robustez e a confiabilidade das inferências causais obtidas, foram conduzidos dois testes placebo complementares, seguindo a metodologia detalhada por Eggers et al. (2024). O primeiro, denominado *Outcome Placebo Test*, substitui os desfechos originais por variáveis que, em princípio, não deveriam ser afetadas causalmente pelo recebimento do PBF no curto prazo. Isso permite verificar se o modelo mantém sua consistência mesmo na ausência de uma relação causal esperada. O segundo, o *Treatment Placebo Test*, substitui o tratamento real por uma variável aleatória, permitindo investigar se o modelo está captando relações espúrias que não correspondem a efeitos causais legítimos.

Para o *Outcome Placebo Test*, foram utilizadas variáveis que representam atributos fixos dos indivíduos e que, portanto, não deveriam ser afetadas causalmente pelo recebimento do PBF. Especificamente, estimou-se os efeitos do PBF sobre dois desfechos placebo: (i) sexo feminino (*dummy* binária, em que 1 = mulher e 0 = homem), e ii) idade em anos completos

(variável contínua). Ambos são atributos que não podem ser influenciados pelo programa de transferência de renda no curto prazo. O sexo é um atributo imutável, enquanto a idade é determinada biologicamente e exógena ao tratamento. A escolha de variáveis placebo que não apresentem associação significativa com o tratamento é fundamental. O objetivo é validar que os efeitos estimados nos desfechos principais refletem relações causais genuínas e não artefatos de especificação incorreta do modelo.

Quanto ao *Treatment Placebo Test*, a variável de tratamento real (recebimento do PBF ou valor do PBF) foi substituída por uma variável aleatória gerada independentemente dos dados observados. Este procedimento permite investigar se o modelo *Causal Forest* está captando relações espúrias ou se as associações observadas são genuinamente causais. Se o modelo detectasse efeitos significativos com um tratamento aleatório, isso indicaria problemas na especificação ou na validade das suposições.

4. Resultados

4.1. Estatísticas descritivas

Os dados da PNAD contínua do segundo trimestre de 2023 mostram que 19,22% dos domicílios são beneficiários do PBF. Esse número representa quase 20% dos domicílios no país em 2023. O valor médio do benefício por família é de R\$ 642,61 e a distribuição desse valor mostra uma grande dispersão, com desvio padrão de R\$ 192,3. Os valores variam de um mínimo de R\$ 600,00 ao limite observado de R\$ 995,03, dependendo da família. A variabilidade é fundamental, pois reflete as regras de elegibilidade e a composição do benefício, que varia conforme o número de crianças e adolescentes no domicílio, evidenciando a heterogeneidade do tratamento. Caracterizar esses valores é essencial para a análise dos efeitos do programa.

A Tabela 2 apresenta algumas características médias de beneficiários e não beneficiários do Programa Bolsa Família (PBF). As estatísticas sugerem que o perfil dos beneficiários do PBF difere de maneira consistente do perfil dos não beneficiários, conforme demonstrado pelos p-valores dos testes t de médias. Apenas a variável “casa_apartamento” não apresentou grande diferença, com p-valor estatisticamente não significativo.

Tabela 2 - Comparação das características médias de beneficiários e não beneficiários do PBF

Variável	Não beneficiários	Beneficiários	Diferença em média	P-valor
mulher (%)	46,83	88,78	41,95	0,000
idade (anos)	38,61	38,02	-0,59	0,000
branco (%)	44,32	22,49	-21,83	0,000
rend_dom_pc (R\$)	2192,89	446,04	-1746,85	0,000
estudo (anos)	10,90	8,63	-2,27	0,000
criança (%)	31,79	58,18	26,39	0,000
cd1 (%)	41,45	66,33	24,88	0,000
próprio (%)	69,96	62,18	-7,79	0,000
casa_apartamento (%)	38,39	38,14	-0,24	0,192
domicilio_alvenaria (%)	95,65	92,42	-3,23	0,000
abastecimento_geral (%)	86,76	75,51	-11,25	0,000
eletricidade (%)	99,84	99,50	-0,33	0,000
esgoto_rede (%)	70,96	48,56	-22,40	0,000
coleta_lixo (%)	93,50	82,33	-11,18	0,000
reg_metr (%)	39,58	29,54	-10,04	0,000
urb (%)	89,09	75,21	-13,88	0,000
norte (%)	8,18	12,84	4,66	0,000
nordeste (%)	24,03	49,74	25,71	0,000
centro_oeste (%)	8,29	5,34	-2,95	0,000
sul (%)	15,20	6,04	-9,16	0,000
sudeste (%)	44,30	26,04	-18,26	0,000

Fonte: Elaboração própria.

Observa-se que o programa Bolsa Família atende principalmente mulheres (88,8% dos beneficiários) e famílias com crianças (58,9%). A renda domiciliar per capita dos beneficiários é significativamente menor (R\$ 446,04) em comparação com os não beneficiários (R\$ 2.192,9). Além disso, os beneficiários têm menor escolaridade média (8,6 anos) e uma proporção menor de pessoas brancas (22,5%) em comparação aos não beneficiários.

Regionalmente, beneficiários estão mais concentrados nas regiões Norte e Nordeste, enquanto não beneficiários predominam nas regiões Sudeste e Sul, refletindo disparidades regionais no Brasil. Em infraestrutura e habitação, beneficiários têm menos acesso a serviços como abastecimento geral (de água), coleta de lixo e rede de esgoto. Complementarmente, os beneficiários estão menos representados em áreas urbanas, com 75,21% frente a 89,09% dos não beneficiários, evidenciando uma condição habitacional mais precária.

Os indicadores de mercado de trabalho mostram diferenças significativas entre beneficiários e não beneficiários (Tabela 3). Os beneficiários do programa apresentam uma taxa de empregabilidade mais baixa (80,12%) em comparação com os não beneficiários (93,1%). Além disso, a proporção de indivíduos com carteira de trabalho assinada também é significativamente menor entre os beneficiários (18,35%) do que entre os não beneficiários (69%). Em relação à carga horária, os beneficiários têm uma menor porcentagem de pessoas trabalhando 40 horas ou mais por semana (30,35% contra 39,64%).

Tabela 3 - Comparação de indicadores de mercado de trabalho entre beneficiários e não beneficiários do PBF

Variáveis	Não beneficiários	Beneficiários	Diferença em média	P-valor
Trabalha (%)	93,10	80,12	-12,98	0,000
Carteira (%)	69,00	18,35	-50,65	0,000
Horas Trabalhadas	39,64	30,35	-8,46	0,000

Fonte: Elaboração própria.

A Tabela 4 revela que entre os beneficiários do Bolsa Família, o rendimento médio apresenta variações significativas em relação às características do mercado de trabalho analisadas. Essa significância não é evidenciada apenas entre quem trabalha e não trabalha. A diferença no rendimento entre aqueles que trabalham (R\$ 634,07) e os que não trabalham (R\$ 638,09) é mínima (R\$ 4,02) e não é estatisticamente significativa (p-valor de 0,4194). Por outro lado, as comparações entre os que possuem e os que não possuem carteira assinada (diferença de R\$51,52) e entre os que trabalham 40 horas ou mais e os que não atingem essa carga horária (diferença de R\$ 15,27) mostraram-se significativos estatisticamente.

Tabela 4 - Valor médio recebido do PBF por indivíduos com diferentes características de mercado de trabalho (R\$)

Grupo	Sim	Não	Diferença em média	P-valor
Trabalha	634,07	638,09	-4,02	0,4194
Carteira Assinada	582,36	633,87	-51,52	0,0000
Trabalha 40 ou mais horas	625,22	640,48	15,27	0,0003

Fonte: Elaboração própria.

De modo geral, há diferenças expressivas entre beneficiários e não beneficiários do PBF, especialmente em relação à renda, escolaridade e condições habitacionais. Os beneficiários tendem a apresentar menores taxas de em-

pregabilidade, formalização e horas trabalhadas. No entanto, o rendimento médio entre os diferentes grupos de beneficiários não revela diferenças estatisticamente significativas. Para investigar mais a fundo essas relações e possíveis efeitos causais, será utilizado um modelo de *Causal Forest*.

4.2. *Causal Forest*

Os resultados da análise com o *Causal Forest*, apresentados na Tabela 5, indicam que o recebimento do PBF tem efeitos estatisticamente significativos sobre diferentes indicadores do mercado de trabalho. O impacto do PBF sobre a probabilidade de estar trabalhando é negativo, com uma redução estimada de 1,8 pontos percentuais, sugerindo que o benefício pode reduzir ligeiramente a participação no mercado de trabalho. Além disso, o PBF diminui em cerca de 20,1 pontos percentuais a probabilidade de o indivíduo possuir carteira de trabalho assinada, indicando uma maior propensão dos beneficiários a ocupar posições informais. Em relação às horas trabalhadas, observa-se uma redução média de 2,56 horas por semana (aproximadamente 2 horas e 34 minutos), o que pode refletir a possibilidade de dedicar mais tempo a outras atividades, como cuidados familiares ou estudo, graças ao suporte financeiro oferecido pelo programa.

Tabela 5 - Resultados *Causal Forest* de tratamento binário

Outputs	Efeito Médio	Erro Padrão	P-valor
Trabalha	-0,018339	0,010845	0,000378
Carteira de Trabalho	-0,201834	0,020483	0
Horas Trabalhadas	-2,564157	0,560165	0

Fonte: Elaboração própria.

Os resultados obtidos estão em consonância com alguns estudos da literatura. Alvim e Godward (2020)improving education and health, and social inclusion of a significant portion of society. However, one of the aspects still unwell studied about the CCTPs is the potential of these programs to stimulate the permanence of low-income Brazilian workers in the informal market, with the purpose of remaining “invisible” to the program supervisors and thus receiving benefits. To analyze this behavior in the labor market in six Brazilian state’s capitals, an Error Correction Vector (VEC sugerem que o PBF pode incentivar trabalhadores de baixa renda a permanecerem no setor informal como forma de manter os benefícios.

De fato, Brauw *et al.* (2015) observam que os beneficiários do programa tendem a realocar horas de trabalho do setor formal para o informal, especialmente em áreas urbanas. Isso ilustra a complexidade dos seus impactos no mercado de trabalho. Esses achados se alinham, parcialmente, ao estudo de Vidigal (2026) que, embora aponte uma elevação na oferta de trabalho, com mais indivíduos procurando emprego, há uma redução no número de horas trabalhadas e crescimento da informalidade.

A Tabela 6 exibe os resultados do modelo com tratamento contínuo, demonstrando como diferentes valores do PBF impactam os indicadores do mercado de trabalho. Na coluna “Efeito Médio”, os valores estimados pelo modelo foram multiplicados por 100 para representar o efeito acumulado a cada R\$ 100 recebidos do PBF. Embora os efeitos sejam modestos, todos são estatisticamente significativos. Para a probabilidade de estar trabalhando (Trabalha), o efeito médio é de -0,23 pontos percentuais a cada R\$ 100 recebidos. No caso da formalização (Carteira de Trabalho), o impacto é de -2,96 pontos percentuais, indicando uma redução na probabilidade de ter um emprego formal com carteira assinada. Quanto ao número de horas trabalhadas (Horas Trabalhadas), há uma redução de 0,34 horas semanais (aproximadamente 20,4 minutos) a cada R\$ 100 recebidos.

Tabela 6 - Resultados *Causal Forest* de tratamento contínuo

Outputs	Efeito Médio	Erro Padrão	P-valor
Trabalha	-0,0023	0,000016	0,004046
Carteira de Trabalho	-0,0296	0,000033	0
Horas Trabalhadas	-0,335	0,000844	0

Fonte: Elaboração própria.

A Tabela 7 apresenta o grau de contribuição de cada variável preditora para as previsões dos modelos, destacando sua importância relativa na determinação dos resultados para cada uma das variáveis dependentes. No modelo “Trabalha”, a variável mais relevante é “rend_dom_pc” (Rendimento Domiciliar per Capita), com uma importância de 0,56, indicando que o rendimento familiar é o principal fator associado à decisão de trabalhar. A “idade” também exerce influência significativa (0,22), sugerindo seu impacto na probabilidade de inserção no mercado de trabalho, enquanto “e3” (Ensino Superior Completo) surge como o terceiro fator mais relevante (0,07), evidenciando a contribuição do nível educacional.

Tabela 7 - Importância de cada variável para as previsões do modelo contínuo

Variável	Trabalha	Carteira	Horas Trabalhadas
mulher	0,025984566	0,008904823	0,416413
idade	0,219316334	0,063078652	0,086849381
branco	0,008913047	0,002046032	0,004209806
rend_dom_pc	0,563198729	-	-
e1	0,005424773	0,011524882	0,008458651
e2	0,002399849	0,000679017	0,002971285
e3	0,066142065	0,006078384	0,006720565
criança	0,007226782	0,007668551	0,010699029
cd1	0,01044176	0,007504101	0,003368353
reg_metr	0,026752945	0,03412336	0,003581307
urb	0,014699865	0,063557604	0,014492973
nordeste	0,042971913	0,208795609	0,068229106
centro_oeste	1,65016E-05	0,002808621	0,000456502
sul	0,004840709	0,007503826	0,002742493
sudeste	0,001670162	0,013240827	0,006412300
sa1	-	0,007504101	0,003368353
sa2	-	0	0,003706564
sa3	-	0,002052761	0,122193404
sa4	-	0	0,006961521
sa5	-	0	0,000502774
sa6	-	0,022592058	0,001452035
sa7	-	0,000280151	0,018633182
sa8	-	0	0,009685006
sa9	-	0,536193208	0,198521089

Fonte: Elaboração própria.

No modelo denominado “Carteira”, a variável *sa9* - *Serviços domésticos* - apresenta uma predominância de 0,54, enfatizando sua importância crucial na previsão relacionada à formalização do trabalho. Ademais, a variável *nordeste* se destaca com o valor de 0,21, evidenciando variações regionais nas condições de formalidade; por sua vez, *urb* - *Área Urbana* - também apresenta relevância, com 0,06, sinalizando diferenças entre as zonas urbanas e rurais. No modelo “Horas Trabalhadas”, a variável *mulher* se destaca como um elemento de significativa importância (0,42), indicando dispari-

dades de gênero na determinação das horas trabalhadas. Em paralelo, *sa9 - Serviços domésticos* preserva sua relevância como uma variável de grande importante (0,20), seguido de *sa3 - Comércio, reparação de veículos automotores e motocicletas* - (0,12) e nordeste (0,07).

A Tabela 8 apresenta os resultados da análise de heterogeneidade entre os efeitos altos e baixos, com base na diferenciação dos CATEs (efeitos médios condicionais de tratamento). Observa-se que, em todos os modelos, exceto no caso do efeito alto de “Trabalha”, os p-valores indicam diferenças estatisticamente significativas entre os grupos de alto e baixo efeito. Esses resultados sugerem que, embora a magnitude dos efeitos varie entre os grupos, eles seguem a mesma direção, indicando consistência nos padrões observados. Em outras palavras, apesar das diferenças nos valores absolutos, os efeitos do tratamento mantêm uma tendência semelhante entre os diferentes grupos.

Tabela 8 - Heterogeneidade entre efeitos altos e baixos

Outputs	Alto		Baixo	
	Efeito Médio	P-valor	Efeito Médio	P-valor
Trabalha	0,0002	0,834595	-0,0051	0,000024
Carteira de Trabalho	-0,0271	0	-0,0347	0
Horas Trabalhadas	-0,3643	0	-0,2931	0,000003

Fonte: Elaboração própria.

4.2.1. Análise da heterogeneidade e mecanismos causais

Ao analisar a heterogeneidade dos efeitos do PBF entre homens e mulheres (Tabela 9), observa-se que os impactos seguem tendências semelhantes, mas com magnitudes distintas. O efeito do PBF sobre a probabilidade de estar trabalhando (Trabalha) não é significativo para homens a 5% de significância (p-valor = 0,092). Para as mulheres, o efeito médio é de -0,0041, indicando uma redução de 0,41 pontos percentuais na probabilidade de estar trabalhando a cada R\$ 100 recebidos. Quanto à formalização no emprego (Carteira de Trabalho), o efeito é de -0,0281 para homens e -0,0369 para mulheres, apontando maior vulnerabilidade feminina à informalidade. No caso do número de horas trabalhadas (Horas Trabalhadas), há uma redução de 0,32 horas semanais para homens e 0,38 horas semanais para mulheres a cada R\$ 100 recebidos. Esses resultados

corroboram os achados de Vidigal (2026), que destaca que o PBF tende a aumentar a informalidade e reduzir a jornada de trabalho, especialmente entre as mulheres.

Tabela 9 - Heterogeneidade entre efeitos de homens e mulheres

Outputs	Homens		Mulheres	
	Efeito Médio	P-valor	Efeito Médio	P-valor
Trabalha	-0,0016	0,092296	-0,0041	0,000589
Carteira de Trabalho	-0,0281	0	-0,0369	0
Horas Trabalhadas	-0,3196	0	-0,3812	0,000002

Fonte: Elaboração própria.

A maior sensibilidade das mulheres aos impactos do PBF, particularmente na redução da formalização e carga horária, pode ser explicada por diversos mecanismos. As responsabilidades familiares e de cuidado, que ainda recaem desproporcionalmente sobre elas, são um fator importante. O benefício do PBF pode permitir que as mulheres aloquem mais tempo para essas tarefas, reduzindo a busca por empregos formais e/ou de tempo integral. Barreiras estruturais - como a discriminação de gênero no mercado de trabalho e a menor oferta de oportunidades flexíveis para mulheres com baixa escolaridade - também contribuem para isso. A decisão de permanecer em trabalhos informais, que oferecem maior flexibilidade de horário, pode ser vista como uma estratégia para conciliar o trabalho remunerado com as demandas domésticas.

A Tabela 10 mostra que os efeitos do PBF variam entre jovens (até 30 anos) e pessoas mais velhas (com 30 anos ou mais), com diferenças significativas em magnitude e relevância. Para a inserção no mercado de trabalho (*output Trabalha*), o impacto é significativo apenas para os mais velhos, com uma redução de 0,21 pontos percentuais na probabilidade de estar trabalhando a cada R\$ 100 recebidos. Entre os jovens, o efeito não é estatisticamente significativo. Quanto à formalização no emprego (*output Carteira de Trabalho*), ambos os grupos apresentam efeitos significativos, com quedas de 2,72 pontos percentuais para os jovens e 3,05 pontos percentuais para os mais velhos, sugerindo maior vulnerabilidade à informalidade com o aumento da idade. Quanto ao número de horas trabalhadas (*output Horas Trabalhadas*), a redução é de 0,23 horas por semana para os jovens e 0,37 horas por semana para os mais velhos, ambos os efeitos estatisticamente

significativos. Apesar das magnitudes serem similares, os indivíduos mais velhos demonstram uma diminuição um pouco mais significativa, o que sugere uma sensibilidade mais pronunciada em relação aos benefícios do programa.

Tabela 10 - Heterogeneidade entre efeitos de mais jovens e mais velhos

Outputs	Até 30 anos		30 anos ou mais	
	Efeito Médio	P-valor	Efeito Médio	P-valor
Trabalha	-0,0028	0,140855	-0,0021	0,012166
Carteira de Trabalho	-0,0272	0	-0,0305	0
Horas Trabalhadas	-0,2307	0,005852	-0,3682	0

Fonte: Elaboração própria.

A maior sensibilidade ao mercado informal, assim como a redução mais acentuada nas horas trabalhadas para indivíduos com 30 anos ou mais, podem ser atribuídas a múltiplos fatores. Para esse grupo, a inserção no mercado de trabalho formal pode ser mais desafiadora em razão de deficiências na qualificação, desatualização de competências e discriminação etária. O benefício do PBF, nesse contexto, pode atuar como uma espécie de seguro. Isso possibilita a aceitação de empregos informais com carga horária reduzida, os quais proporcionam maior flexibilidade e exigem menos deslocamentos ou esforço físico. Outrossim, a busca por maior segurança financeira na velhice, mesmo que via informalidade, pode ser um motivador.

Conforme mostrado na Tabela 11, os efeitos do PBF variam significativamente entre residentes de áreas urbanas e rurais. Para a inserção no mercado de trabalho (Trabalha), a redução na probabilidade de estar trabalhando é de 0,25 pontos percentuais nas áreas urbanas (p-valor = 0,007), enquanto nas áreas rurais o efeito não é estatisticamente significativo (p-valor = 0,146). No que diz respeito à formalização do emprego, os resultados mostram uma redução mais acentuada na probabilidade de ter carteira assinada nas áreas urbanas (-3,08 pontos percentuais) em comparação com as rurais (-2,27 pontos percentuais), ambos com alta significância estatística (p-valor = 0,000). Esse achado está em linha com o trabalho de Ribas e Soares (2011) os quais argumentam que em áreas metropolitanas, o PBF tende a reduzir a participação na oferta de trabalho formal, possivelmente devido à maior dependência dos benefícios do programa e à disponibilidade de alternativas informais.

Tabela 11 - Heterogeneidade entre efeitos de residentes de áreas urbanas e rurais

Outputs	Área urbana		Área rural	
	Efeito Médio	P-valor	Efeito Médio	P-valor
Trabalha	-0,0025	0,007023	-0,0015	0,146162
Carteira de Trabalho	-0,0308	0	-0,0227	0
Horas Trabalhadas	-0,3757	0	-0,1611	0,016519

Fonte: Elaboração própria.

A redução nas horas trabalhadas, mais pronunciada nas áreas urbanas (-0,38 horas semanais por R\$ 100 recebidos) do que nas rurais (-0,16 horas semanais), reforça a ideia de que os beneficiários urbanos são mais sensíveis aos incentivos do programa. Essa maior sensibilidade pode estar relacionada à dinâmica do mercado de trabalho urbano. Nestas áreas, a oferta de empregos informais - de tempo parcial ou flexíveis - é geralmente maior. Assim, oferecem mais opções para ajustar a carga horária em resposta a transferências de renda. Além do mais, a facilidade de acesso a bens e serviços e a complexidade da vida urbana podem levar a uma maior valorização do tempo não-remunerado. Brauw et al. (2015) também observam que programas de transferência de renda podem levar a uma redução na oferta de trabalho urbano, especialmente em contextos em que os beneficiários têm maior capacidade de escolha sobre como alocar seu tempo.

Em síntese, os resultados mostram que o PBF tem impactos heterogêneos no mercado de trabalho. Há reduções na probabilidade de emprego formal e na carga horária semanal, mais pronunciadas entre mulheres, indivíduos com idade de 30 anos ou mais e residentes urbanos. Para as mulheres, responsabilidades familiares e barreiras estruturais, como discriminação de gênero e falta de oportunidades flexíveis, podem limitar sua inserção no trabalho formal. No caso dos indivíduos com mais de 30 anos, a redução nas horas trabalhadas pode refletir uma preferência por atividades informais ou de meio período, mais compatíveis com sua saúde e energia. Já nos centros urbanos, a maior flexibilidade do mercado de trabalho e a disponibilidade de opções informais explicam a maior sensibilidade aos benefícios do programa. Esses achados reforçam que, embora crucial para a redução da pobreza, o PBF pode ter efeitos colaterais na formalização e na oferta de trabalho.

4.3. Validação dos resultados

Os testes para avaliar a robustez e a confiabilidade das inferências causais obtidas são apresentados a seguir.

Os resultados do teste placebo de *outcome*, Tabela 12, apresentam um padrão misto que merece interpretação cuidadosa. De um lado, o desfecho placebo “sexo feminino” não apresenta associações significativas com o tratamento em nenhum dos três modelos analisados (Trabalha, Carteira de Trabalho e Horas Trabalhadas), com p-valores variando de 0,637 a 0,884. De outro lado, o desfecho placebo “idade em anos” apresenta uma associação significativa, especificamente no modelo “Carteira de Trabalho” (p-valor = 0,023). Este resultado, embora inesperado, pode ser interpretado de duas formas complementares, conforme discutido abaixo.

Tabela 12 - Resultados Causal Forest com outcome placebo

Desfecho Placebo	Modelo	Efeito Médio	Erro Padrão	P-Valor
Sexo	Trabalha	-0,000003	0,000007	0,652441
	Carteira de Trabalho	-0,000005	0,000011	0,636917
	Horas Trabalhadas	0,000001	0,000005	0,884591
Idade	Trabalha	0	0	0,701286
	Carteira de Trabalho	-0,000002	0,000001	0,0227999
	Horas Trabalhadas	0,000001	0,000003	0,85035

Fonte: Elaboração própria.

A primeira interpretação é que a significância observada para “*idade*” pode indicar que, mesmo sendo este um atributo fixo do indivíduo, esse resultado pode estar correlacionado com fatores não observados. Tais fatores afetam tanto a elegibilidade para o PBF quanto a probabilidade de ter carteira assinada. A segunda interpretação para a significância pode refletir uma pequena instabilidade do modelo. Isso é suscetível de ocorrer em regiões específicas do espaço de covariáveis onde a densidade de observações é baixa. No entanto, a magnitude do efeito é irrisória (-0,000002), praticamente negligenciável em termos práticos. Aliado a isso, a ausência de significância em outros modelos sugere que este resultado não compromete a validade geral das inferências causais. A robustez geral do modelo é reforçada pela ausência de significância para “*sexo*” em todos os modelos e pela consistência dos padrões observados nos testes de tratamento placebo.

Os resultados do teste de tratamento placebo (*Treatment Placebo Test*), apresentados na Tabela 13, indicam associações não significativas entre o tratamento placebo (aleatório) e os desfechos originais (probabilidade de trabalhar, carteira de trabalho assinada e horas trabalhadas). Para o modelo binário, os efeitos médios são próximos de zero, com p-valores variando entre 0,259 e 0,743. Para o modelo contínuo, os p-valores estão entre 0,142 e 0,249.

Tabela 13 - Resultados Causal Forest com tratamento placebo

Outputs	Tratamento binário		Tratamento contínuo	
	Efeito Médio	P-valor	Efeito Médio	P-valor
Trabalha	-0,003365	0,259717	-0,0043	0,141942
Carteira de Trabalho	-0,010256	0,165185	-0,0511	0,177219
Horas Trabalhadas	-0,059927	0,743093	-0,2608	0,24886

Fonte: Elaboração própria.

Em nenhum caso as variáveis de resultado apresentam associações significativas com o tratamento placebo. Este resultado reforça a robustez das inferências causais e indica que os achados não são influenciados por fatores não observados ou por especificação incorreta do modelo.

Os resultados dos testes de validação confirmam a robustez dos modelos *Causal Forest* aplicados neste estudo. A ausência de associações significativas entre variáveis placebo (tanto de *outcome* quanto de tratamento) e os resultados estimados oferece suporte adicional à confiabilidade das inferências causais. Estes testes de placebo (Eggers e Tuñon 2024) demonstram que os efeitos estimados do PBF sobre a probabilidade de emprego, formalização (carteira de trabalho) e horas trabalhadas não são artefatos de especificação incorreta ou de viés não observado, mas refletem relações causais genuínas entre o tratamento e os desfechos de interesse.

5. Considerações finais

A presente pesquisa examinou os impactos do Programa Bolsa Família (PBF) sobre indicadores do mercado de trabalho no Brasil. Para essa análise, foi utilizado o método *Causal Forest*, uma abordagem inovadora ainda pouco explorada na literatura brasileira sobre políticas sociais. Os dados



revelam que o PBF diminui em 1,83 pontos percentuais a probabilidade de emprego, reduz em 20,18 pontos percentuais a chance de possuir carteira assinada e também resulta em uma diminuição de 2,56 horas na carga horária semanal. Quando o tratamento é analisado de maneira contínua, os efeitos marginais revelam-se modestos, porém preservam a mesma direção: para cada R\$ 100 recebidos, a probabilidade de obtenção de emprego diminui em 0,23 pontos percentuais, a de formalização em 2,96 pontos percentuais, assim como as horas trabalhadas, que reduzem em 0,34 horas semanais.

A análise de heterogeneidade revelou padrões importantes. Mulheres apresentam maior sensibilidade aos impactos do programa, com reduções mais pronunciadas na formalização e nas horas trabalhadas. Isso reflete responsabilidades desproporcionais com cuidados familiares e barreiras estruturais no mercado de trabalho. Pessoas com 30 anos ou mais apresentam-se mais vulneráveis à informalidade, ao passo que habitantes de regiões urbanas demonstram efeitos mais acentuados do que os que residem em zonas rurais. Esses padrões indicam que o PBF não exerce um impacto homogêneo sobre a população, mas sim interage de maneira complexa com características individuais e fatores contextuais.

É fundamental destacar que a análise realizada se fundamenta em dados transversais. Esses dados são referentes a um único período, o que limita a possibilidade de captar dinâmicas de longo prazo e respostas comportamentais ao longo do tempo. Além disso, é importante ressaltar que, embora o *Causal Forest* seja robusto, a identificação causal efetiva está diretamente vinculada à suposição de não confundimento. Isso significa que é fundamental que todas as variáveis relevantes sejam devidamente observadas e, consequentemente, incluídas no modelo adotado. A ausência de alguma dessas variáveis relevantes pode comprometer a eficácia da análise. No entanto, os testes de placebo que foram realizados fornecem respaldo significativo para a validade das inferências que estão sendo feitas. Isso indica que a utilização dessas metodologias ajuda a confirmar as conclusões tiradas a partir dos resultados obtidos.

Os resultados que apontam para uma menor probabilidade de emprego formal e carga horária reduzida não devem ser considerados apenas como um “efeito preguiça”. Essa interpretação é insuficiente para compreender a complexidade da situação. Igualmente, eles expressam as condições estruturais do mercado de trabalho brasileiro, caracterizado pela escassez de emprego formal, as crescentes exigências de qualificação e a segmentação

ocupacional. Muitos beneficiários do PBF apresentam nível educacional reduzido e enfrentam obstáculos substanciais para ingressar no mercado de trabalho formal. A menor participação ou formalização pode ser entendida tanto como uma reação lógica ao apoio financeiro quanto como uma resultante das restrições nas oportunidades disponíveis. Assim, políticas destinadas à promoção do emprego, à capacitação profissional e ao aprimoramento da oferta de trabalho formal revelam-se igualmente fundamentais às políticas de transferência de renda.

Apesar do PBF ser fundamental para a redução da pobreza, ele não se configura como uma solução isolada para os desafios do mercado de trabalho. A variabilidade dos efeitos indica que as políticas públicas precisam ser adaptadas de acordo com os diferentes grupos populacionais: para as mulheres, é necessário implementar políticas que aliam transferências de renda ao acesso a serviços de cuidado e a oportunidades de trabalho flexível; para os indivíduos mais velhos (30 anos ou mais), devem ser desenvolvidos programas de requalificação profissional e de enfrentamento da discriminação etária; e para os habitantes de áreas urbanas, é imprescindível criar políticas voltadas à formalização e ao acesso ao crédito. A expansão do acesso à formação profissional e à educação técnica é essencial, assim como a implementação de políticas que incentivem a geração de empregos formais em setores que acolhem trabalhadores com menor nível de qualificação.

A aplicação inovadora do *Causal Forest* à avaliação do PBF representa uma contribuição metodológica significativa. Essa abordagem permite uma análise mais detalhada e precisa da heterogeneidade dos efeitos em comparação com métodos tradicionais como o *Propensity Score Matching*. Pesquisas futuras podem utilizar dados longitudinais, e essas análises devem incluir variáveis relacionadas à oferta de empregos. Também é importante investigar como o PBF interage com outras políticas públicas. Essas ações podem enriquecer a compreensão dos mecanismos causais, além de identificar combinações de políticas mais eficientes para fomentar a inclusão produtiva. Esta pesquisa enriquece a discussão acerca dos impactos dos programas de transferência de renda, apresentando evidências fundamentadas em uma metodologia rigorosa e inovadora. A expectativa é de que esta obra sirva de estímulo para pesquisas futuras e para o aperfeiçoamento contínuo das políticas públicas voltadas à proteção social e à inclusão produtiva no Brasil.

Referências

- Alvim, Augusto Mussi, e Carlos David Godward. 2020. “O Programa Bolsa Família Estimula a Permanência Dos Trabalhadores Brasileiros de Baixa Renda No Mercado Informal”. *Redes* 25 (dezembro): 2227–50. <https://doi.org/10.17058/REDES.V25I0.14011>.
- Alzúa, María Laura, Guillermo Cruces, e Laura Ripani. 2013. “Welfare Programs and Labor Supply in Developing Countries: Experimental Evidence from Latin America”. *Journal of Population Economics* 26 (4): 1255–84. <https://doi.org/10.1007/s00148-012-0458-0>.
- Amarante, Verónica, Marco Manacorda, Andrea Vigorito, e Mariana Zerpa. 2011. *Social assistance and labor market outcomes: Evidence from the Uruguayan PANES*. <https://publications.iadb.org/en/handle/11319/5853>.
- Araújo, Jevuks Matheus, Gustavo Saraiva Frio, e Pedro Jorge Holanda Alves. 2021. “O efeito do Bolsa Família sobre a distorção idade-série”. *Estudos Econômicos (São Paulo)* 51 (2): 343–71. <https://doi.org/10.1590/0101-41615125jgp>.
- Asfaw, Solomon, Benjamin Davis, Josh Dewbre, Sudhanshu Handa, e Paul Winters. 2014. “Cash Transfer Programme, Productive Activities and Labour Supply: Evidence from a Randomised Experiment in Kenya”. *The Journal of Development Studies* 50 (8): 1172–96. <https://doi.org/10.1080/00220388.2014.919383>.
- Athey, Susan, e Guido Imbens. 2016. “Recursive partitioning for heterogeneous causal effects”. *Proceedings of the National Academy of Sciences* 113 (27): 7353–60. <https://doi.org/10.1073/pnas.1510489113>.
- Athey, Susan, e Stefan Wager. 2019. “Estimating Treatment Effects with *Causal Forests*: An Application”. *Observational Studies* 5 (2): 37–51. <https://doi.org/10.1353/obs.2019.0001>.
- Banerjee, Abhijit V., Rema Hanna, Gabriel E. Kreindler, e Benjamin A. Olken. 2017. *Debunking the Stereotype of the Lazy Welfare Recipient: Evidence from Cash Transfer Programs*. 32 (2): 155–84.
- Barbosa, Ana Luiza Neves de Holanda, e Carlos Henrique Leite Corseuil. 2014. “Conditional cash transfer and informality in Brazil”. *IZA Journal of Labor & Development* 3 (37). <https://izajold.springeropen.com/articles/10.1186/s40175-014-0024-0>.
- Basu, Sumanta, Karl Kumbier, James B. Brown, e Bin Yu. 2018. “Iterative Random Forests to Discover Predictive and Stable High-Order Interactions”. *Proceedings of the National Academy of Sciences* 115 (8): 1943–48. <https://doi.org/10.1073/pnas.1711236115>.
- Borjas, George J. 2016. *Labor Economics*. Seventh edition, International student edition. The McGraw-Hill Series in Economics. McGraw-Hill Education.
- Brasil. 1988. “Constituição da República Federativa do Brasil de 1988”. Presidência da República Casa Civil. https://www.planalto.gov.br/ccivil_03/Constituicao/Constituicao.htm.
- Brauw, Alan de, Daniel O. Gilligan, John Hoddinott, e Shalini Roy. 2015. “Bolsa Família and Household Labor Supply”. *Economic development and cultural change* 63 (3): 423–57.
- Cedeplar, Centro de Desenvolvimento e Planejamento Regional, Secretaria de Avaliação e Gestão da Informação SAGI, e Ministério do Desenvolvimento Social e Combate à Fome MDS. 2007. *Sumário Executivo. Avaliação de impacto do programa bolsa família*. UFMG. <https://fpabramo.org.br/acervosocial/wp-content/uploads/sites/7/2017/08/448.pdf>.
- Chen, Tzai-Shuen. 2018. “Evaluating Conditional Cash Transfer Policies with Machine Learning Methods”. arXiv:1803.06401. Preprint, arXiv, março 16. <http://arxiv.org/abs/1803.06401>.
- Chernozhukov, Victor, Mert Demirer, Esther Duflo, e Ivan Fernandez-Val. 2018. *Generic machine learning inference on heterogeneous treatment effects in randomized experiments, with an application to immunization in India*. National Bureau of Economic Research. <https://www.nber.org/papers/w24678>.
- Covarrubias, Katia, Benjamin Davis, e Paul Winters. 2012. “From Protection to Production: Productive Impacts of the Malawi Social Cash Transfer Scheme”. *Journal of Development Effectiveness*, março 1. world. <https://www.tandfonline.com/doi/abs/10.1080/19439342.2011.641995>.

- Duarte, Gisléia Benini, Breno Sampaio, e Yony Sampaio. 2009. “Programa Bolsa Família: impacto das transferências sobre os gastos com alimentos em famílias rurais”. *Revista de Economia e Sociologia Rural* 47 (4): 903–18. <https://doi.org/10.1590/S0103-20032009000400005>.
- Eggers, Andrew C., Guadalupe Tuñón, e Allan Dafoe. 2024. “Placebo Tests for Causal Inference”. *American Journal of Political Science* 68 (3): 1106–21. <https://doi.org/10.1111/ajps.12818>.
- Foguel, Miguel Nathan, e Ricardo Paes de Barros. 2010. “The Effects of Conditional Cash Transfer Programmes on Adult Labour Supply: An Empirical Analysis Using a Time-Series-Cross-Section Sample of Brazilian Municipalities”. *Estudos Econômicos (São Paulo)* 40 (2): 259–93. <https://doi.org/10.1590/S0101-41612010000200001>.
- Fruttero, Anna, Alexandre Ribeiro Leichsenring, e Luis Henrique Paiva. 2020. “Social Programs and Formal Employment: Evidence from the Brazilian Bolsa Família Program”. *IMF Working Papers*. *IMF Working Papers* 2020 (099). <https://doi.org/10.5089/9781513547701.001.A001>.
- Gerard, François, Joana Naritomi, e Joana Silva. 2021. “Cash Transfers and Formal Labor Markets: Evidence from Brazil”. SSRN Scholarly Paper N. 3886759. Social Science Research Network, junho 1. <https://papers.ssrn.com/abstract=3886759>.
- Géron, Aurélien. 2022. *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow*. O'Reilly Media, Inc.
- Hasan, Amer. 2010. “Time allocation in rural households: The indirect effects of conditional cash transfer programs”. *World Bank Policy Research Working Paper*, n. 5256. https://papers.ssrn.com/sol3/papers.cfm?abstract_id=1585035.
- Hirano, Keisuke, Guido W. Imbens, e Geert Ridder. 2003. “Efficient estimation of Average Treatment Effects using the estimated Propensity Score”. *Econometrica* 71 (4): 1161–89.
- Imbens, Guido W., e Donald B. Rubin. 2015. *Causal Inference in Statistics, Social, and Biomedical Sciences*. Cambridge University Press.
- Jawadekar, Neal, Katrina Kezios, Michelle C. Odden, et al. 2023. “Practical guide to honest *Causal Forests* for identifying heterogeneous treatment effects”. *American Journal of Epidemiology* 192 (7): 1155–65.
- Kuhn, Max, e Kjell Johnson. 2013. *Applied Predictive Modeling*. New York: Springer. <https://doi.org/10.1007/978-1-4614-6849-3>.
- Marx, Luana. 2023. “How is the Bolsa Família program associated with the test scores performance of economically disadvantaged pupils in Brazil?” *International Journal of Educational Development* 102 (outubro): 102878. <https://doi.org/10.1016/j.ijedudev.2023.102878>.
- Nazareno, Luísa, e Juliana De Castro Galvao. 2023. “The Impact of Conditional Cash Transfers on Poverty, Inequality, and Employment During COVID-19: A Case Study from Brazil”. *Population Research and Policy Review* 42 (2): 22. <https://doi.org/10.1007/s11113-023-09749-3>.
- Olson, Zachary, Rachel Gardner Clark, e Sarah Anne Reynolds. 2019. “Can a Conditional Cash Transfer Reduce Teen Fertility? The Case of Brazil’s Bolsa Família”. *Journal of Health Economics* 63 (janeiro): 128–44. <https://doi.org/10.1016/j.jhealeco.2018.10.006>.
- Rehill, Patrick, e Nicholas Biddle. 2024. “Heterogeneous treatment effect estimation with high-dimensional data in public policy evaluation -- an application to the conditioning of cash transfers in Morocco using causal machine learning”. arXiv:2401.07075. Preprint, arXiv, março 29. <http://arxiv.org/abs/2401.07075>.
- Ribas, Rafael P., e Fábio Versas Soares. 2011. “Is the effect of conditional transfers on labor supply negligible everywhere”. Trabalho em evento apresentado em IZA/World Bank Conference: Employment and Development. https://conference.iza.org/conference_files/worldb2011/ribas_r6802.pdf
- Silva, Jeudi Rufino Fernandes da. 2023. “Statistical learning and causal effects: an application to Bolsa Família Program”. Dissertação, UFRGS. <https://lume.ufrgs.br/handle/10183/274202>.
- Soares, Fábio Veras, Rafael Perez Ribas, e Rafael Guerreiro Osario. 2010. “Evaluating the Impact of Brazil’s Bolsa Família”. *Latin American Research Rev* 45 (2): 173–91.

Vidigal, Vinicius. 2026. "The Impact of Conditional Cash Transfers on Labor Supply: New Evidence from Brazil's Bolsa Familia". *Journal of Development Effectiveness* 18 (1): 86–103.

World Bank. 2009. "Conditional Cash Transfers: Paying People to Invest in Children". fevereiro. <https://www.worldbank.org/en/news/feature/2009/02/12/conditional-cash-transfers-paying-people-to-invest-in-children>

Zheng, Li, e Weiwen Yin. 2023. "Estimating and Evaluating Treatment Effect Heterogeneity: A Causal Forests Approach". *Research & Politics* 10 (1): 20531680231153080. <https://doi.org/10.1177/20531680231153080>.

DECLARAÇÃO DE DISPONIBILIDADE DE DADOS

Os dados utilizados neste estudo estão disponíveis mediante solicitação ao autor. Dados adicionais e informações complementares também poderão ser fornecidos para fins de verificação ou replicação. A disponibilização está condicionada à inexistência de restrições de acesso público.

CONTRIBUIÇÕES DE AUTORIA

RS: Conceitualização, Curadoria de dados, Análise formal, Aquisição de financiamento, Investigação, Metodologia, Administração de projetos, Recursos, Programas, Supervisão, Validação, Visualização, Escrita - rascunho original e Escrita - revisão e edição.

CONFLITO DE INTERESSE

Os autores declaram não terem quaisquer conflitos de interesse.

EDITOR-CHEFE

Dante Mendes Aldrighi  <https://orcid.org/0000-0003-2285-5694>

Professor - Department of Economics University of São Paulo (USP)

EDITOR-ASSOCIADO

Fábio Waltenberg  <https://orcid.org/0000-0003-3404-7424>