

UNIVERSIDADE FEDERAL DE VIÇOSA

Impactos do Programa Bolsa Família sobre a segurança e insegurança alimentar no Brasil: uma aplicação de métodos de inteligência artificial

Maurício Almeida Meira
Magister Scientiae

VIÇOSA - MINAS GERAIS
2026

MAURÍCIO ALMEIDA MEIRA

Impactos do Programa Bolsa Família sobre a segurança e insegurança alimentar no Brasil: uma aplicação de métodos de inteligência artificial

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Economia, para obtenção do título de *Magister Scientiae*.

Orientadora: Cristiana T. Rodrigues

**VIÇOSA - MINAS GERAIS
2026**

**Ficha catalográfica elaborada pela Biblioteca Central da Universidade
Federal de Viçosa - Campus Viçosa**

T

M514i
2026

Meira, Maurício Almeida, 1999-

Impactos do Programa Bolsa Família sobre a segurança e insegurança alimentar no Brasil: uma aplicação de métodos de inteligência artificial / Maurício Almeida Meira. – Viçosa, MG, 2026.

1 dissertação eletrônica (85 f.): il. (algumas color.).

Orientador: Cristiana Tristão Rodrigues.

Dissertação (mestrado) - Universidade Federal de Viçosa, Departamento de Economia, 2026.

Referências bibliográficas: f. 80-85.

DOI: <https://doi.org/10.47328/ufvbbt.2026.283>

Modo de acesso: World Wide Web.

1. Programa Bolsa Família (Brasil). 2. Segurança alimentar.
3. Inteligência artificial. I. Rodrigues, Cristiana Tristão, 1980-
II. Universidade Federal de Viçosa. Departamento de Economia.
Programa de Pós-Graduação em Economia. III. Título.

CDD 22. ed. 353.53320981

MAURÍCIO ALMEIDA MEIRA

Impactos do Programa Bolsa Família sobre a segurança e insegurança alimentar no Brasil: uma aplicação de métodos de inteligência artificial

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Economia, para obtenção do título de *Magister Scientiae*.

APROVADA: 12 de março de 2026.

Assentimento:

Maurício Almeida Meira
Autor

Cristiana Tristao Rodrigues
Orientadora

Essa dissertação foi assinada digitalmente pelo autor em 26/05/2026 às 15:22:10 e pela orientadora em 09/06/2026 às 10:01:16. As assinaturas têm validade legal, conforme o disposto na Medida Provisória 2.200-2/2001 e na Resolução nº 37/2012 do CONARQ. Para conferir a autenticidade, acesse <https://siadoc.ufv.br/validar-documento>. No campo 'Código de registro', informe o código **MAF1.HZSO.PFWF** e clique no botão 'Validar documento'.

AGRADECIMENTOS

A Deus, na pessoa de Jesus Cristo e do Espírito Santo, ofereço meu primeiro e mais profundo agradecimento. Foi pela graça, direção e sustento divino que consegui trilhar esta caminhada. O período do mestrado, especialmente vivendo em uma nova cidade, fortaleceu minha fé e ampliou minha visão de mundo. Sair do lugar onde cresci e vivenciar uma realidade maior, cheia de pessoas, histórias, construções e oportunidades, fez-me compreender melhor a grandeza e a complexidade do universo criado por Deus, despertando ainda mais gratidão e propósito em minha trajetória. Ao meu pai, Iolando, registro minha sincera gratidão pelo esforço, trabalho e apoio financeiro. À Universidade Estadual do Sudoeste da Bahia (UESB), especialmente ao curso de Economia, agradeço pela sólida formação que me possibilitou alcançar o mestrado e construir as bases da minha trajetória acadêmica. À Universidade Federal de Viçosa (UFV), instituição tão acolhedora, linda e reconhecida pela excelência acadêmica, deixo minha profunda gratidão. Ao Programa de Pós-Graduação em Economia da UFV, agradeço pela formação, pelas oportunidades acadêmicas e pelo ambiente intelectual que contribuíram para meu desenvolvimento. À minha orientadora, professora Cristiana Tristão Rodrigues, minha sincera e especial gratidão pela orientação sempre educada, gentil e atenciosa. Sua capacidade de conduzir o processo com sensibilidade e rigor acadêmico foi essencial para o desenvolvimento deste trabalho. À cidade de Viçosa, deixo um agradecimento carinhoso pela acolhida generosa. Foi um período marcado por novas aprendizagens, amadurecimento pessoal e convivência com pessoas especiais. Aos colegas, amigos e a todas as pessoas que conheci nessa caminhada, agradeço pelas trocas, conversas, apoio e momentos vividos, que tornaram essa etapa mais leve, rica e inesquecível. À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), agradeço pelo apoio financeiro por meio da bolsa de mestrado, fundamental para minha permanência em Viçosa e dedicação integral aos estudos. Por fim, agradeço a todos que, direta ou indiretamente, contribuíram para a realização deste trabalho e para meu crescimento pessoal, acadêmico e espiritual.

Este trabalho foi realizado com o apoio das seguintes agências de pesquisa brasileiras: Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001, Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) e Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq).

RESUMO

MEIRA, Maurício Almeida, M.Sc., Universidade Federal de Viçosa, março de 2026. **Impactos do Programa Bolsa Família sobre a segurança e insegurança alimentar no Brasil: uma aplicação de métodos de inteligência artificial.** Orientadora: Cristiana Tristao Rodrigues.

Este trabalho analisa os impactos do Programa Bolsa Família sobre a segurança e a insegurança alimentar no Brasil, utilizando microdados da Pesquisa de Orçamentos Familiares 2017–2018. O objetivo é estimar o efeito médio do programa e investigar a heterogeneidade dos impactos entre diferentes grupos socioeconômicos. A metodologia combina o método tradicional de Propensity Score Matching com técnicas de aprendizado de máquina aplicadas à inferência causal, especificamente o Causal Forest e o X-Learner. Os resultados indicam elevada consistência entre os métodos, evidenciando efeito negativo do programa sobre a probabilidade de segurança alimentar e efeitos positivos sobre as categorias de insegurança alimentar, especialmente moderada e grave, o que reflete a natureza focalizada da política. As análises de heterogeneidade mostram que os impactos são mais intensos entre mulheres, indivíduos negros e indígenas, domicílios com menor nível de instrução e residentes em regiões mais vulneráveis. Embora os métodos de inteligência artificial não alterem as conclusões centrais obtidas pelo PSM, eles ampliam a compreensão dos efeitos ao identificar heterogeneidade de forma flexível e estatisticamente validada. Conclui-se que, embora o Bolsa Família atue como importante política para o alívio imediato das privações alimentares, uma vez que permite que os beneficiários tenham acesso a uma maior quantidade de alimentos, porém não tem sido suficiente para melhorar a qualidade dessa alimentação, de modo a tirá-los da situação de insuficiência alimentar em que se encontram (leve, moderada ou grave) e colocá-los numa situação de segurança alimentar. Desse modo, destaca-se a relevância de políticas complementares e o potencial das técnicas de aprendizado de máquina na avaliação de políticas públicas.

Palavras-chave: Segurança Alimentar; Insegurança Alimentar; Bolsa Família; Inteligência Artificial

ABSTRACT

MEIRA, Maurício Almeida, M.Sc., Universidade Federal de Viçosa, March, 2026. **Impacts of the Bolsa Família Program on food security and insecurity in Brazil: an application of artificial intelligence methods.** Adviser: Cristiana Tristao Rodrigues.

This study analyzes the impacts of the Bolsa Família Program on food security and insecurity in Brazil, using microdata from the 2017–2018 Household Budget Survey. The objective is to estimate the average effect of the program and investigate the heterogeneity of impacts among different socioeconomic groups. The methodology combines the traditional Propensity Score Matching method with machine learning techniques applied to causal inference, specifically Causal Forest and X-Learner. The results indicate high consistency between the methods, highlighting a negative effect of the program on the probability of food security and positive effects on food insecurity categories, especially moderate and severe, reflecting the targeted nature of the policy. Heterogeneity analyses show that the impacts are more intense among women, Black and Indigenous individuals, households with lower levels of education, and residents in more vulnerable regions. Although the artificial intelligence methods do not alter the central conclusions obtained by PSM, they broaden the understanding of the effects by identifying heterogeneity in a flexible and statistically validated way. It is concluded that, although Bolsa Família acts as an important policy for the immediate relief of food deprivation, since it allows beneficiaries to access a greater quantity of food, it has not been sufficient to improve the quality of that food, so as to lift them out of the situation of food insecurity in which they find themselves (mild, moderate or severe) and place them in a situation of food security. Therefore, the relevance of complementary policies and the potential of machine learning techniques in the evaluation of public policies are highlighted.

Keywords: Food Security; Food Insecurity; Bolsa Família (Family Allowance Program); Artificial Intelligence

LISTA DE QUADROS

Quadro 1 – Descrição das variáveis dependentes.....	27
Quadro 2 – Descrição das variáveis independentes.....	28

LISTA DE TABELAS

Tabela 1: Estatísticas descritivas das covariáveis: beneficiários e não beneficiários do Programa Bolsa Família (antes do pareamento)	47
Tabela 2: Resultados do modelo logit para participação no Bolsa Família.....	49
Tabela 3 – Teste de balanceamento das covariáveis após o pareamento.....	55
Tabela 4: Efeito médio do tratamento (ATT) — PSM, Causal Forest e X-Learner.....	57
Tabela 5: ATT estimado por diferentes métodos de pareamento (Raio, Kernel e Estratificação).....	60
Tabela 6: Testes de calibração do causal forest (Best Linear Predictor).....	61
Tabela 7: Efeitos heterogêneos por características individuais — PSM, Causal Forest (CF) e X-Learner (XL).....	63
Tabela 8: Efeitos heterogêneos por nível de instrução — PSM, Causal Forest (CF) e X-Learner (XL).....	67
Tabela 9: Efeitos heterogêneos por região — PSM, Causal Forest (CF) e X-Learner (XL).....	69
Tabela 10: Efeitos heterogêneos por localização — PSM, Causal Forest (CF) e X-Learner (XL).....	71

LISTA DE GRÁFICOS

Gráfico 1: Distribuição do escore de propensão antes e depois do pareamento.....	52
Gráfico 2: Gráfico de balanceamento das covariáveis (Love Plot).....	53

SUMÁRIO

1 INTRODUÇÃO	10
1.1 Contextualização e o problema de pesquisa.....	10
1.2 Objetivos	13
1.3 Hipótese.....	14
2 ASPECTOS CONCEITUAIS, TEÓRICOS E EMPÍRICOS	14
2.1 O conceito de segurança e insegurança alimentar.....	14
2.2 Desenho e Características do Programa Bolsa Família no Período Analisado.....	16
2.3 Efeitos de programas de transferência de renda sobre a segurança e insegurança alimentar.....	18
2.4 Aplicação de machine learning para inferência causal em políticas públicas	23
3 METODOLOGIA	25
3.1 A base de dados	25
3.2 Descrição das variáveis	26
3.3 Métodos Analíticos.....	29
3.3.1 Propensity Score Matching (PSM).....	29
3.3.2 Causal Forest (Floresta Causal).....	32
3.3.3 X-learner	39
3.3.4 Análise Comparativa dos Métodos: Vantagens, Limitações e Justificativas	43
4 RESULTADOS E DISCUSSÕES	45
4.1 Estatísticas descritivas e balanceamento	46
4.2 Efeito médio do tratamento (ATT).....	57
4.3 Efeitos heterogêneos	62
4.3.1 Gênero, raça e idade.....	62
4.3.2 Nível de instrução.....	66
4.3.3 Região.....	69
4.3.4 Localização	71
4.4 Comparando os resultados	73
4.5 Discussão dos Mecanismos Causais.....	74
5 CONCLUSÃO	76
REFERÊNCIAS	80

1 INTRODUÇÃO

1.1 Contextualização e o problema de pesquisa

A segurança alimentar e nutricional é um direito humano essencial, mas sua garantia segue como um desafio global no século XXI. No Brasil, apesar dos avanços no combate à fome, os dados da POF 2017-2018 do IBGE mostraram retrocessos. Segundo Hoffmann (2021), após melhora entre 2004 e 2013, a proporção de domicílios com segurança alimentar caiu de 77,4% para 63,3%, nível inferior a 2004. Isso indica que mais de um terço dos lares enfrentava insegurança alimentar. Santiago et al. (2023) detalham que 27,05% viviam com insegurança leve, 8,96% moderada e 4,96% grave. Essa vulnerabilidade é desigual: Norte e Nordeste registraram apenas 37,82% e 45,76% de segurança, contra 76,63% no Sul. Além das diferenças regionais, o problema reflete desigualdades sociais: mulheres, negros e indivíduos com baixo nível de escolaridade são os mais afetados.

Diante desse cenário, políticas de proteção social tornam-se centrais. No Brasil, o Programa Bolsa Família (PBF), criado em 2003, consolidou-se como principal estratégia de transferência de renda e combate à pobreza. Conforme Silva (2018), originado da unificação de programas anteriores, o PBF alia alívio imediato da pobreza, via benefício monetário, à promoção do capital humano, com condicionalidades em saúde e educação. Após mais de duas décadas, mantém-se essencial ao sistema de proteção social, sendo mecanismo de redistribuição de renda e estímulo à demanda agregada.

A avaliação do impacto do Bolsa Família (PBF) sobre a segurança e insegurança alimentar tem sido objeto de diversos estudos, majoritariamente com dados da POF 2008-2009 e o método PSM. Ainda assim, a relativa escassez de análises com dados recentes evidencia uma lacuna na literatura. Alguns trabalhos demonstram que os recursos do programa são majoritariamente usados na compra de alimentos, mitigando a fome mais severa, como apontado por Almeida et al. (2016). Entretanto, o aumento da renda não garante, por si só, a segurança alimentar e nutricional. Isso ocorre porque o poder de compra adicional pode ser utilizado na aquisição de alimentos ultraprocessados, de baixo valor nutritivo, conforme destaca Pereira (2024).

Além disso, a avaliação de impacto de políticas públicas, como o Bolsa Família, enfrenta o desafio metodológico central de construir o contrafactual: estimar o que teria acontecido aos beneficiários sem o programa. Como é impossível observar o mesmo indivíduo em duas realidades, recorre-se a métodos de inferência causal. Técnicas tradicionais como o

Pareamento por Escore de Propensão (PSM), Diferenças em Diferenças (DiD) e Regressão Descontínua (RDD) criam um grupo de comparação com base em não-participantes semelhantes. Contudo, a eficácia desses métodos pode ser limitada em cenários com muitas variáveis, interações complexas e heterogeneidade nos efeitos.

Diante disso, a inteligência artificial, especificamente o aprendizado de máquina, surge como uma alternativa promissora para modelar relações entre covariáveis com maior flexibilidade, permitindo a estimação de efeitos heterogêneos de forma mais adaptativa do que os métodos tradicionais. A aplicação dessa abordagem já foi explorada em alguns trabalhos, demonstrando essa flexibilidade. Wink Junior et al. (2022), por exemplo, utilizaram o algoritmo BART para avaliar o impacto de UPAs em hospitalizações. Em outro contexto, Santos (2023) aplicou Causal Forest para estimar os efeitos heterogêneos de se estudar em escolas federais no desempenho do ENEM. Já Cerdà-Bautista et. al (2024) fizeram uso do método x-learner para estimar o impacto causal de intervenções humanitárias baseadas em transferência de renda (cash-based interventions) sobre a desnutrição aguda (Global Acute Malnutrition – GAM) na Somália, durante episódios severos de seca.

No campo específico do Bolsa Família, trabalhos recentes começam a empregar essas técnicas. Maciel e Duarte (2023), por exemplo, compararam múltiplos algoritmos de machine para aprimorar a estimação do propensity score. Já Silva (2023), aplicou Causal Forests para investigar os efeitos heterogêneos do programa sobre a oferta de trabalho. Desse modo, esses estudos sinalizam uma fronteira metodológica inovadora e com grande potencial para aprimorar as avaliações de políticas sociais.

Diante do exposto, com uso dos dados da Pesquisa de Orçamentos Familiares (POF) de 2017-2018, este trabalho analisa o impacto do Programa Bolsa Família na segurança e insegurança alimentar de seus beneficiários, utilizando dois métodos de machine learning (aprendizado de máquina), que é uma área da inteligência artificial, isto é, o causal forest (ou floresta causal) e o X-learner. Também é utilizado o método Propensity Score Matching (PSM), para fins de comparação. A questão é: o programa bolsa família tem reduzido a insegurança alimentar e promovido a segurança alimentar nos domicílios brasileiros?

Dessa maneira, o diferencial desta pesquisa reside em duas frentes principais. Primeiramente, o trabalho oferece uma contribuição temática relevante ao analisar os impactos do Programa Bolsa Família utilizando os microdados da Pesquisa de Orçamentos Familiares (POF 2017-2018), edição mais recente disponível à época da realização deste estudo. Embora dados mais atuais possam ter surgido desde então, e o programa tenha passado por

reformulações institucionais nos anos seguintes, em um cenário de deterioração dos indicadores sociais no período, fornecer uma avaliação atualizada sobre a capacidade do programa em mitigar a insegurança alimentar preenche uma lacuna temporal na literatura e fornece evidências cruciais para o debate público e para a formulação de políticas em um contexto pós- crise, contrastando com a maioria dos estudos concentrados em dados de quase duas décadas atrás.

Contudo, o pilar central e a contribuição mais significativa deste estudo são de natureza metodológica. A pesquisa se insere em um dos principais desafios da inferência causal em ciências sociais: a construção de um contrafactual válido na ausência de aleatorização. Métodos tradicionais, como o Propensity Score Matching (PSM), embora amplamente consolidados na literatura, baseiam-se na hipótese de seleção em observáveis — assumindo que, condicionadas as características observáveis incluídas no modelo, a participação no programa é como se fosse aleatória — e podem ter sua capacidade analítica limitada ao fornecer apenas o efeito médio do tratamento, sem capturar automaticamente interações complexas entre covariáveis. É importante destacar que os métodos de aprendizado de máquina empregados neste trabalho compartilham essa mesma hipótese de identificação: sua principal vantagem não reside em superar o problema dos não observáveis, mas em modelar as relações entre covariáveis de forma mais flexível e em estimar a heterogeneidade dos efeitos sem necessidade de definir subgrupos a priori.

Este trabalho busca avançar nessa discussão ao empregar métodos de aprendizado de máquina (machine learning). Técnicas como Causal Forests e X-learner conseguem capturar relações não-lineares e padrões de alta dimensionalidade dos dados, permitindo a construção de um grupo de comparação sintético de forma mais flexível. Dessa forma, ao aprimorar a construção do contrafactual, a aplicação de machine learning permite ir além da simples mensuração do impacto médio do programa, pois permite desvendar os efeitos heterogêneos do tratamento, identificando com maior granularidade quais subgrupos populacionais (definidos por características regionais, demográficas, de gênero ou renda) são mais ou menos impactados pela política. Assim, esta pesquisa mostra os efeitos do programa sobre características individuais (gênero, raça e idade), educação (nível de instrução), região (norte, nordeste, centro-oeste, sudeste e sul) e localização (zona urbana e zona rural).

Desse modo, este estudo busca contribuir para a literatura ao oferecer uma avaliação rigorosa e atualizada do impacto do Programa Bolsa Família sobre a segurança e a insegurança alimentar no Brasil, combinando métodos tradicionais de inferência causal com abordagens

recentes baseadas em aprendizado de máquina. Ao estimar tanto o efeito médio do programa quanto a heterogeneidade dos impactos entre diferentes grupos socioeconômicos, a pesquisa amplia a compreensão sobre como a política atua em contextos marcados por elevada desigualdade social e regional. Além de fornecer evidências empíricas relevantes para o debate acadêmico, os resultados têm potencial para subsidiar a formulação e o aprimoramento de políticas públicas, ao indicar em quais perfis populacionais o programa apresenta maior efetividade e onde políticas complementares se mostram mais necessárias. Para tanto, o trabalho organiza-se da seguinte forma: a próxima seção apresenta a revisão de literatura e os fundamentos metodológicos; em seguida, descrevem-se os dados e a estratégia empírica; posteriormente, são discutidos os resultados obtidos a partir dos diferentes métodos de estimação; e, por fim, são apresentadas as conclusões e implicações do estudo.

1.2 Objetivos

Esta pesquisa tem como objetivo geral avaliar o impacto médio e os efeitos heterogêneos do Programa Bolsa Família sobre a segurança e insegurança alimentar dos domicílios brasileiros, combinando métodos econométricos tradicionais e técnicas de machine learning aplicadas aos microdados da POF 2017–2018, de modo a compreender quais perfis de domicílios são mais beneficiados.

São objetivos específicos desta dissertação:

- a) Caracterização dos dados;
- b) Avaliar o impacto médio e efeitos heterogêneos do Programa Bolsa Família sobre a segurança e insegurança alimentar usando o método Propensity Score Matching (PSM);
- c) Avaliar o impacto médio e efeitos heterogêneos do Programa Bolsa Família sobre a a segurança e insegurança alimentar usando o método de machine learning Causal Forest;
- d) Avaliar o impacto médio e efeitos heterogêneos do Programa Bolsa Família sobre a a segurança e insegurança alimentar usando o método de machine learning X-learner;
- e) Comparar os resultados do efeito médio e efeitos heterogêneos do Programa Bolsa Família sobre a segurança e insegurança alimentar dos três métodos

1.3 Hipótese

A hipótese central que norteia este trabalho é que, considerando a aplicação de técnicas de inteligência artificial (machine learning), o Programa Bolsa Família apresenta impacto significativo na redução da insegurança alimentar dos domicílios brasileiros beneficiários. Além disso, parte-se da hipótese de que os efeitos do programa não são homogêneos entre todos os grupos sociais. Espera-se que os impactos sejam mais intensos entre famílias em situação de extrema pobreza, com maior número de crianças, residentes em áreas rurais ou em regiões historicamente mais vulneráveis. Por fim, espera-se que os resultados obtidos pelos métodos de aprendizado de máquina sejam qualitativamente consistentes com os do PSM — dado que todos compartilham a hipótese de seleção em observáveis —, mas que ampliem a análise ao revelar padrões de heterogeneidade dos efeitos de forma mais flexível e estatisticamente validada, sem necessidade de definir subgrupos a priori.

2 ASPECTOS CONCEITUAIS, TEÓRICOS E EMPÍRICOS

2.1 O conceito de segurança e insegurança alimentar

A Segurança Alimentar e Nutricional (SAN) é um conceito complexo e multidimensional que representa um direito humano fundamental. Longe de se limitar à mera disponibilidade de alimentos, sua definição abrange um conjunto de fatores que garantem uma vida digna e saudável. Historicamente, a compreensão sobre o tema evoluiu significativamente, passando de uma preocupação restrita à produção nacional para uma abordagem que engloba o acesso, a qualidade, a cultura e a sustentabilidade, refletindo a complexidade do fenômeno da fome e da má nutrição na sociedade contemporânea.

Inicialmente, de acordo com Custódio et al. (2011), o conceito de Segurança Alimentar surgiu na Europa no início do século XX e estava associado à capacidade de um país de produzir sua própria alimentação, evitando vulnerabilidades externas. Essa visão, centrada na oferta e na autossuficiência, foi ampliada após a Segunda Guerra Mundial com a criação de organismos como a Organização das Nações Unidas para a Agricultura e a Alimentação (FAO). Com a crise de escassez de alimentos na década de 1970, a discussão internacional passou a dar maior ênfase à questão do acesso, ou seja, à capacidade de as populações obterem os alimentos, deslocando o foco da simples produção para a distribuição e a demanda.

Ao longo dos anos, o conceito continuou a se expandir. Conforme apontam Custódio et al. (2011), o componente "nutricional" ganhou força no final da década de 1980, quando a FAO passou a reiterar a importância da qualidade sanitária, biológica e cultural dos alimentos para a plena garantia da SAN. Isso significou que não bastava apenas ter acesso a calorias, mas era preciso que os alimentos fossem seguros para o consumo, adequados do ponto de vista nutricional e respeitassem as práticas e os hábitos culturais de cada povo.

No contexto brasileiro, essa visão ampliada foi consolidada durante a preparação para a Cúpula Mundial de Alimentação. De acordo com Custódio et al. (2011), a delegação brasileira apresentou em 1996 uma definição de SAN que se tornou referência: "garantir a todos condições de acesso a alimentos básicos, seguros e de qualidade, em quantidade suficiente, de modo permanente e sem comprometer o acesso a outras necessidades essenciais, com base em práticas alimentares saudáveis, contribuindo assim para uma existência digna em um contexto de desenvolvimento integral da pessoa humana". Essa definição articula as dimensões de acesso, qualidade, quantidade, regularidade e adequação sociocultural.

Posteriormente, o conceito brasileiro de SAN foi ainda mais aprofundado. Segundo Segall-Corrêa e Marin-Leon (2009), a II Conferência Nacional de Segurança Alimentar e Nutricional, em 2004, ampliou a definição para incluir a sustentabilidade. A SAN passou a ser entendida como o direito ao acesso a alimentos de qualidade, "que respeitem a diversidade cultural e que sejam social, econômica e ambientalmente sustentáveis". Com isso, o conceito passou a englobar não apenas o bem-estar presente, mas também a responsabilidade com as gerações futuras e com o meio ambiente.

Para além da conceituação teórica, a compreensão da insegurança alimentar avançou ao ser entendida como uma experiência progressiva, com estágios de gravidade distintos. Segall-Corrêa e Marin-Leon (2009) descrevem que a insegurança alimentar, do ponto de vista da percepção familiar, não é um evento binário (ter ou não ter fome), mas um processo que se inicia com a preocupação e a incerteza sobre a capacidade de obter alimentos no futuro próximo.

Avançando na severidade, o segundo estágio envolve o comprometimento da qualidade da alimentação. As famílias, na tentativa de garantir a quantidade de comida necessária, passam a consumir uma dieta menos variada e nutricionalmente mais pobre. Conforme a situação se agrava, o terceiro estágio é marcado pela restrição quantitativa, inicialmente entre os adultos do domicílio, que reduzem a quantidade de alimentos que consomem para proteger os mais jovens. Na fase mais grave, a restrição quantitativa atinge também as crianças, caracterizando a experiência da fome.

No Brasil, essa conceituação da insegurança alimentar como uma experiência escalonada foi operacionalizada por meio da Escala Brasileira de Insegurança Alimentar (EBIA). Conforme explicam Segall-Corrêa e Marin-Leon (2009), a EBIA é um instrumento composto por um conjunto de perguntas que buscam captar diretamente essas experiências, permitindo classificar os domicílios em quatro níveis: um de segurança alimentar e três de insegurança alimentar (Leve, Moderada e Grave). Um domicílio só é considerado em segurança alimentar se nenhuma das perguntas da escala for respondida afirmativamente.

Contudo, é fundamental reconhecer as nuances desse método de mensuração. Hoffmann (2021) argumenta que, por se basear em perguntas sobre preocupações e percepções, a EBIA possui um caráter parcialmente subjetivo. Essa subjetividade tem implicações importantes para a interpretação dos dados. Hoffmann (2021) sugere que, em um cenário de crise econômica após um longo período de melhoria, como o ocorrido no Brasil entre 2013 e 2018, a insatisfação e a incerteza podem levar a um aumento das respostas afirmativas, especialmente para a insegurança alimentar leve, que pode não ser proporcional à piora em indicadores objetivos, como os de pobreza. A evolução da insegurança alimentar grave, por outro lado, mostra-se mais alinhada às variações da pobreza.

Desse modo, os conceitos de segurança e insegurança alimentar são robustos e evoluíram de uma visão focada na produção para um direito humano multidimensional que engloba acesso permanente a alimentos adequados, nutritivos, seguros e produzidos de forma sustentável. No Brasil, a operacionalização desse conceito através da EBIA permitiu medir diretamente a experiência da insegurança alimentar em seus diferentes níveis. No entanto, a aplicação desse instrumento revelou que a medição da insegurança, especialmente em seus graus mais leves, carrega um componente subjetivo ligado à percepção e às expectativas da população, o que exige uma análise cuidadosa e contextualizada dos dados para a correta formulação e avaliação de políticas públicas.

2.2 Desenho e Características do Programa Bolsa Família no Período Analisado

O Programa Bolsa Família (PBF), criado em outubro de 2003, consolidou a unificação de programas de transferência de renda anteriores — Bolsa Escola, Bolsa Alimentação, Auxílio-Gás e Cartão Alimentação — em uma única política de proteção social. Conforme Souza et al. (2018), ao longo de seus primeiros quinze anos, o programa consolidou-se como o maior programa de transferência condicionada de renda do mundo, tornando-se referência obrigatória para acadêmicos e formuladores de políticas no campo da proteção social.

No que concerne aos critérios de elegibilidade, para acesso ao programa, os domicílios deveriam atender a critérios de renda estabelecidos pelo governo federal. Segundo Souza et al. (2018), o PBF adotou duas linhas de elegibilidade: a linha de extrema pobreza, para famílias com renda per capita de até R\$ 89,00, e a linha de pobreza, para famílias com renda per capita entre R\$ 89,01 e R\$ 178,00. As famílias em situação de pobreza eram elegíveis desde que possuíssem gestantes, nutrizes ou crianças e adolescentes em sua composição. Além do critério de renda, as famílias deveriam estar cadastradas no Cadastro Único para Programas Sociais do Governo Federal (CadÚnico), que em 2018 possuía mais de 28 milhões de famílias cadastradas.

Com relação a estrutura de benefícios, de acordo com Souza et al. (2018), o PBF era composto por diferentes tipos de transferências. Apenas famílias em extrema pobreza tinham acesso ao benefício básico, de valor único para toda a família. Famílias em situação de pobreza e de extrema pobreza também poderiam receber benefícios variáveis, caso tivessem crianças de até 15 anos de idade, limitados a cinco por família. Em 2007, surgiu o Benefício Variável Vinculado ao Adolescente (BVJ), pago a famílias com jovens entre 16 e 17 anos, limitado a dois por família. Entre 2012 e 2013, foi criado o Benefício para Superação da Extrema Pobreza (BSP), um complemento calculado para garantir que a renda per capita das famílias beneficiárias alcançasse no mínimo a linha de extrema pobreza.

Conforme registros administrativos apresentados por Souza et al. (2018), o valor médio das transferências do PBF aumentou progressivamente ao longo do tempo, situando-se em torno de R\$ 180,00 por mês por família em 2017, o ponto mais alto da série histórica até então. O recebimento do benefício estava vinculado ao cumprimento de condicionalidades nas áreas de saúde e educação. Segundo Silva (2018), as condicionalidades de educação exigiam matrícula e frequência escolar mínima de 85% da carga horária mensal para crianças e adolescentes de 6 a 15 anos, e frequência mínima de 75% para adolescentes de 16 e 17 anos. Na área de saúde, os compromissos incluíam manter atualizado o calendário de vacinação das crianças menores de 7 anos, levá-las para acompanhamento de peso e estatura pelo menos uma vez a cada seis meses, além da participação das gestantes no pré-natal e comparecimento às consultas nas unidades de saúde.

Sobre a cobertura no período, em consonância com Souza et al. (2018), o número de famílias beneficiárias expandiu-se rapidamente nos primeiros anos do programa, saltando de cerca de 6 milhões em 2004 para aproximadamente 11 milhões em 2006. A partir de então, a cobertura cresceu de forma mais gradual até atingir 14 milhões de famílias em 2014, patamar no qual o programa permaneceu com oscilações temporárias. Em 2018, as quase 14 milhões de famílias beneficiárias abarcavam mais de um quinto da população brasileira, permitindo que o

programa cobrisse grande parte da população pobre e vulnerável. A distribuição regional da cobertura refletia as desigualdades socioeconômicas do país, com maior concentração de beneficiários nas regiões Norte e Nordeste.

Dessa forma, o desenho institucional do Programa Bolsa Família no período analisado caracterizava-se pela combinação de transferência monetária condicionada com mecanismos de focalização baseados em critérios de renda, estrutura de benefícios diferenciada conforme a composição familiar e o grau de vulnerabilidade, e exigência de contrapartidas nas áreas de saúde e educação. Essa configuração refletia a concepção do programa como política de alívio imediato da pobreza e, simultaneamente, de investimento no capital humano das famílias beneficiárias. A compreensão dessas características é fundamental para a interpretação dos resultados apresentados neste trabalho, uma vez que o valor médio do benefício, os critérios de elegibilidade e a focalização do programa condicionam tanto a magnitude quanto a natureza dos impactos sobre a segurança e insegurança alimentar dos domicílios beneficiários.

2.3 Efeitos de programas de transferência de renda sobre a segurança e insegurança alimentar

Em um dos estudos seminais sobre o tema, Baptistella (2012), teve como objetivo central avaliar o impacto do Programa Bolsa Família sobre o consumo de alimentos e o status nutricional das famílias beneficiárias, buscando responder em que medida o programa colabora para a segurança alimentar. Para isso, a autora utilizou os microdados da Pesquisa de Orçamentos Familiares (POF) de 2008-2009 e aplicou o método de pareamento por escore de propensão (propensity score matching) para construir um grupo de controle estatisticamente comparável ao grupo de tratamento. As conclusões indicaram que o programa teve um impacto positivo e significativo, elevando o gasto anual com alimentação das famílias tratadas, principalmente em itens que compõem a cesta básica. No que tange ao impacto nutricional, via Índice de Massa Corporal (IMC), os resultados foram mistos: o programa contribuiu para elevar a proporção de crianças e adolescentes com peso normal, mas, em contrapartida, colaborou para um aumento na proporção de adultos com obesidade.

Avançando na discussão sobre a qualidade do consumo, Almeida et al. (2016) analisaram o efeito do PBF sobre o nível de diversificação do consumo de alimentos entre as famílias beneficiárias em áreas urbanas. Utilizando também a POF 2008-2009 e o método de propensity score matching, o diferencial do estudo foi a mensuração de dois indicadores: o Índice de Berry, que mede a variedade de itens, e o Índice de Diversificação Saudável (HFD), que pondera os

alimentos por seu valor nutricional. Os resultados revelaram uma dualidade importante: enquanto o PBF influenciou positivamente a diversificação do consumo (aumento da variedade de itens), esse efeito não se mostrou significativo quando considerada a qualidade nutricional da cesta. A conclusão central foi que o incremento de renda do programa, por si só, não foi suficiente para gerar melhorias na direção de uma dieta com mais itens saudáveis.

Em uma análise com resultados contraintuitivos, Duarte et al. (2019) também investigaram o impacto do PBF sobre as despesas de consumo das famílias, utilizando a POF 2008-2009. A estratégia empírica, assim como nos trabalhos anteriores, baseou-se no Propensity Score Matching, com foco no pareamento estratificado para comparar as despesas totais, alimentares e não alimentares entre os grupos. Surpreendentemente, os resultados indicaram que os beneficiários do programa tiveram um gasto total e em suas subcategorias menor do que o grupo de controle. Os autores justificam essa descoberta pelo baixo valor do benefício na época, incapaz de, por si só, elevar o patamar de consumo, e pela possibilidade de que a renda transferida seja utilizada para outros fins que não o consumo imediato, oferecendo uma perspectiva divergente sobre a efetividade do programa.

Com foco nas disparidades regionais, Sperandio et al. (2016), realizaram um estudo comparativo do impacto do PBF no consumo alimentar entre as regiões Sudeste e Nordeste, utilizando o módulo de consumo individual da POF 2008-2009 e o método de Propensity Score Matching. A principal inovação do trabalho foi a classificação dos alimentos segundo o grau de processamento industrial (in natura, processados, ultraprocessados), alinhada ao Guia Alimentar para a População Brasileira. Os achados apontaram que os beneficiários, em ambas as regiões, consumiram menos alimentos processados e ultraprocessados. Contudo, o impacto positivo no consumo de alimentos in natura ou minimamente processados foi significativo apenas para a região Nordeste, sugerindo que o contexto socioeconômico regional modula os efeitos do programa e que os beneficiários do Nordeste apresentaram um padrão alimentar mais saudável.

Coelho e Melo (2015) focaram sua análise no impacto do PBF sobre a qualidade da dieta, com um estudo de caso para o estado de Pernambuco. Utilizando a POF 2008-2009 e o método de Propensity Score Matching, a pesquisa se diferenciou ao empregar o Índice de Qualidade da Dieta (IQD) como principal variável de resultado, um indicador que avalia a conformidade da alimentação com recomendações nutricionais. Os resultados demonstraram um efeito positivo e significativo, com as famílias beneficiárias apresentando um IQD, em média, 9,05 pontos superior ao das não beneficiárias. Esta melhoria foi associada a um aumento na variedade da dieta e à redução no consumo de gordura e sódio, indicando que, no contexto analisado, o

programa foi eficaz não apenas no acesso, mas também na promoção de uma alimentação qualitativamente superior.

Com uma abordagem distinta, Ferraz et al. (2018) analisaram os determinantes do consumo alimentar domiciliar comparando diferentes estratos de renda no Brasil (pobres, classe média e alta), a partir dos dados da POF 2008- 2009. Ao invés de avaliar o impacto de um programa específico, o estudo utilizou um modelo logístico para verificar quais características sociodemográficas afetam a probabilidade de consumo de determinados grupos de alimentos. Os resultados mostraram que os domicílios pobres têm menor probabilidade de adquirir frutas, legumes e verduras, mas maior probabilidade de consumir aves, ovos e carne de segunda. Em contrapartida, as classes de renda mais altas apresentaram maior chance de consumir açúcares e refrigerantes, evidenciando que a qualidade nutricional é um desafio em todos os estratos sociais.

Já o trabalho de Rocha et al. (2016) buscou investigar como o Programa Bolsa Família (PBF) impactou os padrões de consumo, analisando as diferenças entre os domicílios rurais e urbanos. Para a análise, os autores utilizaram microdados das Pesquisas de Orçamentos Familiares (POF) de 2002-2003 e 2008-2009, aplicando uma combinação dos métodos de Propensity Score Matching (PSM) e Diferenças em Diferenças (DD). Os resultados mostraram que, em valores absolutos, o PBF elevou significativamente o montante gasto em todas as categorias de consumo. Contudo, em termos relativos, a parcela da despesa destinada à alimentação diminuiu tanto nos domicílios rurais (4,89%) quanto nos urbanos (8,46%).

Por fim, com o objetivo de avaliar o impacto da transferência de renda do Programa Bolsa Família sobre os gastos com alimentos de famílias rurais, Duarte et al. (2009) utilizaram o método de Propensity Score Matching (PSM) para corrigir o viés de seleção. A análise foi baseada em dados de uma pesquisa de campo realizada em 2005 com famílias de agricultores no Nordeste. Os resultados apontaram um impacto positivo, mostrando que as despesas anuais com alimentos das famílias beneficiárias superaram em R\$ 246 as dos não participantes. Os autores inferiram que 88% do valor transferido pelo programa foi utilizado para o consumo de alimentos.

Considerando o uso dos dados mais recentes da POF 2017-2018, Palmeira et.al (2022) investigou a associação entre o acesso a programas governamentais e a insegurança alimentar (IA) nas áreas urbana e rural do Nordeste. Diferentemente dos estudos de impacto causal, a metodologia empregou modelos de regressão logística multinomial para estimar a chance de ocorrência dos diferentes níveis de IA. Os resultados revelaram que, na área rural, o acesso ao Bolsa Família associou-se a um fator de proteção contra a IA grave. Já na área urbana, o

principal fator protetor para a IA grave foi o Cartão Alimentação, enquanto o Bolsa Família se associou a uma menor probabilidade apenas de IA leve e moderada. O estudo destaca a importância dos programas, mas também as diferenças contextuais na eficácia de cada benefício.

Focando na demanda individual e na classificação de alimentos por grau de processamento, Pereira (2024), também com base na POF 2017-2018, analisaram o efeito do Bolsa Família na parcela de dispêndio com alimentos in natura ou minimamente processados e ultraprocessados. Utilizando o método de propensity score matching para estimar equações de demanda, as autoras constataram que os beneficiários tendem a destinar uma parcela maior do seu gasto para alimentos in natura e a reduzir a parcela gasta com ultraprocessados. No entanto, o estudo conclui que, apesar dessa mudança positiva na direção de um consumo mais saudável, o benefício não é suficiente para promover uma ampla diversificação alimentar, com o gasto ainda concentrado em poucos itens dentro das categorias consideradas mais saudáveis, como cereais e leguminosas.

Com foco específico na nutrição infantil e utilizando a POF 2017-2018, Torres et al. (2022) identificaram o efeito do PBF sobre o consumo de macronutrientes (energia, carboidratos, proteínas e lipídios) em crianças de famílias beneficiárias. Por meio de métodos de pareamento (Propensity Score Matching e Weighting) ajustados para a estrutura complexa da amostra, os autores constataram um impacto positivo e significativo. Em relação ao valor energético, o programa proporcionou um aumento médio de 469 Kcal na dieta das crianças, além de elevações no consumo de todos os macronutrientes analisados. A análise de efeitos heterogêneos revelou que esses ganhos nutricionais foram mais expressivos e concentrados nas regiões Norte e Nordeste, reforçando a importância do programa nas áreas de maior vulnerabilidade socioeconômica do país.

Ampliando o escopo para outros programas de transferência, Rosales et al. (2022) avaliaram o impacto do Benefício de Prestação Continuada (BPC) sobre o estado nutricional e a segurança alimentar dos idosos, utilizando os dados da POF 2017-2018. A pesquisa destacou-se pela aplicação de duas metodologias de avaliação de impacto, o Propensity Score Matching e o Desenho de Regressão Descontínua (Fuzzy RDD), para aumentar a robustez dos resultados. As conclusões apontaram que o BPC não teve efeito estatisticamente significativo sobre os indicadores de estado nutricional (obesidade e subnutrição). No entanto, o programa demonstrou um impacto importante e positivo no aumento da segurança alimentar e na redução de algum tipo de insegurança alimentar, como a insegurança alimentar grave e leve, indicando que o benefício é crucial para garantir o acesso a alimentos para essa população vulnerável.

Os trabalhos acima utilizaram métodos tradicionais, como o Propensity Score Matching (PSM). Contudo, destaco também alguns que utilizaram técnicas de inteligência artificial, sobretudo machine learning, na avaliação de políticas públicas. Com relação ao uso de machine learning para analisar os impactos de programas de transferência de renda sobre a alimentação, há uma escassez de trabalhos na literatura, com um número muito pequeno de estudos publicados.

Na literatura internacional foram encontrados dois trabalhos que aplicaram um dos métodos utilizados nesta pesquisa, isto é, o X-learner. O primeiro, de Cerdà_Baustista et al. (2024), avaliou o impacto causal da ajuda humanitária em dinheiro na segurança alimentar no Chifre da África. A metodologia combinou um Grafo Acíclico Dirigido (DAG) para estruturar o problema causal com o uso de métodos modernos de machine learning para estimar os efeitos. Especificamente, algoritmos como o T-learner e o X-learner, implementados com Random Forest, foram usados para quantificar o impacto das transferências monetárias na desnutrição. Também aplicando X-learner, além de outros meta-learners como S-learner e T-learner, Kuei (2024) estimou os efeitos causais heterogêneos de um programa de fidelidade por assinatura (iFood Clube) sobre o comportamento de compra dos usuários, usando dados observacionais.

Com relação ao causal forest, foram encontrados os trabalhos de Weiffen et al. (2022), Rehill e Biddle (2024), Shah et al. (2025) e McIntosh e Zeitlin (2021). O primeiro, embora não aborda transferência de renda, avaliou como a transferência de ativos agrícolas impactou a segurança alimentar na Síria, com foco em como a intensidade do conflito modera esses efeitos. Utilizando um algoritmo de machine learning (honest causal forest) em um desenho quasi-experimental, o estudo encontrou um impacto positivo na segurança alimentar. O segundo utilizou o causal forest e Distilled Doubly Robust Causal Tree (DDRCT) para analisar os efeitos heterogêneos de transferências de dinheiro no Marrocos sobre as notas de matemática dos alunos. Shah et al. (2025) usaram Instrumental Causal Forest para analisar os impactos heterogêneos de um programa de transferência de renda da Indonésia sobre a utilização de cuidados de saúde materna. Por fim, o estudo de McIntosh e Zeitlin (2021) empregaram o causal forest (generalized random forest) para comparar um programa de nutrição em espécie a transferências monetárias de custo equivalente em Ruanda e estimar efeitos heterogêneos do tratamento, não sendo encontrados ganhos relevantes a custo equivalente, embora transferências maiores gerem melhorias modestas no crescimento infantil.

Na literatura nacional encontrou somente o trabalho de Maciel e Duarte (2023), os quais avaliaram o impacto do Bolsa Família no consumo de produtos não saudáveis, utilizando os dados da POF 2008-2009. A principal contribuição metodológica do estudo foi a comparação

de diferentes algoritmos de machine learning (random forests, gradient boosting, SVM e redes neurais) com a regressão logística tradicional para estimar o escore de propensão. O algoritmo gradient boosting apresentou a maior sensibilidade e menor taxa de erro. Os resultados substantivos indicaram que, embora os participantes do programa gastem mais com alimentos em geral, eles não alteram significativamente seus gastos com alimentos embalados, álcool ou tabaco, e a probabilidade de comprarem refrigerantes chega a diminuir, sugerindo que o PBF não incentiva o consumo de produtos não saudáveis.

Foram encontrados também alguns trabalhos que embora não tratam do tema da alimentação, avaliam os impactos de programas de transferência de renda sobre outras variáveis utilizando técnicas de machine learning. Na literatura nacional, Silva (2023) aplicou o Causal Forests para investigar os efeitos heterogêneos do programa bolsa família sobre a oferta de trabalho. Os resultados revelaram um impacto negativo mais acentuado para as mulheres, demonstrando a capacidade do método de ir além do efeito médio e mostrar os efeitos heterogêneos.

Em outro contexto, Santos (2023) aplicou o método Causal Forest para estimar os efeitos heterogêneos de se estudar em escolas federais no desempenho do ENEM. Por fim, Wink Junior et al. (2022), utilizaram o algoritmo Bayesian Additive Regression Trees (BART) para avaliar o impacto de Unidades de Pronto Atendimento (UPAs) em hospitalizações, usando o modelo para estimar a função de resposta à dose média (ADRF) e construir o contrafactual a partir de grupos que caem no mesmo "nó folha" da árvore de decisão. Desse modo, esses estudos sinalizam uma fronteira metodológica inovadora e com grande potencial para aprimorar as avaliações de políticas sociais.

2.4 Aplicação de machine learning para inferência causal em políticas públicas

A Inteligência Artificial (IA) pode ser entendida como um vasto campo da ciência da computação dedicado a criar sistemas capazes de realizar tarefas que normalmente exigiriam inteligência humana. Em vez de seguir um conjunto de instruções fixas, esses sistemas podem raciocinar, aprender e se adaptar. No contexto da análise de dados econômicos, a IA se manifesta principalmente por meio de seu subcampo, o aprendizado de máquina, que capacita os computadores a aprenderem padrões diretamente dos dados. Essa capacidade de aprendizado autônomo representa uma mudança de paradigma em relação às abordagens estatísticas tradicionais, que geralmente exigem que o pesquisador especifique previamente as relações funcionais entre as variáveis de interesse.

Dentro da área de inteligência artificial existe o Aprendizado de Máquina, ou Machine Learning (ML), que é um subcampo da IA composto por algoritmos que permitem aos computadores aprender com a experiência, identificando padrões e fazendo previsões sem serem explicitamente programados. Conforme Athey e Imbens (2017), os métodos de ML são tradicionalmente otimizados para a tarefa de previsão. Contudo, uma nova e promissora fronteira de pesquisa, que é o cerne deste trabalho, consiste em adaptar esses procedimentos preditivos para o desafio distinto da inferência causal. Embora a previsão e a estimação causal sejam objetivos diferentes, a capacidade do ML de modelar relações complexas está sendo aproveitada para aprimorar a avaliação de políticas públicas.

Um dos algoritmos de machine learning conhecido são as Florestas Aleatórias (Random Forests), introduzidas por Breiman (2001). O método consiste em construir um grande conjunto de árvores de decisão, onde cada árvore é treinada em uma amostra de dados ligeiramente diferente (processo de bagging). Em cada nó da árvore, apenas um pequeno subconjunto de variáveis é considerado para definir a divisão. Essa dupla aleatoriedade produz árvores descorrelacionadas entre si. O resultado final é obtido pela agregação das previsões de todas as árvores, o que resulta em um modelo robusto, com alta precisão preditiva e menos propenso ao sobreajuste (BREIMAN, 2001).

E foi desse algoritmo Random Forests que surgiu o método Causal Forest, ou Floresta Causal, especificamente desenhado por Wager e Athey (2018) para a inferência causal. Ele se baseia no modelo de resultados potenciais e na hipótese de não confundimento, assumindo que, dadas as características observáveis, a participação no tratamento é como se fosse aleatória. Ele utiliza as chamadas árvores "honestas", a qual usa subamostras distintas de dados para definir a estrutura da árvore e para estimar o efeito, reduzindo o viés de estimação. Este método tem sido útil em estudos observacionais, visto que com ele é possível criar subgrupos comparáveis, fortalecendo a construção do contrafactual, e estimar o impacto de determinada intervenção sobre diferentes perfis.

De forma complementar, Kunzel et al. (2019) propõem o método X-Learner, desenvolvido especificamente para contextos observacionais caracterizados por forte desbalanceamento entre grupos de tratados e controles, situação comum em avaliações de políticas públicas focalizadas. Diferentemente de abordagens que estimam diretamente o efeito médio, o X-Learner combina modelos de aprendizado supervisionado para estimar resultados potenciais e efeitos condicionais, atribuindo pesos distintos às estimativas conforme a densidade de observações em cada grupo. Essa estrutura torna o método particularmente adequado para a estimação do efeito médio do tratamento sobre os tratados (ATT) e para a análise detalhada da

heterogeneidade dos impactos. Ao permitir que os efeitos variem de forma flexível em função das características observáveis, o X-Learner amplia a capacidade de identificação de perfis que se beneficiam mais ou menos da intervenção, oferecendo uma ferramenta poderosa para a avaliação de políticas sociais em cenários de alta complexidade e não linearidade.

Em suma, a aplicação de técnicas de machine learning à inferência causal representa uma fronteira metodológica promissora na avaliação de políticas públicas. Algoritmos originalmente desenvolvidos para fins preditivos, como Random Forests, passaram a ser adaptados para a estimação de efeitos causais, dando origem a métodos como a Causal Forest e o X-Learner. Essas abordagens permitem construir contrafactuais com maior flexibilidade, lidar com alta dimensionalidade e capturar heterogeneidade complexa dos efeitos. Ao possibilitar uma análise mais refinada sobre “o que funciona” e, sobretudo, “para quem funciona”, essas técnicas contribuem para uma compreensão mais profunda do impacto de programas sociais focalizados, como o Programa Bolsa Família, e para o aprimoramento do desenho de políticas públicas baseadas em evidências.

3 METODOLOGIA

3.1 A base de dados

O presente trabalho utiliza como base de dados a POF – Pesquisa de Orçamentos Familiares – do período 2017-2018. A POF é realizada pelo Instituto Brasileiro de Geografia e Estatística (IBGE) por meio de uma amostra representativa de domicílios particulares permanentes, abrangendo áreas urbanas e rurais em todas as unidades da federação do Brasil. O principal objetivo da POF é obter informações sobre a estrutura de orçamentos (aquisições de produtos, serviços e rendimentos) e as condições de vida da população brasileira, incluindo novos módulos sobre bem-estar e percepções subjetivas.

A realização da POF 2017-2018 teve início em junho de 2017 e término em julho de 2018. O tamanho efetivo da amostra foi de 57.920 domicílios entrevistados em todo o território nacional. Ela visa disponibilizar informações sobre a composição dos orçamentos domésticos e as condições de vida da população brasileira, incluindo a percepção subjetiva da qualidade de vida, além de gerar bases de dados e estudos sobre o seu perfil nutricional. No domicílio é identificada a unidade básica da pesquisa – a unidade de consumo (UC) – constituída por um único morador ou conjunto de moradores que partilham da mesma fonte de alimentação ou das despesas com moradia. Em alguns domicílios é possível encontrar mais de uma unidade de

consumo, sendo a sua quantidade definida pelo número de fontes independentes de despesas. Iremos nos referir a unidade de consumo como família durante no decorrer deste trabalho.

A POF 2017-2018 inovou ao incluir, pela primeira vez, um módulo específico para avaliar a qualidade de vida e o bem-estar da população a partir de uma ótica subjetiva. Foram coletadas informações sobre a satisfação com a vida e com aspectos como moradia, trabalho e saúde. Além disso, a pesquisa aplicou a Escala Brasileira de Insegurança Alimentar (EBIA), permitindo uma análise detalhada sobre o acesso das famílias a uma alimentação adequada em quantidade e qualidade. A EBIA permite identificar e classificar os domicílios de acordo com os graus de severidade com que o fenômeno é vivenciado pelas famílias neles residentes, possibilitando, assim, estimar a magnitude do problema da insegurança alimentar nessas unidades. As perguntas referentes à EBIA, cabe destacar, são as mesmas investigadas nas PNADs, mantendo-se, dessa forma, a possibilidade de comparação dos indicadores e as informações da série histórica nacional sobre o tema.

Os resultados apresentados, abarcando as famílias residentes nas áreas urbana e rural, para o conjunto do país e as grandes regiões, enfocam a relação da situação de segurança ou insegurança alimentar existente nos domicílios com as características do orçamento doméstico e o modo de viver das famílias. Para tal, são consideradas informações sobre despesas e aquisições, características dos domicílios, aquisição alimentar domiciliar per capita, rendimento total e variação patrimonial, além da avaliação subjetiva das condições de vida em relação à moradia, saúde, educação e alimentação.

Por fim, outro avanço metodológico foi a investigação aprofundada do consumo alimentar pessoal, registrando-se os alimentos consumidos por cada morador, dentro e fora do domicílio, durante um período determinado. Essa abordagem permitiu uma análise nutricional mais precisa e detalhada dos hábitos alimentares dos brasileiros.

3.2 Descrição das variáveis

Para entender o impacto do programa bolsa família sobre a segurança e insegurança alimentar, seguiu-se a mensuração definida pela Escala Brasileira de Insegurança Alimentar (EBIA), visto que ela permite identificar e classificar as famílias de acordo com os graus de severidade de segurança e insegurança alimentar vivenciado pelas famílias, possibilitando, assim, estimar sua magnitude. O quadro 1 mostra a descrição das variáveis de resultados, as quais foram utilizadas nas estimativas.

Quadro 1: Descrição das variáveis dependentes

Variáveis	Descrição
Segurança alimentar	Dummy que identifica se a família tem segurança alimentar. Categorias: (1) Sim ; (0) Não.
Insegurança Alimentar Leve	Dummy que identifica se a família tem insegurança alimentar leve. Categorias: (1) Sim ; (0) Não.
Insegurança Alimentar Moderada	Dummy que identifica se a família tem insegurança alimentar moderada. Categorias: (1) Sim ; (0) Não.
Insegurança Alimentar Grave	Dummy que identifica se a família tem insegurança alimentar grave. Categorias: (1) Sim ; (0) Não.

Fonte: Elaboração própria com base em Rosales et al. (2022)

Conforme Santiago et al. (2023), a insegurança alimentar leve caracteriza-se pela preocupação ou incerteza quanto ao acesso a alimentos no futuro, o nível moderado já implica uma restrição quantitativa na alimentação dos adultos, e a insegurança alimentar grave representa a fome, que atinge a todos no domicílio. Já a segurança alimentar significa acesso pleno e regular aos alimentos, sem comprometer outras necessidades essenciais. Ou seja, não há preocupação com a falta de alimentos no futuro.

As variáveis de controle escolhidas refletem a participação ou não das famílias no programa bolsa família. Foram escolhidas variáveis relacionadas às características do domicílio, como moradia, água, energia, tipo de paredes, quantidade de cômodos e fogão utilizado; características do chefe das famílias, como educação, idade, gênero e raça, e a variáveis relacionadas à localização da família, isto é, se moram na zona urbana ou rural, e na região (norte, nordeste, centro-oeste, sudeste e sul). O quadro 2 apresenta a descrição das variáveis de controle.

Quadro 2: Descrição das variáveis independentes

Variáveis	Descrição
Características do chefe das famílias	
Educação	Anos de estudo do chefe da família.
Idade	Idade do chefe da família.
Gênero	Dummy que identifica o sexo do chefe da família. Categorias: (1) Sim ; (0) Não.
Raça	Dummy que identifica a raça do chefe da família. Categorias: (1) Sim ; (0) Não.
Características do domicílio	
Moradia	Dummy que identifica se o domicílio é alugado. Categorias: (1) Sim ; (0) Não.
Água	Dummy que identifica se o domicílio possui abastecimento de água por rede geral (1 = Sim; 0 = Não).
Energia	Dummy que identifica se o domicílio possui energia elétrica proveniente de rede geral. Categorias: (1) Sim ; (0) Não.
Tipo de Paredes	Dummy que identifica se o domicílio possui paredes de material sólido. Categorias: (1) Sim ; (0) Não.
Quantidade de cômodos	Número total de cômodos do domicílio.
Fogão	Dummy que identifica o uso de fogão a lenha ou carvão. Categorias: (1) Sim ; (0) Não.
Região	

Norte	Dummy que identifica se o domicílio está localizado na região Norte. Categorias: (1) Sim; (0) Não.
Nordeste	Dummy que identifica se o domicílio está localizado na região Nordeste. Categorias: (1) Sim; (0) Não.
Centro-Oeste	Dummy que identifica se o domicílio está localizado na região Centro-Oeste. Categorias: : (1) Sim; (0) Não.
Região Sudeste	Dummy que identifica se o domicílio está localizado na região Sudeste. Categorias: (1) Sim; (0) Não.
Região Sul	Dummy que identifica se o domicílio está localizado na região Sul. Categorias: : (1) Sim; (0) Não.
Localização do domicílio	
Zona Urbana	Dummy que identifica se o domicílio está localizado na zona urbana. Categorias: (1) Sim; (0) Não.

Fonte: Elaboração própria com base em Baptistella (2012) e Duarte et al. (2019).

Nota: A região Nordeste é utilizada como categoria de base.

Essas variáveis de controle foram utilizadas para estimar o score de propensão.

3.3 Métodos Analíticos

3.3.1 Propensity Score Matching (PSM)

Para estimar o impacto do Programa Bolsa Família (PBF) sobre a segurança e insegurança alimentar, o primeiro método empregado foi o Pareamento por Escore de Propensão, ou Propensity Score Matching (PSM). Cabe destacar que, como os demais métodos empregados neste trabalho, o PSM baseia-se na hipótese de seleção em observáveis: assume-se que, condicionadas as características observáveis incluídas no modelo, a participação no programa é como se fosse aleatória. Essa hipótese não garante controle sobre variáveis não observáveis que possam diferenciar beneficiários e não beneficiários, de modo que os resultados devem ser interpretados como diferenças médias condicionais robustas, e não como efeitos causais em sentido estrito. A escolha do PSM como método tradicional de base para esta

pesquisa se fundamenta em sua adequação à natureza dos dados. Proposto por Rosenbaum e Rubin (1983), é amplamente utilizado em estudos observacionais para mitigar o viés de seleção que surge quando os grupos de tratamento e controle não são formados aleatoriamente. A ideia central é construir um grupo de controle estatisticamente comparável ao grupo de tratamento, com base em um conjunto de características observáveis.

O método se baseia no modelo de resultados potenciais, onde cada família i possui dois resultados potenciais: $Y_i(1)$, seu nível de (in)segurança alimentar caso participe do PBF, e $Y_i(0)$, seu nível de (in)segurança alimentar caso não participe. O desafio é que apenas um desses resultados é observado. O PSM busca resolver esse problema construindo um contrafactual válido para os participantes do programa. A aplicação do método para este trabalho seguiu quatro passos principais.

Passo 1: Estimação do Escore de Propensão

O primeiro passo consistiu em estimar, para cada família da amostra, a probabilidade condicional de ser beneficiária do PBF, dadas suas características observáveis. Essa probabilidade é o escore de propensão, $p(x)$. Conforme Rosenbaum e Rubin (1983), o escore de propensão é um *balancing score*, o que significa que, ao condicionar a análise a este escore, as distribuições das características observáveis (X) se tornam independentes da condição de tratamento.

Para estimar o escore de propensão, foi utilizado um modelo de probabilidade logit. A variável dependente foi uma dummy RECEBE_BOLSA_FAMILIA, que assume valor 1 se a família é beneficiária do programa e 0 caso contrário. As variáveis independentes foram o conjunto de características das famílias e dos domicílios (vetor X_i) descritas no quadro 2. Seguindo Rosenbaum e Rubin (1983), a especificação do modelo logit, baseada na formulação do escore de propensão $e(x) = \text{pr}(z = 1 | x)$ e sua modelagem via logit é a seguinte:

$$\begin{aligned} \text{logit} (P(PBF_i = 1|X_i)) &= \ln \left(\frac{P(PBF_i = 1|X_i)}{1 - P(PBF_i = 1|X_i)} \right) \\ &= \beta_0 + \beta_1 Renda_i + \beta_2 Idade_i + \beta_3 C\acute{o}modos_i + \beta_4 Mulher_i + \beta_5 Ra\c{c}a_i \\ &+ \beta_6 Educa\c{c}\tilde{a}o_i + \beta_7 Regi\tilde{a}o_i + \beta_8 Zona Urbana_i + \beta_9 Infraestrutura_i \end{aligned}$$

Onde:

- $P(PBF_i = 1|X_i)$ é a probabilidade da família i ser beneficiária do PBF, dadas suas características X_i .
- As variáveis Renda, Idade, Cômodos, Mulher, Raça, Educação, Região, Zona Urbana e Raça são as covariáveis de controle. Para as variáveis categóricas como Região, foram utilizadas dummies, tendo uma categoria como base (ex: Nordeste).

A partir deste modelo, calcula-se o escore de propensão, $\hat{P}(X_i)$, para cada família da amostra, tanto do grupo de tratamento quanto do grupo de controle potencial.

Passo 2: Pareamento (Matching) e a Construção do Contrafactual

Após a estimação dos escores de propensão foi realizado o pareamento. Para cada família beneficiária do PBF (grupo de tratamento), o algoritmo procurou no grupo de não beneficiários (controle) uma ou mais famílias que fossem o mais próximo possível em termos de escore de propensão. Este processo criou um novo grupo de controle que é, em suas características observáveis, estatisticamente semelhante ao grupo de tratamento. Este grupo de controle pareado constitui o contrafactual da análise, representando o que teria acontecido com as famílias beneficiárias na ausência do programa.

Para a efetivação do pareamento, é fundamental que a condição de suporte comum seja satisfeita. Isso significa que deve haver uma sobreposição substancial nas distribuições dos escores de propensão entre os grupos de tratamento e controle. As famílias tratadas cujos escores de propensão estavam fora da faixa de valores dos controles (e vice-versa) foram descartadas da análise, pois não possuem bons "pares" para comparação. Foram utilizados algoritmos de pareamento consolidados na literatura, como o vizinho mais próximo (*nearest neighbor*), raio (*radius*) ou Kernel, para encontrar as melhores correspondências.

Passo 3: Verificação do Balanceamento

Após o pareamento, é crucial verificar se o procedimento foi bem-sucedido em equilibrar as covariáveis entre os grupos de tratamento e o novo grupo de controle. Para isso, foram realizados testes de diferença de médias (teste t) para todas as variáveis de controle (X_i) utilizadas no modelo logit, com intuito de verificar se houve diferenças estatisticamente significativas nas médias dessas variáveis entre os dois grupos.

Passo 4: Estimação do Efeito do Tratamento sobre os Tratados (ATT)

Finalmente, uma vez que um grupo de controle balanceado foi construído, foi estimado o impacto médio e heterogêneo do programa. O parâmetro de interesse é o Efeito Médio do Tratamento sobre os Tratados (ATT), que mede o efeito médio do PBF exclusivamente sobre a população que de fato o recebeu. A definição do ATT deriva diretamente do conceito de efeito causal individual ($r_{1i} - r_{0i}$) e do efeito médio populacional ($E(r_1) - E(r_0)$) estabelecidos por Rosenbaum e Rubin (1983). Formalmente, o ATT é definido como:

$$ATT = E[Y_1 | PBF = 1] - E[Y_0 | PBF = 1]$$

Onde:

- Y_1 é o resultado observado para as famílias que participam do programa.
- Y_0 é o resultado observado para as famílias que não participam do programa, mas que foram pareadas com base em seus propensity scores.

Na prática, a estimativa do ATT é obtida pela diferença entre a média do resultado para o grupo de beneficiários e a média do resultado para o grupo de controle pareado. Foram estimados o ATT médio e os efeitos heterogêneos considerando as características individuais (Homens, Mulheres, Brancos, Pretos, Pardos, Amarelos, Indígenas, Jovens, Adultos e Idosos), educação (nível de instrução), região (norte, nordeste, centro-oeste, sudeste e sul) e localização (zona urbana e zona rural).

3.3.2 Causal Forest (Floresta Causal)

O método Causal Forest, ou Floresta Causal, desenvolvido por Wager e Athey (2018), é uma adaptação e extensão do popular algoritmo de Random Forest (Breiman, 2001) para o campo da inferência causal. Seu principal objetivo é estimar efeitos de tratamento heterogêneos, ou seja, entender como o impacto de uma intervenção varia entre diferentes subgrupos de uma população, com base em suas características observáveis. A grande vantagem do método é sua capacidade de fazer isso de forma não paramétrica e adaptativa, sendo especialmente poderoso em cenários com um grande número de variáveis (covariáveis). A estimação do efeito de tratamento heterogêneo por meio do Causal Forest segue um processo estruturado, fundamentado no modelo de resultados potenciais (Neyman, 1923; Rubin, 1974). O passo a passo pode ser descrito da seguinte forma:

Passo 1: Definição do Efeito de Tratamento

O primeiro passo é definir formalmente o objeto de interesse. No modelo de resultados potenciais, para cada unidade i (neste caso, uma família), existem dois resultados potenciais: $Y_i^{(1)}$, o resultado se a família recebe o tratamento (participa do programa), e $Y_i^{(0)}$, o resultado se a família não recebe o tratamento. O efeito causal do tratamento para uma família com um vetor de características $X_i = x$ é a diferença esperada entre esses dois resultados potenciais:

$$T(x) = E[Y_i^{(1)} - Y_i^{(0)} \mid X_i = x]$$

Como apenas um dos resultados potenciais é observado para cada família, a estimação de $\tau(x)$ requer uma hipótese fundamental: a de não confundimento (*unconfoundedness*). Essa hipótese assume que, condicionais às características observáveis X_i , a designação para o tratamento (W_i) é independente dos resultados potenciais. Matematicamente:

$$\{Y_i^{(0)}, Y_i^{(1)}\} \perp W_i \mid X_i$$

Isso significa que, dentro de subgrupos de famílias com as mesmas características X_i , a participação no programa é "como se" fosse aleatória, permitindo a comparação direta entre tratados e não tratados.

Passo 2: Construção de Árvores Causais "Honestas" - Duas Abordagens

O núcleo do método é a construção de múltiplas árvores de decisão. Uma inovação crucial de Wager e Athey (2018) é o conceito de honestidade (*honesty*), que impede que a mesma observação seja usada para definir a estrutura da árvore e para estimar os efeitos dentro dela, reduzindo o viés. Os autores propõem duas maneiras principais de alcançar a honestidade:

- **Abordagem A: Árvores de Amostra Dupla (Double-Sample Trees)**

Nesta abordagem cada subamostra de dados usada para construir uma árvore é dividida em duas: Primeiro, têm-se a mostra de Divisão (*splitting sample*), a qual é usada para construir a estrutura da árvore. O algoritmo busca por divisões nas covariáveis que maximizem a heterogeneidade do efeito de tratamento. Ou seja, ele utiliza a variável de resultado (Y) desta amostra para encontrar os subgrupos onde o impacto do tratamento mais varia. Já a segunda se trata da amostra de estimação (*estimating sample*), em que após a árvore ser definida, esta

segunda amostra é usada para popular as folhas e calcular o efeito do tratamento de forma imparcial. A vantagem dessa abordagem é que ela é auxiliada no descobrimento de qualquer tipo de heterogeneidade, pois usa diretamente a informação do resultado para guiar as divisões.

- **Abordagem B: Árvores de Propensão (Propensity Trees)**

Nesta segunda abordagem a honestidade é alcançada de outra forma. Para construir a estrutura da árvore, o algoritmo utiliza as covariáveis (X) e a variável de tratamento (W), mas ignora completamente a variável de resultado (Y). A árvore é construída como se fosse uma árvore de classificação com o objetivo de prever quem recebe o tratamento ($W=1$) e quem não recebe ($W=0$). As divisões são escolhidas para criar folhas que sejam o mais homogêneas possível em relação à probabilidade de receber o tratamento (o escore de propensão).

Uma vez que as folhas são definidas com base nessa "propensão ao tratamento", os valores de resultado (Y) são usados para calcular o efeito do tratamento dentro de cada folha, como de costume. É uma abordagem particularmente útil em estudos observacionais, onde o principal desafio é o viés de seleção. Ao focar em criar grupos comparáveis primeiro (com escores de propensão similares), ela minimiza o risco de encontrar diferenças no efeito que são, na verdade, devidas a diferenças pré-existentes entre os grupos de tratamento e controle.

Para a avaliação de impacto do Programa Bolsa Família, um estudo observacional onde a participação é determinada por critérios de elegibilidade e não por sorteio, a abordagem de árvores de propensão (propensity trees) é a mais indicada. A principal preocupação metodológica neste contexto é o viés de seleção: as famílias que recebem o PBF são, por definição, diferentes das que não recebem em características cruciais como renda, o que também afeta a segurança alimentar. As Árvores de Propensão são projetadas especificamente para lidar com esse desafio, pois seu primeiro objetivo é particionar a amostra para criar subgrupos (as folhas) onde os beneficiários e não beneficiários sejam o mais semelhantes possível em suas características observáveis. Isso fortalece a validade da comparação feita posteriormente dentro de cada folha.

Passo 3: Estimação do Efeito nas Folhas e Construção do Contrafactual

Uma vez que a estrutura da árvore está definida, para qualquer ponto de teste x que caia em uma folha terminal L , o efeito do tratamento $\hat{T}(x)$ é estimado como a diferença entre a

média do resultado para as unidades tratadas e a média do resultado para as unidades de controle, usando apenas os dados da amostra de estimação que pertencem aquela folha:

$$\hat{T}(x) = \frac{1}{|\{i: W_i = 1, X_i \in L\}|} \sum_{\{i: W_i=1, X_i \in L\}}^{Y_i} - \frac{1}{|\{i: W_i = 0, X_i \in L\}|} \sum_{\{i: W_i=0, X_i \in L\}}^{Y_i} .$$

É neste passo que o contrafactual é construído de forma implícita e adaptativa. Para uma unidade tratada i que pertence à folha L , seu cenário contrafactual (o que teria acontecido com ela na ausência do tratamento) é representado pela média dos resultados de todas as unidades de controle que também caíram na mesma folha L . Como as folhas agrupam indivíduos com características similares (conforme aprendido pela árvore), este grupo de controle serve como um contrafactual local e específico para os tratados daquela folha.

Passo 4: Agregação das Árvores em uma Floresta Causal

Uma única árvore pode ser instável. Para mitigar isso, o *Causal Forest* constrói um grande número B de árvores causais honestas (por exemplo, $B=2000$). Cada árvore é construída sobre uma subamostra diferente dos dados originais. O efeito de tratamento final para um indivíduo com características x , $\hat{T}(x)$, é simplesmente a média das estimativas de todas as B árvores:

$$\hat{T}(x) = B^{-1} \sum_{b=1}^B \hat{T}_b(x)$$

Essa agregação resulta em um contrafactual muito mais robusto, pois para cada indivíduo, seu contrafactual final é uma média ponderada dos controles que foram considerados seus "vizinhos" em milhares de diferentes partições dos dados.

Passo 5: Inferência Estatística e Intervalos de Confiança

Após calcular a estimativa $\hat{T}(x)$, é possível quantificar a incerteza dessa estimativa. Uma das contribuições centrais de Wager e Athey (2018) é a derivação de uma teoria assintótica que permite a inferência estatística. Eles provam que as estimativas $\hat{T}(x)$, são assintoticamente normais e centradas no verdadeiro valor $T(x)$:

$$\left(\hat{T}(x) - T(x)\right) / \sqrt{\text{Var}[\hat{T}(x)]} \Rightarrow N(0,1)$$

Os autores propõem o uso do infinitesimal jackknife (IJ) para estimar a variância da estimativa, a qual pode ser calculada com a seguinte fórmula:

$$\widehat{V}_{IJ}(x) = \frac{n-1}{n} \left(\frac{n}{n-s}\right)^2 \sum_{i=1}^n \text{Cov}_*[\widehat{t}_b^*(x), N_{ib}^*]^2$$

Onde:

- s é o tamanho da subamostra usada para cada árvore.
- N_{ib}^* é uma variável que indica se a observação i foi usada na construção da árvore b .
- Cov_* é a covariância calculada sobre o conjunto de todas as árvores B na floresta

Desse modo, $\text{Cov}_*[\widehat{t}_b^*(x), N_{ib}^*]^2$ captura a covariância, entre todas as árvores b da floresta, entre a predição da árvore e o fato de a observação i ter sido usada para construí-la. Assim, com essa estimativa de variância $\widehat{V}_{IJ}(x)$, pode-se calcular o erro padrão e construir um intervalo de confiança para o efeito do tratamento $\hat{T}(x)$, da seguinte forma:

$$IC_{95\%} = \hat{T}(x) \pm 1.96 \times \sqrt{\widehat{V}_{IJ}(x)}$$

Uma variância alta significa que a estimativa é incerta. Isso significa que se repetirmos o estudo com outra amostra, o resultado para aquele subgrupo pode mudar bastante. Já uma variância baixa indica uma estimativa precisa e estável. O intervalo de confiança, por sua vez, fornece uma faixa de valores plausíveis para o verdadeiro efeito do tratamento, $T(x)$, para um subgrupo com características x .

Diante disso, para aplicar o método Causal Forest considerando o objetivo desta pesquisa, o primeiro passo foi definir as variáveis:

- Tratamento (W_i): $W_i = 1$ se a família é beneficiária do PBF; $W_i = 2$ se a família não é beneficiária, mas possui perfil elegível.
- Resultados (Y_i): Dummies para Segurança alimentar, Insegurança Alimentar Leve, Moderada e Grave.

- Covariáveis (X_i): Vetor com as características do chefe das famílias: educação, idade, gênero, raça, região, localização e características relacionadas ao domicílio

Com o uso do pacote `grf` no software R, o modelo foi treinado para aprender a função $T(x)$, que representa o impacto do PBF na probabilidade de uma família com características x se encontrar em determinado estado de (in)segurança alimentar. O contrafactual para uma família beneficiária do PBF foi construído de forma dinâmica pela floresta. Para cada família tratada, seu contrafactual é a média dos resultados (ex: proporção de insegurança alimentar grave) das famílias não-beneficiárias que, em cada uma das milhares de árvores, foram agrupadas na mesma folha por terem características socioeconômicas e demográficas semelhantes.

Uma questão fundamental é como analisar os efeitos para diferentes perfis. É importante destacar que o modelo *Causal Forest* é estimado uma única vez, utilizando todas as covariáveis simultaneamente. Este único modelo treinado produz a função de efeito de tratamento heterogêneo, $\hat{T}(x)$. A partir desta função, será possível explorar o impacto do programa para qualquer subgrupo de interesse. A análise ocorre da seguinte forma:

- **Estimação Individual:** Após o treinamento do modelo, é gerada uma estimativa de impacto individual, $\hat{T}(x_i)$, para cada família i na amostra. Este valor representa o impacto predito do PBF para uma família com aquele perfil específico.
- **Análise por Subgrupos (Categorias):** Para entender o efeito em diferentes categorias, basta agrupar as estimativas individuais e calcular a média.
- ✓ **Por Região:** Para saber o efeito médio do PBF na Região Nordeste, por exemplo, foi selecionado todas as famílias i pertencentes a essa região e, assim, calculado a média de suas estimativas individuais. O mesmo procedimento foi feito para as demais regiões, permitindo comparar onde o programa é mais ou menos eficaz.
- ✓ **Por Gênero do Chefe da Família:** Compara-se o efeito médio para famílias chefiadas por mulheres com o efeito médio para famílias chefiadas por homens, novamente calculando a média das estimativas $\hat{T}(x_i)$, dentro de cada um desses dois grupos.
- ✓ **Por Raça, Localização (Urbana/Rural):** A mesma lógica de agrupar e calcular a média das predições individuais se aplica, permitindo identificar disparidades no impacto do programa com base nessas características.
- **Análise por Variáveis Contínuas:**

- ✓ **Por Educação e Idade:** Para variáveis contínuas como Anos de estudo do chefe e Idade do chefe, além de agrupar em faixas (ex: 0-4 anos de estudo, 5-8 anos, etc.), é possível visualizar a heterogeneidade de forma mais direta. Isso pode revelar tendências, como, por exemplo, se o impacto do programa na redução da insegurança alimentar diminui ou aumenta à medida que a escolaridade do chefe da família cresce.

Em resumo, a estimação de um único modelo *Causal Forest* irá um rico conjunto de predições de impacto individuais. A análise subsequente consiste em agregar e visualizar essas predições para explorar como o efeito do Bolsa Família varia em função das múltiplas características das famílias, fornecendo um panorama detalhado e multifacetado da eficácia da política.

A utilização do *Causal Forest* é justificada por uma série de vantagens metodológicas, dentre as quais se destacam:

- **Estimação de Efeitos Heterogêneos:** O *Causal Forest* fornece a função completa do efeito de tratamento condicional, $\hat{T}(x)$. Isso permite ir além da pergunta "qual o impacto médio do programa?" e responder a "qual o impacto do programa para diferentes perfis de beneficiários?".
- **Adaptatividade e Desempenho em Alta Dimensão:** O método funciona como um "vizinho mais próximo adaptativo". A floresta aprende com os próprios dados quais variáveis e interações são mais importantes para definir "vizinhanças" (as folhas), conferindo um poder muito maior, especialmente em cenários com dezenas de covariáveis.
- **Inferência Estatística Válida:** A capacidade de construir intervalos de confiança e realizar testes de hipóteses para o efeito de tratamento em qualquer subgrupo confere rigor estatístico à análise de heterogeneidade, combatendo o risco de encontrar resultados ruins.
- **Modelação de Relações Complexas:** A estrutura baseada em árvores captura naturalmente relações não lineares e interações de alta ordem entre as variáveis, sem que o pesquisador precise especificá-las previamente no modelo.

- **Redução de Viés:** O uso de árvores "honestas" e a subamostragem são mecanismos desenhados especificamente para reduzir o viés de estimação, um desafio central em métodos adaptativos.

Em suma, o método Causal Forest, uma adaptação do Random Forest para inferência causal, oferece uma estrutura robusta para estimar os efeitos heterogêneos de uma política. Ao construir múltiplas árvores "honestas" e agregar suas previsões, ele cria um contrafactual preciso e adaptativo para diferentes subgrupos, superando a limitação dos métodos que calculam apenas um impacto médio. A capacidade de realizar inferência estatística válida para esses efeitos permite uma análise granular e rigorosa, revelando com maior profundidade para quem e em que medida o Bolsa Família de fato funciona

3.3.3 X-learner

Para complementar a análise de efeitos heterogêneos e aprimorar a robustez da estimação do impacto do Programa Bolsa Família (PBF) sobre a insegurança alimentar, este trabalho empregou também o método X-learner, proposto por Kunzel et al. (2019), projetado especificamente para estimar efeitos de tratamento heterogêneos de forma mais eficiente que os meta-algoritmos tradicionais. Segundo eles, o esse método se destaca por sua capacidade de adaptar-se a situações em que os tamanhos dos grupos de tratamento e controle são desiguais e de explorar propriedades estruturais da função de efeito de tratamento, características frequentemente encontradas em estudos observacionais.

A principal inovação X-learner reside em sua abordagem de utilizar cada observação do conjunto de dados de forma entrecruzada (daí o nome "X"), construindo o contrafactual de maneira mais sofisticada que métodos como o T-learner e o S-learner. O método combina a capacidade de modelar separadamente as funções de resposta de cada grupo (como o T-learner) com a habilidade de explorar informações estruturais sobre o efeito de tratamento propriamente dito.

De acordo com Kunzel et al. (2019), o X-learner baseia-se no modelo de resultados potenciais (Neyman, 1923; Rubin, 1974), no qual cada unidade i possui dois resultados potenciais: $Y_i(1)$, o resultado caso a família receba o tratamento (participe do PBF), e $Y_i(0)$, o resultado caso não receba o tratamento. O efeito causal individual é definido como $D_i = Y_i(1) - Y_i(0)$. Como observado por eles, embora não seja possível observar ambos os resultados potenciais simultaneamente para qualquer unidade (problema fundamental da inferência

causal), o objetivo do X-learner é estimar a função de Efeito Médio Condicional do Tratamento (CATE), definida como:

$$T(x) = E[Y_i^{(1)} - Y_i^{(0)} \mid X_i = x]$$

A função CATE, $\tau(x)$, é uma função que mapeia as características de uma unidade (família) para o efeito esperado do tratamento naquela unidade, diferente do ATT que é um número único que representa o efeito médio do tratamento sobre todas as unidades que efetivamente receberam o tratamento. A hipótese fundamental para a identificação do CATE é a de não confundimento (unconfoundedness), que assume que, condicionais às características observáveis X_i , a designação para o tratamento W_i é independente dos resultados potenciais:

$$\{Y_i^{(0)}, Y_i^{(1)}\} \perp W_i \mid X_i$$

Isso significa que, dentro de subgrupos de famílias com as mesmas características X_i , a participação no programa pode ser tratada como se fosse aleatória, permitindo a comparação direta entre tratados e não tratados. Sendo assim, de acordo com Kunzel et al. (2019), o X-learner opera em três estágios distintos, cada um com um objetivo específico:

Primeiro Estágio: Estimação das Funções de Resposta

No primeiro estágio o método estima separadamente as funções de resposta para os grupos de controle e tratamento:

$$\mu_0(x) = E[Y(0) \mid X = x]$$

$$\mu_1(x) = E[Y(1) \mid X = x]$$

Essas estimativas, denotadas como $\widehat{\mu}_0$ e $\widehat{\mu}_1$, podem ser realizadas utilizando qualquer algoritmo de aprendizado supervisionado ou método de regressão, denominados aprendizes de base (base learners) do primeiro estágio. Essa flexibilidade permite que o pesquisador escolha os algoritmos mais adequados às características específicas dos dados.

Segundo Estágio: Imputação dos Efeitos de Tratamento Individuais

O segundo estágio constitui a principal inovação do X-learner. De acordo com Kunzel et al. (2019), nesta etapa o método imputa os efeitos de tratamento individuais para cada observação, utilizando as funções de resposta estimadas no primeiro estágio. A lógica central é engenhosa: para as famílias tratadas, subtrai-se a estimativa do resultado sob controle do resultado observado; para as famílias de controle, subtrai-se o resultado observado da estimativa do resultado sob tratamento. Formalmente, os efeitos de tratamento imputados são calculados como:

$$\begin{aligned}\widetilde{D}_i^1 &= Y_i^1 - \widehat{\mu}_0(X_i^1) && \text{para o grupo de tratamento} \\ \widetilde{D}_i^0 &= \widehat{\mu}_1(X_i^0) - Y_i^0 && \text{para o grupo de controle}\end{aligned}$$

onde Y_i^1 e X_i^1 denotam, respectivamente, o resultado observado e as características da i -ésima família no grupo de tratamento, e Y_i^0 e X_i^0 são os correspondentes para o grupo de controle. A intuição por trás dessa abordagem, conforme explicam Kunzel et al. (2019), é que se as estimativas $\widehat{\mu}_0$ e $\widehat{\mu}_1$ fossem perfeitas ($\widehat{\mu}_0 = \mu_0$ e $\widehat{\mu}_1 = \mu_1$), então os efeitos imputados seriam estimativas não viesadas do verdadeiro efeito de tratamento:

$$T(x) = E[D^1 | X = x] = E[D^0 | X = x]$$

Na prática, embora as estimativas não sejam perfeitas, esta construção permite explorar informações de um grupo para melhorar a estimação do contrafactual do outro. Após calcular os efeitos de tratamento imputados, os autores propõem empregar algoritmos de aprendizado supervisionado ou métodos de regressão para estimar a função CATE de duas maneiras distintas:

$$\begin{aligned}T_1(x) &= E[D^1 | X = x] \\ T_0(x) &= E[D^0 | X = x]\end{aligned}$$

Esses algoritmos são denominados aprendizes de base do segundo estágio. Segundo Kunzel et al. (2019), essa abordagem permite que o método capture propriedades estruturais da

função CATE (como linearidade, esparsidade ou suavidade) que podem não estar presentes nas funções de resposta $\widehat{\mu}_0$ e $\widehat{\mu}_1$.

Terceiro Estágio: Combinação das Estimativas

No terceiro estágio, de acordo com Kunzel et al. (2019), o X-learner combina as duas estimativas $\widehat{T}_0(x)$ e $\widehat{T}_1(x)$ por meio de uma função de ponderação $g(x) \in [0,1]$:

$$\widehat{T}(x) = g(x)\widehat{T}_0(x) + (1 - g(x))\widehat{T}_1(x)$$

A escolha da função de ponderação é crucial para o desempenho do método. Kunzel et al. (2019) recomendam utilizar uma estimativa do escore de propensão, $\hat{e}(x)$, como função de ponderação, de modo que $g(x) = \hat{e}(x)$. A lógica subjacente é intuitiva: em situações onde o grupo de controle é muito maior que o grupo de tratamento, o escore de propensão será pequeno, atribuindo maior peso a $\widehat{T}_1(x)$, que é estimado com base em um grupo de controle maior e, portanto, potencialmente mais preciso. Alternativamente, em casos extremos de desbalanceamento, pode-se optar por $g(x) = 0$ (quando o grupo de controle é muito maior) ou $g(x) = 1$ (quando o grupo de tratamento é muito maior), utilizando exclusivamente a estimativa mais confiável.

Kunzel et al. (2019) demonstram formalmente várias vantagens teóricas do X-learner em relação a outros meta-algoritmos:

- **Adaptatividade a Designs Desbalanceados:** O X-learner é comprovadamente eficiente quando o número de unidades em um grupo de tratamento é muito maior que no outro, situação comum em estudos observacionais onde dados de controle são abundantes mas dados de tratados são escassos.
- **Exploração de Propriedades Estruturais:** Segundo Kunzel et al. (2019), o X-learner pode explorar propriedades estruturais da função CATE. Por exemplo, se o CATE for linear e as funções de resposta forem Lipschitz contínuas, o X-learner ainda pode alcançar a taxa paramétrica sob condições de regularidade, mesmo que as funções de resposta μ_0 e μ_1 sejam complexas.

Uma das principais vantagens do X-learner é sua capacidade de revelar como o impacto do PBF varia entre diferentes subgrupos populacionais. O método gera uma estimativa individual $\hat{T}(x_i)$ para cada família, capturando a heterogeneidade dos efeitos do tratamento. Para compreender o efeito em diferentes categorias, agrupam-se as estimativas individuais e calcula-se a média dentro de cada subgrupo de interesse: educação, idade, raça, gênero, região e localização. Assim como no causal forest, esse método foi aplicado utilizando o pacote `grf` no software R.

Em resumo, o X-learner representa, um avanço metodológico significativo na estimação de efeitos de tratamento heterogêneos. Sua capacidade de adaptar-se a base de dados desbalanceadas, explorar propriedades estruturais da função CATE, e fornecer estimativas mais precisas em diversas situações o torna particularmente adequado para avaliar o impacto do Programa Bolsa Família sobre a segurança alimentar das famílias brasileiras, especialmente considerando a natureza observacional dos dados da POF 2017-2018 e a potencial heterogeneidade dos efeitos do programa entre diferentes perfis de beneficiários.

3.3.4 Análise Comparativa dos Métodos: Vantagens, Limitações e Justificativas

A utilização conjunta de três métodos distintos para estimação do efeito causal — Propensity Score Matching (PSM), Causal Forest e X-learner visa maximizar a robustez e a profundidade das conclusões. Esta subseção apresenta uma análise comparativa sistematizada das vantagens, limitações e da lógica de complementaridade entre as abordagens adotadas. Assim, começando pelo PSM, entre as suas principais vantagens destacam-se: (i) ampla consolidação na literatura empírica de avaliação de políticas públicas, o que facilita a comparabilidade com estudos anteriores; (ii) transparência e interpretabilidade das estimativas, uma vez que o procedimento de pareamento é explícito e verificável; (iii) possibilidade de verificação direta do balanceamento das covariáveis através de testes estatísticos e análises gráficas; e (iv) estimação clara e direta do Efeito Médio do Tratamento sobre os Tratados (ATT).

Entretanto, conforme reconhecem Rosenbaum e Rubin (1983), o método apresenta limitações relevantes. Primeiramente, o PSM é sensível à especificação funcional do modelo utilizado para estimar o escore de propensão, tipicamente um modelo logit ou probit. Em segundo lugar, a identificação de efeitos heterogêneos requer a definição prévia de subgrupos pelo pesquisador, o que pode limitar a descoberta de padrões inesperados de heterogeneidade. Terceiro, o método pressupõe que todas as variáveis relevantes para a seleção ao tratamento são

observáveis (hipótese de não confundimento baseada em observáveis), não oferecendo proteção contra viés de variáveis omitidas. Por fim, em contextos com muitas covariáveis e interações complexas, a capacidade do PSM de capturar adequadamente todas as dimensões relevantes pode ser limitada.

Com relação ao método Causal Forest, de acordo com Wager e Athey (2018), sua principal contribuição reside na capacidade de estimar efeitos de tratamento heterogêneos de forma não paramétrica e adaptativa, identificando automaticamente quais covariáveis e interações são mais relevantes para explicar a variação dos impactos. As vantagens centrais do Causal Forest incluem: (i) estimação flexível do Efeito Condicional Médio do Tratamento (CATE) em função das características individuais, sem necessidade de especificação prévia de subgrupos; (ii) capacidade de capturar relações não lineares e interações de alta ordem entre covariáveis; (iii) funcionamento como um "vizinho mais próximo adaptativo no qual a própria estrutura dos dados determina quais observações são mais comparáveis; (iv) possibilidade de inferência estatística válida, com intervalos de confiança assintoticamente normais para os efeitos estimados; e (v) utilização de árvores "honestas" (honest trees), que empregam subamostras distintas para definir a estrutura da árvore e para estimar os efeitos, reduzindo o viés de estimação.

Quanto às limitações, Wager e Athey (2018) reconhecem que o método requer amostras relativamente grandes para que as propriedades assintóticas se manifestem adequadamente. Além disso, a interpretabilidade das estimativas individuais pode ser menos direta do que no PSM, embora a agregação por subgrupos permita análises intuitivas. O método também assume a hipótese de não confundimento, compartilhando esta limitação com o PSM.

Por fim, no que concerne ao X-learner, sua principal inovação reside em na abordagem de utilizar cada observação de forma "entrecruzada" para construir o contrafactual, atribuindo maior peso às estimativas derivadas do grupo com maior quantidade de observações. As vantagens específicas do X-learner incluem: (i) eficiência comprovada quando o número de unidades em um grupo de tratamento é muito maior que no outro, situação frequente em estudos observacionais; (ii) capacidade de explorar propriedades estruturais da função CATE, como linearidade ou esparsidade, mesmo quando as funções de resposta subjacentes são complexas; (iii) flexibilidade na escolha dos algoritmos base (base learners), podendo utilizar desde regressões lineares até métodos avançados como Random Forests ou redes neurais; e (iv) adequação particular para estimação do ATT, parâmetro de interesse central em avaliações de políticas focalizadas. Entre as limitações, Künzel et al. (2019) apontam que o desempenho do método depende da qualidade dos algoritmos base escolhidos e da adequação destes às

características específicas dos dados. Além disso, assim como os demais métodos, o X-learner requer a hipótese de não confundimento para identificação causal.

Diante disso, estratégia de triangulação metodológica adotada neste trabalho fundamenta-se na complementaridade entre as abordagens. O PSM fornece uma estimativa transparente e amplamente comparável com a literatura existente, funcionando como benchmark tradicional. O Causal Forest permite explorar a heterogeneidade dos efeitos de forma flexível e estatisticamente validada, sem impor estruturas funcionais rígidas. O X-learner oferece robustez adicional para o contexto específico desta pesquisa, caracterizado pelo desbalanceamento inerente entre beneficiários e não beneficiários do Programa Bolsa Família. A convergência de resultados entre métodos baseados em pressupostos e estratégias de estimação distintas constitui evidência de que os achados não são artefatos de uma escolha metodológica específica. Quando os três métodos apontam para conclusões semelhantes — como ocorre nesta pesquisa —, a credibilidade empírica dos resultados é substancialmente fortalecida.

Ademais, cada método contribui com informações complementares: o PSM estabelece a magnitude do efeito médio e permite análise de heterogeneidade por subgrupos predefinidos; o Causal Forest revela padrões de heterogeneidade que poderiam passar despercebidos em análises convencionais e fornece validação estatística formal da existência de heterogeneidade; o X-learner confirma a robustez dos achados em um contexto de dados desbalanceados e permite verificar se as conclusões se mantêm sob uma estrutura de estimação alternativa. Portanto, a combinação dos três métodos não representa redundância, mas uma estratégia deliberada para ampliar o escopo analítico e verificar a estabilidade das conclusões entre abordagens distintas, permitindo responder não apenas 'qual o impacto médio do programa', mas também 'para quem os efeitos são mais intensos' e 'os padrões identificados se mantêm sob diferentes estratégias de estimação'.

4 RESULTADOS E DISCUSSÕES

Esta seção apresenta e discute os resultados da avaliação de impacto do Programa Bolsa Família (PBF) sobre a segurança e a insegurança alimentar dos domicílios brasileiros, com base nos microdados da POF 2017–2018. São empregados três métodos: Propensity Score Matching (PSM), Causal Forest e X-Learner. É fundamental destacar, desde o início, que os três métodos compartilham a mesma hipótese de identificação — seleção em observáveis (unconfoundedness): assume-se que, condicionadas as características observáveis incluídas no

modelo, a participação no programa é como se fosse aleatória. Nenhum dos métodos controla, por construção, possíveis diferenças não observáveis entre beneficiários e não beneficiários — como o grau de vulnerabilidade pré-programa ou a motivação para buscar o cadastro. A contribuição dos métodos de aprendizado de máquina não reside, portanto, em identificar efeitos causais mais robustos do que o PSM, mas em estimar a heterogeneidade dos impactos de forma mais flexível, capturando relações não lineares e interações entre covariáveis sem necessidade de definir subgrupos a priori, e em validar estatisticamente essa heterogeneidade. Os resultados devem, portanto, ser lidos como associações condicionais robustas, e não como efeitos causais em sentido estrito.

4.1 Estatísticas descritivas e balanceamento

Antes da estimação dos efeitos, é necessário verificar as diferenças iniciais entre beneficiários e não beneficiários e a qualidade do balanceamento obtido pelo PSM. Para a estimação do Efeito Médio do Tratamento sobre os Tratados (ATT), utilizando o PSM, adotou-se como método principal o algoritmo de pareamento pelo Vizinho Mais Próximo (*Nearest Neighbor Matching*). Esta escolha fundamenta-se na sua adequação aos dados, seguindo a estratégia metodológica adotada em trabalhos como os de Almeida et al. (2016) e Sperandio et al. (2017). A fim de verificar a robustez das estimativas principais, foram aplicados algoritmos alternativos — Pareamento por Raio (*Radius/Caliper*), Kernel e Estratificação. Os resultados consolidados destas especificações, demonstram a consistência dos sinais e das magnitudes do impacto, corroborando a estabilidade dos achados independentemente do método de pareamento empregado.

A tabela 1 apresenta as estatísticas descritivas das principais covariáveis utilizadas na estimação do escore de propensão, comparando domicílios beneficiários e não beneficiários do Programa Bolsa Família antes do pareamento. Além das médias, a tabela reporta a diferença padronizada, métrica amplamente utilizada na literatura para avaliar o grau de desequilíbrio entre os grupos tratados e de controle.

Tabela 1: Estatísticas descritivas das covariáveis: beneficiários e não beneficiários do Programa Bolsa Família (antes do pareamento)

Variáveis	Média Tratados	Média Controles	Diferença Padronizada
RENDA_PER_CAPITA	642.59758653	1998.79510134	-0.69223069
IDADE	42.44975981	52.44864403	-0.68838369
QUANTIDADE_COMODOS	5.21317054	6.14029468	-0.51083992
MULHER	0.45656525	0.42223646	0.06920672
RACA_PRETA	0.13420737	0.11068403	0.07180516
RACA_PARDA	0.63901121	0.45493155	0.37627124
RACA_AMARELA	0.00300240	0.00557572	-0.03938396
RACA_INDIGENA	0.00650520	0.00488766	0.02149350
URBANO	0.65102082	0.81009325	-0.36442864
REGIAO_NORTE	0.20676541	0.11644957	0.24722207
REGIAO_SUDESTE	0.12840272	0.28751750	-0.39980183
REGIAO_SUL	0.04593675	0.16807839	-0.40305910
REGIAO_CENTRO	0.07295837	0.13747123	-0.21142220
EDUC_BAIXA	0.64391513	0.45443329	0.38789461
EDUC_MEDIA	0.15242194	0.11993736	0.09481622
EDUC_ALTA	0.20366293	0.42562934	-0.49224161
ÁGUA_REDE	0.66092874	0.79763684	-0.31136818
LUZ_REDE	0.97467974	0.99508862	-0.16784787

Fonte: Elaboração própria a partir dos dados da POF 2017-2018

Os resultados apresentados na Tabela 1 evidenciam diferenças substanciais entre os domicílios beneficiários e não beneficiários do Programa Bolsa Família, indicando a presença de forte viés de seleção observável. Em termos de renda, os domicílios beneficiários apresentam renda per capita média significativamente inferior à dos não beneficiários (R\$ 642,60 contra R\$ 1.998,80), com uma diferença padronizada elevada em magnitude (-0,69). Esse resultado reflete o caráter fortemente focalizado do programa e está plenamente alinhado com a metodologia de avaliação de impacto, pois a renda é uma variável observável fundamental para o cálculo do propensity score, conforme amplamente discutido por Rosenbaum e Rubin (1983) no contexto da necessidade de correção do viés de seleção em estudos observacionais

Diferenças relevantes também são observadas nas características demográficas. Os responsáveis pelos domicílios beneficiários são, em média, mais jovens, apresentando diferença padronizada próxima a $-0,69$, e residem em domicílios com menor número médio de cômodos, indicador associado a piores condições habitacionais. A proporção de domicílios chefiados por mulheres é ligeiramente maior entre os beneficiários, ainda que a diferença padronizada seja de pequena magnitude, resultado consistente com o desenho do programa que prioriza a mulher como titular, condição destacada por Duarte et al. (2009).

No que se refere à composição racial, a desagregação das categorias permite uma análise mais precisa das desigualdades associadas ao acesso ao programa. Observa-se uma sobre-representação significativa de responsáveis pardos entre os beneficiários do Bolsa Família, com diferença padronizada elevada ($0,38$), enquanto as diferenças associadas aos grupos preto, amarelo e indígena apresentam magnitudes reduzidas. Esse resultado indica que a dimensão racial da focalização do programa se manifesta de forma heterogênea, refletindo desigualdades estruturais historicamente associadas à população parda no Brasil, em consonância com a literatura que relaciona raça, pobreza e vulnerabilidade socioeconômica.

As disparidades regionais e locais também se mostram expressivas. Os beneficiários estão relativamente menos concentrados em áreas urbanas e nas regiões Sudeste e Sul, ao passo que apresentam maior participação relativa na Região Norte. Tais padrões corroboram evidências empíricas anteriores que apontam maior incidência do programa em regiões historicamente mais pobres do país, onde os indicadores de insegurança alimentar são mais severos.

No tocante ao capital humano, observa-se uma maior proporção de responsáveis com baixa escolaridade entre os beneficiários, enquanto a participação de indivíduos com ensino superior é substancialmente menor nesse grupo. As diferenças padronizadas associadas às categorias educacionais são elevadas, reforçando o papel da escolaridade como fator central correlacionado à pobreza e à elegibilidade ao programa, conforme amplamente documentado na literatura de avaliação de impacto.

Por fim, as variáveis relacionadas à infraestrutura domiciliar indicam que os domicílios beneficiários apresentam piores condições de moradia, com menor acesso à rede geral de água, menor proporção de domicílios com paredes sólidas e maior utilização de fogão a lenha. Esses resultados são coerentes com a literatura que associa precariedade habitacional à insegurança alimentar e à vulnerabilidade socioeconômica.

Em conjunto, os elevados valores das diferenças padronizadas para diversas covariáveis confirmam que os grupos de beneficiários e não beneficiários são substancialmente distintos

antes do pareamento, reforçando a necessidade da utilização do Propensity Score Matching como estratégia para reduzir o viés de seleção observável. Nesse sentido, a Tabela 2 apresenta os resultados do modelo Logit utilizado para estimar o escore de propensão, cuja função é exclusivamente instrumental, conforme a prática consolidada na literatura (Rosenbaum e Rubin, 1983), não sendo interpretada como evidência de efeito causal.

Tabela 2: Resultados do modelo logit para participação no Bolsa Família

Variável	Coefficiente	Erro Padrão	z	p - valor
(Intercept)	3.17655024	1.426220e-01	22.27251006	6.826811e-110
RENDA_PER_CAPITA	-0.00182576	3.416663e-05	-53.43700993	0.000000e+00
IDADE	-0.049490504	1.161354e-03	-42.61448353	0.000000e+00
QUANTIDADE_COMODOS	-0.071946800	9.460284e-03	-7.60514172	2.845919e-14
MULHER	0.219065445	2.853126e-02	7.67808575	1.614834e-14
RACA_PRETA	0.123333527	4.718147e-02	2.61402478	8.948255e-03
RACA_PARDA	0.161730206	3.390890e-02	4.76955055	1.846374e-06
RACA_AMARELA	-0.231121630	2.462437e-01	-0.93858908	3.479418e-01
RACA_INDIGENA	0.091336922	1.818925e-01	0.50214780	6.155636e-01
URBANO	-0.245501655	4.144750e-02	-5.92319641	3.157433e-09
REGIAO_NORTE	-0.636194602	4.314648e-02	-14.74499444	3.313471e-49
REGIAO_SUDESTE	-0.891902142	3.948806e-02	-22.58662650	5.865966e-113
REGIAO_SUL	-1.555975346	6.198480e-02	-25.10252876	4.666981e-139

REGIAO_CENTRO	-0.909688772	5.103175e-02	-17.82593574	4.445893e-71
EDUC_BAIXA	0.943607704	3.754232e-02	25.13450624	2.087602e-139
EDUC_MEDIA	0.550570785	4.539571e-02	12.12825639	7.482567e-34
ÁGUA_REDE	-0.002155800	3.897280e-02	-0.05531551	9.558871e-01
LUZ_REDE	-0.105955614	1.202238e-01	-0.88131978	3.781448e-01
PAREDE_SOLIDA	-0.367112987	5.079061e-02	-7.22796917	4.902700e-13
FOGAO_LENHA	0.578839750	3.413699e-02	16.95637852	1.726638e-64
ALUGADO	0.139072921	3.140700e-02	4.42808659	9.507273e-06

Elaboração própria a partir dos dados da POF 2017-2018

Os resultados do modelo Logit apresentados na Tabela 2 evidenciam que a probabilidade de participação no Programa Bolsa Família está fortemente associada a características tradicionalmente relacionadas à pobreza e à vulnerabilidade socioeconômica, corroborando o mecanismo de focalização do programa. A renda per capita exerce influência negativa e altamente significativa sobre a probabilidade de recebimento do benefício, indicando que domicílios com menor renda apresentam maior propensão a participar do programa. Esse resultado confirma o papel central da renda como critério de elegibilidade e está em consonância com a literatura empírica que avalia o Bolsa Família, como Duarte et al. (2019) e Rocha et al. (2016).

A idade do responsável pelo domicílio também apresenta coeficiente negativo e estatisticamente significativo, sugerindo que domicílios chefiados por indivíduos mais jovens possuem maior probabilidade de serem beneficiários. Da mesma forma, o número de cômodos do domicílio apresenta coeficiente negativo, indicando que melhores condições habitacionais estão associadas a menor probabilidade de participação no programa. No que se refere às características demográficas, domicílios chefiados por mulheres apresentam maior probabilidade de recebimento do benefício, resultado estatisticamente significativo e

consistente com a priorização feminina como titular do Bolsa Família, amplamente documentada na literatura.

A desagregação da variável raça permite uma análise mais refinada da dimensão racial da focalização do programa. Observa-se que responsáveis identificados como pretos e, sobretudo, pardos apresentam maior probabilidade de participação no Bolsa Família em relação à categoria de referência (brancos), com coeficientes positivos e estatisticamente significativos. Em contraste, os coeficientes associados aos grupos amarelo e indígena não se mostram estatisticamente significativos, possivelmente refletindo sua menor representatividade na amostra. Esses resultados indicam que a dimensão racial da elegibilidade ao programa se manifesta de forma heterogênea, concentrando-se principalmente entre os grupos historicamente mais vulneráveis do ponto de vista socioeconômico, em consonância com a literatura que relaciona raça, desigualdade e pobreza no Brasil.

As variáveis regionais revelam diferenças expressivas em relação à região de referência. Todas as demais regiões apresentam coeficientes negativos e estatisticamente significativos, com destaque para a Região Sul, que exibe a menor probabilidade relativa de participação no programa. Esses resultados reforçam o caráter regionalmente focalizado do Bolsa Família e reproduzem padrões amplamente documentados na literatura empírica, como em Rocha et al. (2016) e Almeida et al. (2016).

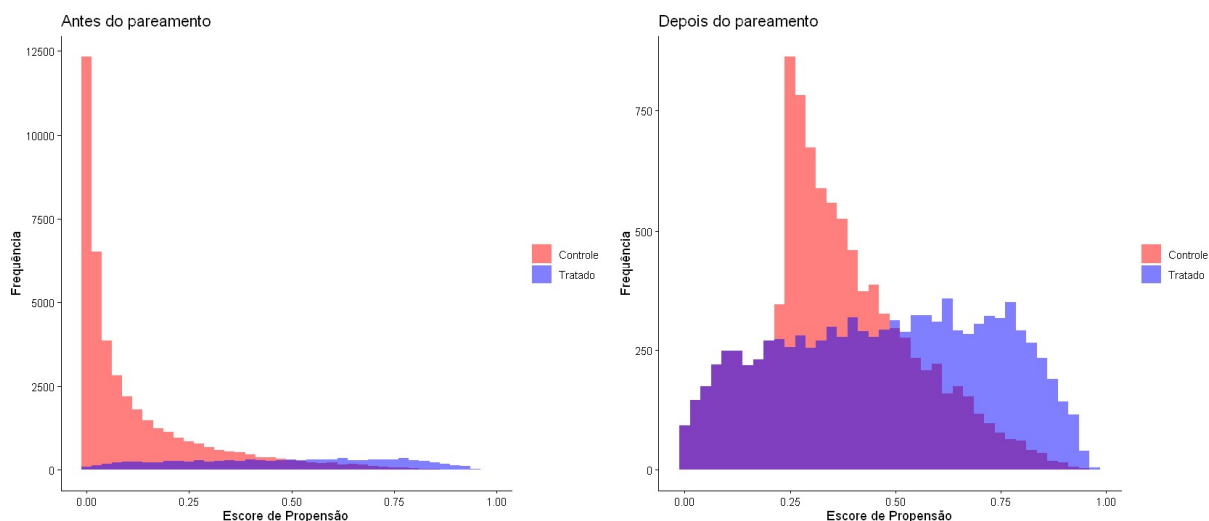
No tocante à escolaridade, os coeficientes positivos e altamente significativos associados aos níveis educacionais mais baixos indicam que domicílios com responsáveis de menor escolaridade possuem maior probabilidade de serem beneficiários do programa, reforçando a associação entre baixo capital humano, menor inserção no mercado de trabalho e maior vulnerabilidade social.

Entre as variáveis de infraestrutura domiciliar, destaca-se o efeito positivo e estatisticamente significativo do uso de fogão a lenha, indicador clássico de precariedade habitacional, bem como o efeito positivo da condição de domicílio alugado, que pode refletir maior instabilidade residencial entre os beneficiários. Em contrapartida, o acesso à rede geral de água e à rede elétrica não se mostra estatisticamente significativo no modelo.

De modo geral, os resultados do modelo Logit indicam que a especificação adotada captura adequadamente os determinantes observáveis da participação no Programa Bolsa Família. Ressalta-se que os coeficientes estimados não são interpretados como efeitos causais, mas possuem caráter instrumental, sendo utilizados exclusivamente para a construção do escore de propensão, conforme a prática consolidada na literatura de Propensity Score Matching (Rosenbaum e Rubin, 1983). O Gráfico 1 apresenta a distribuição do escore de propensão para

os grupos de tratados e controles antes e após o pareamento, permitindo avaliar visualmente a condição de suporte comum e a efetividade do procedimento de pareamento.

Gráfico 1: Distribuição do escore de propensão antes e depois do pareamento




Fonte: Elaboração própria a partir dos dados da POF 2017-2018

Antes do pareamento, observa-se uma forte assimetria na distribuição dos escores entre os grupos. Os domicílios do grupo controle concentram-se majoritariamente em valores muito baixos do escore de propensão, próximos de zero, enquanto os domicílios beneficiários do Programa Bolsa Família apresentam escores predominantemente mais elevados. Essa configuração indica baixo grau de sobreposição inicial entre tratados e controles, evidenciando a presença de viés de seleção observável. Esse padrão é consistente com a forte focalização do programa, uma vez que os beneficiários apresentam características socioeconômicas sistematicamente distintas dos não beneficiários, conforme documentado na literatura empírica sobre o Bolsa Família.

Após o pareamento, a distribuição dos escores de propensão dos dois grupos torna-se substancialmente mais próxima, especialmente na região intermediária do suporte. Observa-se uma redução clara da distância entre as distribuições de tratados e controles, indicando que o procedimento de matching conseguiu aumentar a comparabilidade entre os grupos ao selecionar observações do grupo controle com características observáveis semelhantes às dos beneficiários. Ainda que permaneçam diferenças nas caudas da distribuição, o aumento da sobreposição sugere que o pareamento foi eficaz em restringir a análise a uma região de suporte comum mais adequada.

Em conjunto, o gráfico confirma que o Propensity Score Matching contribuiu para reduzir o desequilíbrio inicial entre os grupos, criando uma amostra pareada mais comparável e, portanto, mais apropriada para a estimação do efeito médio do tratamento sobre os tratados (ATT), em linha com os procedimentos adotados nos estudos empíricos que avaliam o impacto do Programa Bolsa Família. O gráfico 2 também apresenta as diferenças médias padronizadas das covariáveis antes e após o pareamento.

Gráfico 2: Gráfico de balanceamento das covariáveis (Love Plot)



Fonte: Elaboração própria a partir dos dados da POF 2017-2018

O gráfico 2 apresenta as diferenças médias padronizadas das covariáveis antes e após a aplicação do Propensity Score Matching, permitindo avaliar visualmente a qualidade do balanceamento entre os grupos de tratados e controles. Antes do pareamento, observa-se que diversas covariáveis exibem diferenças substanciais, com destaque para renda per capita, idade,

número de cômodos, escolaridade, localização regional e composição racial, indicando forte desequilíbrio inicial entre os grupos.

Após o pareamento, verifica-se uma redução expressiva das diferenças padronizadas para todas as covariáveis consideradas. As diferenças ajustadas concentram-se próximas de zero e permanecem, em sua totalidade, abaixo do limiar convencional de 0,1, critério amplamente adotado na literatura como indicativo de bom balanceamento. Esse resultado sugere que o procedimento de pareamento foi eficaz em reduzir o viés de seleção observável, inclusive para covariáveis fortemente correlacionadas com a elegibilidade ao programa.

A desagregação da variável racial permite observar que as diferenças associadas aos grupos preto, pardo, amarelo e indígena também são substancialmente reduzidas após o pareamento, indicando que o método foi capaz de equalizar adequadamente a composição racial entre tratados e controles na amostra pareada. Sob a perspectiva socioeconômica, o balanceamento obtido indica que os grupos pareados passam a apresentar perfis semelhantes em termos de renda, capital humano, infraestrutura domiciliar e localização geográfica. Esse resultado está em consonância com a importância atribuída a essas características observáveis na literatura, tais como destacadas por Coelho e Melo (2015) e Rosales et al. (2022) no contexto de avaliação de impacto.

Em conjunto, o gráfico 2 confirma a adequação do procedimento de pareamento adotado, reforçando que a amostra pareada atende aos critérios usuais de qualidade do matching, o que fornece base empírica consistente para a estimação do efeito médio do tratamento sobre os tratados (ATT). A tabela 3 apresenta as médias das covariáveis para os grupos de tratados e controles, bem como a diferença padronizada após a aplicação do Propensity Score Matching. A análise dessas diferenças permite avaliar se o procedimento de pareamento foi capaz de reduzir o viés de seleção observável identificado antes do matching.

Tabela 3 – Teste de balanceamento das covariáveis após o pareamento

Variável	Média Tratados	Média Controles	Diferença Padronizada
RENDA_PER_CAPITA	642.597586527	772.367391259	-0.237256436
IDADE	42.449759808	44.627201761	-0.158395681
QUANTIDADE DE COMODOS	5.213170536	5.401621297	-0.122746868
MULHER	0.456565252	0.452662130	0.007838273
RACA_PRETA	0.134207366	0.135208167	-0.002931221
RACA_PARDA	0.639011209	0.613390713	0.052971484
RACA_AMARELA	0.003002402	0.003702962	-0.012118948
RACA_INDIGENA	0.006505204	0.005804644	0.008956896
URBANO	0.651020817	0.720776621	-0.150703501
REGIAO_NORTE	0.206765412	0.190552442	0.040641317
REGIAO_SUDESTE	0.128402722	0.156725380	-0.081070520
REGIAO_SUL	0.045936749	0.059147318	-0.059232049
REGIAO_CENTRO	0.072958367	0.096877502	-0.085880402
EDUC_BAIXA	0.643915132	0.582766213	0.125808375
EDUC_MEDIA	0.152421938	0.158726982	-0.017395343
EDUC_ALTA	0.203662930	0.258506805	-0.130377413
ÁGUA_REDE	0.660928743	0.712369896	-0.111064387
LUZ_REDE	0.974679744	0.986789432	-0.088179587

Fonte: Elaboração própria a partir dos dados da POF 2017-2018

Os resultados apresentados na tabela 3 indicam uma melhora substancial no balanceamento das covariáveis após a aplicação do Propensity Score Matching. Em comparação ao cenário pré-pareamento, observa-se uma redução expressiva das diferenças

padronizadas para todas as variáveis consideradas, evidenciando a capacidade do procedimento de matching em reduzir o viés de seleção observável.

De modo geral, todas as diferenças padronizadas em valor absoluto permanecem abaixo do limiar de 0,25, e a maioria situa-se abaixo de 0,10, critério amplamente adotado na literatura como indicativo de bom balanceamento. Esse resultado contrasta fortemente com a situação anterior ao pareamento, na qual diversas covariáveis, como renda per capita, idade, escolaridade e características regionais, apresentavam diferenças substanciais entre tratados e controles.

As variáveis contínuas, como renda per capita, idade e número de cômodos do domicílio, apresentam diferenças padronizadas moderadas após o pareamento. Em particular, embora a diferença padronizada da renda per capita permaneça relativamente mais elevada em comparação às demais covariáveis, seu valor é significativamente inferior ao observado antes do pareamento, indicando que o matching conseguiu reduzir de forma relevante o desequilíbrio associado à principal variável de elegibilidade ao Programa Bolsa Família.

As características demográficas e locais exibem, em sua maioria, bom balanceamento. As diferenças padronizadas associadas ao sexo do responsável e à composição racial são bastante reduzidas, situando-se próximas de zero. No caso das variáveis de localização urbana e regional, observa-se pequena persistência de diferenças residuais, ainda assim dentro de limites considerados aceitáveis segundo os critérios usuais da literatura.

No que se refere à escolaridade e às condições de infraestrutura domiciliar, os resultados também apontam melhora significativa no balanceamento. As diferenças padronizadas das categorias educacionais, do acesso à água e à energia elétrica, do material das paredes e da condição de moradia são, em geral, reduzidas. Destaca-se que a variável associada ao uso de fogão a lenha apresenta uma diferença padronizada relativamente mais elevada em relação às demais, refletindo a forte associação dessa característica com situações de pobreza extrema. Ainda assim, o valor observado permanece abaixo dos limiares usualmente considerados problemáticos, não comprometendo a qualidade do pareamento.

Em síntese, os resultados do teste de balanceamento confirmam que o Propensity Score Matching foi eficaz em reduzir substancialmente o viés de seleção observável, produzindo uma amostra pareada com perfis socioeconômicos amplamente comparáveis entre os grupos de tratados e controles. Dessa forma, a amostra resultante atende aos pressupostos necessários para a estimação do efeito médio do tratamento sobre os tratados (ATT).

4.2 Efeito médio do tratamento (ATT)

A Tabela 4 apresenta o efeito médio do tratamento sobre os tratados (ATT) estimado pelos três métodos simultaneamente, para as quatro variáveis dependentes.

Tabela 4: Efeito médio do tratamento (ATT) — PSM, Causal Forest e X-Learner

Variável Dependente	PSM		Causal Forest		X-Learner	
	Coef.	(EP)	Coef.	(EP)	Coef.	(EP)
Segurança Alimentar	-0,1706***	(0,0068)	-0,1176***	(0,0077)	-0,1186***	(0,0076)
Inseg. Alimentar Leve	0,0357***	(0,0067)	0,0251**	(0,0092)	0,0265**	(0,0085)
Inseg. Alimentar Mod.	0,0695***	(0,0051)	0,0531***	(0,0066)	0,0540***	(0,0064)
Inseg. Alimentar Grave	0,0655***	(0,0042)	0,0459***	(0,0057)	0,0451***	(0,0057)

Fonte: Elaboração própria a partir dos dados da POF 2017-2018.

Erros padrão entre parênteses. *** $p < 0,01$; ** $p < 0,05$; * $p < 0,10$. Para o PSM, resultados referem-se ao pareamento pelo Vizinheiro Mais Próximo; robustez confirmada por Raio, Kernel e Estratificação (sinais idênticos)

O resultado central da Tabela 4 é a convergência plena entre os três métodos: em todos eles, o PBF está associado a efeito negativo sobre a probabilidade de segurança alimentar e a efeitos positivos sobre as três categorias de insegurança alimentar — leve, moderada e grave —, com sinais idênticos e ordenamento consistente de magnitudes. Essa convergência é particularmente relevante porque os três métodos diferem substancialmente em suas arquiteturas de estimação: o PSM constrói o contrafactual por pareamento direto com base no escore de propensão; o Causal Forest utiliza florestas aleatórias com honestidade amostral e estimadores duplamente robustos; e o X-Learner emprega uma estratégia entrecruzada de imputação do contrafactual, especialmente adequada para contextos de forte desbalanceamento entre tratados e controles, conforme proposto por Künzel et al. (2019). O fato de que três

estratégias tão distintas chegam ao mesmo padrão qualitativo reduz significativamente a probabilidade de que os resultados sejam artefatos de uma escolha metodológica específica, fortalecendo a credibilidade empírica do estudo.

As diferenças de magnitude entre o PSM e os métodos de aprendizado de máquina são esperadas e têm explicação metodológica direta. O PSM produz estimativas sistematicamente maiores em valor absoluto — por exemplo, $-0,1706$ para segurança alimentar, contra $-0,1176$ (Causal Forest) e $-0,1186$ (X-Learner). Isso decorre do fato de que os estimadores de ML regularizam as estimativas ao longo do espaço das covariáveis, produzindo resultados mais conservadores. Causal Forest e X-Learner, por sua vez, apresentam magnitudes praticamente idênticas entre si — com diferenças inferiores a $0,002$ em todos os desfechos —, o que é notável dado que utilizam algoritmos distintos. Segundo Santos (2023), efeitos médios agregados frequentemente ocultam variações substantivas ao longo da distribuição do desfecho, o que justifica o uso de métodos de aprendizado de máquina causal como complemento às abordagens tradicionais. De forma semelhante, Silva (2023) argumenta que o Causal Forest permite identificar padrões de heterogeneidade que permanecem invisíveis em estimativas médias obtidas via PSM.

Os resultados apresentados na Tabela 4 indicam efeitos estatisticamente significativos do Programa Bolsa Família sobre a distribuição dos domicílios entre os diferentes estados de segurança e insegurança alimentar. O ATT estimado para a condição de Segurança Alimentar é negativo e altamente significativo nos três métodos ($-0,1706$ no PSM; $-0,1176$ no Causal Forest; $-0,1186$ no X-Learner), indicando que os domicílios beneficiários apresentam menor probabilidade de se encontrarem em situação de segurança alimentar em comparação aos domicílios do grupo controle.

Esse resultado, à primeira vista contraintuitivo, é amplamente documentado na literatura e reflete o caráter focalizado do programa: os beneficiários são domicílios estruturalmente mais vulneráveis, de modo que, mesmo após o pareamento por observáveis, o grupo tratado parte de uma posição alimentar mais desfavorável do que o grupo controle. Almeida et al. (2016) e Sperandio et al. (2017) destacam que, mesmo após o controle por características observáveis, o impacto do programa nem sempre é suficiente para gerar melhorias imediatas na qualidade da dieta ou segurança alimentar.

Da mesma forma, Duarte et al. (2019) e Rocha et al. (2016) indicam que as transferências de renda não eliminam as restrições orçamentárias e alteram a alocação de gastos das famílias, mantendo perfis de consumo e despesas que refletem a vulnerabilidade estrutural associada à insegurança alimentar. É importante destacar, ainda, que todos os três métodos

empregados baseiam-se na hipótese de seleção em observáveis: variáveis não observáveis — como o grau de vulnerabilidade pré-programa ou a motivação para buscar o cadastro — podem ainda diferenciar beneficiários e não beneficiários após o pareamento, contribuindo para o sinal observado. Os resultados devem, portanto, ser lidos como diferenças médias condicionais robustas, e não como efeitos causais em sentido estrito.

Um aspecto central dos resultados é o gradiente de severidade nos efeitos estimados, consistente nos três métodos: os efeitos positivos sobre insegurança alimentar são mais intensos nas categorias moderada e grave do que na leve. Esse gradiente tem interpretação substantiva importante e deve ser analisado à luz das especificidades de cada nível de insegurança. A insegurança alimentar leve caracteriza-se pela preocupação ou incerteza quanto ao acesso a alimentos no futuro — uma dimensão mais subjetiva, menos diretamente determinada pela renda imediata, conforme destacado por Santiago et al. (2023) —, o que explica o menor efeito positivo observado nessa categoria (ATT entre 0,020 e 0,036).

A insegurança moderada já implica restrição quantitativa real na alimentação dos adultos do domicílio, refletindo privação mais concreta; os efeitos mais intensos nesse nível (ATT entre 0,053 e 0,070) são coerentes com a concentração de beneficiários nesses estratos de vulnerabilidade. A insegurança grave representa a fome, atingindo todos os membros do domicílio, incluindo crianças; os efeitos também elevados nesse nível (ATT entre 0,045 e 0,066) indicam que o programa alcança prioritariamente os domicílios em situação de extrema vulnerabilidade, conforme destacado em Sperandio et al. (2017), Almeida et al. (2016) e Rosales et al. (2022).

A interpretação predominante na literatura é que o Bolsa Família atua como uma política de alívio, reduzindo a intensidade da privação alimentar, mas não eliminando completamente a insegurança alimentar severa, especialmente em contextos de pobreza estrutural. Duarte e Sampaio (2009) ressaltam que o Bolsa Família, isoladamente, não é suficiente para eliminar a vulnerabilidade alimentar; conclusões análogas sobre a persistência da insegurança alimentar em programas de transferência de renda são encontradas por Rosales et al. (2022) ao avaliarem o impacto do BPC.

Para a Insegurança Alimentar Leve, o efeito positivo estimado (ATT = 0,036 no PSM; 0,025 no Causal Forest; 0,027 no X-Learner) indica maior probabilidade de os domicílios beneficiários se encontrarem nessa categoria em relação aos controles pareados. Coelho e Melo (2015), Rocha et al. (2016) e Pereira (2024) interpretam os efeitos do programa como uma reconfiguração do orçamento e do consumo familiar, atuando na mitigação das restrições econômicas imediatas, o que é fundamental para o enfrentamento da insegurança alimentar,

ainda que não garanta sua plena superação. Esse resultado é coerente com a magnitude do benefício médio em 2018 (aproximadamente R\$ 186,78), que representava cerca de 40% do custo de referência de uma cesta básica (DIEESE, 2018) — suficiente para garantir acesso a alimentos calóricos básicos, mas insuficiente para sustentar uma dieta diversificada e de qualidade que sustente a segurança alimentar plena.

A Tabela 5 apresenta os efeitos médios do tratamento estimados por diferentes métodos de pareamento — Raio, Kernel e Estratificação — com o objetivo de avaliar a robustez dos resultados obtidos pelo Vizinho Mais Próximo.

Tabela 5: ATT estimado por diferentes métodos de pareamento — análise de robustez do PSM

Variável Dependente	ATT — Raio	ATT — Kernel	ATT — Estratificação
Segurança Alimentar	-0,1332***	-0,1189***	-0,2065***
Inseg. Alimentar Leve	0,0388***	0,0202**	0,1014***
Inseg. Alimentar Moderada	0,0531***	0,0526***	0,0623***
Inseg. Alimentar Grave	0,0414***	0,0460***	0,0428***

Fonte: Elaboração própria a partir dos dados da POF 2017-2018.

*** $p < 0,01$; ** $p < 0,05$; * $p < 0,10$. Os sinais são consistentes entre todos os métodos de pareamento para todas as variáveis de resultado.

Observa-se que os sinais dos ATTs são consistentes entre os métodos para todas as variáveis de resultado, indicando que os efeitos estimados não dependem de uma especificação particular do procedimento de pareamento. As diferenças observadas nas magnitudes refletem as distintas formas de construção do contrafactual em cada método: o Kernel produz estimativas mais suavizadas, ao ponderar todas as observações do grupo controle de acordo com sua proximidade no escore de propensão; enquanto a Estratificação tende a amplificar os efeitos ao explorar variações dentro de estratos do escore de propensão. Ainda assim, a proximidade entre as estimativas de Raio e Kernel reforça a robustez empírica dos resultados. Em conjunto, esses achados corroboram que as conclusões centrais do estudo são estáveis à escolha do método de pareamento, fortalecendo a credibilidade das estimativas apresentadas.

Para o Causal Forest, o teste de calibração pelo Best Linear Predictor (BLP), proposto por Wager e Athey (2018), fornece duas informações adicionais importantes, mostradas na tabela 6.

Tabela 6: Testes de calibração do causal forest (Best Linear Predictor)

Coefficiente	Descrição	Estimativa	Erro-Padrão	Estatística t	Valor-p
Intercepto (α)	Previsão média da floresta	0,0180	0,0011	15,8534	< 0,001
$\hat{\tau}$ (β)	Previsão diferencial da floresta	0,6948	0,0279	24,9008	< 0,001

Fonte: Elaboração própria com base nos dados da POF 2017-2018

Nota: O teste de calibração avalia se as previsões do Causal Forest estão bem calibradas e se há evidência estatística de heterogeneidade nos efeitos do tratamento, conforme proposto por Wager e Athey (2018)

O coeficiente associado à previsão média da floresta ($\alpha = 0,0180$; $p < 0,001$) indica que as estimativas produzidas pelo modelo estão bem calibradas em relação ao efeito médio observado nos dados, atendendo aos critérios de calibração propostos na literatura. Mais importante, o coeficiente associado à previsão diferencial da floresta ($\beta = 0,6948$; $p < 0,001$) é elevado e estatisticamente significativo, permitindo rejeitar formalmente a hipótese nula de efeitos constantes. Esse achado constitui evidência formal da presença de heterogeneidade nos efeitos do tratamento e valida o uso das estimativas condicionais (CATE) produzidas pelo modelo na análise da seção seguinte. Esse procedimento segue exatamente a recomendação metodológica de Wager e Athey (2018), segundo a qual a análise da heterogeneidade deve ser precedida por testes de calibração que assegurem a confiabilidade das previsões da floresta. Resultados semelhantes são documentados em aplicações empíricas recentes, como em Santos (2023) e Silva (2023), bem como em estudos internacionais sobre segurança alimentar e políticas públicas, como Weiffen et al. (2022), nos quais a significância do coeficiente diferencial é interpretada como condição necessária para a exploração substantiva da heterogeneidade dos efeitos.

Em conjunto, os resultados das Tabelas 4 e 5 indicam que o Programa Bolsa Família não promove, no curto prazo, um deslocamento massivo dos domicílios beneficiários para a condição de segurança alimentar. No entanto, exerce um papel relevante no alívio imediato das

privações alimentares, especialmente nos níveis mais severos de insegurança. Esse padrão é consistente com os achados da literatura, que enfatizam que transferências monetárias condicionadas atuam como políticas compensatórias, cujos efeitos dependem da articulação com políticas complementares de emprego, educação e acesso a serviços públicos. No contexto internacional, estudos como Weiffen et al. (2022) e Shah et al. (2025) evidenciam a heterogeneidade dos efeitos de transferências de renda, mostrando que o impacto é modulado por fatores contextuais específicos. Os resultados encontrados neste trabalho seguem essa mesma lógica, e a seção seguinte examina como esses efeitos médios se distribuem entre diferentes grupos populacionais.

4.3 Efeitos heterogêneos

As subseções a seguir examinam como os efeitos do PBF variam conforme características individuais, nível de instrução, região e localização. Em cada dimensão, uma única tabela consolida os resultados dos três métodos para todas as quatro variáveis dependentes. Como os sinais são consistentes em praticamente todos os subgrupos a discussão foca nos padrões que apresentam variações de magnitude relevantes entre subgrupos e destaca onde os métodos convergem ou diferem.

4.3.1 Gênero, raça e idade

A Tabela 7 apresenta os efeitos heterogêneos do Programa Bolsa Família por características individuais dos responsáveis pelos domicílios — gênero, raça/cor e faixa etária —, estimados de forma consolidada pelos três métodos. Os efeitos são estimados a partir da amostra pareada obtida pelo PSM e pelos CATEs médios do Causal Forest e do X-Learner, de modo que as comparações são realizadas entre beneficiários e não beneficiários com características observáveis semelhantes.

Tabela 7: Efeitos heterogêneos por características individuais — PSM, Causal Forest e X-Learner

Subgrupo	PSM				Causal Forest				X-Learner			
	Seg. Alim.	IA Leve	IA Mod.	IA Grave	Seg. Alim.	IA Leve	IA Mod.	IA Grave	Seg. Alim.	IA Leve	IA Mod.	IA Grave
Gênero												
Homens	-0,1789	0,0553	0,0707	0,0529	-0,1238	0,0526	0,0437	0,0295	-0,1244	0,0517	0,0438	0,0301
Mulheres	-0,1599	0,0121	0,0676	0,0802	-0,1382	0,0536	0,0448	0,0509	-0,1399	0,0525	0,0451	0,0518
Raça/Cor												
Brancos	-0,1681	0,0393	0,0754	0,0534	-0,1332	0,0564	0,0457	0,0373	-0,1346	0,0556	0,0457	0,0380
Pretos	-0,1838	0,0258	0,0830	0,0751	-0,1511	0,0626	0,0570	0,0385	-0,1510	0,0614	0,0577	0,0395
Pardos	-0,1660	0,0369	0,0633	0,0658	-0,1225	0,0482	0,0399	0,0397	-0,1235	0,0472	0,0401	0,0404
Indígenas	-0,1676	-0,0125	0,0430	0,1371	-0,1324	0,0415	0,0501	0,0479	-0,1317	0,0410	0,0496	0,0485
Amarelos	0,0135	-0,1243	0,0982	0,0396	-0,1308	0,0526	0,0456	0,0383	0,1320	0,0513	0,0451	0,0388
Faixa Etária												
Jovens (< 30)	-0,2065	0,0567	0,0888	0,0610	-0,1338	0,0502	0,0512	0,0366	-0,1362	0,0505	0,0575	0,0345
Adultos (30-59)	-0,1759	0,0276	0,0753	0,0729	-0,1306	0,0516	0,0448	0,0406	-0,1325	0,0510	0,0456	0,0412
Idosos (≥ 60)	-0,0938	0,0465	0,0198	0,0276	-0,1262	0,0576	0,0380	0,0367	-0,1264	0,0546	0,0377	0,0373

Fonte: Elaboração própria a partir dos dados da POF 2017-2018.

IA = Insegurança Alimentar; Seg. Alim. = Segurança Alimentar; Mod. = Moderada. Grupos amarelo e indígena têm representatividade amostral reduzida; interpretar com cautela.

Os resultados da Tabela 7 indicam que os efeitos do Programa Bolsa Família sobre a segurança e a insegurança alimentar apresentam variações relevantes de magnitude entre diferentes grupos populacionais, embora os sinais dos efeitos permaneçam, em geral, consistentes com os resultados médios apresentados na seção anterior. Mais importante, o padrão de heterogeneidade é preservado entre os três métodos: o ordenamento relativo dos grupos e a direção dos efeitos são quase idênticos entre PSM, Causal Forest e X-Learner.

As magnitudes estimadas pelo PSM tendem a ser mais elevadas, especialmente nas categorias de insegurança moderada e grave, enquanto o Causal Forest e o X-Learner produzem

estimativas mais suavizadas e praticamente idênticas entre si — diferença esperada e metodologicamente explicada pelo fato de que os estimadores de ML regularizam os efeitos de forma contínua ao longo do espaço das covariáveis, enquanto o PSM produz estimativas médias dentro de subgrupos discretos. Essa convergência qualitativa entre métodos distintos reforça a robustez dos padrões de heterogeneidade identificados, em linha com o que documentam Santos (2023) e Silva (2023), segundo os quais o Causal Forest permite revelar variações sistemáticas dos efeitos que permanecem ocultas em estimativas médias, sobretudo em contextos marcados por forte desigualdade socioeconômica.

No que se refere ao gênero, o efeito negativo sobre a Segurança Alimentar é verificado tanto entre homens quanto entre mulheres nos três métodos, com magnitudes relativamente próximas. No PSM, o efeito é ligeiramente mais intenso entre os homens ($ATT = -0,179$) do que entre as mulheres ($ATT = -0,160$), sugerindo que domicílios chefiados por homens beneficiários permanecem relativamente mais distantes da condição de segurança alimentar, possivelmente refletindo diferenças na alocação intradomiciliar de recursos e na composição familiar.

Esse padrão se inverte no Causal Forest e no X-Learner, onde as mulheres apresentam efeito ligeiramente mais negativo ($-0,138$ e $-0,140$, respectivamente), sugerindo que o estimador mais flexível capta variações nas covariáveis que o PSM não modela automaticamente. Para a Insegurança Alimentar Grave, contudo, o padrão é consistente nos três métodos: o efeito é consideravelmente mais intenso entre mulheres ($0,0802$ no PSM; $0,0509$ no CF; $0,0518$ no XL) do que entre homens ($0,0529$; $0,0295$; $0,0301$). Esse resultado pode estar associado ao desenho institucional do PBF, que prioriza a mulher como titular do benefício, e é consistente com a interpretação de que o programa atua de forma mais intensa justamente nos segmentos mais expostos à privação extrema. Para a insegurança leve, o padrão é menos diferenciado entre gêneros, o que se coaduna com o caráter mais subjetivo desse nível de insegurança — que capta principalmente preocupação e incerteza, dimensão menos diretamente modulada pela titularidade do benefício.

A análise por raça/cor revela heterogeneidade adicional consistente nos três métodos. O efeito negativo sobre a Segurança Alimentar é mais pronunciado entre responsáveis pretos — ATT de $-0,184$ no PSM, $-0,151$ no Causal Forest e $-0,151$ no X-Learner —, enquanto entre brancos a magnitude é ligeiramente menor. Esses achados estão em consonância com a literatura que documenta desigualdades raciais persistentes no acesso a renda, emprego e condições de vida, mesmo entre domicílios beneficiários de programas sociais.

Para a Insegurança Alimentar Moderada, os efeitos positivos são observados de forma relativamente homogênea entre os grupos raciais, com magnitudes ligeiramente mais elevadas entre pretos e brancos no PSM, indicando que, embora o programa contribua para aliviar a intensidade da privação alimentar, uma parcela significativa dos beneficiários permanece em situação de vulnerabilidade moderada, refletindo restrições estruturais associadas à baixa escolaridade, à precariedade do mercado de trabalho e às desigualdades regionais, conforme argumentado por Duarte e Sampaio (2009) e Rosales et al. (2022).

Para a Insegurança Alimentar Grave, os efeitos são mais intensos entre pretos e pardos, e de forma particularmente acentuada entre indígenas no PSM ($ATT = 0,1371$), valor substancialmente superior à média geral. Nos métodos de ML, o efeito entre indígenas situa-se em torno de 0,048 — menor do que no PSM, mas ainda superior à média dos demais grupos, o que pode ser resultado da suavização dos estimadores ou da menor representatividade desse grupo na amostra.

Dada a reduzida representatividade amostral dos grupos amarelo e indígena, os resultados referentes a esses grupos devem ser interpretados com cautela. Esse padrão sugere que o programa alcança com maior intensidade os domicílios em situação de extrema vulnerabilidade, nos quais a insegurança alimentar grave persiste mesmo após o recebimento do benefício — padrão amplamente documentado na literatura, que enfatiza o papel do Bolsa Família como política de alívio da fome extrema, embora insuficiente, isoladamente, para eliminar completamente a insegurança alimentar.

Ao considerar as faixas etárias, observa-se que o efeito negativo sobre a Segurança Alimentar é mais intenso entre jovens ($ATT = -0,206$ no PSM; $-0,134$ no CF; $-0,136$ no XL), seguido por adultos, enquanto entre idosos a magnitude do efeito é substancialmente menor, padrão consistente nos três métodos. Esse resultado sugere que domicílios chefiados por indivíduos mais jovens enfrentam maior dificuldade em alcançar segurança alimentar, possivelmente em função de maior instabilidade no mercado de trabalho e menor acesso a rendas previdenciárias, resultado amplamente discutido por Duarte e Sampaio (2009).

Para a Insegurança Alimentar Moderada, os efeitos são ligeiramente mais elevados entre jovens e adultos nos três métodos, com magnitudes próximas. Entre idosos, os efeitos sobre insegurança moderada e grave são substancialmente menores do que nos demais grupos etários. Esse padrão pode refletir a complementação do PBF por outras políticas de proteção social, como aposentadorias e Benefício de Prestação Continuada (BPC), que tendem a reduzir a vulnerabilidade alimentar desse grupo de forma independente do programa avaliado. No caso da insegurança leve, nota-se que os idosos apresentam efeitos positivos próximos aos dos

demais grupos nos métodos de ML (0,058 no CF; 0,055 no XL), sugerindo que esse nível — associado à preocupação e incerteza quanto ao acesso futuro a alimentos — afeta de forma relativamente homogênea todas as faixas etárias, independentemente das rendas complementares recebidas.

Em síntese, os resultados da Tabela 7 indicam que o impacto do Programa Bolsa Família sobre a segurança e a insegurança alimentar é heterogêneo entre diferentes grupos populacionais, e que essa heterogeneidade é robusta entre métodos: PSM, Causal Forest e X-Learner convergem no ordenamento dos grupos e na direção dos efeitos, divergindo apenas nas magnitudes. Os maiores impactos sobre as formas mais severas de insegurança concentram-se entre mulheres, pretos, indígenas e jovens, grupos estruturalmente mais expostos à privação alimentar extrema.

No plano internacional, trabalhos como Weiffen et al. (2022) e Shah et al. (2025) mostram que programas de transferência de renda tendem a apresentar efeitos mais pronunciados em grupos estruturalmente mais vulneráveis, especialmente no que se refere a desfechos extremos — padrão diretamente compatível com os achados desta análise. Embora o programa exerça papel relevante na amenização das formas mais severas de privação, seus efeitos são condicionados a características individuais associadas a desigualdades estruturais, reforçando a necessidade de políticas complementares voltadas ao emprego, à educação e à redução das desigualdades sociais. A seção seguinte examina como esses efeitos variam conforme o nível de instrução do responsável pelo domicílio.

4.3.2 Nível de instrução

A Tabela 8 apresenta os efeitos heterogêneos do Programa Bolsa Família conforme o nível de instrução do responsável pelo domicílio, estimados de forma consolidada pelos três métodos.

Tabela 8: Efeitos heterogêneos por nível de instrução — PSM, Causal Forest (CF) e X-Learner (XL)

Subgrupo	PSM				Causal Forest				X-Learner			
	Seg. Alim.	IA Leve	IA Mod.	IA Grave	Seg. Alim.	IA Leve	IA Mod.	IA Grave	Seg. Alim.	IA Leve	IA Mod.	IA Grave
Baixa instrução	-0,1611	0,0234	0,0678	0,0699	-0,1281	0,0483	0,0442	0,0408	-0,1274	0,0459	0,0447	0,0418
Média instrução	-0,1873	0,0484	0,0769	0,0620	-0,1277	0,0492	0,0460	0,0370	-0,1266	0,0496	0,0470	0,0376
Alta instrução	-0,1656	0,0665	0,0575	0,0416	-0,1358	0,0609	0,0431	0,0362	-0,1371	0,0607	0,0430	0,0369

Fonte: Elaboração própria a partir dos dados da POF 2017-2018.

Os efeitos sobre a Segurança Alimentar são negativos em todos os níveis educacionais e em todos os métodos, com magnitudes relativamente próximas entre si. No PSM, o efeito é ligeiramente mais intenso entre responsáveis com instrução média (ATT = -0,187), seguido pelos grupos com alta (ATT = -0,166) e baixa instrução (ATT = -0,161); no Causal Forest e no X-Learner, as magnitudes situam-se entre -0,127 e -0,137, sem diferenças expressivas entre os grupos. Esse padrão sugere que, mesmo entre indivíduos com maior nível educacional, os domicílios beneficiários tendem a permanecer com menor probabilidade de alcançar segurança alimentar plena em comparação aos controles pareados, reforçando a interpretação de que o programa atinge famílias estruturalmente mais vulneráveis, independentemente do capital humano formal do responsável.

Os três métodos apresentam elevada convergência qualitativa: o ordenamento dos grupos e a direção dos efeitos são preservados entre PSM, Causal Forest e X-Learner, com diferenças apenas nas magnitudes — mais elevadas no PSM e mais suavizadas nos métodos de ML, conforme esperado dada a natureza regularizada dos estimadores de aprendizado de máquina causal. Segundo Santos (2023), a educação tende a modular os efeitos das políticas públicas principalmente nos pontos intermediários da distribuição do desfecho, enquanto nos extremos os impactos se tornam mais uniformes — padrão que os resultados da Tabela 8 confirmam de forma consistente. De forma semelhante, Silva (2023) encontra que o Causal Forest revela gradientes educacionais relevantes apenas em determinados estágios da vulnerabilidade, resultado também documentado em estudos internacionais sobre transferência de renda e segurança alimentar.

Para a Insegurança Alimentar Leve, os resultados revelam um gradiente educacional claro e consistente nos três métodos: o efeito positivo cresce com o nível de instrução, variando de 0,023 (baixa) a 0,048 (média) e 0,066 (alta) no PSM, e de forma mais suavizada no Causal Forest (0,048; 0,049; 0,061) e no X-Learner (0,046; 0,050; 0,061). A literatura interpreta esse padrão como evidência de que o capital humano pode potencializar a capacidade de conversão da transferência monetária em melhorias parciais nas condições alimentares: entre domicílios mais escolarizados — mais próximos do limiar de segurança alimentar —, o benefício atua sobretudo evitando deteriorações marginais no status alimentar, isto é, impedindo a transição para formas iniciais de insegurança, ainda que insuficiente para garantir segurança plena.

Para a Insegurança Alimentar Moderada, os efeitos estimados pelos três métodos são relativamente homogêneos entre os níveis de instrução, com leve predominância do grupo de média instrução no PSM ($ATT = 0,077$) e variações menores no Causal Forest e no X-Learner (em torno de 0,043–0,047 em todos os grupos). Esse padrão indica que, em situações de vulnerabilidade intermediária, o impacto do Bolsa Família tende a ser mais uniforme em termos educacionais, funcionando como um mecanismo de contenção da piora das condições alimentares. A relativa proximidade das estimativas sugere que a persistência da insegurança moderada entre os beneficiários não é fortemente diferenciada pelo nível educacional, refletindo a presença de restrições estruturais — como baixa renda, inserção precária no mercado de trabalho e desigualdades regionais —, conforme destacado por Duarte e Sampaio (2009) e Rosales et al. (2022).

Para a Insegurança Alimentar Grave, observa-se o padrão inverso ao da insegurança leve: os maiores efeitos concentram-se entre os indivíduos de baixa instrução, com redução progressiva à medida que o nível educacional aumenta. No PSM, os valores variam de 0,070 (baixa) a 0,062 (média) e 0,042 (alta); o Causal Forest e o X-Learner confirmam esse ordenamento com magnitudes menores, em torno de 0,037–0,042. Esse resultado é particularmente relevante do ponto de vista de política pública: segundo Künzel et al. (2019), o X-Learner é especialmente adequado para captar esse tipo de heterogeneidade em contextos de dados desbalanceados, nos quais o efeito médio agregado pode mascarar variações substantivas entre subgrupos. O padrão encontrado sugere que, entre os indivíduos de baixa instrução, o Bolsa Família desempenha papel fundamental como rede de proteção contra a fome extrema, justamente onde os mecanismos privados de proteção — como maior renda potencial, acesso à informação e redes de apoio — são mais limitados.

Em síntese, os resultados da Tabela 8 indicam que a educação exerce papel relevante na modulação dos efeitos do programa, ainda que de forma diferenciada conforme o tipo de

insegurança alimentar. Níveis mais elevados de instrução estão associados a maiores efeitos sobre a insegurança leve, ao passo que os efeitos sobre a insegurança grave são mais pronunciados entre os menos escolarizados. A convergência entre os três métodos nesse padrão — mesmo com diferenças de magnitude — reforça a robustez dos achados. Os resultados também reforçam a interpretação de que o Bolsa Família, isoladamente, não é suficiente para eliminar a privação alimentar grave, sendo necessárias políticas complementares voltadas à educação, ao emprego e ao acesso a serviços públicos para a superação sustentável da insegurança alimentar. A seção seguinte examina como esses efeitos variam conforme a região do Brasil.

4.3.3 Região

A Tabela 9 apresenta os efeitos heterogêneos do Programa Bolsa Família por região do Brasil, estimados de forma consolidada pelos três métodos. O efeito negativo sobre a Segurança Alimentar está presente em todas as regiões e em todos os métodos, com ordenamento regional consistente: os impactos são mais intensos no Sul e no Sudeste, enquanto o Nordeste e o Centro-Oeste apresentam as menores magnitudes.

Tabela 9: Efeitos heterogêneos por região — PSM, Causal Forest e X-Learner

Subgrupo	PSM				Causal Forest				X-Learner			
	Seg. Alim.	IA Leve	IA Mod.	IA Grave	Seg. Alim.	IA Leve	IA Mod.	IA Grave	Seg. Alim.	IA Leve	IA Mod.	IA Grave
Norte	-0,1780	-0,0089	0,0770	0,1098	-0,1276	0,0402	0,0444	0,0511	-0,1273	0,0377	0,0444	0,0518
Nordeste	-0,1446	0,0269	0,0650	0,0527	-0,1238	0,0496	0,0454	0,0367	-0,1246	0,0478	0,0455	0,0377
Centro-Oeste	-0,1363	0,0426	0,0353	0,0584	-0,1354	0,0584	0,0376	0,0388	-0,1337	0,0581	0,0376	0,0397
Sudeste	-0,1902	0,0923	0,0559	0,0420	-0,1298	0,0561	0,0440	0,0347	-0,1298	0,0558	0,0447	0,0354
Sul	-0,2339	0,1035	0,0867	0,0436	-0,1495	0,0642	0,0457	0,0378	-0,1469	0,0633	0,0466	0,0386

Fonte: Elaboração própria a partir dos dados da POF 2017-2018.

No PSM, os valores variam de $-0,136$ (Centro-Oeste) a $-0,234$ (Sul); no Causal Forest e no X-Learner, as magnitudes são sistematicamente menores — entre $-0,124$ e $-0,150$ —, o que é esperado dada a natureza regularizada dos estimadores de ML, em contraste com as comparações discretas por subgrupos no pareamento. A convergência qualitativa entre os três

métodos é robusta: o ordenamento regional é preservado em todos os casos. O efeito mais intenso sobre a Segurança Alimentar no Sul e no Sudeste pode ser interpretado como reflexo do custo de vida mais elevado nessas regiões, que reduz o poder de compra real do benefício.

É importante ressaltar, contudo, que os dados disponíveis não permitem verificar diretamente esse mecanismo — trata-se de uma hipótese interpretativa que exigiria análise espacial mais detalhada. Esse padrão está em consonância com estudos que aplicam Causal Forest em políticas públicas, como Santos (2023) e Silva (2023), bem como com evidências internacionais apresentadas por Weiffen et al. (2022) e Shah et al. (2025), que destacam a dimensão espacial como determinante central da heterogeneidade dos impactos de transferências de renda.

Para a Insegurança Alimentar Leve, os três métodos convergem em revelar efeitos mais elevados no Sul e no Sudeste — com destaque para o PSM (0,104 e 0,092, respectivamente), enquanto no Norte o efeito estimado é próximo de zero ou ligeiramente negativo. Esse padrão sugere que, nessas regiões, o programa pode estar associado a um deslocamento mais pronunciado dos domicílios beneficiários para situações de insegurança leve, possivelmente refletindo melhor acesso a mercados e oportunidades de renda, que ampliam a capacidade de conversão marginal da transferência monetária em melhorias parciais no consumo alimentar. Para a Insegurança Moderada, os efeitos positivos são observados em todas as regiões com menor variação, refletindo que, em situações de vulnerabilidade intermediária, o impacto do programa tende a ser mais uniforme no território nacional, conforme argumentado por Duarte e Sampaio (2009) e Rosales et al. (2022).

Para a Insegurança Alimentar Grave, o padrão se inverte em relação à insegurança leve: os maiores efeitos concentram-se no Norte, com destaque para o PSM (ATT = 0,110) e valores em torno de 0,051–0,052 nos métodos de ML. Esse resultado reforça a evidência de que a insegurança alimentar severa é mais concentrada nas regiões historicamente mais vulneráveis do país, mesmo após o recebimento do benefício. Fatores como isolamento geográfico, precariedade da infraestrutura e menor dinamismo econômico limitam a capacidade do programa de eliminar completamente a privação alimentar grave nessas regiões, corroborando achados de Sperandio et al. (2017), Almeida et al. (2016) e Rosales et al. (2022). No Sul, o segundo maior efeito sobre a insegurança grave nos métodos de ML pode indicar a presença de bolsões persistentes de pobreza em uma região relativamente mais desenvolvida — hipótese que, contudo, os dados disponíveis não permitem confirmar diretamente.

Em síntese, os resultados da Tabela 9 indicam que o impacto do Programa Bolsa Família sobre a segurança e a insegurança alimentar é heterogêneo entre as regiões brasileiras, e essa

heterogeneidade é robusta entre métodos. As desigualdades estruturais do território nacional — expressas em diferentes níveis de custo de vida, acesso a mercados e vulnerabilidade estrutural — modulam de forma relevante os efeitos do programa. Segundo Künzel et al. (2019), o X-Learner é particularmente adequado para capturar essa heterogeneidade espacial em contextos de dados desbalanceados, nos quais os efeitos médios agregados tendem a ocultar variações regionais relevantes. A seção seguinte examina como esses efeitos variam conforme a localização urbana ou rural do domicílio.

4.3.4 Localização

A Tabela 10 apresenta os efeitos heterogêneos do Programa Bolsa Família conforme a localização do domicílio — zona urbana ou rural —, estimados pelos três métodos.

Tabela 10: Efeitos heterogêneos por localização — PSM, Causal Forest e X-Learner

Subgrupo	PSM				Causal Forest				X-Learner			
	Seg. Alim.	IA Leve	IA Mod.	IA Grave	Seg. Alim.	IA Leve	IA Mod.	IA Grave	Seg. Alim.	IA Leve	IA Mod.	IA Grave
Zona Urbana	-0,1644	0,0373	0,0633	0,0638	-0,1320	0,0545	0,0436	0,0389	-0,1326	0,0536	0,0440	0,0395
Zona Rural	-0,1891	0,0368	0,0835	0,0688	-0,1276	0,0489	0,0453	0,0374	-0,1256	0,0467	0,0455	0,0389

Fonte: Elaboração própria a partir dos dados da POF 2017-2018.

O efeito sobre a Segurança Alimentar é negativo em ambos os contextos em todos os métodos. No PSM, a magnitude é ligeiramente mais elevada na zona rural (ATT = -0,189) do que na urbana (ATT = -0,164); no Causal Forest e no X-Learner, o padrão se inverte de forma moderada — com efeito ligeiramente mais intenso na zona urbana (-0,132 e -0,133, respectivamente) do que na rural (-0,128 e -0,126). Essa diferença entre métodos é compatível com suas propriedades: o PSM compara médias em subgrupos discretos, enquanto os estimadores de ML regularizam os efeitos de forma contínua, suavizando diferenças extremas.

Para a Insegurança Alimentar Leve, os três métodos convergem em indicar efeito positivo ligeiramente maior na zona urbana do que na rural. Esse padrão sugere que, em áreas urbanas, onde o acesso aos alimentos depende mais diretamente de renda monetária, o programa pode atuar principalmente como mecanismo de estabilização frente a choques de curto prazo,

prevenindo deteriorações marginais no consumo alimentar. Em contraste, em áreas rurais, a presença de produção própria, autoconsumo e redes locais de apoio pode atenuar parcialmente a sensibilidade imediata à renda monetária, reduzindo o efeito marginal do benefício nesse nível de insegurança. Esse padrão está em consonância com evidências apresentadas por Silva (2023), que identifica heterogeneidade relevante entre contextos urbanos e rurais ao aplicar métodos de aprendizado de máquina causal.

Para a Insegurança Alimentar Moderada e Grave, os três métodos indicam efeitos relativamente próximos entre zonas urbana e rural, com leve predominância da zona rural no PSM — mais expressiva para a moderada (0,084 versus 0,063) e para a grave (0,069 versus 0,064) — e diferenças menores no Causal Forest e no X-Learner. Essa convergência entre métodos sugere que, nos estágios mais severos da privação alimentar, a localização geográfica exerce papel menos diferenciador do que nos níveis mais leves. Nas áreas rurais, restrições estruturais mais profundas — como acesso limitado a mercados, precariedade de serviços públicos e menor diversificação das fontes de renda — concentram o impacto do programa nas formas intermediárias e graves de insegurança, conforme discutido pela literatura sobre pobreza rural no Brasil. O Causal Forest e o X-Learner confirmam que a fome extrema não é um fenômeno exclusivamente rural, estando fortemente presente também em áreas urbanas pobres, especialmente em periferias metropolitanas.

Em síntese, os resultados da Tabela 10 indicam heterogeneidade moderada entre zonas urbana e rural, com padrões distintos conforme o nível de severidade da insegurança alimentar. A convergência qualitativa entre os três métodos — sobretudo no que se refere à insegurança moderada e grave — reforça a robustez dos achados. Segundo Künzel et al. (2019) e evidências internacionais apresentadas por Weiffen et al. (2022) e Shah et al. (2025), políticas nacionais produzem efeitos distintos conforme o ambiente socioeconômico local, sendo a dimensão territorial central para a compreensão dos impactos de intervenções de transferência de renda. Os resultados desta seção, em conjunto com os das seções anteriores, evidenciam que o impacto do Programa Bolsa Família é sistematicamente heterogêneo e condicionado a características individuais, educacionais, regionais e locais dos domicílios beneficiários.

4.4 Comparando os resultados

A comparação dos resultados obtidos pelos métodos Propensity Score Matching (PSM), Causal Forest e X-Learner evidencia elevado grau de consistência empírica, tanto no que se refere aos efeitos médios quanto aos padrões de heterogeneidade dos impactos do Programa Bolsa Família. Em todos os métodos, observa-se efeito negativo sobre a probabilidade de segurança alimentar e efeitos positivos sobre as categorias de insegurança alimentar, especialmente moderada e grave, sugerindo que o programa contribui para o alívio imediato das privações alimentares, mas não se mostra suficiente, no curto prazo, para promover a transição dos beneficiários para a condição de segurança alimentar plena. É importante destacar, contudo, que essa interpretação é condicionada à hipótese de seleção em observáveis — compartilhada pelos três métodos —, de modo que os resultados refletem associações condicionais robustas, e não efeitos causais em sentido estrito.

No âmbito do efeito médio do tratamento, os valores estimados por PSM, Causal Forest e X-Learner apresentam sinais idênticos e ordenamento consistente de magnitudes. Essa convergência indica que os resultados não são sensíveis à escolha do método de estimação, reforçando a estabilidade das conclusões. Enquanto o PSM fornece uma estimativa do ATT baseada na comparação entre grupos pareados por características observáveis, os métodos de aprendizado de máquina corroboram esse efeito médio ao mesmo tempo em que exploram estruturas mais flexíveis de relação entre covariáveis e desfechos. As diferenças de magnitude — com PSM produzindo estimativas sistematicamente maiores do que Causal Forest e X-Learner — são esperadas e decorrem das distintas arquiteturas de cada estimador, e não de divergências substantivas nos resultados.

As diferenças entre os métodos tornam-se mais evidentes na análise da heterogeneidade dos efeitos. O PSM, ao estimar efeitos por subgrupos definidos a priori, identifica padrões relevantes associados a gênero, raça, idade, escolaridade, região e localização. O Causal Forest aprofunda essa análise ao demonstrar formalmente a existência de heterogeneidade estatisticamente significativa — validada pelos testes de calibração — e ao permitir a estimação contínua dos efeitos condicionais ao longo do espaço de características, sem necessidade de definir subgrupos a priori. O X-Learner, por sua vez, confirma esses padrões de heterogeneidade e apresenta estimativas particularmente estáveis em contextos de forte desbalanceamento entre tratados e controles, reforçando os resultados obtidos pelas demais abordagens. Cabe ressaltar, entretanto, que os três métodos se baseiam na mesma hipótese de identificação — seleção em observáveis —, de modo que nenhum deles supera o problema dos

não observáveis: a contribuição dos métodos de ML está na implementação mais flexível dessa hipótese, e não em identificar efeitos causais mais robustos do que o PSM.

De forma geral, os três métodos convergem ao indicar que mulheres, indivíduos negros e indígenas, domicílios com menor nível de instrução e residentes em regiões e contextos mais vulneráveis concentram os maiores impactos do programa sobre as formas mais severas de insegurança alimentar. Assim, enquanto o PSM fornece uma base para a identificação do efeito médio, os métodos de aprendizado de máquina ampliam a análise ao revelar com maior precisão como os impactos se distribuem entre os beneficiários. Essa complementaridade metodológica fortalece a estabilidade interna dos resultados e demonstra o valor da integração entre abordagens tradicionais e técnicas modernas de inferência causal na avaliação de políticas sociais.

Embora os três métodos conduzam a conclusões substantivas semelhantes quanto ao efeito médio do Programa Bolsa Família, a principal diferença reside no grau de informação fornecido por cada abordagem. O Propensity Score Matching, enquanto método tradicional amplamente consolidado na literatura, mostrou-se adequado para reduzir o viés de seleção observável e identificar o efeito médio do tratamento, além de permitir análises de heterogeneidade por subgrupos pré-definidos. No entanto, suas conclusões dependem da escolha ex ante desses subgrupos e da forma funcional imposta pelo pesquisador. Em contraste, os métodos baseados em aprendizado de máquina — Causal Forest e X-Learner — não alteram o sinal nem o ordenamento central dos efeitos estimados, mas ampliam a capacidade analítica ao permitir a identificação flexível e contínua da heterogeneidade dos impactos.

Esses métodos confirmam os resultados obtidos pelo PSM e, adicionalmente, demonstram que a heterogeneidade é estatisticamente relevante e sistemática, validada por testes formais de calibração e pela distribuição dos efeitos condicionais. Assim, a contribuição dos métodos de aprendizado de máquina não está em substituir o PSM, mas em complementá-lo, fornecendo evidência mais detalhada sobre como os impactos do programa variam entre os beneficiários. Essa convergência entre abordagens distintas fortalece a estabilidade dos achados e reduz a probabilidade de que as conclusões sejam artefatos de uma estratégia metodológica específica.

4.5 Discussão dos Mecanismos Causais

Os resultados apresentados nas seções anteriores estabelecem que o Programa Bolsa Família está associado a impactos sobre a distribuição da segurança e insegurança alimentar

dos domicílios beneficiários, com padrões que requerem interpretação cuidadosa à luz do perfil focalizado do programa e das limitações metodológicas inerentes aos métodos empregados. A compreensão desses resultados pode ser aprofundada pela identificação dos mecanismos através dos quais o programa opera — os canais que conectam o recebimento do benefício às diferenças observadas nos indicadores alimentares. Três mecanismos principais podem ser discutidos a partir dos dados e da literatura disponíveis.

O primeiro mecanismo refere-se ao alívio da restrição orçamentária e à insuficiência do valor do benefício frente ao custo de uma alimentação adequada. Segundo dados do Ministério do Desenvolvimento Social (MDS), o benefício médio mensal do Programa Bolsa Família em 2018 situou-se em torno de R\$ 186,78. Em contrapartida, estimativas do DIEESE indicam que o custo da cesta básica nas capitais brasileiras variava aproximadamente entre R\$ 340 e R\$ 470 em 2018, com valores próximos a R\$ 470 nas capitais mais caras. Assim, o benefício médio representava cerca de 40% do custo de referência de uma alimentação básica, o que pode explicar parcialmente os resultados observados: o programa contribui para amenizar as privações ao garantir acesso a alimentos calóricos básicos, mas possivelmente insuficiente para promover uma transição completa para a segurança alimentar, que requer acesso a uma dieta variada, rica em micronutrientes e de qualidade. A persistência de insegurança alimentar entre os beneficiários pode refletir, em parte, essa insuficiência monetária para cobrir todas as dimensões de uma dieta adequada.

O segundo mecanismo está relacionado à titularidade feminina do programa e à alocação intradomiciliar de recursos. Os efeitos mais intensos observados sobre a insegurança grave entre domicílios chefiados por mulheres podem ser parcialmente associados ao desenho institucional do programa, que prioriza a mulher como titular do benefício. A literatura sobre transferências condicionadas sugere que recursos direcionados às mulheres tendem a apresentar maior propensão a gastos alimentares, especialmente voltados ao consumo infantil, conforme apontado por Thomas (1990) e Duflo (2003). Esse padrão pode refletir tanto diferenças na alocação intradomiciliar de recursos quanto o papel tradicionalmente desempenhado pelas mulheres na gestão alimentar do domicílio. Assim, a priorização feminina no recebimento do benefício pode potencializar a conversão da transferência monetária em melhorias no consumo alimentar, ainda que essa hipótese não possa ser verificada diretamente com os dados disponíveis.

O terceiro mecanismo está relacionado à estrutura de mercado e à infraestrutura local como fatores moderadores dos efeitos do programa. A maior intensidade dos impactos sobre a insegurança grave nas regiões Norte e em áreas rurais pode estar associada ao papel da

precariedade da infraestrutura de transporte e à dependência de mercados locais — feiras e pequenos comércios —, que limitam a diversidade da oferta alimentar. Nessas regiões, a falta de acesso a alimentos frescos e os preços relativamente mais elevados de itens saudáveis podem restringir a capacidade do benefício de melhorar a qualidade da dieta além da satisfação calórica, mantendo os domicílios em situação de insegurança alimentar. Nas regiões Sul e Sudeste, embora o acesso a mercados seja mais desenvolvido, o custo de vida mais elevado pode reduzir o poder de compra real do benefício, o que pode contribuir para explicar os maiores efeitos negativos sobre a segurança alimentar nessas regiões — hipótese que, contudo, os dados disponíveis não permitem verificar diretamente.

Em conjunto, esses mecanismos são consistentes com a interpretação de que o programa, embora contribua para o alívio imediato das privações, não é suficiente para promover a transição dos beneficiários para a condição de segurança alimentar no curto prazo. Esse padrão pode ser atribuído a múltiplos fatores: a magnitude do benefício, ainda que relevante, não compensa integralmente o déficit de renda dos domicílios mais pobres; a segurança alimentar requer não apenas renda, mas também acesso adequado a mercados, educação nutricional e infraestrutura de saneamento; e os beneficiários frequentemente enfrentam outras vulnerabilidades — como inserção precária no mercado de trabalho e baixa escolaridade — que limitam sua capacidade de superar estruturalmente a condição de insegurança alimentar. Essas considerações reforçam a interpretação de que o Bolsa Família atua primordialmente como política de alívio das privações, sendo fundamental, porém insuficiente isoladamente, para a garantia plena da segurança alimentar. Assim, a superação sustentável da insegurança alimentar demanda a articulação do programa com políticas complementares nas áreas de educação, mercado de trabalho, saúde e infraestrutura.

5 CONCLUSÃO

Este trabalho teve como objetivo avaliar o impacto do Programa Bolsa Família sobre a segurança e a insegurança alimentar dos domicílios brasileiros, utilizando microdados da Pesquisa de Orçamentos Familiares 2017–2018 e combinando métodos tradicionais de avaliação de políticas públicas com técnicas de aprendizado de máquina voltadas à inferência causal. Para tanto, foram empregados o Propensity Score Matching (PSM), o Causal Forest e o X-Learner, permitindo a estimação tanto do efeito médio do tratamento quanto da heterogeneidade dos impactos entre diferentes grupos socioeconômicos. É importante destacar que os três métodos compartilham a hipótese de seleção em observáveis, de modo que os

resultados refletem associações condicionais robustas, e não efeitos causais em sentido estrito. A principal contribuição metodológica do trabalho reside, portanto, na comparação entre abordagens com distintas arquiteturas de estimação, demonstrando que os padrões identificados são estáveis à escolha metodológica.

Os resultados obtidos indicam elevada convergência entre os três métodos no que se refere ao efeito médio do tratamento. Em todas as abordagens, o Programa Bolsa Família está associado a efeito negativo sobre a probabilidade de segurança alimentar e a efeitos positivos sobre as categorias de insegurança alimentar, especialmente nas formas moderada e grave. Esse padrão, longe de indicar ineficácia do programa, reflete sua natureza focalizada: os beneficiários pertencem a domicílios estruturalmente mais vulneráveis, e o efeito estimado captura a diferença média entre tratados e controles com características observáveis semelhantes — e não necessariamente um efeito causal no sentido estrito. Assim, o efeito médio estimado sugere que o programa atua amenizando, de forma imediata, as privações alimentares dos beneficiários, ainda que não seja suficiente, isoladamente, para promover segurança alimentar plena no curto prazo.

A discussão dos mecanismos permite compreender os canais pelos quais esses resultados se manifestam. O primeiro mecanismo refere-se ao alívio da restrição orçamentária: embora o benefício médio em 2018 (em torno de R\$ 186,78) representasse aproximadamente 40% do custo da cesta básica, esse valor pode ser suficiente para garantir acesso a alimentos calóricos básicos, mas possivelmente insuficiente para promover uma dieta diversificada e de qualidade. O segundo mecanismo relaciona-se à titularidade feminina do benefício, que pode potencializar a conversão da transferência em melhorias no consumo alimentar, dado que recursos direcionados às mulheres tendem a apresentar maior propensão a gastos alimentares, conforme destaca Thomas (1990) e Duflo (2003). O terceiro mecanismo envolve a estrutura de mercado e a infraestrutura local: nas regiões Norte e em áreas rurais, a precariedade logística pode limitar a diversidade da oferta alimentar, enquanto nas regiões Sul e Sudeste o custo de vida mais elevado pode reduzir o poder de compra real do benefício — hipóteses que, contudo, os dados disponíveis não permitem confirmar diretamente.

No que se refere às hipóteses centrais do trabalho, os resultados oferecem evidências parcialmente consistentes com as expectativas formuladas. A hipótese de que o Programa Bolsa Família está associado a diferenças na insegurança alimentar dos domicílios beneficiários foi avaliada à luz das limitações inerentes aos dados transversais utilizados e à hipótese de seleção em observáveis. Os resultados indicam que o programa alcança domicílios em situação de maior

vulnerabilidade alimentar, incluindo aqueles em insegurança grave. Contudo, a natureza transversal dos dados não permite mensurar diretamente a transição dos beneficiários entre estados de segurança e insegurança alimentar ao longo do tempo, tampouco identificar o efeito causal em sentido estrito, dada a possível presença de não observáveis que diferenciam tratados e controles. O que se pode afirmar é que o benefício, isoladamente e no curto prazo, não parece suficiente para promover a transição imediata para a segurança alimentar, reforçando a necessidade de articulação com políticas complementares. Já a hipótese de heterogeneidade dos efeitos foi amplamente corroborada: tanto o PSM quanto os métodos de aprendizado de máquina apontam impactos mais intensos entre mulheres, indivíduos negros e indígenas, domicílios com menor nível de instrução, residentes em áreas rurais e em regiões historicamente mais vulneráveis.

Por outro lado, a hipótese de que os métodos de aprendizado de máquina produziram resultados substancialmente divergentes em relação ao PSM não se confirmou: ao contrário, o Causal Forest e o X-Learner mostraram elevada consistência com os resultados obtidos pelo método tradicional, reforçando a estabilidade empírica dos achados. Esses métodos não identificam efeitos causais mais robustos do que o PSM — pois compartilham a mesma hipótese de seleção em observáveis —, mas auxiliam no aprofundamento da análise ao permitir a identificação flexível e estatisticamente validada da heterogeneidade dos efeitos, sem a necessidade de impor estruturas funcionais ou definir subgrupos de forma *ex ante*. Assim, a principal contribuição dos métodos de aprendizado de máquina neste trabalho não reside na substituição do Propensity Score Matching, mas em sua complementação: enquanto o PSM fornece estimativas interpretáveis do efeito médio e de heterogeneidades básicas, o Causal Forest e o X-Learner ampliam a compreensão sobre como os impactos variam ao longo da distribuição dos beneficiários, capturando padrões que seriam difíceis de identificar com métodos tradicionais. A convergência entre abordagens distintas fortalece a credibilidade dos resultados e reduz a probabilidade de que as conclusões sejam artefatos de uma escolha metodológica específica.

Em termos de implicações de política pública, os resultados sugerem que o Bolsa Família, embora contribua para o alívio das privações alimentares, pode não ser suficiente, isoladamente, para promover a segurança alimentar plena dos beneficiários no curto prazo, reforçando a necessidade de políticas complementares nas áreas de educação, mercado de trabalho, infraestrutura e acesso a serviços públicos.

A partir dos resultados e dos mecanismos identificados, algumas recomendações de política podem ser delineadas. Em primeiro lugar, considerando a heterogeneidade dos efeitos, sugere-se que a calibração do programa considere as características dos grupos mais vulneráveis, priorizando mulheres chefes de domicílio, indivíduos negros e indígenas, famílias com baixa escolaridade e residentes em regiões historicamente desfavorecidas. Em segundo lugar, dado que o benefício monetário isoladamente pode não garantir segurança alimentar plena, recomenda-se a articulação do Bolsa Família com políticas complementares de educação nutricional, fortalecimento da agricultura familiar, ampliação do acesso a mercados locais e programas de alimentação escolar. Em terceiro lugar, os resultados apontam para a necessidade de estratégias territorializadas: nas regiões Norte e em áreas rurais, investimentos em infraestrutura logística e ampliação da oferta de alimentos frescos podem potencializar os efeitos do programa; nas regiões Sul e Sudeste, políticas de geração de emprego e renda podem complementar a transferência monetária diante do maior custo de vida.

Por fim, considerando que o Bolsa Família, isoladamente e no curto prazo, não se mostrou suficiente para promover a transição dos beneficiários para a segurança alimentar, recomenda-se que futuras pesquisas avaliem a atuação sinérgica das políticas sociais brasileiras. Sob a perspectiva da interseccionalidade de políticas, torna-se relevante investigar se a combinação do Bolsa Família com outras intervenções — como o Programa Nacional de Alimentação Escolar (PNAE), o Programa de Aquisição de Alimentos (PAA), o Sistema Único de Assistência Social (SUAS) e políticas de inclusão produtiva — potencializa os efeitos sobre a segurança alimentar, contribuindo de forma mais efetiva para a superação sustentável da vulnerabilidade alimentar dos domicílios beneficiários. Adicionalmente, futuras pesquisas poderiam avançar na direção de estratégias de identificação que permitam controlar não observáveis — como o uso de variáveis instrumentais, desenhos de regressão descontínua ou dados em painel —, superando a principal limitação dos métodos empregados neste trabalho. Desse modo, este trabalho evidencia o potencial dos métodos de inferência causal baseados em aprendizado de máquina como ferramentas para a avaliação comparativa de políticas públicas em contextos de alta complexidade e heterogeneidade social, demonstrando que a convergência entre abordagens distintas constitui, em si mesma, uma contribuição metodológica relevante.

REFERÊNCIAS

ALMEIDA, A. T. C. de; MESQUITA, S. P. de; SILVA, M. V. B. da. Impactos do Programa Bolsa Família sobre a diversificação do consumo de alimentos no Brasil. **Pesquisa e Planejamento Econômico**, v. 46, n. 1, 2016. Disponível em: <https://repositorio.ipea.gov.br/entities/publication/357af9d6-854e-4b87-9a69-49466108d2f8>. Acesso em 15 maio. 2025.

ATHEY, S.; IMBENS, G. W. Machine Learning Methods That Economists Should Know About. **arXiv**, 2019. Disponível em: <https://doi.org/10.48550/arXiv.1903.10075>. Acesso em: 29 jun. 2026.

BAPTISTELLA, J. C. Avaliação de programas sociais: uma análise do Bolsa Família sobre o consumo de alimentos. 2012. Dissertação (Mestrado em Economia Aplicada) - **Universidade Federal de São Carlos**, São Carlos, 2012. Disponível em: <https://repositorio.ufscar.br/handle/20.500.14289/2151>. Acesso 28 maio. 2025.

BREIMAN, Leo. Random Forests. **Statistics Department University of California Berkeley**, 2001. Disponível em: <https://www.stat.berkeley.edu/~breiman/randomforest2001.pdf>. Acesso em: 9 jan. 2026.

CERDÀ-BAUTISTA, Jordi *et al.* Assessing the Causal Impact of Humanitarian Aid on Food Security. **arXiv**, 22 maio 2024. Disponível em: <https://doi.org/10.48550/arXiv.2310.11287>. Acesso em: 14 jul. 2025.

COELHO, P. L.; MELO, A. S. S. A. Impacto do Programa "Bolsa Família" sobre a qualidade da dieta das famílias de Pernambuco no Brasil. **Ciência & Saúde Coletiva**, Rio de Janeiro, v. 22, n. 2, p. 393-402, 2017. Disponível em: <https://doi.org/10.1590/1413-81232017222.13622015>. Acesso em 12 maio. 2025.

CORRÊA, A. M. S.; LEON, L. M. A segurança alimentar no Brasil: proposições e usos da Escala Brasileira de Medida da Insegurança Alimentar (EBIA) de 2003 a 2009. **Segurança Alimentar e Nutricional**, Campinas, v. 16, n. 2, p. 1-19, 2009. Disponível em: <https://periodicos.sbu.unicamp.br/ojs/index.php/san/article/view/8634782>. Acesso em: 5 jul. 2025.

CUSTÓDIO, M. B. *et al.* Segurança alimentar e nutricional e a construção de sua política: uma visão histórica. **Segurança Alimentar e Nutricional**, Campinas, v. 18, n. 1, p. 1–10, 2015. Disponível em: <https://periodicos.sbu.unicamp.br/ojs/index.php/san/article/view/8634683>. Acesso em: 5 jul. 2025.

DIEESE - DEPARTAMENTO INTERSINDICAL DE ESTATÍSTICA E ESTUDOS SOCIOECONÔMICOS. **Pesquisa Nacional da Cesta Básica de Alimentos**. Disponível em: <https://www.dieese.org.br/analisecestabasica/2018/201812cestabasica.pdf>. Acesso em 09 de set. 2025.

DUARTE, H. F. F. L.; FARIA, A. C. L. de; RODRIGUES, C. T. Avaliação de impacto do Programa Bolsa Família sobre o consumo das famílias beneficiárias: uma análise através da POF 2008-2009. **RDE - Revista de Desenvolvimento Econômico**, v. 3, n. 44, p. 230–251, 2019. Disponível em: <https://revistas.unifacs.br/index.php/rde/article/view/6357/4003>. Acesso em 2 de jun. 2025.

DUARTE, G. B.; SAMPAIO, B.; SAMPAIO, Y. Programa Bolsa Família: impacto das transferências sobre os gastos com alimentos em famílias rurais. **Revista de Economia e Sociologia Rural**, v. 47, n. 4, p. 903-918, 2009. Disponível em: <https://doi.org/10.1590/S0103-20032009000400005>. Acesso em 03 de jun. 2025.

DUFLO, Esther. Grandmothers and granddaughters: old-age pensions and intrahousehold allocation in South Africa. **The World Bank Economic Review**, v. 17, n. 1, p. 1-25, jun. 2003. Disponível em: <https://doi.org/10.1093/wber/lhg013>. Acesso em 15 de março. 2026.

FERRAZ, D. *et al.* Os determinantes do consumo alimentar domiciliar: uma comparação entre estratos de renda no Brasil pelos dados da POF de 2008/2009. **Segurança Alimentar e Nutricional**, Campinas, v. 25, n. 2, p. 38–50, 2018. Disponível em: <https://periodicos.sbu.unicamp.br/ojs/index.php/san/article/view/8649989>. Acesso em: 25 jun. 2025.

HOFFMANN, Rodolfo. Insegurança alimentar no Brasil após crise, sua evolução de 2004 a 2017-2018 e comparação com a variação da pobreza. **Segurança Alimentar e Nutricional**, Campinas, v. 28, p. e021014, 2021. Disponível em: <https://periodicos.sbu.unicamp.br/ojs/index.php/san/article/view/8663556>. Acesso em: 23 jul. 2025.

IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Pesquisa de Orçamentos Familiares 2017/2018 (POF)**: microdados. Rio de Janeiro: IBGE, 2017-2018. Disponível em: <https://www.ibge.gov.br/estatisticas/sociais/populacao/24786-pesquisa-de-orcamentos-familiares-2.html?=&t=microdados>. Acesso em 05 de set. 2025.

KUEI, Jaime Kiyoshi. Heterogeneous Treatment Effects in Loyalty Programs: a study case of causal inference approach to understanding customer behaviour. 2024. Dissertação (Mestrado em Data Science and Advanced Analytics) – **NOVA Information Management School, Universidade Nova de Lisboa**, Lisboa, 2024. Disponível em: <https://hdl.handle.net/10362/179865>. Acesso em 25 set. 2025.

KUNZEL, Sören R. *et al.* Meta-learners for Estimating Heterogeneous Treatment Effects using Machine Learning. **arXiv**, 2019. Disponível em: <https://arxiv.org/abs/1706.03461>. Acesso em: 3 nov. 2025.

MACIEL, Fernanda Araujo; DUARTE, Diogo. The impact of cash transfer participation on unhealthy consumption in Brazil. **Health Policy OPEN**, v. 4, e100087, 2023. Disponível em: <https://doi.org/10.1016/j.hpopen.2022.100087>. Acesso em: 24 jun. 2025.

MCINTOSH, Craig; ZEITLIN, Andrew. Cash versus Kind: Benchmarking a Child Nutrition Program against Unconditional Cash Transfers in Rwanda. **arXiv**, 01 jun 2021. Disponível em: <https://arxiv.org/pdf/2106.00213>. Acesso em: 15 ago. 2025.

MDS – **MINISTÉRIO DO DESENVOLVIMENTO SOCIAL**. Disponível em: https://www.mds.gov.br/webarquivos/sala_de_imprensa/boletins/boletim_bolsa_familia/2018/dezembro/06122018_boletim_BFInforma.html . Acesso em 09 de set. 2025.

NEYMAN, J. Sur les applications de la théorie des probabilités aux expériences agricoles: essai des principes. **Roczniki Nauk Rolniczych**, v. 10, p. 1-51, 1923.

PALMEIRA, Poliana de Araújo; BEM-LIGNANI, Juliana; SALLES-COSTA, Rosana. Acesso aos benefícios e programas governamentais e insegurança alimentar nas áreas rurais e urbanas do Nordeste brasileiro. **Ciência & Saúde Coletiva**, Rio de Janeiro, v. 27, n. 7, p. 2583-2595, 2022. DOI: <https://doi.org/10.1590/1413-81232022277.21592021>.

PEREIRA, Ana Carolina Dias. **Políticas públicas e consumo individual de alimentos: comparativo entre alimentos in natura ou minimamente processados e ultraprocessados**. 2024. Dissertação (Mestrado em Economia Aplicada) - Universidade Federal de Viçosa, Viçosa, 2024. Disponível em: <https://locus.ufv.br/handle/123456789/33136>. Acesso em: 15 out. 2025.

REHILL, Patrick; BIDDLE, Nicholas. 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**, 13 jan. 2024. Disponível em: <https://doi.org/10.48550/arXiv.2401.07075>. Acesso em: 27 out. 2025.

ROCHA, M. A. *et al.* Efeito do Programa Bolsa Família sobre o consumo dos domicílios rurais e urbanos no Brasil. **Revista Econômica do Nordeste**, v. 47, n. 2, p. 9-25, 2016. Disponível em: <https://doi.org/10.61673/ren.2016.623>. Acesso em 01 jun. 2025.

ROSALES, Maritza. **Programa de benefício de prestação continuada: impacto no estado nutricional e na segurança alimentar dos idosos**. 2022. Tese (Doutorado em Economia Aplicada) - Universidade Federal de Viçosa, Viçosa, 2022. Disponível em: <https://locus.ufv.br/items/ccb4b71e-2a3a-4d66-a5c6-4034f49e49cd>. Acesso em: 9 nov. 2025.

ROSENBAUM, P. R.; RUBIN, D. B. The central role of the propensity score in observational studies for causal effects. **Biometrika**, Oxford, v. 70, n. 1, 1983. Disponível em: https://www.stat.cmu.edu/~ryantibs/journalclub/rosenbaum_1983.pdf. Acesso em 19 jun 2025.

RUBIN, D. B. Estimating causal effects of treatments in randomized and nonrandomized studies. **Journal of Educational Psychology**, [S. l.], v. 66, n. 5, p. 688-701, 1974. Disponível em: <https://doi.org/10.1037/h0037350>. Acesso em 19 jun. 2025.

SANTIAGO, Rafael do Amaral *et al.* Vulnerabilidade à insegurança alimentar no Brasil: um olhar sobre os dados da POF 2017-2018. **Revista Estudo & Debate**, [S. l.], v. 30, n. 1, 2023. Disponível em: <https://univates.br/revistas/index.php/estudoedebate/article/view/3166>. Acesso em: 24 jul. 2025.

SANTOS, Leandro Pereira dos. Potential heterogeneous treatment effect of education in public federal schools: an analysis of Brazilian high school. **Planejamento e Políticas Públicas**, Brasília, DF, n. 67, p. 42-73, jul./set. 2023. Disponível em: <https://doi.org/10.38116/ppp67art2>. Acesso em 10 jun.2025.

SHAH, Vishalie *et al.* Exploring the heterogeneous impacts of Indonesia's conditional cash transfer scheme (PKH) on maternal health care utilisation using instrumental causal forests. **arXiv**, 22 jan. 2025. Disponível em: <https://arxiv.org/abs/2501.12803>. Acesso em: 1 jul. 2025.

SILVA, J. R. F. da. Statistical learning and causal effects: an application to Bolsa Família Program. 2023. Dissertação (Mestrado em Economia) - **Universidade Federal do Rio Grande do Sul**, Porto Alegre, 2023. Disponível em: <https://lume.ufrgs.br/handle/10183/274202>. Acesso em: 22 maio. 2025.

SILVA, Tiago Falcão (org.). Bolsa Família 15 Anos (2003-2018). Brasília, DF: **Enap**, 2018. Disponível em: <https://repositorio.enap.gov.br/handle/1/3647>. Acesso em: 1 jul. 2025.

SOUZA, P. H. G. F. de; OSORIO, R. G.; PAIVA, L. H.; SOARES, S. Os efeitos do Programa Bolsa Família sobre a pobreza e a desigualdade: um balanço dos primeiros 15 anos. In: SILVA, T. F. (Org.). Bolsa Família 15 Anos (2003-2018). Brasília: **Enap**, 2018. p. 155-192. Disponível em: <https://repositorio.enap.gov.br/handle/1/3647>. Acesso em: 1 jul. 2025.

SPERANDIO, N. *et al.* Impacto do programa bolsa família no consumo de alimentos: estudo comparativo das regiões Sudeste e nordeste do Brasil. **Ciência & Saúde Coletiva**, v. 22, n. 6, p. 1771-1780, 2017. Disponível em: <http://cienciaesaudecoletiva.com.br/artigos/impacto-do-programa-bolsa-familia-no-consumo-de-alimentos-estudo-comparativo-das-regioes-sudeste-e-nordeste/15701?id=15701>. Acesso em 24 maio. 2025.

THOMAS, Duncan. Intra-household resource allocation: an inferential approach. **Journal of Human Resources**, v. 25, n. 4, p. 635-664, 1990. Disponível em: [https://users.nber.org/~rdehejia/!@\\$devo/Lecture%2009%20Gender/supplemental/Thomas_JHR_145670.pdf](https://users.nber.org/~rdehejia/!@$devo/Lecture%2009%20Gender/supplemental/Thomas_JHR_145670.pdf)

TORRES, Theo da Fonseca *et al.* A study on the effect of the Brazilian conditional cash transfer program on child nutrition. In: ENCONTRO NACIONAL DE ECONOMIA, 50., 2022, Fortaleza. Anais... Fortaleza: **ANPEC**, 2022. Disponível em: https://www.anpec.org.br/encontro/2022/submissao/files_I/i12-9b138c46ce957f95df9436947994d1b2.docx. Acesso em: 15 maio 2025.

WAGER, S.; ATHEY, S. Estimation and Inference of Heterogeneous Treatment Effects using Random Forests. **arXiv**, 2018. Disponível em: <https://doi.org/10.48550/arXiv.1510.04342>. Acesso em: 1 jul. 2025.

WEIFFEN, Dorothee; BALIKI, Ghassan; BRÜCK, Tilman. Violent conflict moderates food security impacts of agricultural asset transfer in Syria: a heterogeneity analysis using machine learning. **ISDC**, 2022. Disponível em: <https://isdc.org/publications/violent-conflict-moderates-food-security-impacts-of-agricultural-asset-transfers-in-syria-a-heterogeneity-analysis-using-machine-learning/>. Acesso em: 9 set. 2025.

WINK JUNIOR, Marcos Vinicio *et al.* Impact assessment of emergency care units on hospitalizations for respiratory system diseases in Brazil. **Ciência & Saúde Coletiva**, Rio de Janeiro, v. 27, n. 9, p. 3627-3636, 2022. DOI: <https://doi.org/10.1590/1413-81232022279.06302022>.