

MODELAGEM MICROECONOMÉTRICA PARA AVALIAR IMPACTOS
DA DESIGUALDADE SOCIOECONÔMICA E DA MUDANÇA DO CLIMA NA
DEMANDA DE ELETRICIDADE DO SETOR RESIDENCIAL BRASILEIRO

Talita Borges Cruz

Tese de Doutorado apresentada ao Programa de Pós-graduação em Planejamento Energético, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Doutor em Planejamento Energético.

Orientadores: Roberto Schaeffer
André Frossard Pereira de
Lucena

Rio de Janeiro
Setembro de 2021

MODELAGEM MICROECONOMÉTRICA PARA AVALIAR IMPACTOS
DA DESIGUALDADE SOCIOECONÔMICA E DA MUDANÇA DO CLIMA NA
DEMANDA DE ELETRICIDADE DO SETOR RESIDENCIAL BRASILEIRO

Talita Borges Cruz

TESE SUBMETIDA AO CORPO DOCENTE DO INSTITUTO ALBERTO LUIZ
COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE ENGENHARIA DA
UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE DOS
REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE DOUTOR EM
CIÊNCIAS EM PLANEJAMENTO ENERGÉTICO.

Orientadores: Roberto Schaeffer

André Frossard Pereira de Lucena

Aprovada por: Prof. Roberto Schaeffer

Prof. André Frossard Pereira de Lucena

Prof. Amaro Olimpio Pereira Junior

Prof^a. Carolina Grottera

Prof. Reinaldo Souza

RIO DE JANEIRO, RJ – BRASIL

SETEMBRO DE 2021

Cruz, Talita Borges

Modelagem microeconômica para avaliar impactos da desigualdade socioeconômica e da mudança do clima na demanda de eletricidade do setor residencial brasileiro/Talita Borges Cruz – Rio de Janeiro: UFRJ/COPPE, 2021.

XIV, 184 p.: il.; 29,7 cm.

Orientadores: Roberto Schaeffer

André Frossard Pereira de Lucena

Tese (Doutorado) – UFRJ/ COPPE/ Programa de Planejamento Energético, 2021.

Referências Bibliográficas: p. 155-179.

1. Demanda de Energia 2. Heterogeneidade Socioeconômica.
3. Mudanças Climáticas. 4. Adaptação. I. Schaeffer, Roberto *et al.* II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Planejamento Energético. III. Título.

Ao meu grande amigo Gabriel Barbosa, “In Memoriam”.

AGRADECIMENTOS

Esta tese não seria possível sem o apoio, carinho e amor de pessoas incríveis que permaneceram ao meu lado durante essa montanha russa que é o doutorado. Vocês são muitos, mas gostaria de agradecer especialmente a alguns.

Começo agradecendo aos meus orientadores que foram tão mais do que isso. Roberto Schaeffer e André Lucena, é difícil colocar em palavras o tamanho da minha admiração e respeito. São mais de sete anos com vocês ao meu lado. Obrigada por todos os ensinamentos, acolhimento e até mesmo pelos puxões de orelha. Devo muito a vocês pela pesquisadora que sou hoje. Obrigada por acreditarem no meu potencial e me guiarem até aqui.

Agradeço aos professores Amaro Olimpio Pereira Junior, Carolina Grottera e Reinaldo Souza por aceitarem participar da Banca Examinadora, e pela revisão minuciosa que tanto contribuiu para a evolução deste trabalho.

Aos professores Alexandre Szklo, Pedro Rochedo e Joana Portugal por todo o conhecimento compartilhado com afeto e dedicação. Agradeço também a todos meus colegas do Cenergia, podendo citar alguns, dentre tantos: Alberto, Amanda, Bruno, Camila, Cindy, Eduardo, Esperanza, Eveline, Fabio, Gerd, Luiz Bernardo, Leticia, Maíra, Mariana, Marianne, Matheus, Rafael, Rebecca e Tainan. É um prazer participar desse grupo de pesquisadores excepcionais. Em especial à Camilla, por tantas conversas, conselhos e torcida, obrigada por ter sido fonte força e inspiração.

Agradeço imensamente a minha dupla dinâmica. O que teria sido de mim sem a “Paulita”. Paula, foi um enorme prazer te ter como parceira, confidente, professora, psicóloga e tantos outros papéis que você preencheu nesses anos de doutorado. Que orgulho eu tenho da profissional que você é, e de tudo que realizamos e ainda vamos realizar juntas. Já falei algumas vezes que você é minha super-heroína. Obrigada de verdade por ter se tornado, além de tudo, uma grande amiga!

Não poderia deixar de agradecer ao pessoal da secretaria do PPE, à Sandrinha, Paulo, Fernando, Queila e Cláudia, que foram tão gentis e me salvaram em tantas situações burocráticas.

Thanks to professor Enrica De Cian and all my colleagues in the EnergyA project, especially Filippo and Malcolm. I learned so much about microdata and microeconometrics with you.

To Shonali Pachauri, Miguel Poblete-Cazenave and all the amazing people that I met during IIASA's 2019 Young Scientists Summer Program (YSSP), and that made me feel part of a big family. I'll always remember our summer days in Vienna.

À minha família, tanto a de sangue quanto a que eu escolhi, por serem meus pilares e me encherem de coragem. Por acreditarem tanto em mim, que me fizeram acreditar em mim mesma. À minha mãe, meu pai, tias, tios, avós, primas, primos e amigos. Em especial à Bruna, minha grande amiga por todo o carinho na revisão desta tese.

Por último e mais importante, agradeço ao amor da minha vida, ao meu melhor amigo e companheiro de aventuras, Alê. Por ter ficado ao meu lado cada segundo dessa dolorosa e recompensadora jornada. Pela compressão infinita e amor incondicional, fundamental para esse final feliz. Te amo!

Resumo da Tese apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Doutor em Ciências (D.Sc.)

MODELAGEM MICROECONOMÉTRICA PARA AVALIAR IMPACTOS
DA DESIGUALDADE SOCIOECONÔMICA E DA MUDANÇA DO CLIMA NA
DEMANDA DE ELETRICIDADE DO SETOR RESIDENCIAL BRASILEIRO

Talita Borges Cruz

Setembro/2021

Orientadores: Roberto Schaeffer

André Frossard Pereira de Lucena

Programa: Planejamento Energético

Atualmente, dois desafios globais urgentes enfrentados pela humanidade são a desigualdade socioeconômica e as mudanças climáticas. Contudo, grande parte dos modelos utilizados para explorar as políticas e ações de mitigação e adaptação do clima têm uma capacidade limitada de representar os pobres e vulneráveis, assim como a heterogeneidade climática dentro dos países. Há, portanto, uma necessidade de superar a abordagem de um “consumidor representativo” e adotar melhores práticas que incorporem a heterogeneidade social e climática, avançando para uma representação mais realista dos padrões de demanda. Esta tese contribui para esse fim ao desenvolver modelos microeconômicos de demanda residencial para o Brasil capazes de capturar os impactos da heterogeneidade socioeconômica e das condições climáticas sobre a demanda de eletricidade. A abordagem utilizada permite investigar o comportamento do consumidor domiciliar e controlar a heterogeneidade observada a partir de um conjunto de covariáveis, possibilitando uma compreensão mais profunda sobre os principais impulsionadores da demanda elétrica brasileira. Resultados indicam que diferenças relativas às características econômicas, geográficas, habitacionais, climáticas e familiares explicam uma parte significativa da variação nas necessidades energéticas dos domicílios brasileiros. Não considerar explicitamente tais características domiciliares pode influenciar significativamente o viés das estimativas sobre a contribuição marginal de renda e clima. Ademais, simulações realizadas com base em cenários socioeconômicos e climáticos auxiliam no entendimento sobre os impactos de mudanças da renda e do clima na demanda domiciliar de eletricidade no Brasil.

Abstract of Thesis presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Doctor of Science (D.Sc.)

MICROECONOMETRIC MODELING TO ASSESS IMPACTS OF
SOCIOECONOMIC INEQUALITY AND CLIMATE CHANGE ON ELECTRICITY
DEMAND IN THE BRAZILIAN RESIDENTIAL SECTOR

Talita Borges Cruz

September/2021

Advisors: Roberto Schaeffer

André Frossard Pereira de Lucena

Department: Energy Planning

Currently, two urgent global challenges faced by humanity are socioeconomic inequality and climate change. However, most models used to explore climate mitigation and adaptation policies and actions have a limited ability to represent the poor and vulnerable, as well as climate heterogeneity within countries. Therefore, there is a need to move beyond the “representative consumer” approach and adopt better practices that incorporate social and climate heterogeneity, stepping forward to a more realistic representation of demand patterns. This Thesis contributes to this end by developing microeconomic residential demand models for Brazil capable of capturing the impacts of socioeconomic heterogeneity and climatic conditions on electricity demand. The approach allows investigating the behavior of household consumers and controlling the observed heterogeneity based on a set of covariates, thus enabling a deeper understanding of the main drivers of Brazilian electricity demand. Results indicated that differences related to economic, geographic, housing, climatic and family characteristics explain a significant part of the variation in the energy needs of Brazilian households, which can significantly bias the estimates of the marginal contribution of income and climate if not explicitly accounted for. Furthermore, simulations carried out based on socioeconomic and climate scenarios help to understand the impacts of income and climate changes on household electricity demand in Brazil.

SUMÁRIO

1	INTRODUÇÃO	1
2	DEMANDA RESIDENCIAL DE ELETRICIDADE, HETEROGENEIDADE SOCIOECONÔMICA E ADAPTAÇÃO DAS FAMÍLIAS À MUDANÇA DO CLIMA	5
2.1	Os principais forçantes da demanda residencial de energia	10
2.2	O papel de modelos microeconômicos na projeção de demanda de energia	13
2.3	O crescimento econômico e a heterogeneidade socioeconômica	18
2.4	A necessidade de adaptação à mudança do clima e a heterogeneidade climática	34
3	PROCEDIMENTO METODOLÓGICO	42
3.1	Processamento de dados	42
3.1.1	Microdados da Pesquisa de Orçamentos Familiares (POF)	43
3.1.2	Dados de <i>Cooling Degree Days wet bulb</i> (CDD _{wb})	56
3.2	Modelagem microeconômica	59
3.2.1	Fundamentos econômicos, matemáticos e econométricos	61
3.2.2	Modelagem da heterogeneidade	66
3.2.2.1	Modelos de análise de covariância	67
3.2.2.2	Inferência estatística	69
3.2.3	Testes de robustez	75
3.2.3.1	Resistência aos outliers	75
3.2.3.2	Peso amostral	77
3.2.3.3	O problema da endogeneidade do preço	78
4	RESULTADOS E DISCUSSÃO	87
4.1	Análise estatística da base de dados	87
4.1.1	Microdados da Pesquisa de Orçamentos Familiares (POF)	87
4.1.2	Dados de <i>Cooling Degree Days wet bulb</i> (CDD _{wb})	104
4.2	Modelagem microeconômica	109
4.2.1	Modelagem da heterogeneidade	109
4.2.1.1	Modelos de análise de covariância	109
4.2.1.2	Inferência estatística	109
4.2.2	Teste de robustez	121
4.3	Comparação entre os modelos	125

4.4	Sensibilidade do modelo: o papel da renda e do clima na demanda residencial de eletricidade	134
4.4.1	Ritmos de crescimento econômico	135
4.4.2	Graus de distribuição de renda	141
4.4.3	Mudanças de clima (temperatura e umidade)	144
5	CONCLUSÕES	149
	REFERÊNCIAS BIBLIOGRÁFICAS	155
	APÊNDICE	180

ÍNDICE DE FIGURAS

Figura 1. Consumo de eletricidade <i>per capita</i> e participação da eletricidade no consumo final total nas economias avançadas e em desenvolvimento de acordo com diferentes cenários futuros da IEA	6
Figura 2. Variação anual no consumo global de eletricidade por setor final no cenário STEPS da IEA	8
Figura 3. Principais <i>drivers</i> da demanda de eletricidade em mercados emergentes e economias em desenvolvimento no cenário STEPS da IEA	9
Figura 4. Técnicas de modelagem <i>top-down</i> e <i>bottom-up</i> para estimar o consumo regional ou nacional de energia residencial	14
Figura 5. Energia final <i>per capita</i> versus população acumulada para 11 regiões do mundo, considerando 137 países, em ordem decrescente de uso de energia <i>per capita</i> de acordo com diferentes setores em 2005 (GJ)	18
Figura 6. Os 17 Objetivos do Desenvolvimento Sustentável (ODS)	22
Figura 7. As linhas de pobreza do Banco Mundial de acordo com o nível de renda de cada país	24
Figura 8. Evolução da pobreza e extrema pobreza no Brasil no período 1981-2019 (% da população brasileira)	25
Figura 9. Curva de Lorenz para o Brasil nos anos 2021, 2015 e 2019	27
Figura 10. Índice de Gini da distribuição do rendimento mensal domiciliar <i>per capita</i> segundo Unidades da Federação (2018)	29
Figura 11. Consumo de energia global para resfriamento ambiente em edifícios de acordo com fontes energéticas no período 1990-2016 (TWh versus % na energia final)	36
Figura 12. Renda <i>per capita</i> e taxa de propriedade familiar de aparelhos de AC	38
Figura 13. Crescimento do consumo de eletricidade total e para o condicionamento de ar no setor residencial brasileiro no período 2005-2017 (2005=100)	39
Figura 14. Anatomia da modelagem econométrica	61
Figura 15. Exemplo ilustrativo de preço marginal, preço médio e preço marginal esperado	79
Figura 16. Exemplo ilustrativo de uma tarifa multipartes por bloco crescente	80
Figura 17. Descontos no preço da eletricidade pago pelos consumidores de baixa renda beneficiados pela TSEE	82
Figura 18. Descontos no preço da eletricidade pago pelos consumidores quilombolas e indígenas registrados no Cadastro Único	83
Figura 19. Médias históricas do CDD _{wb} em graus-dias, por Unidade da Federação para os diferentes períodos analisados	108
Figura 20. Matriz de correlação da POF (2017-2018)	119
Figura 21. Matriz de correlação da POF (2008-2009)	120
Figura 22. Matriz de correlação da POF (2002-2003)	121

Figura 23. Média de CDD_{wb} em graus-dias por Unidades da Federação de acordo com diferentes cenários climáticos	146
Figura 24.A. Posse de eletrodomésticos no Brasil por grupos socioeconômicos de acordo com POF (2002-2003)	180
Figura 25.A. Tecnologias de resfriamento ambiente no Brasil por grupos socioeconômicos de acordo com POF (2002-2003)	180

ÍNDICE DE TABELAS

Tabela 1. Principais descobertas sobre os <i>drivers</i> da demanda elétrica residencial a partir de uma revisão literária de diferentes estudos de pesquisa empírica feita por TAALE & KYEREMEH [12]	11
Tabela 2. Informações gerais sobre as três últimas ondas da POF utilizadas na análise microeconômica	44
Tabela 3. Descrição das variáveis socioeconômicas potenciais para a análise microeconômica	50
Tabela 4. Informações gerais sobre a base de dados climática utilizada na análise microeconômica	59
Tabela 5. Acompanhamento mensal por Unidade da Federação da TSEE no mês de julho de 2018	84
Tabela 6. Sumário estatístico das principais variáveis socioeconômicas e climáticas no período 2002-2018	89
Tabela 7. Percentual da população e das famílias em situação de pobreza e extrema pobreza ao longo das POFs	93
Tabela 8. Renda média no Brasil por decis considerando urbano <i>versus</i> rural no período 2002-2018 (em BRL ₂₀₁₇ /ano/domicílio)	95
Tabela 9. Sumário estatístico de dados climáticos históricos por Estados e Estrato Geográfico (valores para CDD _{wb} no período)	104
Tabela 10. Sumário de regressão para cada ano da POF – Modelo Base	111
Tabela 11. Sumário de regressão da POF (2017-2018) – Especificação do modelo e escolha de variáveis controle	113
Tabela 12. Sumário de regressão para cada onda da POF – Modelo de especificação preferencial	117
Tabela 13. Sumário de regressão da POF (2017-2018) – Teste de Robustez	123
Tabela 14. Sumário de regressão para cada onda da POF – Modelo Final (com peso amostral e sem <i>outliers</i>)	126
Tabela 15. Sumário de regressão para POF (2017-2018) – Modelo Final escolhido para projeções: Longo Prazo <i>versus</i> Curto Prazo	133
Tabela 16. Mudança em % na renda dos decis de acordo com cenários de distribuição de renda	142
Tabela 17.A. Sumário de regressão da POF (2008-2009) – Especificação do modelo e escolha de variáveis controle	181
Tabela 18.A. Sumário de regressão da POF (2002-2003) – Especificação do modelo e escolha de variáveis controle	182
Tabela 19.A. Sumário de regressão da POF (2008-2009) – Teste de Robustez	183
Tabela 20.A. Sumário de regressão da POF (2002-2003) – Teste de Robustez	184

ÍNDICE DE QUADROS

Quadro 1. Informações gerais sobre os questionários da POF (2017-2018) _____	45
Quadro 2. Variáveis independentes potenciais da análise microeconômica _____	73

ÍNDICE DE GRÁFICOS

Gráfico 1. Renda média no Brasil por grupos socioeconômicos de acordo com POF (2008-2009) e POF (2017-2018) (BRL ₂₀₁₇ /ano/domicílio) _____	96
Gráfico 2. Posse de eletrodomésticos no Brasil por grupos socioeconômicos de acordo com POF (2008-2009) e POF (2017-2018) _____	97
Gráfico 3. Tecnologias de resfriamento ambiente no Brasil por grupos socioeconômicos de acordo com POF (2008-2009) e POF (2017-2018) _____	99
Gráfico 4. Fontes de energia para aquecimento de água no Brasil por grupos socioeconômicos de acordo com POF (2008-2009) e POF (2017-2018) _____	100
Gráfico 5. Fontes de energia para cocção no Brasil por grupos socioeconômicos de acordo com POF (2008-2009) e POF (2017-2018) _____	101
Gráfico 6. Consumo médio de eletricidade no Brasil por grupos socioeconômicos de acordo com POF (2008-2009) e POF (2017-2018) _____	103
Gráfico 7. Consumo de eletricidade domiciliar previsto pelos modelos da POF (2017-2018) de curto e longo prazo versus resultados observados no período 2017-2018 _	134
Gráfico 8. Renda média domiciliar por classes de renda e cenários socioeconômicos	137
Gráfico 9. Demanda domiciliar média de eletricidade por classes de renda e de acordo com diferentes cenários socioeconômicos (kWh/ano) _____	138
Gráfico 10. Variação no consumo de eletricidade dos mais pobres (D1) e mais ricos (D10) de acordo com os cenários socioeconômicos dos SSPs _____	139
Gráfico 11. Distribuição da renda domiciliar de acordo com os cenários socioeconômicos _____	140
Gráfico 12. Distribuição da renda domiciliar de acordo com os cenários de distribuição de renda _____	142
Gráfico 13. Variação no consumo de eletricidade dos mais pobres (D1) e mais ricos (D10) de acordo com os cenários socioeconômicos POV e EXT _____	143
Gráfico 14. Consumo de eletricidade domiciliar médio de acordo com Unidade da Federação e cenários climáticos (kWh/ano/domicílio) _____	148

1 INTRODUÇÃO

A crise pandêmica da Covid-19 acentuou a imprecisão sobre narrativas futuras relacionadas à demanda de energia. Contudo, também serviu como reforço sobre a posição central da eletricidade na vida moderna [1]. Assim, segundo os estudos da Agência Internacional de Energia (IEA, do inglês, *International Energy Agency*) [2-3] a demanda de eletricidade continuará em uma forte trajetória de ascensão até a metade do século, com o setor residencial desempenhando um papel relevante como consumidor.

De acordo com IEA [1], grande parte desse aumento esperado na demanda elétrica do setor residencial é impulsionada tanto pelo crescimento econômico como pela necessidade de adaptação à mudança do clima em países do Sul Global¹, caracterizados por altos níveis de desigualdade socioeconômica e clima quente.

Pelo lado da mudança do clima, em geral, ações adaptativas consomem quantidades extras de energia [4-6]. A adaptação é uma opção crítica para lidar com a mudança do clima, pois alivia os danos climáticos residuais não evitados por medidas de mitigação [5]. Assim, segundo IEA [2], o aquecimento global ocasionado pelas mudanças climáticas, por causar extremos de temperatura mais frequentes e um aumento de longo prazo na temperatura média global, aumenta a demanda por serviços de resfriamento de ambientes e a energia necessária para fornecê-los.

Em contrapartida, pelo lado do crescimento econômico, à medida que uma economia amadurece, sua demanda domiciliar por energia cresce em termos absolutos, aumentando com a renda disponível e o consequente aumento na demanda por serviços energéticos [7]. Especificamente no setor residencial, esse aumento tem sido atrelado a uma maior posse de eletrodomésticos [8]. Assim, conforme a população enriquece, parte de sua demanda latente de energia passa a ser suprida.

¹ Esta tese adota a definição do termo utilizada por MAZZONE *et al.* [268], que diferencia o Norte Global e o Sul Global, não pela *Brandt Line*, mas sim considerando dois fatores: (i) áreas climáticas e (ii) as desigualdades dentro dos próprios países. “Portanto, países com áreas climáticas quentes-áridas e quentes-úmidas na maioria do ano e que estão mais propensos ao risco de sofrer com mudanças climáticas e ainda registram altos índices de desigualdade, fazem parte do Global Sul. Os países com o Índice de Gini mais baixo e que apresentam um clima mais temperado/frio na maioria do ano, constituem o Global Norte.” [268] (p.2)

Nesse contexto de alta da demanda elétrica residencial, um melhor entendimento sobre os fatores que influenciam a demanda é oportuno, e, por isso, esforços nessa direção vêm ganhando destaque [9-12]. No entanto, estudos que estimam a demanda domiciliar de eletricidade em países em desenvolvimento e países quentes permanecem escassos [13-19], em parte, devido à falta de dados adequados [19]. Consequentemente, grande parte dos estudos que modelam a demanda de energia foi conduzida em países desenvolvidos de clima ameno. No entanto, não é evidente que os estudos de clima/energia feitos em países desenvolvidos se apliquem aos países em desenvolvimento [20]. Isso, pois geralmente, não consideram características chave de países em desenvolvimento, como a presença de heterogeneidade social e climática.

De acordo com RAO *et al.* [21], os modelos atuais utilizados nas pesquisas climática e energética são, em sua maioria, muito agregados para dar conta dessa heterogeneidade social. Assim, distribuições ou heterogeneidade de populações são raramente modeladas, gerando resultados agregados que ignoram as desigualdades na sociedade. Há, portanto, uma necessidade de superar a abordagem de um “consumidor representativo médio” e adotar práticas que incorporem a heterogeneidade social, avançando para uma representação mais realista acerca dos padrões de demanda [22-24].

Neste quesito, o Brasil é um estudo de caso emblemático, sendo um país em desenvolvimento, com alta heterogeneidade social, de dimensão continental e com clima tropical. Possui um clima quente e úmido com alta heterogeneidade climática, devido à sua extensão [2,18,25]. Ademais, apesar de ter sido apontado na década passada como um dos líderes mundiais no crescimento econômico regional [8], sofreu grandes retrocessos nos últimos anos, devido principalmente à crise econômica em curso e aos cortes governamentais nas políticas sociais, resultando em um aumento da disparidade socioeconômica [26,27]. O Brasil figura atualmente entre os 10 países com maior desigualdade de renda no mundo [28-29], sendo o segundo com pior concentração de renda, atrás apenas do Catar [30].

Ainda que o Brasil apresente alta heterogeneidade socioeconômica e climática, a maioria das análises sobre a estimativa empírica da demanda de eletricidade no país produz análises agregadas (e.g. [31-33]). Algumas tentativas de desagregação dos resultados foram empreendidas (e.g. [20,34,35]). No entanto, não são de conhecimento dos autores, análises que estimam empiricamente a demanda elétrica residencial, com

representatividade nacional, considerando tanto diferentes fatores socioeconômicos, como fatores climáticos que vão além da temperatura.

De forma a ajudar a preencher esta lacuna da literatura, esta tese tem como objetivo principal o desenvolvimento de um modelo microeconômico de demanda residencial de eletricidade para o Brasil capaz de capturar os efeitos da heterogeneidade socioeconômica e das condições climáticas na demanda de eletricidade.

A abordagem microeconômica utilizada na modelagem da demanda elétrica permite investigar o comportamento do consumidor domiciliar e controlar a heterogeneidade observada a partir de um conjunto de covariáveis relativas às características econômicas, geográficas, habitacionais, climáticas e familiares. Isso possibilita uma compreensão mais profunda sobre os principais impulsionadores da demanda elétrica brasileira.

Neste estudo são desenvolvidos três modelos de curto prazo de corte transversal com equilíbrio parcial e representatividade nacional, estáticos, de análise de covariância, estimados por Mínimos Quadrados Ordinários (MQO), com estimadores consistentes da matriz de covariância para heterocedasticidade e robustos a fatores tendenciosos.

Os modelos são calibrados com microdados coletados das três ondas mais recentes (referente ao período 2002-2017) da Pesquisa de Orçamentos Familiares (POF), pesquisa domiciliar de renda/despesa familiar mais confiável do Brasil com representação nacional divulgada pelo IBGE (Instituto Brasileiro de Geografia e Estatística). Os dados socioeconômicos da POF são mesclados com dados climáticos – temperatura e umidade – representados pelo indicador climático *Cooling Degree Days* de bulbo úmido (CDD_{wb})².

Todos os modelos, assim como o processamento de dados, são codificados em linguagem e ambiente R via R-Studio; *software*³ gratuito de computação estatística e formulação gráfica baseado em linguagem S [36].

² É um indicador climático que, dentre outras abordagens, busca analisar o efeito da temperatura ambiente do ar e da umidade relativa no consumo de energia.

³ É um projeto GNU (nome do sistema operacional) que fornece uma grande variedade de técnicas estatísticas (modelagem linear e não-linear, testes estatísticos clássicos, análise de série temporal, classificação, agrupamento etc.) e técnicas gráficas. É um *software* altamente extensível. O R está disponível como Software Livre sob os termos da Licença Pública Geral GNU da *Free Software Foundation* na forma de código-fonte, podendo assim ser utilizado gratuitamente. Ele é compilado e

Por fim, quanto à estrutura, esta tese é composta por cinco capítulos. Após a contextualização do tema e exposição dos objetivos do trabalho neste primeiro capítulo introdutório, o **Capítulo 2**, apresenta uma revisão literária acerca da heterogeneidade socioeconômica e a necessidade de adaptação das famílias às mudanças climáticas, destacando o caso brasileiro. O **Capítulo 2** também aborda a importância de um melhor entendimento sobre os impulsionadores de demanda de energia, discutindo as diferentes formas de modelá-los e calcular/projetar a demanda energética das famílias, frisando o papel dos modelos microeconômicos.

Já o **Capítulo 3** faz um detalhamento da metodologia utilizada no desenvolvimento dos modelos microeconômicos propostos, sendo dividido em duas partes. A primeira pormenoriza o processamento e análise dos dados utilizados como entrada nos modelos microeconômicos (POF e CDD_{wb}), enquanto a segunda descreve a modelagem microeconômica realizada. Ou seja, expõe os modelos microeconômicos desenvolvidos, as técnicas de estimação de parâmetros utilizadas em cada um deles, os principais testes realizados para garantir sua adequação e funcionalidade, assim como os testes de robustez dos parâmetros estimados.

Em seguida, o **Capítulo 4** apresenta e discute os resultados do procedimento metodológico, sendo um espelho do capítulo anterior, em que inicialmente são apresentados os resultados do processamento e análise estatística da base de dados utilizada para calibrar os modelos, e, posteriormente, são revelados os resultados da inferência estatística da modelagem microeconômica. Além disso, o capítulo empreende uma comparação entre os diferentes modelos desenvolvidos, aborda a escolha do modelo mais adequado para prever a demanda de eletricidade e apresenta resultados de simulações sobre a demanda de eletricidade de acordo com diferentes cenários socioeconômicos e climáticos. Por fim, o **Capítulo 5** resgata as conclusões centrais dos capítulos anteriores, apontando as principais limitações do estudo e sinalizando possíveis caminhos futuros.

executado em uma ampla variedade de plataformas UNIX e sistemas semelhantes (incluindo FreeBSD e Linux), Windows e MacOS [36].

2 DEMANDA RESIDENCIAL DE ELETRICIDADE, HETEROGENEIDADE SOCIOECONÔMICA E ADAPTAÇÃO DAS FAMÍLIAS À MUDANÇA DO CLIMA

Os setores de demanda final – agricultura, indústria, residencial, resíduos, serviços⁴, transportes etc. – transformam as fontes de energia final (eletricidade, gás natural (GN), gás liquefeito de petróleo (GLP), biomassa⁵, gasolina, óleo, querosene etc.) em bens e serviços energéticos que são demandados pelas famílias, em conjunto com o governo, as exportações e os investimentos [37-40]. Em outras palavras, os serviços energéticos de cada setor são a demanda energética das famílias que precisa ser suprida [41].

A análise do consumo energético das famílias via setores finais é de extrema importância para o planejamento energético da oferta de energia, uma vez que o objetivo final da oferta é suprir a demanda [41] – sobretudo, a análise do setor residencial no que concerne a demanda elétrica. As famílias não demandam eletricidade para consumo direto, mas sim para o consumo de serviços energéticos finais (condicionamento térmico, luz, água quente, comida preparada etc.) [42-44].

Por outro lado, o setor residencial é responsável por 26,9% do total de eletricidade consumida no mundo [45], somente atrás da indústria, com 42% do total. Comparativamente, de acordo com o Balanço Energético Nacional 2020 – BEN 2020 [46], o setor residencial consome 26,1% do total da eletricidade demandada no Brasil, equivalente a 142.572 GWh, também atrás apenas do setor industrial, que representa uma demanda elétrica de 195.867 GWh (35,8%).

Segundo a literatura sobre o tema, a demanda de eletricidade continuará em uma trajetória de ascensão. Isso é particularmente verdade para os países do Sul Global [1-3]. O relatório anual “*World Energy Outlook (WEO)*”⁶, elaborado pela Agência internacional de Energia [3] –, aponta uma taxa de crescimento médio na demanda de eletricidade de

⁴ Contabilizado no BEN pelo setor comercial mais o público.

⁵ Biomassa tradicional inclui lenha, carvão mineral, carvão vegetal. Já a chamada biomassa moderna engloba bagaço de cana, etanol, biodiesel [46].

⁶ O relatório WEO vem sendo utilizado pela IEA por mais de 40 anos, mantendo o objetivo geral de aprofundar a compreensão sobre o futuro da energia. O WEO analisa as escolhas que irão moldar nosso uso de energia, nosso meio ambiente e nosso bem-estar. São futuros possíveis, dadas tendências observadas no passado e *expert illicitation* [3].

3% ao ano até 2040 em países em desenvolvimento, o que corresponde a quase o dobro dos níveis atuais de consumo no final do período. Como é possível observar na **Figura 1**, resultados destacam o Brasil como o país com maior crescimento na demanda elétrica entre os países da América do Sul, com um aumento no consumo de eletricidade de quase 330 TWh no período.

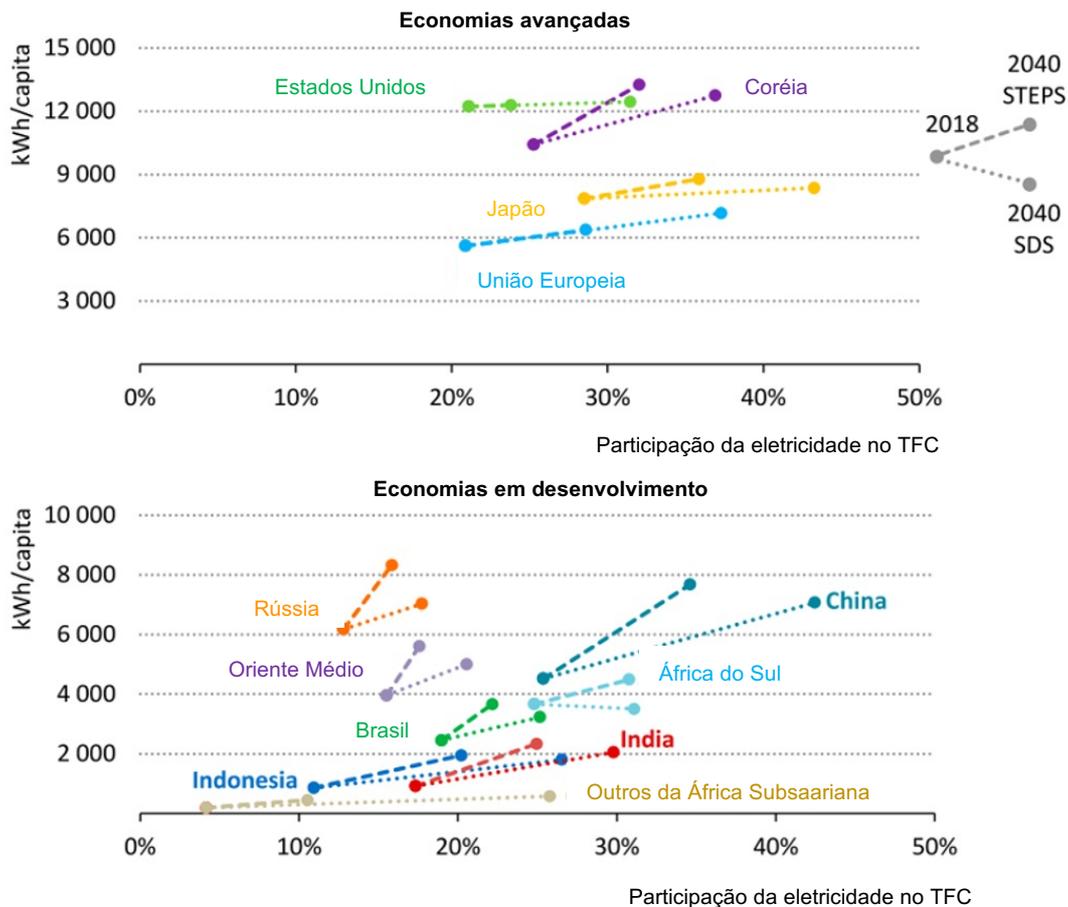


Figura 1. Consumo de eletricidade *per capita* e participação da eletricidade no consumo final total nas economias avançadas e em desenvolvimento de acordo com diferentes cenários futuros da IEA

Fonte: Adaptado de IEA [3]

Nota: TFC = *Total Final Consumption*; STEPS = *Stated Policies Scenario*; DRS = *Delayed Recovery Scenario*⁷; e *Other sub-Saharan Africa* = exclui África do Sul.

Contudo, a crise pandêmica da Covid-19 acentuou a imprecisão sobre narrativas futuras relacionadas à demanda de energia. A incerteza sobre a duração da pandemia, seus

⁷ STEPS, DRS e SDS (*Sustainable Development Scenario*) são cenários ou narrativas futuras criadas pela [3]. Para mais detalhes sobre as premissas de cada cenário, ver IEA [1,3].

impactos econômicos e sociais e as respostas políticas abrem uma ampla gama de possíveis futuros de energia. No entanto, a crise também serviu como reforço sobre a posição central da eletricidade na vida moderna. O fornecimento de eletricidade confiável em combinação com tecnologias de comunicação modernas proporcionou uma rede de segurança crucial para a interação social, bem como para muitas áreas da vida econômica [1].

Considerando o novo cenário mundial, o mais recente WEO [1] continua indicando um aumento na demanda de eletricidade residencial, mesmo que mais modesto em relação às projeções do WEO-2019 [3] e apesar da projeção de queda em 2020 na demanda total de eletricidade⁸ – **Figura 2**. Paralisações e restrições de atividade humana durante 2020 levaram a mais tempo gasto em casa, crescimento do tele-trabalho (*home office*) e da educação à distância, além de maior uso de entretenimento digital, aumentando a demanda de eletricidade nas residências de economias avançadas e emergentes. Além disso, algumas mudanças provocadas pela pandemia provavelmente serão duradouras. Por exemplo, é provável que o número de pessoas trabalhando em casa nos próximos anos permaneça bem acima dos níveis anteriores à Covid-19, podendo impactar o consumo residencial [1].

⁸ O WEO-2020 [1] apresenta uma queda de cerca de 2% em 2020 na demanda total de eletricidade, variando de país para país, em razão da queda do consumo de eletricidade do setor industrial e de serviços (**Figura 2**). Alguns dos maiores impactos ocorrem em economias como Índia ou Europa, que passaram por longos períodos de quarentena, ou em países como os Estados Unidos e o Brasil, onde os serviços representam uma grande parcela da economia.

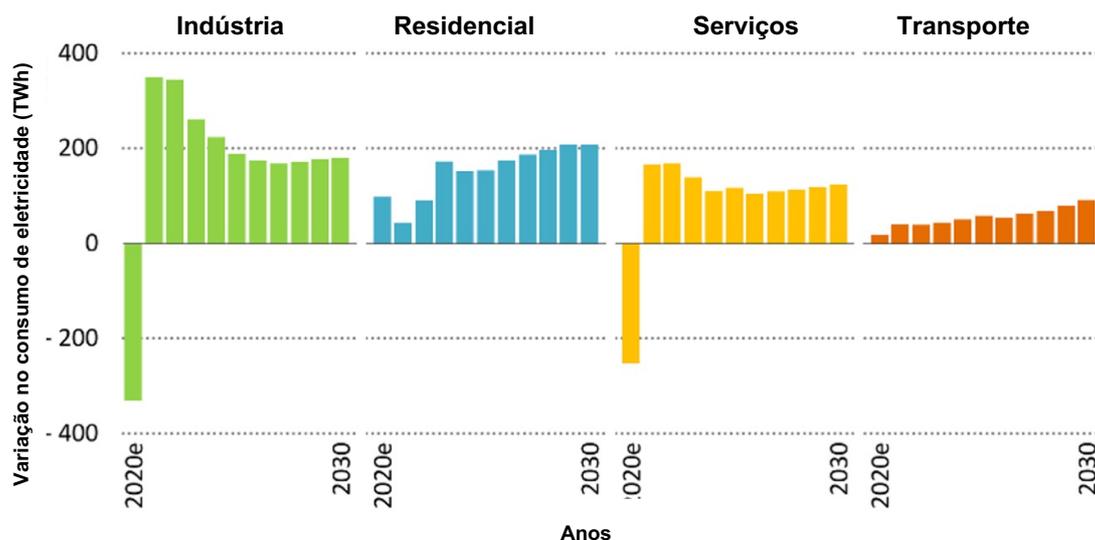


Figura 2. Variação anual no consumo global de eletricidade por setor final no cenário STEPS da IEA

Fonte: Adaptado de IEA [1]
 Nota: 2020e = valores estimados para 2020.

Especificamente em relação ao Brasil e a outros mercados emergentes, apesar de o WEO-2020 apresentar valores mais baixos comparados ao WEO-2019, a demanda de eletricidade continua com forte trajetória ascendente no longo prazo, até 2040 (**Figura 3**). Ainda segundo [1], 80% do aumento na demanda global de eletricidade residencial até 2025 são impulsionados pelo aumento no número dos principais eletrodomésticos e condicionadores de ar nos mercados emergentes e nas economias em desenvolvimento, o que é atribuído a um crescimento econômico e necessidade de adaptação à mudança do clima dos países do Sul Global. Sozinha, a demanda por refrigeração de ambientes residenciais aumentará em 260 TWh até 2025.

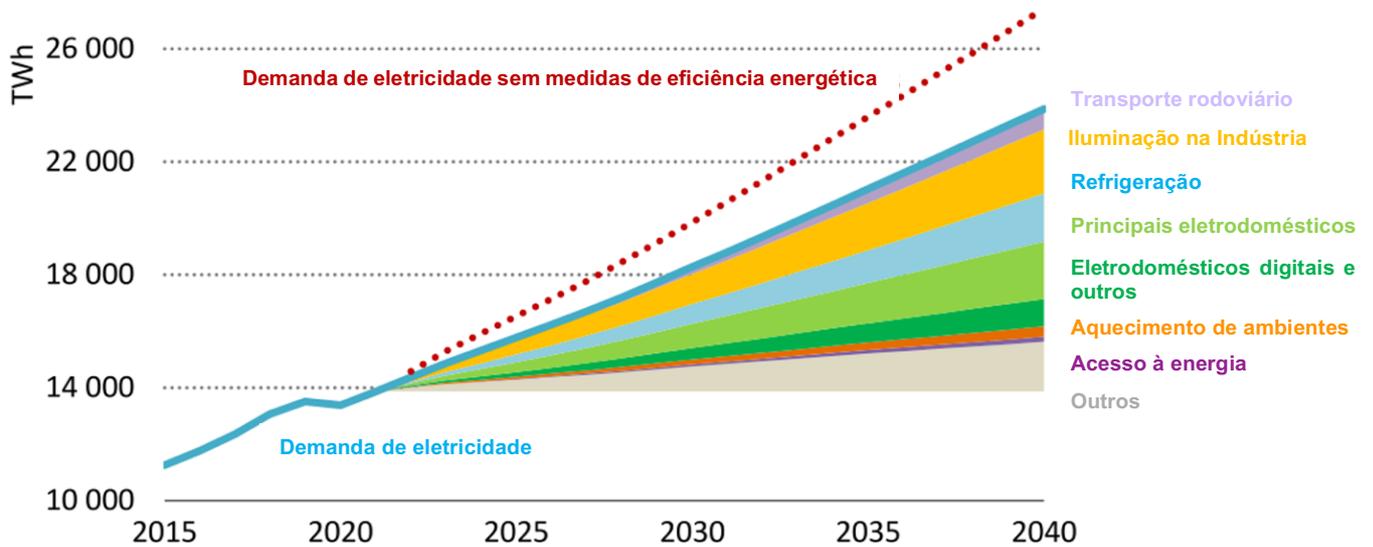


Figura 3. Principais *drivers* da demanda de eletricidade em mercados emergentes e economias em desenvolvimento no cenário STEPS da IEA

Fonte: Adaptado de IEA [1]

Nota: *Outros* = outros usos finais de eletricidade não detalhados na figura.

Compreender o provável crescimento da demanda por energia elétrica é fundamental por várias razões. Em primeiro lugar, os investimentos em infraestrutura energética exigem longos prazos de entrega, e a maioria dos governos e empresas de energia baseiam suas decisões de investimento em projeções de demanda. Previsões incorretas podem levar à escassez de energia local, afetando a produtividade e o bem-estar [47]. Em uma escala global, um crescimento na demanda de energia mais rápido do que o previsto pode levar a aumentos significativos nos preços da energia. Em segundo lugar, o uso de energia é um contribuinte importante para a mudança climática, uma vez que as emissões relacionadas à energia são responsáveis por três quartos das emissões antropogênicas mundiais de gases de efeito estufa (GEE) [48].

Cabe destacar que o Brasil ocupa uma posição única entre os maiores emissores de GEE do mundo, pois, historicamente, possui baixas emissões *per capita* de GEE relacionadas à energia [49]. A baixa emissão *per capita* de GEE é atribuível às abundantes fontes de energia limpa do país. No que diz respeito ao setor residencial, o Brasil possui uma matriz elétrica majoritariamente limpa, onde 83% da oferta interna de eletricidade provém de fontes renováveis, com destaque para o papel da hidroelétrica [46]. Além disso, historicamente, as principais fontes de emissões têm se concentrado na agricultura,

silvicultura e outros usos da terra (AFOLU)⁹ Contudo, segundo LA ROVERE *et al.* [50], na próxima década, as emissões relacionadas à queima de combustíveis fósseis para produção e consumo de energia vão representar um parcela crescente das emissões totais, impondo um grande desafio ao Brasil: manter seus níveis historicamente baixos de emissões de GEE relacionadas à energia e ao mesmo tempo buscar padrões de vida mais elevados para sua população [50].

Tendo esse contexto em vista, um melhor entendimento sobre os fatores que influenciam a demanda elétrica residencial é oportuno. Além disso, estudos que estimam a demanda domiciliar de eletricidade em países em desenvolvimento permanecem escassos, em parte, devido à falta de dados adequados [19]. Por essa razão, a **Seção 2.1** aborda os principais forçantes da demanda energética residencial, seguida por uma discussão sobre as diferentes formas de modelar esses forçantes e calcular/projetar a demanda energética das famílias (**Seção 2.2**). Já nas seções **2.3** e **2.4**, respectivamente, são discutidos pontos centrais da tese: a heterogeneidade socioeconômica e a adaptação à mudança climática.

2.1 Os principais forçantes da demanda residencial de energia

No contexto de trajetória de alta na demanda residencial de energia apresentado anteriormente, os esforços para identificar os principais impulsionadores da demanda residencial – e, mais especificamente, a elétrica – ganharam destaque [9-12]. Além disso, observou-se que compreender a demanda residencial de energia e suas oscilações em resposta a variações em preditores importantes, como por exemplo renda, estoque de aparelhos e características da residência, é um primeiro passo importante para gerenciar o consumo residencial de energia [10,51-54].

Consequentemente, a pesquisa sobre os determinantes do consumo residencial de eletricidade cresceu rapidamente [12], com alguns *drivers* do uso de energia no setor já usualmente conhecidos em nível macro; são estes: a renda, o clima, as características demográficas, juntamente com a dinâmica do preço da energia, tipo de moradia e evolução tecnológica, incluindo tecnologias de informação e comunicação (TIC) [55] [22,56-58].

⁹ Relacionadas principalmente ao desmatamento, cultivo de safras e pecuária [50].

Outro impulsionador importante relatado na literatura é a idade da construção [10,59-61]. Ademais, o número de cômodos, de dormitórios e de andares e a área do piso, além da presença de aquecimento elétrico, ventilação, sistemas elétricos de aquecimento de água quente e sistemas de ar-condicionado (AC), são outros elementos do tipo *built-environment* que influenciam o consumo de energia [10,62]. O fato de a casa ser própria ou não (propriedade da residência) também é identificado como tendo um impacto significativo no consumo total de eletricidade residencial [10,63]. A composição familiar (isto é, presença de crianças, adolescentes, adultos e idosos) e a idade do chefe da família também são reconhecidas como fatores cruciais no consumo de energia [10,63].

TAALE & KYEREMEH [12] realizaram uma revisão literária sobre os principais *drivers* (forçantes) do consumo elétrico residencial, e suas principais descobertas são relatadas na **Tabela 1** (ver [12] para uma completa referência dos estudos revisados).

Tabela 1. Principais descobertas sobre os *drivers* da demanda elétrica residencial a partir de uma revisão literária de diferentes estudos de pesquisa empírica feita por TAALE & KYEREMEH [12]

Variável	Principal descoberta
Renda	A relação entre a renda e a despesa com eletricidade no domicílio é positiva
Clima	Famílias em áreas com temperaturas mais altas gastam mais em eletricidade em comparação com aquelas em áreas com temperaturas favoráveis
Localização (urbano <i>versus</i> rural)	As famílias nas áreas urbanas gastam mais com eletricidade em comparação com as das áreas rurais
Residência própria	Pessoas em casas próprias gastam menos com eletricidade em comparação com aqueles em outros tipos de habitação
Número de cômodos	O número de quartos tem um efeito positivo sobre a despesa com eletricidade nas residências
Membros na família	O gasto com eletricidade está inversamente relacionado ao tamanho da família devido às economias de escala associadas a um tamanho maior da família
Composição da família	A presença de crianças e idosos aumenta o consumo de eletricidade devido à alta necessidade de entretenimento e conforto térmico
Educação	A ligação entre gastos com eletricidade e anos de escolaridade é negativa
Idade do chefe da família	O gasto com eletricidade é inversamente influenciado pela idade do chefe da família
Sexo do chefe da família	Gastos com eletricidade são menores em lares chefiados por mulheres
Posse de eletrodomésticos	Número de aparelhos elétricos exerce uma influência positiva significativa na despesa elétrica

Fonte: Elaboração própria com base em TAALE & KYEREMEH [12]

No entanto, a maioria dos estudos foi conduzida em países desenvolvidos, e as conclusões alcançadas podem ser totalmente diferentes em países em desenvolvimento, como o Brasil e a Índia, onde as práticas socioculturais específicas são relevantes para impulsionar a demanda de energia [64].

Além disso, a maioria dos estudos interpreta "fatores socioculturais" como um conceito vago, que ocasionalmente destaca o nível de educação ou diferenças regionais como influenciadores [65], enquanto um grande número de estudiosos analisa a influência da renda familiar e papéis de gênero [66] nas escolhas da fonte de energia. Embora educação, gênero e práticas sociais sejam todos elementos constitutivos da dimensão sociocultural, há elementos persistentemente deixados de lado na análise cultural das escolhas energéticas e, mais especificamente, no serviço de cocção [67].

Assim, de acordo com MAZZONE *et al.* [67], há uma falta de profundidade na avaliação da dimensão sociocultural da pesquisa sobre forçantes para o consumo de energia no setor residencial brasileiro. As autoras sustentam seu ponto de vista através de um estudo de caso de uma aldeia remota da Amazônia brasileira. O estudo busca identificar os motivadores socioculturais por trás do uso de lenha para cocção e por trás da adoção de fogões mais limpos, como os que funcionam com Gás Liquefeito de Petróleo (GLP). Os resultados do estudo sugerem que a persistência do consumo de lenha para cozinhar está fortemente relacionada a indicadores culturais, como preferências alimentares, hábitos culinários, religiões, normas e crenças locais, identidade étnica, práticas familiares, rituais, materiais utilizados na construção da casa e conhecimento etnobotânico. Contudo, o trabalho reconhece que, pela natureza da abordagem do estudo de caso realizado, não é possível generalizar tais resultados, uma vez que o Brasil é um país extremamente heterogêneo [67].

Ademais, de acordo com MIKAYILOV *et al.* [24], avaliações dos forçantes da demanda de eletricidade em nível nacional podem não ser representativas das diferentes regiões com suas diferentes características. Há grande evidência – a partir de estudos que utilizam microdados em nível domiciliar – de que a demanda de energia doméstica pode variar enormemente entre rendas, climas, estações e regiões, mesmo dentro das nações [19,68-71], especialmente em países fortemente desiguais como o Brasil.

Diante disso, modelos de demanda energética capazes de lidar com a heterogeneidade socioeconômica vêm ganhando destaque na literatura. A seguir são apresentados os diferentes tipos de modelos de demanda de energia, destacando o papel dos chamados modelos microeconômicos.

2.2 O papel de modelos microeconômicos na projeção de demanda de energia

Modelos de projeção de uso de energia, particularmente modelos de demanda de energia residencial, permitem calcular ou simular o consumo de energia das famílias e, por isso, tornaram-se ferramentas essenciais para o desenvolvimento e avaliação de estratégias de planejamento energético que buscam a mitigação e adaptação às mudanças climáticas, formulação de políticas energéticas e concretização dos Objetivos do Desenvolvimento Sustentável – ODS [72,73].

SWAN & UGURSAL [74] conduziram uma revisão crítica das várias técnicas de modelagem do consumo de energia do setor residencial e concluíram que as mesmas podem ser agrupadas em duas principais categorias: *top-down* (no português, “de cima para baixo”) e *bottom-up* (ou “de baixo para cima”).

Modelos *top-down* em uma estrutura que equilibra o consumo histórico de energia com aquele estimado conforme variáveis de entrada. Variáveis comumente empregadas incluem indicadores macroeconômicos, como PIB (Produto Interno Bruto), taxa de emprego, índices de preços, condições climáticas, taxas de construção/demolição de moradias, estimativas de posse de eletrodomésticos e número de unidades do setor residencial. Um dos pontos fortes desse tipo de modelagem é a suficiência de dados agregados, amplamente disponíveis, além de simplicidade e confiança em valores históricos de energia do setor residencial, que fornecem “inércia” ao modelo. Como o setor residencial raramente passa por mudanças de paradigma, um modelo ponderado fornece boa capacidade de previsão para pequenos desvios do status quo. A dependência de dados históricos é uma desvantagem, pois representa incapacidade de modelar avanços descontínuos em tecnologia. Além disso, a falta de detalhes sobre o consumo de energia de usos finais individuais impede a identificação de áreas-chave para melhorias na redução do consumo de energia [74].

A abordagem *bottom-up* abrange todos os modelos que usam dados de entrada de um nível hierárquico inferior ao do setor. Os dados mais utilizados nesse tipo de modelagem envolvem propriedades residenciais, como geometria, tecido de envelope, equipamentos e eletrodomésticos, propriedades climáticas, bem como temperaturas internas, horários de ocupação e uso de equipamentos. O alto nível de detalhamento é um dos pontos fortes desses modelos, oferecendo a capacidade de guiar opções tecnológicas, determinar o consumo de energia de cada uso final e, assim, identificar áreas de melhoria.

Conforme o consumo de energia é calculado, a abordagem *bottom-up* consegue determinar o consumo do setor residencial sem depender de uma série temporal de dados históricos. A principal desvantagem causada por esse nível de detalhe é a maior necessidade de dados de entrada em relação aos modelos *top-down* e maior complexidade nas técnicas de cálculo ou simulação dos modelos [74].

A decisão acerca da categoria mais apropriada depende de diferentes níveis de dados de entrada e diferentes cálculos/técnicas de simulação, fornecendo resultados com diferentes aplicabilidades [74]. Os desdobramentos das duas categorias, *top-down* e *bottom-up*, são apresentados no fluxograma da **Figura 4**.

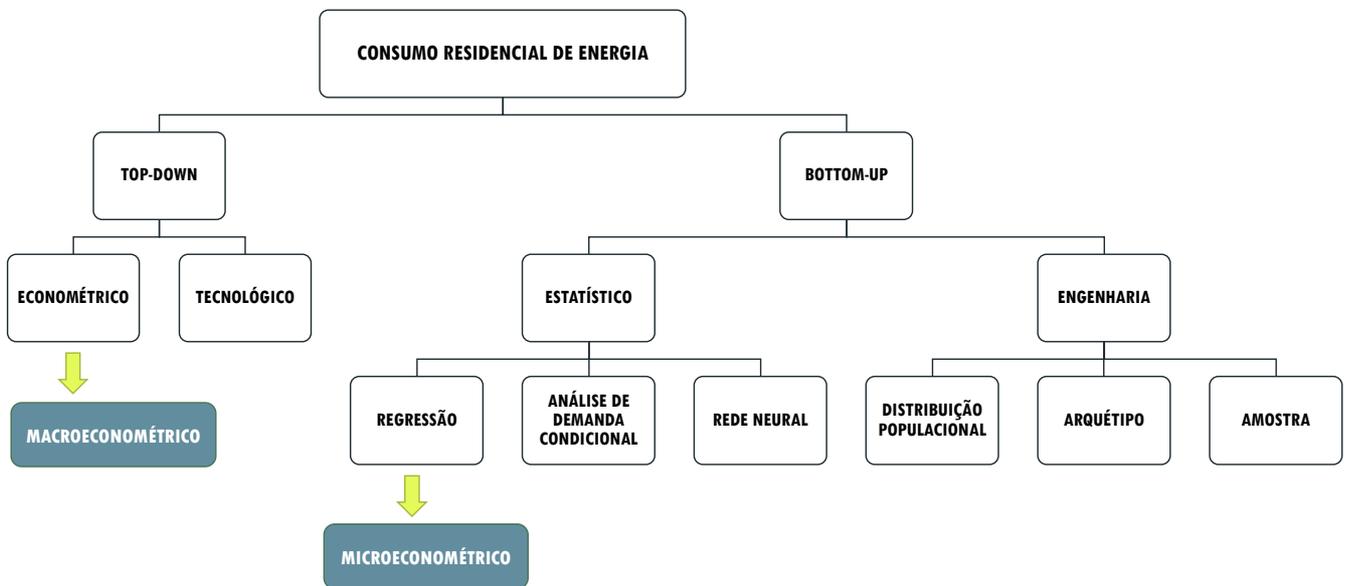


Figura 4. Técnicas de modelagem *top-down* e *bottom-up* para estimar o consumo regional ou nacional de energia residencial

Fonte: Elaboração própria com base em SWAN & UGURSAL [74]

Falando especificamente de modelos econométricos, enquanto modelos econométricos *top-down*, também conhecido como **macroeconométricos**, aplicam estatística e matemática com base na teoria econômica para prever resultados específicos, modelos de regressão/estatísticos *bottom-up*, ou chamados de **microeconométricos**, têm sido tradicionalmente usadas para prever o consumo de energia de todo o edifício ou de uso final, desenvolvendo correlações entre esses resultados e os principais parâmetros (intercepto mais coeficientes angulares) de entrada [74].

Os modelos microeconômicos diferem dos modelos macroeconômicos, pois permitem estudos microeconômicos com maior nível de detalhes e frequentemente cobrem as interações entre famílias, indivíduos e organizações [73]. O foco desta tese está voltado aos modelos microeconômicos.

A microeconometria diz respeito à análise do comportamento econômico de indivíduos, famílias ou empresas em nível individual de dados: os chamados microdados. Esse tipo de análise geralmente envolve a aplicação de métodos de regressão com modelagem de dados de corte transversal, que são mais detalhados no **Capítulo 3**, e dados em painel [75,76].

A análise de dados individuais tem uma longa história, mas a microeconometria moderna – baseada em dados individuais de domicílios ou estabelecimentos comerciais – teve grande reconhecimento no século XX, culminando com a concessão do Prêmio Nobel de Economia do ano 2000 a James Heckman e Daniel McFadden por suas contribuições à disciplina. A subdisciplina, reconhecida a partir da década de 1950, deve muito à maior disponibilidade de dados de pesquisas transversais e de amostras longitudinais e dados de censo. Nas últimas duas décadas, com a expansão do registro eletrônico e da coleta de dados no nível individual, houve um crescimento muito expressivo no volume de dados. O mesmo aconteceu com a capacidade computacional de analisar conjuntos de dados grandes e complexos. O processamento e a análise estatística dessa extensa base de microdados, que têm como objetivo descobrir padrões de comportamento econômico, constituem o núcleo da microeconometria [75].

A primeira e mais óbvia diferença entre a micro e macroeconometria se refere ao alto nível de desagregação dos dados microeconômicos. Isso tem uma consequência significativa para as formas funcionais usadas para analisar as variáveis de interesse. Mais fundamentalmente, a desagregação traz à tona a heterogeneidade de indivíduos, firmas e organizações, que devem ser controladas (modeladas) de maneira adequada caso se queira fazer inferências válidas sobre os relacionamentos subjacentes [75].

Em contraponto, a macroeconometria é usualmente baseada em suposições mais fortes: a hipótese do agente representativo é um exemplo marcante. Um apelo frequente é feito ao raciocínio microeconômico para justificar determinadas especificações e interpretações de resultados empíricos. No entanto, raramente é possível dizer explicitamente como eles são afetados pela agregação ao longo do tempo e espaço

(microunidades). Como alternativa, são feitas suposições de agregação muito extremas. Por exemplo, considera-se que os dados agregados refletem o comportamento de um agente representativo hipotético, mas essas suposições tampouco são confiáveis [21,75,77]. O uso de dados microeconômicos permite captar comportamentos individuais relevantes não capturados por estudos macro [78].

Finalmente, um retrato realístico da atividade econômica deve acomodar uma ampla gama de resultados e respostas que são consequência da heterogeneidade individual e previstos pela teoria subjacente. Nesse sentido, conjuntos de microdados são capazes de suportar modelos mais realistas. Os dados microeconômicos são frequentemente derivados de pesquisas domiciliares ou empresariais, geralmente abrangendo uma ampla gama de comportamentos, com muitos dos resultados comportamentais assumindo a forma de respostas discretas (conhecidas também como categóricas, ordinais, qualitativas ou binárias). Esses conjuntos de dados têm muitas características estranhas que requerem ferramentas especiais na formulação e análise que, embora não totalmente ausentes do trabalho macroeconômico, são menos amplamente utilizadas [75].

As vantagens potenciais dos conjuntos de microdados podem ser percebidas se tais dados forem elucidativos. Como as pesquisas por amostragem geralmente fornecem observações independentes em milhares de unidades transversais, esses dados são considerados mais informativos do que o padrão, em geral altamente correlacionado em série, em que macrosséries temporais geralmente consistem em no máximo algumas centenas de observações [75].

Os benefícios da desagregação, que foram enfatizados anteriormente, têm um custo: à medida que os dados se tornam mais desagregados, aumenta a importância de controlar a heterogeneidade interindividual. A heterogeneidade desempenha um papel muito importante na microeconometria. Obviamente, muitas variáveis que refletem a heterogeneidade interindividual, como gênero, raça, escolaridade e fatores sociais e demográficos, são apuradas diretamente e, portanto, podem ser controladas através de variáveis sociodemográficas. Em contraste, as diferenças na motivação individual, capacidade, inteligência e assim por diante não são observadas ou, na melhor das hipóteses, imperfeitamente observadas em variáveis psicográficas [75]. Como colocado por MAZZONE *et al.* [67] e já comentado anteriormente, é importante analisar fatores

socioculturais além das tradicionais variáveis relacionadas ao nível de educação e gênero. No entanto, há um grande desafio na modelagem de tais variáveis (por exemplo, religiões, normas e crenças locais, identidade étnica, práticas familiares etc.), uma vez que, em grande parte, elas também não são observadas. Dentre as limitações apresentadas pelos microdados, o problema da heterogeneidade é o mais significativo [79].

A saída mais simples é ignorar tal heterogeneidade não-observada, isto é, absorvê-la no distúrbio de regressão. Afinal, é assim que tratamos a miríade de pequenos fatores não-observados. Essa etapa, é claro, aumenta a parte inexplicada da variação. Além disso, ignorar diferenças interindividuais persistentes acarreta confusão quando as contribuições individuais de diferentes regressores (variáveis explanatórias) à variação da variável de interesse não podem ser estatisticamente separadas. Suponha que se diga, por exemplo, que o fator x_1 (escolaridade) é a fonte de variação em y (rendimentos), enquanto outra variável x_2 (habilidade) não aparece no modelo. Então a parcela da variação total atribuível à segunda variável pode ser incorretamente atribuída à primeira. Intuitivamente, suas importâncias relativas são confundidas. Uma das principais fontes de *bias* (viés) é a omissão incorreta de regressores do modelo e a inclusão de outras variáveis que são *proxies* da variável omitida [75].

A solução mais extrema, de ignorar todas as diferenças interindividuais não-observadas, não causará os problemas mencionados, caso algumas premissas sejam mantidas. Isso depende de a heterogeneidade não-observada não estar correlacionada com a heterogeneidade observada, e o resultado em estudo não possuir dependência intertemporal. Contudo, essas são suposições fortes e que não eliminam as dificuldades econométricas [75].

Existem algumas abordagens disponíveis para lidar com o problema da heterogeneidade em dados microeconômicos. Uma alternativa é modelar a heterogeneidade observada por meio de **variáveis binárias**. Outra possibilidade é modelar a heterogeneidade não-observada como um **efeito fixo** ou como um **efeito aleatório**. Tais opções dependem da natureza dos microdados disponíveis para os modelos econométricos. A opção por meio de variáveis binárias é um passo importante para a modelagem da heterogeneidade e é abordada no capítulo metodológico. Contudo, antes disso, abordaremos as diferentes fontes e formas de heterogeneidade, destacando a socioeconômica e a climática, respectivamente, nas seções **2.3** e **2.4** a seguir.

2.3 O crescimento econômico e a heterogeneidade socioeconômica

O crescimento da população, o aumento da prosperidade econômica, a classe média em expansão e o padrão de vida das pessoas mais ricas do mundo têm impulsionado o rápido aumento do uso de energia nas últimas décadas. Porém, mesmo com a aceleração no uso total de energia, há grande variação *per capita* (até um fator de 10) no uso final dentre as principais regiões do mundo (**Figura 5**). Considerando uma base individual, essa variação é da mesma ordem de magnitude que a disparidade na distribuição de renda global [80].

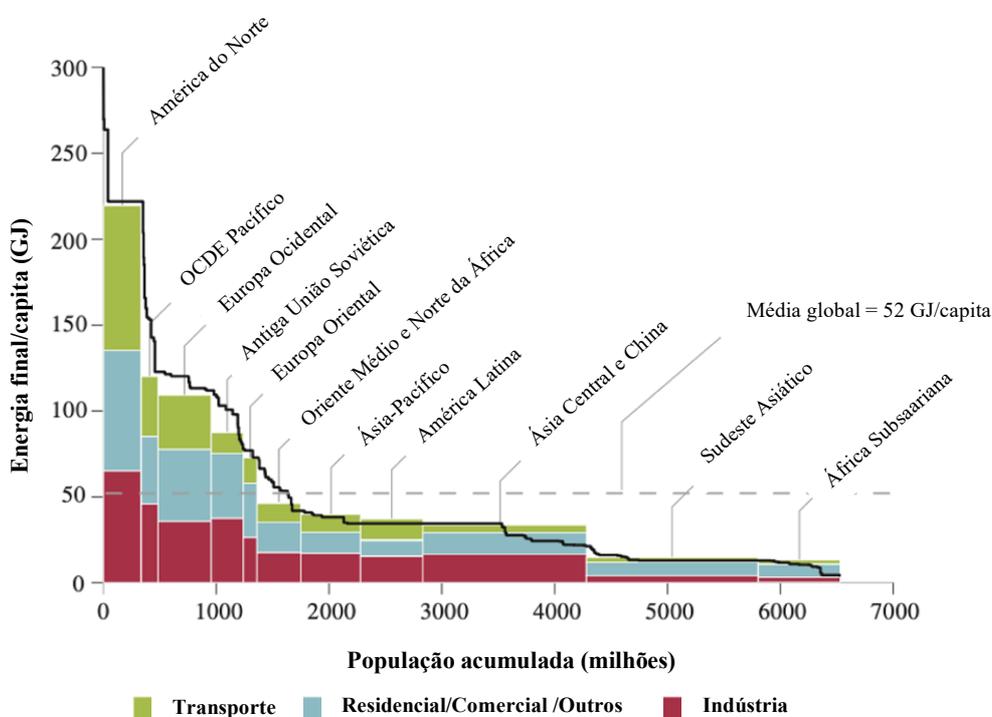


Figura 5. Energia final *per capita* versus população acumulada para 11 regiões do mundo, considerando 137 países, em ordem decrescente de uso de energia *per capita* de acordo com diferentes setores em 2005 (GJ)

Fonte: Adaptado de JOHANSSON *et al.* [80]

À medida que as nações em desenvolvimento saem da pobreza para a riqueza relativa, e a fração da população urbana cresce mais rápido do que o crescimento populacional geral, são esperados impactos substanciais no nível e na qualidade da demanda de energia. Conforme as economias se desenvolvem e se tornam mais

igualitárias, as necessidades e prioridades de energia dos países mudam. Como resultado, e como foi o caso do século passado, a renda global provavelmente aumentará muito mais rapidamente do que a população. Na verdade, a estabilização da população mundial tem se mostrado um resultado direto do aumento da prosperidade. Assim, a segurança energética global e a sustentabilidade no século XXI dependerão mais da renda e de sua distribuição do que da população global [8].

Com base em evidências empíricas, FOUQUET [7] mostra que a trajetória de evolução da demanda energética é alterada de acordo com diferentes estágios de desenvolvimento econômico de um país. A demanda por energia aumenta rapidamente nos estágios iniciais do desenvolvimento econômico, à medida que uma economia evolui de economia agrária a industrial, com um aumento associado nas atividades de mineração e manufatura. A industrialização também está associada a um rápido aumento da demanda por aquecimento e transporte de mercadorias. À medida que a economia industrializada amadurece, a demanda por energia do setor industrial continua a crescer em termos absolutos, mas diminui em relação aos setores doméstico e de serviços, em parte porque as importações intensivas em energia são substituídas pela produção doméstica (vide **Figura 5**) [7].

Assim, à medida que a economia industrializada amadurece, a demanda domiciliar por energia continua a crescer em termos absolutos e aumenta com a renda disponível devido ao aumento da demanda por conforto térmico, aquecimento da água e transporte individual. Especificamente no setor residencial, esse aumento tem sido atrelado a uma maior posse de eletrodomésticos [8]. Na medida em que a população enriquece, parte de sua demanda latente de energia passa a ser suprida.

Embora seja de se esperar que a demanda por energia atinja um ponto de saturação em altos níveis de desenvolvimento, as evidências disponíveis até o momento sugerem que, se novas tecnologias mais eficientes reduzirem a quantidade de energia necessária para operar aparelhos e equipamentos, a redução de custos implícita frequentemente serve, *ceteris paribus*, para estimular atividades dependentes de energia adicionais. Isso é conhecido como **efeito bumerangue** e surge porque as melhorias na eficiência energética reduzem efetivamente o custo dos serviços de energia, levando a uma renda disponível adicional e, portanto, aumentando potencialmente a demanda [8].

Apesar das flutuações no crescimento econômico global, principalmente em anos mais recentes, na primeira década do milênio, alguns países foram líderes consistentes do crescimento econômico regional¹⁰. Conseqüentemente, a dinâmica e a influência desses países – particularmente África do Sul, Brasil, China e Índia –, serão críticas para moldar não apenas o novo mundo em desenvolvimento, mas também as tendências energética, econômica e de mitigação do clima [8]. As enormes necessidades de investimento em infraestrutura energética por parte desses países nas próximas décadas proporcionarão uma janela única de oportunidade para o desenvolvimento de energia sustentável e com baixo teor de carbono. Ao mesmo tempo, continuarão a enfrentar os desafios de sustentar o crescimento econômico e eliminar a pobreza [8].

Tendo esse contexto em vista, o grande debate na literatura sobre o crescimento da demanda de energia esteve focado – nas últimas décadas – em um melhor entendimento sobre impactos da erradicação da pobreza e enriquecimento da população (*growing affluence*) dos países em desenvolvimento. Tais países são caracterizados por alto nível de heterogeneidade socioeconômica intra-regional.

Há um amplo debate sobre como o aumento da renda entre os mais pobres do mundo irá impactar o consumo de energia e as emissões de carbono [81]. Existem muitas incertezas e riscos envolvendo o consumo energético, alguns associados ao desenvolvimento econômico [82].

Nesse âmbito, diversos estudos têm levantado as seguintes questões: em um mundo de pobreza persistente, qual será o impacto, na demanda de energia, de um levantar global a um padrão de vida adequado? Devemos nos preocupar com os impactos da erradicação da pobreza na demanda de energia e emissões de GEE, ou o grande impulsionador de demanda é na verdade o enriquecimento da classe média? Como as emissões de carbono associadas a esse "desenvolvimento humano sustentável" se comparam ao orçamento de emissões disponível, se quisermos estabilizar a mudança climática em níveis relacionados ao alvo de 2° C [83-87]?

A posse de eletrodomésticos e equipamentos determina a demanda por eletricidade e combustível em residências ao redor do globo [19]. Estudos como os de WOLFRAM *et al.* [88], AUFFHAMMER & WOLFRAM [89] e GERTLER *et al.* [48]

¹⁰ Definidos como grandes economias emergentes com impactos globais sobre os balanços de oferta e demanda [8].

sugerem que, à medida que a renda dos pobres aumenta e eles passam a comprar eletrodomésticos pela primeira vez, sua demanda por eletricidade tende a aumentar substancialmente ao longo da **margem extensiva**, isto é a forma como o consumo energético aumenta devido ao aumento na posse de equipamentos/eletrodomésticos [90].

No entanto, evidências recentes de outros estudos [58,91,92] sugerem que a difusão de aparelhos pode permanecer baixa, apesar do aumento da renda, se os aparelhos forem muito caros ou se o fornecimento de eletricidade não for confiável. Ou seja, ainda não há um consenso na literatura sobre os impactos da **demand latente** de energia de populações pobres. Além disso, essa demanda reprimida raramente é estimada por causa dos desafios envolvidos em fazê-lo [19].

Mesmo antes da pandemia da Covid-19, que evidenciou ainda mais as desigualdades, já crescia a preocupação de que a sociedade global estava em uma trajetória de afastamento da estabilidade climática, da justiça social¹¹ e da sustentabilidade ambiental [93]. Os Objetivos de Desenvolvimento do Milênio – ODM¹² tentaram amenizar essa preocupação no início do milênio, tentativa fortalecida em 2015, com a criação da Agenda 2030 para o Desenvolvimento Sustentável e a adoção dos 17 Objetivos de Desenvolvimento Sustentável (ODS)¹³ por todos os Estados-Membros das Nações Unidas – **Figura 6**. A Agenda Universal estabelece objetivos ambiciosos para acelerar o ritmo do desenvolvimento humano básico [94] e reconhece que “a erradicação da pobreza em todas as suas formas e dimensões, incluindo a pobreza

¹¹ A teoria da justiça social guarnece raízes para a pesquisa sobre as justiças energética e ambiental. Assim, as justiças social, energética e ambiental conectam os mais antigos conceitos das ciências sociais e da filosofia, incluindo ética, equidade e moralidade. Em uma visão geral, busca garantir que os benefícios e custos dos serviços energéticos sejam disseminados de forma justa, apoiados por tomadas de decisão representativas e imparciais. Dessa forma, assume-se um conjunto de princípios que asseguram que nenhum grupo de indivíduos, sejam grupos étnicos, raciais ou de classe, suporte uma parcela desproporcional de degradação do bem comum, além de garantir o acesso igualitário de recursos energéticos e ambientais. Dentre os princípios básicos podem ser citados: acessibilidade (*affordability*); transparência e *accountability*; sustentabilidade; equidade intra-geracional; equidade intergeracional; e responsabilidade [93,270,271].

¹² São oito metas do milênio estabelecidas pela Organização das Nações Unidas (ONU) em 2000, com o apoio de 191 nações [272].

¹³ São 17 ODSs e 169 metas que demonstram a escala e a ambição da nova Agenda Universal. Eles se constroem sobre o legado dos Objetivos de Desenvolvimento do Milênio (ODM). São integrados e indivisíveis e equilibram as três dimensões do desenvolvimento sustentável: a econômica, a social e a ambiental. Foram aprovados por unanimidade pelas Nações Unidas e aspiram a um mundo de educação universal, saúde e emprego com crescimento econômico inclusivo, livre de fome, injustiça e pobreza absoluta, baseado na transparência, dignidade e equidade, tudo alcançado dentro dos limites do planeta [95].

extrema, é o maior desafio global e um requisito indispensável para o desenvolvimento sustentável” [95] (p.1).



Figura 6. Os 17 Objetivos do Desenvolvimento Sustentável (ODS)

Fonte: Adaptado de UFMS [96]

Desde o início da década de 1990, o Banco Mundial (*World Bank*) monitora a extrema pobreza em nível global através da chamada “*International Poverty Line – IPL*” ou, em português, linha internacional da pobreza, mais recentemente denominada “pobreza global” [97-100]. Apesar da mudança nos métodos utilizados para medir a pobreza global ao longo do tempo, o princípio orientador se manteve o mesmo: refletir a forma com que os países mais pobres do mundo estimam um limiar mínimo de vida que atenda às necessidades básicas em suas sociedades [97].

O lançamento em 2014 de um novo conjunto de fatores de conversão de Paridade de Poder de Compra – PPC¹⁴ (*Purchasing Power Parity – PPP*) para o ano de 2011 provocou uma revisão da IPL do Banco Mundial. FERREIRA *et al.* [97] afirmam que essa revisão buscou minimizar as mudanças no poder de compra real da linha anterior de USD 1,25 PPC₂₀₀₅/pessoa/dia, com a intenção de preservar a integridade dos propósitos relacionados à erradicação da pobreza, tanto para os objetivos internacionais, como para os ODS e os objetivos do Banco Mundial, que foram definidos em relação a essa linha. Em conclusão, a nova linha internacional de pobreza é de USD 1,90 PPC₂₀₁₁/pessoa/dia. Apesar da definição da nova IPL e do forte enfoque

¹⁴ Paridade de Poder de Compra (PPC) é “utilizada para comparar o poder de compra entre diferentes países, ou moedas, e é utilizada como alternativa à taxa de câmbio, que, em geral varia com mudanças nos índices de preços e mesmo a volatilidade do mercado de capitais e especulação. O fator de conversão de PPC é o número de unidades da moeda de um país necessárias para comprar a mesma quantidade de bens e serviços no mercado interno como dólares comprariam nos Estados Unidos” [101] (p. 57).

político para acabar com a extrema pobreza globalmente, segundo FERREIRA *et al* [97], a definição e a medida da pobreza continuam sendo empreendimentos desafiadores, sujeitos a muito debate sobre os conceitos, métodos e dados mais apropriados. O centro desse debate se dá em como comparar os padrões de vida de povos amplamente diferentes, que consomem bens e serviços muito distintos, todos com preços contados em diferentes moedas. Um dos desafios é definir um limiar comum (ou linha de pobreza) que representa o mesmo padrão de vida, em todos os países e ao longo do tempo, abaixo do qual uma pessoa é considerada pobre [97].

Deste modo, existem diversos critérios para construção de linha de pobreza que variam de acordo com os objetivos dos estudos, e a linha de pobreza definida pelo Banco Mundial é apenas uma das opções. Segundo IGBE [101], as linhas de pobreza podem ser absolutas, sendo definidas a partir de um valor específico, ou linhas relativas – mais utilizadas em países desenvolvidos –, resultado de uma proporção.

JOLLIFFE & PRYDZ [102] argumentam que a IPL de USD 1,90 PPC₂₀₁₁/pessoa/dia é típica de países classificados como baixa-renda (*low-income*), mas ela não é absolutamente verdade quando analisamos países com padrão de renda mais elevados. Levando esses fatores em consideração, desde outubro de 2017 o Banco Mundial passou a reportar três linhas adicionais de pobreza: uma ILP de “*lower-middle-income country*” (país de renda média-baixa), fixada em USD 3,20 PPC₂₀₁₁/pessoa/dia; outra ILP de “*upper-middle-income country*” (país de renda média-alta), fixada em USD 5,50 PPC₂₀₁₁/pessoa/dia; e por fim, uma ILP de “*high-income country*” (país de renda alta), fixada em USD 21,70 PPC₂₀₁₁/pessoa/dia (**Figura 7**). Contudo, é preciso deixar claro que a linha internacional da pobreza considerada oficial permanece a de USD 1,90 PPC₂₀₁₁/pessoa/dia [103].

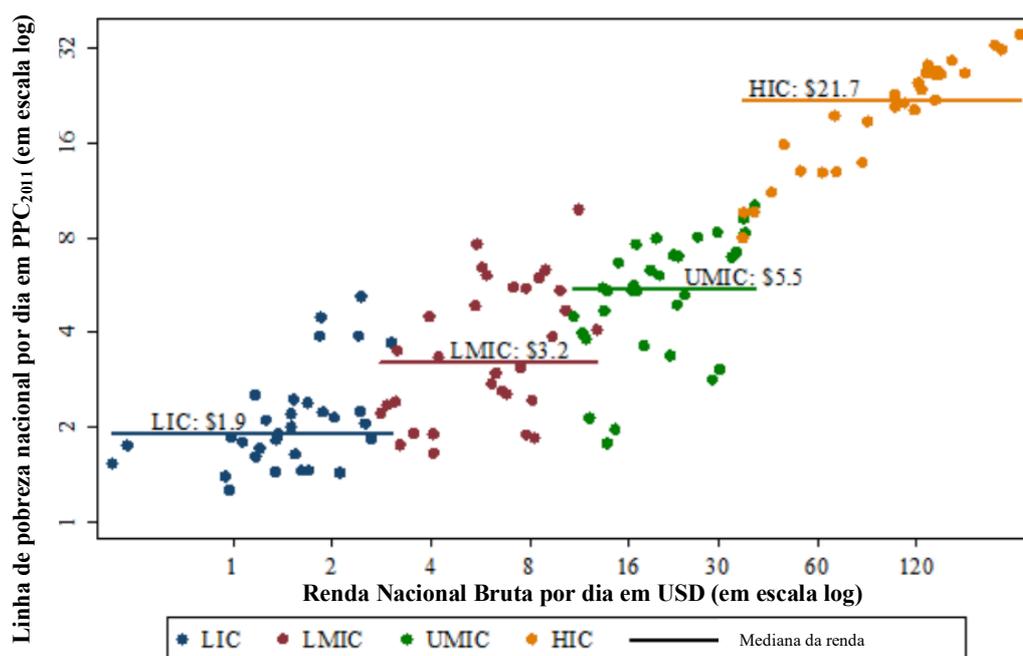


Figura 7. As linhas de pobreza do Banco Mundial de acordo com o nível de renda de cada país

Fonte: Adaptado de FERREIRA *et al.* [97]

Nota: A classificações dos países é feita com base no Rendimento Nacional Bruto – RNB (*Gross National Income – GNI per capita*) em USD [104]. Significado das siglas: *LIC* (*low-income country*); *LMIC* (*lower-middle-income country*); *UMIC* (*upper-middle-income country*); e *HIC* (*high-income country*).

Isso posto, como já comentado anteriormente, o Brasil foi apontado na década passada como um dos líderes mundiais no crescimento econômico regional [8] e parecia estar no caminho de alcançar a ODS 1 – erradicar a pobreza até 2030. No entanto, como será melhor abordado a frente, essa conquista está cada vez mais distante.

O progresso do Brasil na redução das disparidades sociais foi notável entre 2003-2014 [50]. Alguns fatores impulsionaram a ascensão social brasileira, dentre os quais podemos destacar: *boom* do preço internacional das *commodities* no mesmo período¹⁵; melhora nos termos de troca; queda na taxa de desemprego; aumento da renda do trabalho; políticas de valorização do salário-mínimo; e programas públicos de proteção

¹⁵ A alta demanda por *commodities* por países emergentes como China e Índia no início do milênio levou à valorização do seu preço no mercado internacional e à expansão do setor de *commodities*. O setor passou a atrair mão de obra não especializada, o que elevou a renda do trabalho e reduziu a taxa de desemprego. A alta oferta de emprego acabou se espalhando em outros setores, como o de construção. Concomitantemente, as receitas públicas aumentaram, o que apoiou a elevação do investimento público e estimulou a geração de empregos.

social, com destaque para o Benefício de Prestação Continuada (BPC) e o **Bolsa Família (BF)**¹⁶.

Como é possível observar pela **Figura 8**, antes de 2003 o número de pessoas pobres e extremamente pobres no Brasil era alto e não conseguia manter uma trajetória decrescente constante. A partir de 2003, houve uma redução significativa e constante do número de pessoas em situação de pobreza e extrema pobreza. A queda foi intensificada a partir de 2006 com a implementação do BF, atingindo os menores valores históricos em 2014 [101]. Assim, até 2014, o Brasil foi exitoso e atingiu antecipadamente os ODMs de reduzir a fome e a pobreza [105].

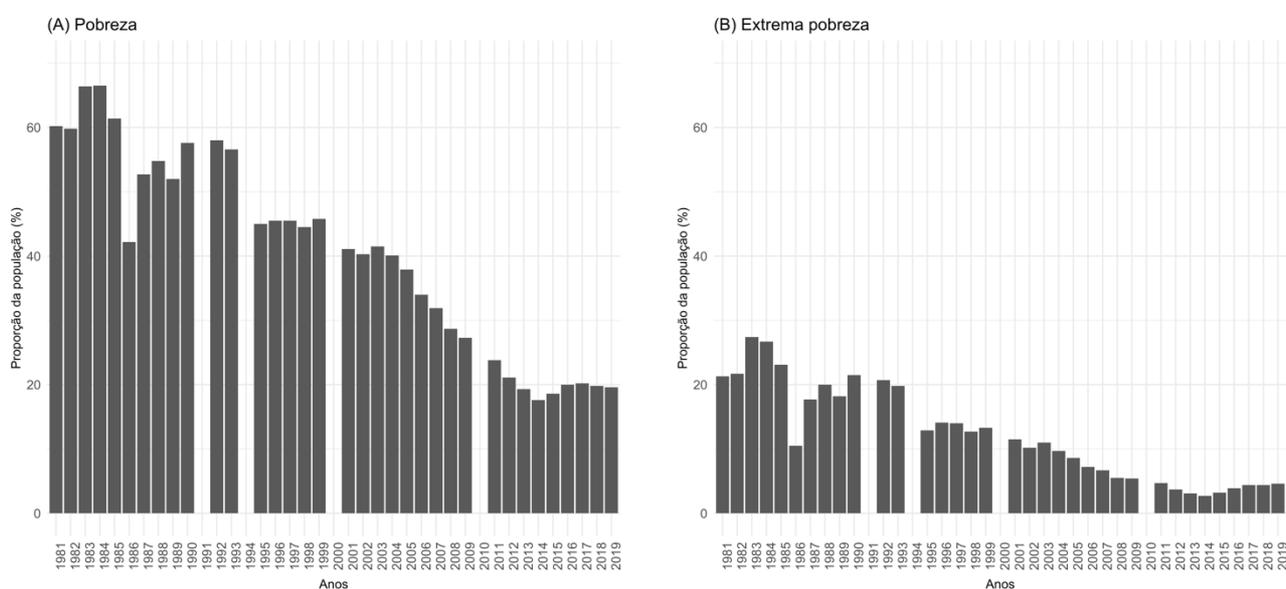


Figura 8. Evolução da pobreza e extrema pobreza no Brasil no período 1981-2019 (% da população brasileira)

Fonte: Elaboração própria com base em Banco Mundial [106]

Nota: Percentuais calculados para o Brasil com base nas linhas de pobreza definida pelo Banco Mundial. Pobreza = USD 5,50 PPC₂₀₁₁/pessoa/dia; e Extrema pobreza = USD 1,90 PPC₂₀₁₁/pessoa/dia.

¹⁶ O BF é um programa de transferência direta de renda do governo federal com o objetivo de eliminar a pobreza extrema e a má nutrição, e garantir o mínimo de serviços sociais, como saúde e educação. Os principais objetivos do BF são [273]: (i) combater a fome e promover a segurança alimentar e nutricional; (ii) combater a pobreza e outras formas de privação; e (iii) promover o acesso aos serviços públicos, especialmente saúde, educação e assistência social. O programa apoia famílias com crianças que vivem abaixo da linha da pobreza em diferentes graus, dependendo de sua situação. Cada família recebe um cartão eletrônico da CAIXA, onde o valor do benefício é repassado mensalmente. Atualmente, os valores variam entre R\$ 89 mensais, na categoria de “Benefício Básico”, até R\$ 205,00 na modalidade de “Benefício Variável” [273] (para mais detalhes ver MAZZONE *et al.* [268]).

No entanto, grandes retrocessos têm sido observados desde o final de 2014, devido principalmente à crise econômica em curso e aos cortes governamentais nas políticas sociais, resultando em um aumento da disparidade socioeconômica e no retorno à pobreza e à extrema pobreza de milhões de famílias, observado nos últimos anos da série histórica da **Figura 8** [26,27]. Muitos programas e ações da área social, que vinham contribuindo para a redução das desigualdades, sofreram cortes orçamentários drásticos ou foram descontinuados, e houve grande aumento da informalidade, com mais da metade da população trabalhando no setor de serviços. Seguir esse caminho, sem reorientar o modelo de desenvolvimento para um projeto efetivamente social, econômico e ambientalmente sustentável, não permitirá que o Brasil cumpra seu compromisso referente ao ODS-1 [105].

Segundo ROCHA [107], a queda da pobreza entre 2003-2014 foi acompanhada pela piora da desigualdade entre os pobres em dois aspectos críticos. Primeiramente o regional, refletindo uma maior desigualdade entre as cinco regiões do Brasil; segundo sob o aspecto etário, uma vez que a redução da pobreza não acarretou um benefício primordial às crianças.

Contudo, enfrentar a extrema pobreza e a pobreza no Brasil, Meta 1.1¹⁷ do ODS 1, passa obrigatoriamente por enfrentar as desigualdades – raciais e étnicas, de gênero e regionais, etárias, entre outras – que se abrigam em diversas modalidades da pobreza [105]. Da mesma forma, combater as desigualdades resulta em benefícios conjuntos sobre bem-estar social e pobreza [27].

O nível de desigualdade de renda é exposto na **Figura 9**, que apresenta a **Curva de Lorenz**¹⁸ para três anos recentes. De acordo com a curva apresentada, 10% da

¹⁷ Meta 1.1: Até 2030, erradicar a pobreza extrema (menos de USD 1,25 PPC₂₀₀₅/pessoa/dia ou menos de USD 1,90 PPC₂₀₁₁/pessoa/dia) para todas as pessoas em todos os lugares.

¹⁸ “Desenvolvida, em 1905, pelo economista americano Max O. Lorenz, a Curva de Lorenz é, até os dias atuais, o gráfico mais utilizado para representar a distribuição de rendimentos em uma determinada população. É construída a partir da ordenação dos rendimentos, do menor para o maior, e ilustra a proporção de rendimentos (eixo x) recebida por cada proporção de população (eixo y). Assim, se 10% do total de rendimentos correspondesse a 10% do total da população, 20% dos rendimentos correspondessem a 20% da população e assim por diante, seria possível concluir que o total de rendimentos estaria equitativamente distribuído entre as pessoas. Em uma representação gráfica, a reta de 45° corresponde a essa distribuição perfeitamente equitativa e a Curva de Lorenz, situada abaixo, representa a distribuição real observada. De uma forma geral, aos mais pobres correspondem parcelas bem inferiores àqueles com maiores rendimentos e, quanto mais a curva se afasta da reta de equidade da distribuição, mais desigual é a distribuição de rendimentos observada” [108] (p. 50).

população brasileira com menores rendimentos domiciliares *per capita* recebem parcela de 0,8% do total de rendimentos em 2019. Em comparação, metade dos brasileiros retém 15,6% dos rendimentos observados no mesmo ano, cabendo aos 10% da população mais rica 42,9% de todo o rendimento recebido pelas pessoas [108]. O padrão de 2019, ano mais recente disponível, é muito similar ao observado em 2012, o que demonstra a falta de avanço no combate à desigualdade de renda na última década. O Brasil segue como um dos países mais desiguais do mundo.

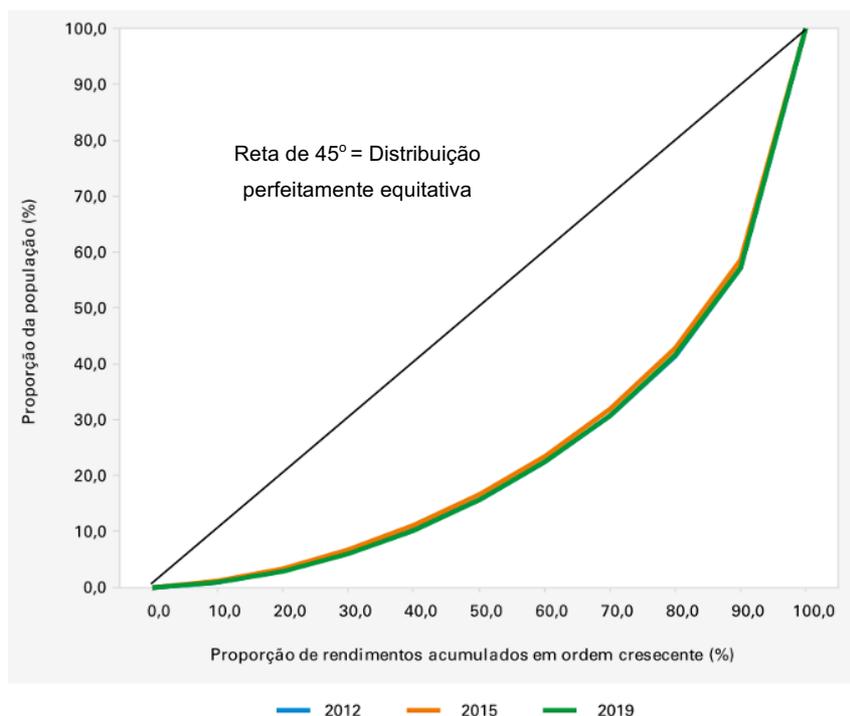


Figura 9. Curva de Lorenz para o Brasil nos anos 2012, 2015 e 2019

Fonte: Adaptado de IBGE [108]

O Brasil foi classificado como a segunda pior concentração de renda do mundo, atrás apenas do Catar. O que significa que, no Brasil, a parcela 1% mais rica concentra 28,3% da renda total do país (no Catar, essa proporção é de 29%). Ou seja, quase um terço da renda está nas mãos dos mais ricos [30]. Assim, nos últimos anos, o país passou de um crescimento inclusivo para uma recessão em que um grupo da sociedade está arcando com o fardo, e outro não é afetado ou está em melhor situação [27].

Para mais, houve piora em relação aos indicadores sintéticos utilizados como *proxy* do nível de desigualdade de rendimentos. Tanto o **Índice de Gini**¹⁹ (medida mais popular de desigualdade) como o **Índice de Desenvolvimento Humano – IDH** (ou HDI, do inglês *Human Development Index*) pioraram nos anos recentes [27]. De acordo com o **Coefficiente de Gini**, o Brasil figura atualmente entre os 10 países com maior desigualdade de renda no mundo [28,29] e foi classificado em 79º no IDH, atingindo o valor de 0,761 em 2018 [30].

De acordo com NERI [27], a piora na desigualdade de renda começou no quarto trimestre de 2014 e sofreu aumentos trimestrais ininterruptos até o segundo trimestre de 2019. O movimento de concentração de renda durou 17 trimestres consecutivos, ou seja, quatro anos de aumento consecutivo de desigualdade, recorde de duração nas séries históricas brasileiras. Nem mesmo em 1989, que constitui o pico histórico de desigualdade brasileira, houve um movimento de concentração de renda por tantos períodos consecutivos. Consequentemente, houve também a queda da equidade²⁰ [27].

O mapa da **Figura 10** mostra que o Brasil apresenta não só um alto nível de desigualdade econômica inter-regional de acordo com o Índice de Gini, mas também um alto nível de heterogeneidade socioeconômica intra-regional, considerando as Unidades da Federação (estados mais Distrito Federal).

¹⁹ “A partir da Curva de Lorenz se constrói um dos mais conhecidos indicadores de desigualdade de rendimentos, o coeficiente ou índice de Gini. Seu valor corresponde justamente ao tamanho da área delimitada pela reta de distribuição equitativa (45°) e a curva de distribuição de rendimentos observada (Lorenz). Quanto maior essa área, maior a desigualdade e o Gini, que varia de 0 (perfeita igualdade) a 1 (desigualdade máxima, situação em que um indivíduo receberia toda a renda de uma economia). A construção do indicador para rendimentos prevê, portanto, a utilização de toda informação disponível de uma população, considerando a distribuição como um todo e sintetizando-a em um único valor” [108] (p. 51).

²⁰ “Bem Estar = Média (1- desigualdade). A formulação de Sen usa medida de desigualdade mais popular que é o Índice de Gini. Como o Índice de Gini varia entre 0 a 1 - uma sociedade perfeitamente igualitária onde todos são exatamente iguais e 1 uma sociedade onde uma só pessoa detém toda renda. O índice de equidade vai ser o inverso.” [27] (p. 6)

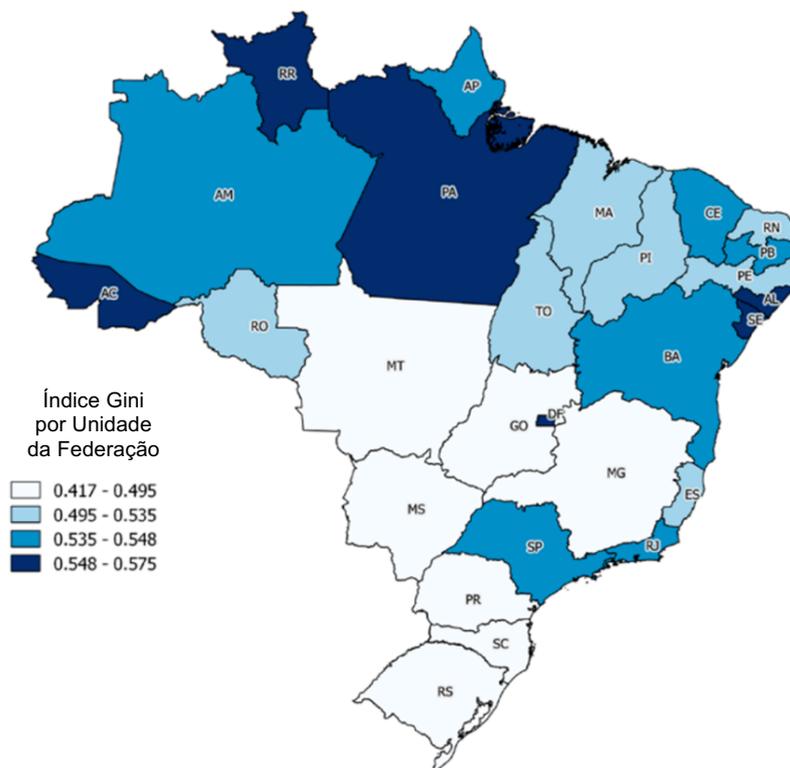


Figura 10. Índice de Gini da distribuição do rendimento mensal domiciliar *per capita* segundo Unidades da Federação (2018)

Fonte: Adaptado de IBGE [101]

A expectativa futura é de piora nesses indicadores sintéticos (desigualdade de rendimentos). Isso se dá porque uma recessão econômica prolongada – atualmente derivada da crise sanitária causada pela pandemia da Covid-19 – aumenta as desigualdades globais, já que aqueles com rendas mais baixas têm maior probabilidade de perder empregos, principalmente por causa da perda generalizada de empregos no setor informal, que responde por cerca de 70% dos empregos nos mercados emergentes e nas economias em desenvolvimento [109].

No Brasil, em 2019, 41,6% da população ativa, que representam 39,3 milhões de brasileiros, estavam no trabalho informal, ocupando uma de suas cinco modalidades de trabalho – empregado sem carteira, trabalhador doméstico sem carteira, conta própria não contribuinte, empregador não contribuinte ou trabalhador familiar auxiliar. Os resultados de 2019 em relação a 2018 mostram que a informalidade se manteve estável em proporção [108].

Devido ao nível de informalidade do mercado de trabalho brasileiro, o suporte financeiro do Governo Federal para trabalhadores informais, chamado de Auxílio Emergencial, foi fundamental para o não agravamento da crise econômica em 2020 [110]. O benefício forneceu valores entre R\$ 600 e R\$ 1.200 mensais e teve o objetivo de proporcionar proteção emergencial no período de enfrentamento à crise causada pela pandemia da Covid-19. Em julho de 2020, mês em que o efeito do benefício atingiu o seu ápice, a taxa de extrema pobreza do país foi reduzida a 2,4%, e, a de pobreza, a 20,3% [110-112].

Por outro lado, já no final de 2020, o chamado Auxílio Emergencial Extensão, com parcelas de R\$ 300 ou R\$ 600 mensais, não foi suficiente para conter os baixos níveis de pobreza. Em 2021, a expectativa é de que o Auxílio Emergencial 2021 (benefício financeiro destinado às pessoas que receberam Auxílio Emergencial e Auxílio Emergencial Extensão) não seja suficiente para conter o avanço da pobreza no país, devido ao baixo valor do novo benefício, entre R\$ 150 e R\$ 375 mensais [110]. Consequentemente, estudos projetam que a extrema pobreza atinja 9,1% da população e a pobreza chegue a 28,9% em 2021 [111,112].

Apesar desse contexto global de extrema desigualdade econômica, agravada pela pandemia da Covid-19, RAO *et al.* [21] argumentam que a maioria dos modelos atuais utilizados nas pesquisas climática e energética têm capacidade limitada de representar os pobres e vulneráveis, pois tais modelos são, em sua maioria, muito agregados para dar conta dessa heterogeneidade. Segundo os autores, eles raramente modelam distribuições de renda ou heterogeneidade de populações, o que resulta em resultados agregados que ignoram as desigualdades na sociedade. Em contraponto, o número estimado de pessoas no mundo que vivem em extrema pobreza tornou-se um indicador cada vez mais importante para medir o progresso do desenvolvimento [97].

Estudos anteriores focaram a atenção na estimativa de um modelo nacional único e agregado de demanda de eletricidade e na comparação de estimativas entre os países [24]. Assim, as projeções de demanda de eletricidade residencial para o planejamento do setor de energia em países em desenvolvimento geralmente envolvem suposições sobre o uso médio de eletricidade por consumidor ou estimam isso aplicando elasticidade de renda média constante das estimativas de demanda [19,113-117]. É preciso superar esse

tipo de abordagem e incorporar maiores níveis de heterogeneidade socioeconômica das famílias na modelagem da demanda [24].

Além disso, a grande maioria dos modelos de projeção de demanda de energia foi criada para países desenvolvidos e, por isso, acaba não levando em consideração características chave de países em desenvolvimento, como as mudanças estruturais e a divisão entre pobres/ricos e urbanos/rurais. Dentre as particularidades de países em desenvolvimento como o Brasil, também podemos citar a economia informal e o uso de biocombustíveis tradicionais [40,72,118].

O problema é que muitos desses modelos assumem que as demandas de energia dos países em desenvolvimento simplesmente seguirão, com algum atraso, as dos países desenvolvidos, o que na maioria dos casos não é verdade [72,118]. O pensamento atual é baseado na suposição de que todas as famílias em um determinado nível de renda teriam os mesmos eletrodomésticos. Mas essas suposições não foram validadas empiricamente de forma sistemática [58]. RAO & UMMEL [58] utilizam microdados de três economias emergentes – África do Sul, Brasil e Índia – e mostra que essa suposição simplifica demais a realidade.

Adicionalmente, como apontado por ABREU [40], a condição de pobreza não é um problema sistêmico e latente na maioria dos países desenvolvidos. Como demonstrado por GROTTERA *et al.* [119], em uma comparação entre Brasil e França, países em desenvolvimento possuem um consumo de eletricidade uniformemente distribuído entre decis de renda, reflexo indireto das condições de distribuição de renda dos mesmos. O oposto é observado em países em desenvolvimento.

Portanto, agregar e homogeneizar o comportamento de um grupo de diversos agentes heterogêneos pode nos impedir de compreender totalmente questões distributivas, como a pobreza, e levar a conclusões enganosas e, em última análise, a políticas climáticas injustas. Representar as desigualdades entre vários grupos (por exemplo, renda, idade, gênero, raça, nível de escolaridade ou tamanho da família) tornou-se uma parte essencial da literatura sobre mudanças climáticas, especialmente na busca por uma transição energética justa [77]. Assim, pesquisas que ajudem a compreender melhor a relação entre o consumo de energia e o bem-estar humano, para além da sua dimensão econômica, se fazem cada vez mais necessárias [85].

Isto posto, melhores práticas de representatividade precisam ser adotadas, assim como novas características de modelagem, que incorporem heterogeneidade social e diferentes mecanismos políticos, precisam ser desenvolvidas. Mais modelos devem ultrapassar a representação de efeitos regionais médios e passar a quantificar e projetar efeitos distributivos e suas complexidades dentro dos países [21], avançando para uma representação mais realista das escolhas de energia dos consumidores finais em modelos de sistemas de energia [23].

Ademais, modelos que já incorporam distribuições de renda, mas de forma estática, podem ampliar sua capacidade através da construção de cenários de convergência e divergência de renda futuras, tanto entre países quanto dentro dos países. Tais cenários podem consistir em suposições estilizadas, ou incorporar dinâmicas econômicas, na medida em que sejam viáveis [21].

No entanto, o primeiro passo é reconhecer a heterogeneidade como fator importante na análise do uso da energia residencial [120]. Dentro da heterogeneidade, os grupos de renda e as classes urbanas/rurais foram identificados como os mais estatisticamente significativos na determinação dos padrões de consumo de energia de uma família, a partir dos resultados do estudo de caso da Índia [13,121,122]. Cabe destacar que, em países em desenvolvimento, tais fatores socioeconômicos (grupos de renda e classes urbanas/rurais) são mais heterogêneos do que em países industrializados [77,122-124].

Existem diferentes formas de categorizar os grupos de renda. Estudos mais antigos costumavam classificar a renda das famílias de acordo com faixas salariais (por exemplo JANNUZZI & SCHIPPER [125], COHEN *et al.* [37] e ACHÃO & SCHAEFFER [126]). Devido à natureza exógena desse tipo de classificação, tal metodologia, comumente baseada em faixas de salário-mínimo, foi substituída por uma categorização baseada em quintis/decis de renda. Por ser uma metodologia endógena, a divisão dos domicílios por percentis tem como benefício a adoção de valores internos à distribuição de renda [40,127,128].

A metodologia de percentis é utilizada sob o argumento de que número de classes de renda e seus limites mudam regularmente, complicando a comparação ao longo do tempo e entre diferentes países. Alguns estudos [19,22,114,120,129], agrupam classes de

renda como quintis de despesas²¹, cada um contendo 20% da população. Os quintis ainda são classificados em rurais ou urbanos, chegando a um total de 10 grupos de consumidores. Nesses estudos, a metodologia criada para representar a heterogeneidade social – em suas análises da demanda de energia no setor residencial – começou sendo aplicada para o estudo de caso da Índia [22,129], sendo posteriormente adotada para outros países em desenvolvimento.

Dentre os estudos citados, o modelo residencial de demanda de energia que merece destaque é o MESSAGE-Access desenvolvido pelo IIASA (*International Institute for Applied Systems Analysis*). O modelo foi o primeiro a considerar a heterogeneidade nas escolhas de energia, agrupando as pessoas de acordo com seu nível de renda e separadamente para áreas urbanas e rurais. É frequentemente usado para avaliar os caminhos para alcançar o acesso universal à energia moderna para cozinhar [130].

A criação do MESSAGE-Access começou com EKHOLM *et al.* [22] e sofreu algumas modificações e melhorias ao longo dos anos. Algumas destas são encontradas em PACHAURI *et al.* [114,131] e CAMERON *et al.* [132]. A última versão do modelo é encontrada em POBLETE-CAZENAVE & PACHAURI [19], em que uma nova abordagem de estimativa estrutural baseada em simulação é desenvolvida para estimar a capacidade de resposta da demanda de eletricidade, considerando diferentes níveis de renda e outros fatores socioeconômicos. O modelo utiliza microdados de quatro países em desenvolvimento com realidades distintas: África do Sul, Gana, Guatemala e Índia. O Brasil ainda não foi incluído no modelo.

Apesar da importância do estudo de caso do Brasil no contexto abordado, ainda são poucos os trabalhos que analisam especificamente a demanda de energia das famílias brasileiras considerando sua heterogeneidade socioeconômica.

²¹ Os dados sobre a renda familiar raramente estão disponíveis nos países em desenvolvimento, pois muitas famílias pobres não pagam imposto sobre o rendimento, inúmeras atividades de subsistência não são monetizadas, e, durante as pesquisas, as pessoas geralmente escondem parte de sua renda [129]. Devido a essa dificuldade, a atividade econômica das famílias é frequentemente representada por despesas em vez de renda. Em baixos níveis de renda, as despesas das famílias podem ser assumidas como aproximadamente iguais a sua renda. No entanto, em níveis de renda mais altos, as famílias podem usar parte de sua renda para poupança, o que não se reflete diretamente nos dados de despesas [129]. Apesar dessa limitação, na maioria dos estudos as despesas monetárias totais são utilizadas como um *proxy* da renda.

COHEN *et al.* [37], TUDESCHINI *et al.* [133], SANTOS *et al.* [35] e ABREU [40] utilizam matrizes insumo-produtos para analisar o consumo direto e indireto de energia das famílias brasileiras.

JANNUZZI & SCHIPPER [125], COHEN *et al.* [37], ACHÃO & SCHAEFFER [126] utilizam faixas de salário-mínimo para representar a heterogeneidade econômica, enquanto SANCHES-PEREIRA *et al.* [134], TUDESCHINI [133], GROTTERA *et al.* [35], ABREU [40] classificam a renda de acordo com decis da população. No entanto, esses estudos não abordam outras fontes de heterogeneidade. Por outro lado, GHISI *et al.* [135], UHR *et al.* [136] e PEREIRA UHR *et al.* [34] focam em características além da renda, como demografia, tamanho da residência, idade do chefe da família, número de eletrodomésticos, etc., mas não realizam simulações de acordo com diferentes cenários. Na próxima seção, é adicionado mais um fator de importância na determinação da demanda e na questão da heterogeneidade, o clima.

2.4 A necessidade de adaptação à mudança do clima e a heterogeneidade climática

O impacto das mudanças climáticas no padrão de consumo é tópico importante do planejamento energético, uma vez que a demanda por energia, assim como o conforto térmico, são fortemente afetados pelas condições meteorológicas [4,6]. A mudança do clima através do aquecimento global impacta a demanda de energia das famílias de duas formas: (i) diretamente, através da necessidade de adaptação ao novo clima; e (ii) indiretamente, através da necessidade de mitigação das emissões de GEE. Apesar da importância das medidas de mitigação, este trabalho analisa os efeitos da adaptação das famílias ao novo clima.

A adaptação é uma opção crítica para lidar com a mudança do clima, pois alivia os danos climáticos residuais não evitados por medidas de redução de emissões de gases de efeito estufa (GEE) – medidas de mitigação do clima [5]. Segundo o relatório “*The Future of Cooling*” da IEA [2], o aquecimento global, por causar extremos de temperatura mais frequentes e um aumento de longo prazo na temperatura média global, aumentará a demanda por serviços de resfriamento e a energia necessária para fornecê-los. Assim, a necessidade de resfriamento será cada vez mais um impulsionador importante da demanda futura de energia, enquanto se espera que a necessidade de aquecimento diminua [137,138].

A demanda por energia em edifícios varia fortemente entre países e zonas climáticas. Essas diferenças resultam de múltiplos fatores, cuja evolução futura é incerta [139]. Além disso, muitos dos efeitos potenciais de cenários de mudanças climáticas no setor de edificações ainda não são bem conhecidos [140]. No entanto, há indicações na literatura que a demanda futura de energia provavelmente aumentará devido à mudança climática, mas a magnitude desse aumento ainda depende de muitas fontes de incerteza e interação [141].

Contudo, uma revisão bibliográfica realizada por COLELLI & CIAN [138], mostra que projeções futuras subestimam a demanda de energia do setor de edificações quando o uso de energia é impulsionado unicamente por fatores de renda e população e não por mudanças nas condições climáticas e, subsequentemente, pelas crescentes necessidades de adaptação. Em todos os estudos revisados pelos autores, a mudança climática em 2050, sob o *Representative Concentration Pathways* – RCP 4,5 e 8,5, induz uma variação percentual mediana de 80% a 90% da demanda de energia de um edifício para resfriamento e uma variação percentual mediana de -22% e -24% para aquecimento, levando a 10% a 13% de aumento quando o resfriamento e o aquecimento são combinados,

Consequentemente, olhando para o futuro, espera-se que a expansão na demanda energética seja impulsionada pelo consumo de energia para resfriamento ambiente [139], fazendo com que ações adaptativas consumam, em geral, quantidades extras de energia [5].

O consumo de eletricidade é particularmente relevante tanto do ponto de vista de adaptação às mudanças climáticas quanto de redução de emissões [142], pois a demanda de resfriamento é quase que inteiramente suprida por aparelhos elétricos – ventilador elétrico ou sistema de ar-condicionado (AC)²². Porém a difusão constante do AC residencial continua sendo um dos pontos cegos mais críticos no debate atual sobre energia [2,25].

Além disso, a crescente demanda por resfriamento ambiente em edificações – que mais do que triplicou entre 1990 e 2016 (**Figura 11**) – já está colocando enorme pressão

²² O AC é comum hoje em países que experimentam clima quente por pelo menos várias semanas ou meses do ano. Em países de clima frio, principalmente no hemisfério norte, o AC é simplesmente desnecessário na maioria das vezes, com ventiladores elétricos geralmente suficientes durante as ondas de calor [2].

sobre os sistemas elétricos de muitos países, além de aumentar as emissões. O aumento das cargas dos aparelhos de AC aumenta não apenas as necessidades gerais de energia, mas também a necessidade de capacidade de geração e distribuição para atender à demanda nos horários de pico, colocando ainda mais pressão no sistema elétrico. Em uma média global, o resfriamento ambiente foi responsável por cerca de 14% da demanda de pico em 2016 [2]. Com o aumento da população em áreas de alta temperatura, a demanda de eletricidade para maior uso de AC pode também levar a demandas extremas de pico de eletricidade [143].

Construir, manter e operar a capacidade de eletricidade para atender a essa demanda de pico é muito caro, porque corresponde apenas a períodos limitados, aumentando os custos gerais. Enquanto isso, as emissões de dióxido de carbono (CO₂) do resfriamento triplicaram desde 1990 para 1.130 milhões de toneladas (Mt), o equivalente às emissões totais do Japão. Os poluentes do ar locais causados pela demanda de energia de resfriamento também aumentaram [2].

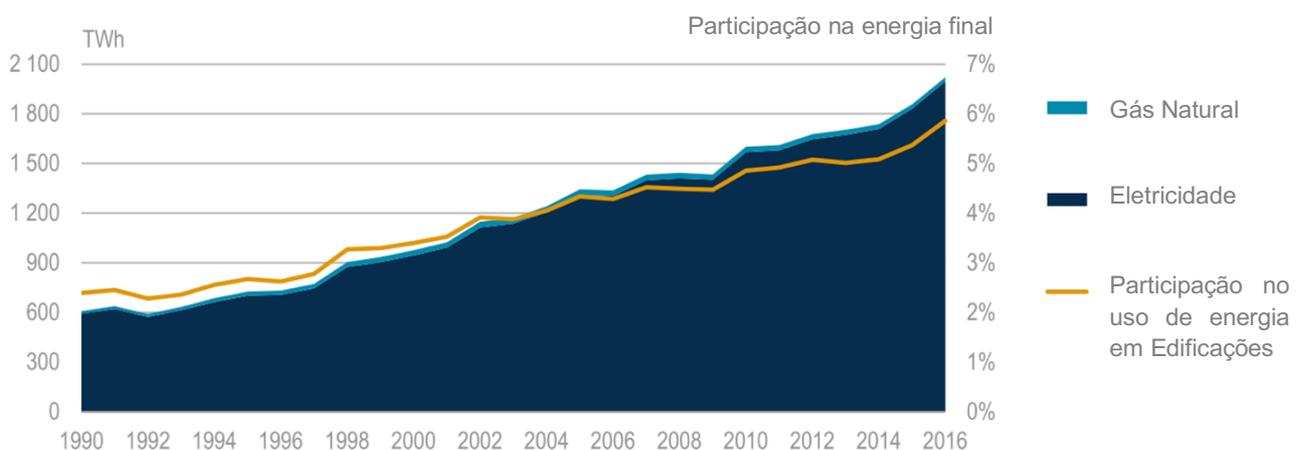


Figura 11. Consumo de energia global para resfriamento ambiente em edifícios de acordo com fontes energéticas no período 1990-2016 (TWh versus % na energia final)

Fonte: Adaptado de IEA [2]

No que diz respeito às tendências futuras sobre a posse de AC, uma das principais preocupações são as economias do Sul Global, como o Brasil. Espera-se que a localização desses países nas áreas mais quentes do mundo, juntamente com aumentos de temperatura projetados acima da média como resultado das mudanças climáticas, amplie as tendências

de aquisição de AC [2,25]. As vendas globais de AC já têm crescido de forma constante e significativa. Desde 1990, as vendas anuais globais de ACs quase quadruplicaram para 135 milhões de unidades [2].

Estudos existentes, de fato, destacaram o papel da renda, juntamente com o clima, como um motivador crítico na demanda de energia [25,90,144-146]. Destarte, embora o clima²³ – nesse caso, a temperatura do ar e o nível de umidade – seja o principal impulsionador da demanda por resfriamento de ambientes, a renda e a riqueza determinam o grau em que essa demanda é atendida [2]. Segundo DAVIS & GERTLER [90], tanto o clima quanto a renda são importantes para prever a adoção do AC, mas a interação entre os dois é consideravelmente mais importante do que os fatores individuais em si. Aumentos de temperatura contribuem para o aumento na adoção de ACs, mas o crescimento da receita das famílias por si só explica a maior parte desse crescimento na posse.

De acordo com [2], a relação clima-riqueza é forte, especialmente para os países com climas mais quentes (**Figura 12**). Em países com *Cooling Degree Days* (CDDs) acima de 3.000 graus-dias, incluindo Brasil, Egito, Índia, Indonésia, Tailândia e Venezuela, a posse de AC aumenta muito com a renda, pois o resfriamento é virtualmente essencial para as pessoas viverem e trabalharem com conforto [2]. Dessa maneira, para um determinado tipo de clima, a posse de ACs em uma residência aumenta com o desenvolvimento econômico e aumento da renda, e muito rapidamente no caso dos países mais quentes e úmidos.

²³ O principal fator climático que determina a demanda por refrigeração do ambiente é a temperatura do ar, embora a umidade também seja importante. Os dois geralmente caminham juntos, pois, quanto mais alta a temperatura, maior a capacidade do ar de reter água, embora algumas regiões desérticas possam experimentar temperaturas muito altas e umidade relativamente baixa. Altos níveis de umidade tendem a aumentar a necessidade de resfriamento para atingir um determinado nível de conforto térmico, e os ACs reduzem automaticamente o nível de umidade e também a temperatura do ar [2].

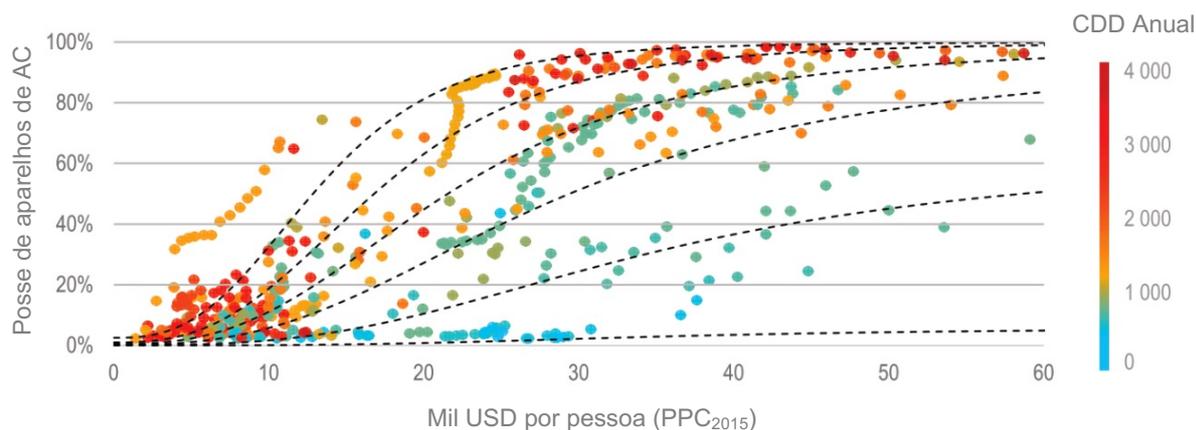


Figura 12. Renda *per capita* e taxa de propriedade familiar de aparelhos de AC

Fonte: Adaptado de IEA [2]

Nota: As linhas pontilhadas mostradas aqui são caminhos ilustrativos para um lugar ou país típico de acordo com CDDs ajustados para umidade relativa.

Sob outra ótica, com os crescentes riscos à saúde decorrentes do aumento das temperaturas no Sul Global, a falta de refrigeração interna essencial é cada vez mais vista como uma dimensão da pobreza energética e do bem-estar humano. É previsto que os impactos econômicos negativos do aumento das temperaturas vão afetar os países do Sul Global de forma mais severa [147,148], levando a um aumento da desigualdade global [149]. O acesso ao resfriamento é uma questão social importante, e, apesar de se esperar que a posse de AC aumente significativamente com o aumento da renda, é provável que muitos que precisam de AC não o tenham [2,150]. Atualmente, das 2,8 bilhões de pessoas que vivem nas partes mais quentes do mundo, apenas 8% possuem ACs, em comparação com 90% da propriedade nos Estados Unidos e no Japão. Consequentemente, a rapidez com que a demanda por energia relacionada ao resfriamento cresce depende de maneira crítica da ação política do governo [2].

Além do mais, MENDELSON *et al.* [151] e DE CIAN *et al.* [152] argumentam que diferentes populações dentro dos países são afetadas de diferentes maneiras pelas políticas de mudança climática e mitigação do clima, muitas vezes lesando a população pobre mais drasticamente, por ser a mais vulnerável [153,154]. Os impactos das mudanças climáticas constantes podem assim prejudicar os esforços para erradicar a pobreza [155]. As mudanças climáticas afetam a pobreza por intermédio de muitos canais, como através dos meios de subsistência, do consumo, dos bens, da saúde e da

produtividade [156]. Dessa forma, muitos estudos estão buscando compreender como as mudanças climáticas afetam os mais pobres, por exemplo [151,152,156,157].

Tendo isso em vista, estimar o impacto das mudanças climáticas no uso de energia é essencial para a análise das políticas de mitigação e adaptação, principalmente em países do Sul Global.

Em relação aos estudos destinados ao Sul Global, o Brasil é um estudo de caso relevante, sendo um país em desenvolvimento, continental e com clima tropical. Adicionalmente, a estabilidade econômica e a elevação da renda média das famílias no começo do milênio criaram condições para suprir parte de uma demanda reprimida por conforto ambiental, expressa principalmente pelo aumento do consumo de eletricidade devido ao uso de aparelhos de AC no país. Estima-se que o consumo de energia elétrica por condicionadores de ar no setor residencial tenha aumentado cerca de 237% nos últimos 12 anos, cerca de 9% ao ano, atingindo 18,7 TWh em 2017 (**Figura 13**) [158].

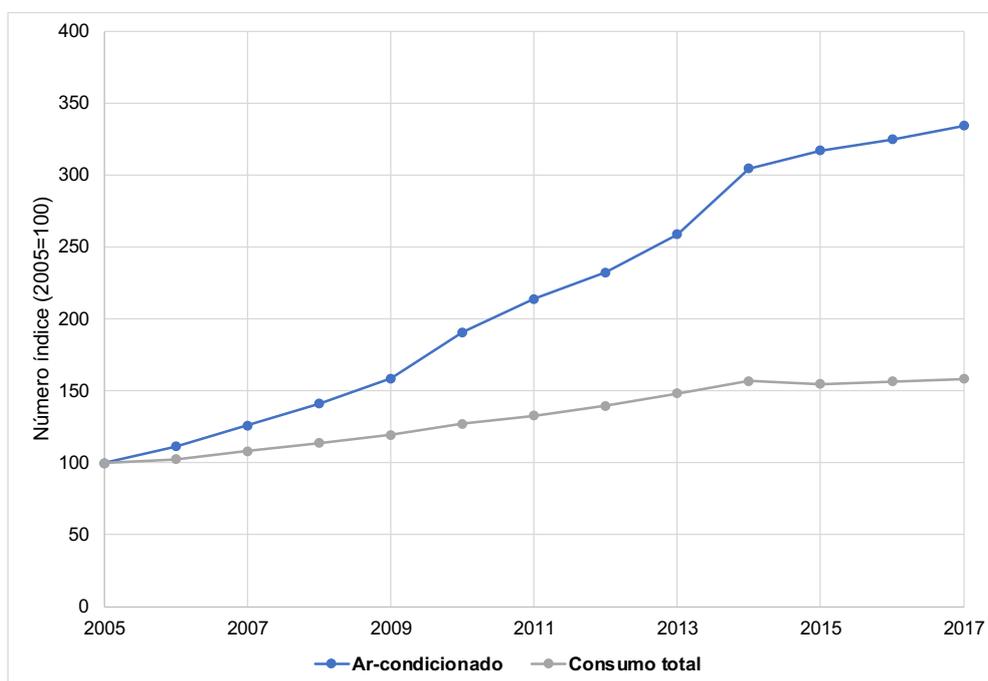


Figura 13. Crescimento do consumo de eletricidade total e para o condicionamento de ar no setor residencial brasileiro no período 2005-2017 (2005=100)

Fonte: Elaboração própria com base em EPE [159]

Apesar do aumento da demanda por climatização artificial observado nos últimos anos, parte do consumo de eletricidade foi evitado devido a ações de eficiência. Estima-se que o ganho acumulado de eficiência energética dos aparelhos de ar condicionado tenha sido de 8% entre 2005 e 2017 [158], o que evidencia a importância de medidas de eficiência energética no gerenciamento da demanda (*demand side management – DSM*) do setor residencial brasileiro [18].

Em termos de participação no consumo total de eletricidade no setor residencial, o aumento da quantidade de unidades vendidas permitiu que os condicionadores de ar apresentassem um ganho de participação relevante nos últimos anos, sendo o único eletrodoméstico com aumento de participação no consumo final de eletricidade do setor residencial entre 2005-2017. A participação dos ACs passou de 7% em 2005 para 14% em 2017 [158].

Contudo, a penetração de AC no Brasil ainda é considerada baixa, principalmente quando comparada com países desenvolvidos como os EUA. Associada ao potencial crescimento de renda da população brasileira no longo prazo e as condições climáticas e ambientais presentes no país, sugere a existência de uma demanda potencial por condicionamento de ar no Brasil que deverá ser atendida no futuro.

Apesar da importância dos fatores climáticos e do entendimento que a temperatura é um dos principais impulsionadores da variação da demanda de energia elétrica [160], poucos estudos consideram a influência da temperatura na demanda de eletricidade no Brasil e em outros países do Sul Global. A cobertura geográfica dos estudos regionais sobre o tema ainda é irregular e tende a sobrerrepresentar os países do Norte Global [14-18,161].

Dentre os estudos sobre países do Norte Global, o destaque vai para: análises dos EUA, como em SHEN [162], ZHAI & HELMAN [163] e JIANG *et al.* [164] com o caso da Flórida; estudos sobre a União Europeia como um todo [165] e países específicos, como Alemanha [166], Espanha [167] e Turquia [168,169]; e países da OCDE [25,170] e Austrália [171].

Já na literatura sobre o Sul Global, os estudos de caso da China são os mais correntes (e.g. [172-175]); mas estudos sobre México [90], Taiwan [176] e África Subsaariana [177] também são encontrados na literatura.

Por outro lado, existem também os estudos globais (e.g. [141,143,150,178-180]), que incluem o Brasil em suas análises.

Falando especificamente em análises para o Brasil, apenas DEPAULA & MENDELSON [20], HOLLANDA *et al.* [181], TROTTER *et al.* [182] e CABRAL *et al.* [160] incorporaram o clima como fator explicativo para a demanda residencial de eletricidade, e somente BEZERRA *et al.* [18] analisou especificamente o país com foco em suas particularidades regionais.

Os estudos regionais são relevantes para esse tipo de análise devido à maior granularidade destes com respeito ao clima local e às circunstâncias socioeconômicas, que podem ser usados para explorar ainda mais as diferenças regionais [16]. Esse é particularmente o caso do Brasil, cujas cinco regiões geográficas apresentam padrões socioeconômicos e climáticos diferentes [4,20,160].

Apesar de os estudos de caso do Brasil apresentados acima e aqueles citados na **Seção 2.3** terem começado a tratar da heterogeneidade socioeconômica e climática na demanda de energia das famílias, a literatura disponível não conseguiu exaurir esse assunto, principalmente no que se refere à demanda elétrica do setor residencial e diferentes cenários socioeconômicos e climáticos. Além disso, não foi encontrado nenhum estudo com representatividade nacional que considerasse em um mesmo modelo de projeção de demanda as características socioeconômicas e climáticas de acordo com diferentes grupos de consumidores finais. Em vista dessa lacuna, o **Capítulo 3** apresenta a proposta metodológica para a criação de um modelo capaz de lidar com essas particularidades, escassos na literatura devido à sua complexidade.

3 PROCEDIMENTO METODOLÓGICO

Este capítulo detalha a metodologia utilizada no desenvolvimento dos modelos microeconômicos propostos nesta tese. Tais modelos auxiliam no entendimento das relações casuais não-exatas entre variáveis socioeconômicas e climáticas na determinação do consumo de eletricidade pelo setor residencial brasileiro. Consequentemente, ajudam a entender quais são os principais impulsionadores da demanda elétrica e seus pesos relativos. O capítulo está dividido em duas seções principais: a **Seção 3.1** detalha o processamento e análise dos dados utilizados como entrada nos modelos microeconômicos; enquanto a **Seção 3.2** descreve os modelos desenvolvidos para as análises microeconômicas realizadas.

Como mencionado no capítulo introdutório, o processamento de dados e a modelagem microeconômica são executados em ambiente R via R-Studio que é baseado em linguagem S [36]. O *software* R contém um conjunto amplo de funções econométricas. Uma vantagem notável de usar R em econometria é a possibilidade de documentar a análise explicitamente, passo a passo, facilitando sua atualização e expansão. Isso permite reutilizar o código para aplicações semelhantes, com dados diferentes. Além disso, os programas R são totalmente reproduzíveis, viabilizando para outros a compreensão e validação dos resultados [183]. Para um melhor conhecimento sobre modelagem microeconômica em R, consultar HANCK & ARNALD [183] e ADAMS [184].

3.1 Processamento de dados

O objetivo desta seção é construir uma base de dados homogênea a nível domiciliar para o período 2002-2018, na qual microdados sobre o comportamento das famílias brasileiras são posteriormente combinados com dados climáticos estaduais. Foram analisadas duas bases de dados: a primeira diz respeito aos microdados socioeconômicos das famílias brasileiras contidos na Pesquisa de Orçamentos Familiares (POF); e, a segunda, aos dados climáticos – temperatura e umidade – de diferentes localidades do país, interpretados posteriormente pelo indicador climático *Cooling Degree Days* de bulbo úmido (CDD_{wb}).

As subseções a seguir explicitam todo o processo de análise para criação da base de dados, que serviu como entrada nos modelos microeconômicos.

3.1.1 Microdados da Pesquisa de Orçamentos Familiares (POF)

Os microdados são a menor fração de um dado coletado e informam, por meio de códigos numéricos, a resposta individual dos informantes ao questionário aplicado pela pesquisa [185]. A agregação de microdados possibilita inferir informações sobre a amostra.

Quando microdados estão disponíveis, podemos nos beneficiar do altíssimo nível de desagregação, que é sua principal característica, e modelar a heterogeneidade entre as microunidades ou o agrupamento de microunidades. Além disso, como já mencionado, o nível de detalhamento dos dados de entrada de modelos econométricos é determinante na escolha entre as diferentes técnicas de modelagem [74]. Para mais, o uso de microdados por refletir o comportamento individual ou familiar, é considerado mais adequado para lançar luz sobre a natureza das respostas do consumidor e estilos de vida [13].

Isto posto, abordamos nesta subseção os microdados disponibilizados pela POF do Instituto Brasileiro de Geografia e Estatística (IBGE). A pesquisa tem como unidade de investigação o domicílio e é realizada por amostragem a cada seis a oito anos, com o objetivo de disponibilizar informações sobre [186]:

- Composição orçamentária doméstica;
- Condições de vida da população (incluindo a percepção subjetiva da qualidade de vida); e
- Perfil nutricional da população.

A POF ganhou destaque, entre outras pesquisas domiciliares realizadas pelo IBGE, por adicionar temas importantes em virtude da necessidade de informações detalhadas sobre as condições de vida a partir do consumo, especialmente das famílias de menor rendimento. Atualmente, é conhecida como a pesquisa domiciliar com representação nacional mais confiável do Brasil, em termos de renda e despesas familiares [186] [187].

A pesquisa começou a ser divulgada em 1987, embora já contasse com uma edição de 1974 chamada ENDEF (Estudo Nacional da Despesa Familiar). Contudo, até a década

de 1990 foi realizada apenas com amostras das Regiões Metropolitanas²⁴. Apenas nos anos 2000, especificamente na POF (2002-2003), sua realização passou a considerar todo o Território Brasileiro, com inclusão da área rural [186,187], razão pela qual esse ano foi escolhido como o início do período da base de dados criada.

Dessa forma, as três últimas ondas da POF – POF (2002-2003), POF (2008-2009) e POF (2017-2018) –, representando o período 2002-2018 e com uma representatividade a nível nacional, foram selecionadas como dados socioeconômicos. Os microdados são então processados e analisados para serem utilizados como entrada nos diferentes modelos microeconômicos desenvolvidos nesta tese. A **Tabela 2** contém as informações gerais de cada um dos anos analisados, o número de famílias e indivíduos entrevistados (amostra) em cada ano e sua respectiva representação no universo da população brasileira.

Tabela 2. Informações gerais sobre as três últimas ondas da POF utilizadas na análise microeconômica

Informações gerais	Representação dos dados	POF (2002-2003)	POF (2008-2009)	POF (2017-2018)
Número de famílias	Amostra	48.470	55.970	57.920
	Universo	48.394.067	57.691.781	68.862.296
Número de indivíduos	Amostra	182.333	190.159	178.431
	Universo	175.845.964	190.519.297	207.103.790
Número de variáveis explanatórias		> 500	> 500	> 500
Período das entrevistas		Julho-Junho	Maió-Maió	Junho-Julho

Fonte: Elaboração própria com base em IBGE [188]

O primeiro passo para o processamento da base de dados é transformar variáveis originais da pesquisa, derivadas das perguntas contidas nos questionários, e manipulá-las para obter informações relevantes à análise microeconômica proposta. Dessa forma, após a coleta dos microdados em IBGE [188] no formato de texto corrido (.txt), são necessários *scripts* (rotinas) na linguagem de programação estatística que consigam interpretar os valores numéricos contidos nos arquivos e convertê-los em tabelas de dados, chamadas no R de “*data tables*”. As tabelas de dados são matrizes que conseguem conter grande quantidade de informação, cujas colunas representam as perguntas dos

²⁴ Regiões Metropolitanas de Belém, Fortaleza, Recife, Salvador, Belo Horizonte, Rio de Janeiro, São Paulo, Curitiba e Porto Alegre, no Município de Goiânia, e no Distrito Federal.

questionários aplicados (variáveis), e, as linhas, as respostas de cada microunidade – no caso da POF, domicílios ou indivíduos (observações).

Cabe aqui esclarecer que a POF faz uma diferenciação entre a microunidade chamada de “domicílio” e a microunidade “família” e por isso optamos por utilizar a microunidade domicílio como representativa da família. Segundo o [186] (p. 9):

A POF é uma pesquisa realizada por amostragem, na qual são investigados os domicílios particulares permanentes. No domicílio, por sua vez, é identificada a unidade básica da pesquisa – unidade de consumo – que compreende um único morador ou conjunto de moradores que compartilham da mesma fonte de alimentação ou compartilham as despesas com moradia. É importante ressaltar que esta definição, que será detalhada mais adiante, segue as recomendações e práticas internacionais referentes às pesquisas similares.

O conceito de família no IBGE, também atendendo às recomendações internacionais, é especificamente adotado no Censo Demográfico e demais pesquisas domiciliares e refere-se às pessoas ligadas por laços de parentesco, dependência doméstica ou normas de convivência, sem referência explícita ao consumo ou despesas. Entretanto, na maior parte das situações, a unidade de consumo da POF coincide com a família, segundo o conceito adotado no IBGE. No ENDEF e nas POFs, para efeito de divulgação de resultados, o termo família tem sido utilizado para representar o conceito de unidade de consumo e, na presente publicação, este procedimento é mantido.

A cada onda, a POF aplica cerca de sete questionários aos entrevistados sendo divididos nos chamados “Registros”, com diferentes blocos de perguntas em cada um. As perguntas (variáveis) são tanto de caráter qualitativo, com opções pré-elaboradas para as respostas, quanto quantitativo, com unidades de medida para padronização das respostas. No **Quadro 1** abaixo encontra-se a listagem com os nomes dos sete diferentes questionários e doze registros de respostas da POF (2017-2018), recém-lançada pelo IBGE [188], que teve como novidade em relação as ondas anteriores, as seções de condições de vida e características da dieta²⁵.

Quadro 1. Informações gerais sobre os questionários da POF (2017-2018)

Questionário		Registro (microdados)	Microunidade	Número do quadro	Informações
POF 1	Características do domicílio e dos moradores	DOMICILIO	Domicílio	2	Investiga características gerais do domicílio, como por exemplo, o material que predomina na construção, número de cômodos etc., e características os
		MORADOR	Indivíduo	3-4	

²⁵ Para um conhecimento mais detalhado da seção de características da dieta e consumo alimentar, ver BELIK [274].

					moradores, como cor, sexo, escolaridade entre outros.
POF 2	Aquisição coletiva	ALUGUEL_ESTIMADO	Família	-	Aquisições monetária e não monetária de produtos de uso comum da família cuja aquisição não é frequente como eletrodomésticos, móveis etc. Também coleta informações de despesas com serviços de energia elétrica, água e esgoto, entre outros. O questionário é estruturado pela frequência da aquisição dos bens e serviços, que podem ser de 90 dias ou 12 meses.
		INVENTARIO	Família	14	
		DESPEZA_COLETIVA	Família	6-13 e 15-19	
POF 3	Caderneta de aquisição coletiva	CADERNETA_COLETIVA	Família	63-69	Informações sobre aquisições monetária e não monetária de alimentos, bebidas, artigos e produtos de limpeza, entre outras aquisições que costumam ser frequente e, em geral, servem a todos os moradores. Este questionário tem como período de referência 7 dias.
POF 4	Aquisição individual	DESPEZA_INDIVIDUAL	Indivíduo	21-51	Informações sobre aquisições monetárias e não monetárias de produtos e serviços, em geral de utilização pessoal, não pesquisadas no POF 2 e no POF 3, como produtos farmacêuticos, transportes, comunicação, vestuário, alimentação fora do domicílio etc. Este questionário utiliza todos os períodos de referência, de 7 dias, 30 dias, 90 dias e 12 meses.
POF 5	Trabalho e rendimento individual	RENDIMENTO_TRABALHO	Indivíduo	53	Todos os rendimentos monetários obtidos através de trabalho de transferências, outros rendimentos, receitas, empréstimos, entre outros além de informações sobre as ocupações dos indivíduos, atividades e posições na ocupação. Este questionário tem o período de referência de 12 meses.
		OUTROS_RENDIMENTOS	Indivíduo	54-57	
POF 6	Avaliação das condições de vida	CONDICAO_VIDA	Família	61	Informações de caráter subjetivo a respeito das condições de vida da unidade de consumo, como a opinião sobre a suficiência do rendimento mensal, a quantidade e qualidade dos alimentos para consumo pela família, as condições de moradia, entre outros.
POF 7	Bloco de consumo alimentar pessoal	CARACTERISTICAS_DIETA	Indivíduo	71	Informações referentes ao consumo alimentar efetivo de todos os indivíduos moradores do domicílio com 10 anos ou mais, tais como: fonte do alimento, horário do consumo efetivo, forma de preparo e outros.
		CONSUMO_ALIMENTAR	Indivíduo	72-73	

Fonte: Elaboração própria com base em IBGE [188]

Anexos às respostas das microunidades são fornecidos documentos complementares que auxiliam no entendimento dos microdados, dentre os quais se destacam o “Dicionário de Variáveis” e o “Cadastro de Produtos”. O primeiro contém informações necessárias para transformar os números em cadeia dos arquivos de texto em variáveis, e o segundo é um registro de todas as *commodities* contidas nas respostas dos questionários. No arquivo de Excel “Cadastro de Produtos”, cada onda da pesquisa possui mais de 13 mil produtos cadastrados, que vão desde o tipo de energia demandada pela família, como GLP (gás liquefeito de petróleo), até alimentos exóticos consumidos, como língua de boi. Os produtos cadastrados indicam tanto o destino das despesas familiares como a fonte de renda das famílias.

Após a leitura dos microdados e a transformação dos números contidos nos arquivos originais em perguntas e respostas (variáveis *versus* observações), é possível começar a identificar quais variáveis originais, fornecidas pelo IBGE [188], necessitam de algum tipo de tratamento para alimentar os modelos microeconômicos.

Um passo importante nessa etapa do processamento de dados é definir qual microunidade será analisada empiricamente. Nesta tese, escolhemos o domicílio (ou, na língua inglesa, *household*) como unidade observacional representante das famílias²⁶. Para poder acompanhar os domicílios ao longo dos diferentes questionários e garantir que estamos efetivamente observando a mesma microunidade, é necessário gerar um código de identificação único a cada domicílio em cada onda, conhecido na linguagem de programação como “*id*” – no caso desta tese, “*hhid*” (*household identification*).

Como já mencionado, o número de questionários varia ao longo das ondas. Com o aprimoramento da pesquisa, novas variáveis e questionários são percebidos como relevantes e adicionados, enquanto outros perdem importância e acabam sendo excluídos. Em razão disso, na POF (2002-2003) e (2008-2009) é possível criar o *hhid* das famílias com as mesmas variáveis, através da junção de cinco variáveis originais: “CÓDIGO DA UF”, “NÚMERO SEQÜENCIAL”, “DV DO SEQÜENCIAL”, “NÚMERO DO DOMICÍLIO” e “ESTRATO GEOGRÁFICO”. Por outro lado, na POF (2017-2018), algumas variáveis tiveram nomes alterados e outras foram substituídas em relação as ondas anteriores, contudo a lógica do *hhid* permanece a mesma: criar uma sequência de

²⁶ É possível encontrar mais de uma família morando em um mesmo domicílio [188], condição estatisticamente irrelevante na amostra utilizada.

dígitos que identifique os domicílios de forma única. No caso da POF (2017-2018) as variáveis originais são: “CÓDIGO DA UNIDADE PRIMÁRIA”, “ESTRATO GEOGRÁFICO”, “URBANO” e “NÚMERO DO DOMICÍLIO”.

Cabe destacar aqui que não é possível utilizar o mesmo *hhid* ao longo do período analisado, porque diferentes famílias são entrevistadas em diferentes anos da pesquisa. Consequentemente, a pesquisa é incapaz de observar a mesma microunidade – neste caso, os domicílios – ao longo do tempo [186].

O processamento dos microdados da POF nos permitiu chegar a aproximadamente 100 variáveis tratadas e uma média de 50 mil observações (domicílios) por onda da POF. Como resultado, temos um total de 162.363 observações no período 2002-2018. Das 100 variáveis criadas, 44 foram consideradas potenciais para modelagem microeconômica. As variáveis são consideradas potenciais, pois sua relevância estatística só é confirmada após a realização da inferência estatística. Em outras palavras, são variáveis que, *a priori* – a partir da revisão da literatura empírica (**Tabela 1**) –, são julgadas relevantes para explicar o consumo de eletricidade no setor residencial brasileiro. Mostraremos a seguir como essas variáveis foram criadas a partir das variáveis originais da pesquisa.

Basicamente, as variáveis explanatórias potenciais selecionadas foram consideradas influentes na caracterização socioeconômica e demográfica do domicílio. A base de microdados é articulada em seções de domínios que descrevem: dados demográficos; características do domicílio; características do chefe da família; padrão de receita e despesa; uso de energia; e propriedade de bens duráveis (eletrodomésticos). A seguir, um detalhamento maior sobre cada domínio:

- I. Dados demográficos** – diferentes níveis geográficos foram selecionados para testar qual teria melhor interação com os dados climáticos. Do nível mais agregado ao menos agregado temos: situação do domicílio (urbano *versus* rural), região, unidade da federação e estrato geográfico. Cabe aqui destacar que, o desenho atual da amostra da POF não fornece informações sobre o município ou distrito onde as famílias estão situadas para não prejudicar o sigilo dos entrevistados. Assim, o mais alto nível de desagregação geográfica é categorizado por quatro alternativas, denominadas “Estrato Geográfico”, uma para as áreas

rurais e três para as áreas urbanas – municípios das capitais, região metropolitana ou outros municípios urbanos [186];

- II. Características do domicílio** – para melhor compreensão sobre as condições de vida das famílias, foram recolhidas informações sobre a área de habitação e suas características, a maioria delas criada a partir do registro “Domicílio”. Algumas das variáveis selecionadas foram: fontes de cocção, de iluminação e de água potável, acesso a energia elétrica, tipos de banheiro etc.;
- III. Características do chefe da família** – o chefe da família tem uma condição de destaque na unidade de consumo (UC)²⁷. É a pessoa de referência, que teoricamente toma as decisões importantes que afetam outros membros da família. Foram selecionadas características socioculturais como gênero, raça, idade e anos de escolaridade;
- IV. Uso de energia** – para entender diferentes padrões de consumo de energia, o consumo de eletricidade foi contabilizado a nível domiciliar, assim como a despesa com eletricidade e preço pago por consumidor. Outras fontes de energia, como gás (gás natural/GLP) e lenha, foram encontradas na pesquisa, mas com dados não tão confiáveis;
- V. Padrão de receita e despesa** – foram coletados dados de renda e despesas das famílias, especificamente despesas com eletricidade. A partir do dado de renda, foi possível classificar as famílias em diferentes classes de renda a partir de decis, e entender quais delas pertencem à linha de pobreza e extrema pobreza. Além

²⁷ “Cabe ainda, nessas considerações iniciais, esclarecer sobre a adoção do termo família nas publicações de resultados da POF. A POF é uma pesquisa realizada por amostragem, na qual são investigados os domicílios particulares permanentes. No domicílio, por sua vez, é identificada a unidade básica da pesquisa – unidade de consumo – que compreende um único morador ou conjunto de moradores que compartilham da mesma fonte de alimentação ou compartilham as despesas com moradia. É importante ressaltar que esta definição, que será detalhada mais adiante, segue as recomendações e práticas internacionais referentes às pesquisas similares.

O conceito de família no IBGE, também atendendo às recomendações internacionais, é especificamente adotado no Censo Demográfico e demais pesquisas domiciliares e refere-se às pessoas ligadas por laços de parentesco, dependência doméstica ou normas de convivência, sem referência explícita ao consumo ou despesas. Entretanto, na maior parte das situações, a unidade de consumo da POF coincide com a família, segundo o conceito adotado no IBGE. No ENDEF e nas POFs, para efeito de divulgação de resultados, o termo família tem sido utilizado para representar o conceito de unidade de consumo e, na presente publicação, este procedimento é mantido.” [186] (p. 9)

disso, dividindo os dados de consumo de eletricidade pelas despesas com energia elétrica foi possível calcular o preço da eletricidade;

VI. Propriedade de bens duráveis (eletrodomésticos) – a literatura sobre demanda residencial destaca alguns eletrodomésticos como os responsáveis por um maior consumo de eletricidade. Estudos como os de JANNUZZI & SCHIPPER [125] e GROTTERA *et al.* [189] foram levados em consideração na seleção de bens duráveis a serem analisados. A informação sobre a posse de equipamentos foi retirada da base do registro “Inventário” do “POF 2 - Questionário de Aquisição Coletiva”²⁸. Os eletrodomésticos selecionados como potenciais aparecem na **Tabela 3**, junto com as demais variáveis potenciais.

Tabela 3. Descrição das variáveis socioeconômicas potenciais para a análise microeconômica

Variável	Tipo	Descrição	Unidade de medida/Categorias
Dados demográficos			
Urbano	Binária	Localidade geográfica mais agregada	Urbano ou rural
Unidades da Federação	Categórica	Localidade geográfica	26 Estados + Distrito Federal
Região	Categórica	Localidade geográfica	5 Regiões
Estrato Geográfico	Categórica	Localidade geográfica mais desagregada	1 Estrato rural + 3 Estratos urbanos
Membros na família	Contínua	Número de membros na família	Numeral
Número da UC	Contínua	Número da unidade de consumo	Numeral
Características do domicílio			
Residência própria	Binária	Situação de compra do domicílio	Própria ou não
Tipo de domicílio	Binária	Tipo de domicílio	Casa, apartamento ou cômodo
Material da parede	Categórica	Material que predomina nas paredes externas	6 categorias
Material do telhado	Categórica	Material que predomina na cobertura	7 categorias
Eletricidade via rede pública	Binária	Forma de fornecimento da eletricidade	Rede pública ou não
Tipo de banheiro	Categórica	Tipo de escoadouro sanitário	4 categorias
Acesso a eletricidade	Binária	Se possui acesso a eletricidade	Com ou sem acesso
Formas de iluminação	Categórica	Tipo de iluminação	6 categorias relacionadas
Formas de cocção	Categórica	Fonte energética para cocção	10 categorias
Fonte de água potável	Categórica	Proveniência da água potável	4 categorias
Índice da <i>household</i>	Binária	Condição de vida da família	Alta ou baixa qualidade
Características do chefe da família			
Sexo	Binária	Sexo do chefe da família	Feminino ou masculino
Raça	Binária	Raça do chefe da família	Branco ou não
Idade	Contínua	Idade do chefe da família	Anos
Anos de educação	Contínua	Anos de educação do chefe da família	Anos

²⁸ Na POF (2002-2003), equivale ao “POF 2 – Questionário de Despesa Coletiva”.

Uso de energia

Eletricidade (variável dependente)	Contínua	Quantidade consumida de eletricidade pelo domicílio	Ln kWh/ano
Despesa _E	Contínua	Despesa com eletricidade	Ln BRL ₂₀₁₇ /ano
Preço _E	Contínua	Preço da eletricidade	Ln BRL ₂₀₁₇ /kWh/ano

Padrão de receita e despesa

Renda	Contínua	Renda da família	Ln BRL ₂₀₁₇ /ano
Decil	Catagórica	Classes de renda baseadas em decis	10 classes de renda baseadas em decis
Linha da pobreza	Binária	Se pertence a categoria de pobreza	Pobre ou não
Linha da extrema pobreza	Binária	Se pertence a categoria de pobreza global	Extremamente pobre ou não

Propriedade de bens duráveis

AC	Contínua		
Ventilador	Contínua		
Computador	Contínua		
Micro-ondas	Contínua		
TV	Contínua		
Geladeira	Contínua		
Freezer	Contínua	Quantidade de eletrodoméstico	Numeral
Máquina de lavar roupa	Contínua		
Ferro	Contínua		
Rádio	Contínua		
Máquina de costura	Contínua		
Aspirador	Contínua		
Chuveiro elétrico	Contínua		

Fonte: Elaboração própria

Algumas dessas variáveis já estavam bem definidas nos dados originais da POF, outras demandaram mais atenção para se chegar à informação desejada. A complexidade da transformação da variável original em uma variável final/desejada também depende do ano da POF. Como já informado, a pesquisa sofreu alterações visando sua melhoria. Nesta seção são expostas as variáveis com as transformações que merecem maior destaque:

- a) **Renda das famílias (Ln Renda em BRL₂₀₁₇/ano/domicílio)** – nas ondas da POF, as receitas são reportadas mensalmente em moeda corrente local (reais). Dentre as diferentes variáveis de renda disponíveis nos microdados originais da pesquisa optamos pela “RENDA TOTAL MENSAL DA UC”, que corresponde ao valor do rendimento mensal bruto da unidade de consumo (família). Tal variável é obtida através da soma dos rendimentos monetários brutos de todos os residentes da UC, obtidos através do trabalho, transferências, outros rendimentos e saldo positivo de operações financeiras,

acrescido da parcela relativa à receita não-monetária²⁹ da unidade de consumo [186]. Em seguida, computamos a renda em logaritmo natural anual e em BRL_{2017} ³⁰(R\$ ou reais).

b) Despesa com eletricidade ($\ln Despesa_E$ em $BRL_{2017}/kWh/domicílio$) – as despesas da POF possuem bases de reporte diferentes. Algumas são mensais, outras anuais e há também as trimestrais, como as fontes de energia; conforme descrito anteriormente no **Quadro 1**. O valor das despesas considera a unidade de medida da *commodity* consumida – no caso específico da eletricidade, BRL/kWh . Dentre as opções disponíveis escolhemos a variável “VALOR DA DESPESA ANUALIZADO E EXPANDIDO (FATOR2)” e dividimos pelo “FATOR DE EXPANSÃO 2 (AJUSTADO P/ ESTIMATIVAS)”. Esses valores consideram o ‘CÓDIGO DO ITEM’ e o ‘NÚMERO DO QUADRO’, referentes à *commodity* eletricidade discriminada no “Cadastro de Produtos”. Na POF (2002-2003) a *commodity* eletricidade está cadastrada no Quadro 7, sob dois códigos “0201 - ENERGIA ELETRICA (DOMICILIO PRINCIPAL)” e “0202 - ENERGIA ELETRICA (KWH)”. Já na POF (2008-2009) está no Quadro 6, “00201 - ENERGIA ELETRICA (KWH)”. Por fim, na POF (2017-2018) também se encontra no Quadro 6, mas sob o código de produto “600101 - ENERGIA ELETRICA (KWH)”. A despesa com eletricidade de cada domicílio é então computada em logaritmo natural anual e em BRL_{2017}/kWh .

c) Preço da eletricidade ($\ln Preço_E$ em $BRL_{2017}/kWh/ano/domicílio$) – é calculado a partir da razão entre os gastos com eletricidade e o consumo de energia elétrica. Assim, chega-se a um valor de $BRL_{2017}/kWh/ano$ por família (consumidor final). Outros estudos, como os de KRISHNAMURTHY &

²⁹ Segundo IBGE [186], as receitas monetárias referem-se aquelas efetuadas através de pagamento, à vista ou a prazo, em dinheiro, cheque ou com utilização de cartão de crédito. Já as receitas classificadas como não-monetárias são efetuadas sem o pagamento monetário, ou seja, quando a receita é obtida através de doação, retirada do negócio, troca, produção própria, pescado, caçado e coletado durante os períodos de referência da pesquisa, disponíveis para utilização. Os valores das receitas monetárias foram definidos pelos próprios informantes dos questionários, considerando os preços vigentes no mercado local.

³⁰ Todos os valores da POF (2002-2003) e POF (2008-2009) foram convertidos para 2017 utilizando o **Índice Nacional de Preços ao Consumidor Amplo (IPCA)** que tem por objetivo medir a inflação de um conjunto de produtos e serviços comercializados no varejo, referentes ao consumo pessoal das famílias. Assim BRL 1,00 em 2002 é igual a BRL 2,59 in 2017, enquanto BRL 1,00 em 2008 é igual a BRL 1,73 em 2017.

KRISTRÖM [190], SILVA *et al.* [191] e PEREIRA UHR *et al.* [34], utilizam essa mesma lógica para o cálculo do preço da eletricidade.

- d) Linhas de pobreza e extrema pobreza (Pobreza e Extrema pobreza)** – as duas variáveis binárias foram criadas a partir das linhas de pobreza definidas pelo Banco Mundial³¹ [97-100]. Como explicado na **Seção 2.3**, o Banco Mundial define a linha da pobreza para países como o Brasil – classificados como países de rendimento médio-alto – equivalente ao limite de renda *per capita* por dia de USD 5,50 PPC₂₀₁₁/dia. Já a linha de extrema pobreza, é limitada a USD 1,90 PPC₂₀₁₁/dia [192]. Analogamente, conforme IBGE [101], isso significa uma renda *per capita* mensal de respectivamente BRL₂₀₁₈ 420 (para a linha de pobreza) e BRL₂₀₁₈ 145/mês (para a linha de extrema pobreza). Como forma de comparação, o valor de BRL₂₀₁₈ 420 corresponde a aproximadamente 44% do salário mínimo vigente em 2018 [101].

Para transformar as linhas de pobreza em variáveis *dummy*, primeiro convertemos a “RENDA TOTAL MENSAL DA UC” em USD PPC₂₀₁₁³² e depois dividimos pelo número de membros do domicílio (“QUANTIDADE DE MORADORES”), chegando então na renda média anual *per capita* em USD PPC₂₀₁₁. Posteriormente dividimos esse valor por 365, total de dias em um ano, chegando na renda *per capita* em USD PPC₂₀₁₁ diária e consideramos que domicílio com valores iguais ou abaixo de USD 5,50 PPC₂₀₁₁/dia ou USD 1,90 PPC₂₀₁₁/dia, pertencem a linha de pobreza e extrema pobreza respectivamente.

- e) Classes de renda (Decil)** – a categorização das famílias em diferentes classes de renda a partir de decis foi conduzida utilizando a variável “Renda das famílias” em moeda corrente para o ano de realização da pesquisa. Também

³¹ A linha de pobreza do Banco Mundial foi escolhida, uma vez que o Brasil não possui uma linha oficial de pobreza [186].

³² Para isso, em um primeiro passo é necessário converter os valores em BRL, *Local Currency Units* (LCU), para USD PPP corrente usando a base de dados do Banco Mundial (<https://data.worldbank.org/indicator/%20PA.NUS.PRVT.PP>) para cada um dos anos 2002, 2003 e 2008. Em segundo, para transformar de valores correntes USD PPP para constante em USD PPP₂₀₁₁, é utilizado a *CPI Inflation Calculator from the U.S. Bureau of Labor Statistics* (https://www.bls.gov/data/inflation_calculator.htm), considerando o mês/ano inicial da pesquisa.

foram considerados decis de acordo com o número de famílias na área urbana e na área rural. Em estatística, a metodologia do decil divide a variável – neste caso, a renda – em dez partes iguais, de modo que cada parte representa 1/10 da amostra das famílias. Como consequência, são obtidas 10 classes de renda, estendendo-se das famílias mais pobres (Decil 1) até as mais ricas (Decil 10).

A metodologia dos decis de renda tem uma grande vantagem em relação às classes de renda definidas exogenamente por salário-mínimo [193]. Por ser uma metodologia endógena, a classificação dos domicílios por decis tem como benefício a adoção de valores internos à distribuição de renda [40,127,128].

f) Nível de qualidade da residência (índice da *household*) – variável que busca refletir a qualidade da residência na qual a família se encontra, além de sua condição de vida e de entorno. É uma junção de cinco outras variáveis binárias que pretendem juntas classificar a condição da residência como de “alta qualidade” ou “baixa qualidade”. A variável relaciona materiais de construção de habitações (paredes e telhado), tipo de banheiro (escoadouro sanitário), fontes de acesso a água potável e formas de iluminação. Sua criação foi inspirada em PAVANELLO *et al.* [194]. Para a residência ser considerada de alta qualidade, ela precisa ter:

- (i) *paredes de alvenaria ou madeira* – a variável original transformada em *dummy* foi “MATERIAL QUE PREDOMINA NAS PAREDES EXTERNAS”; se a resposta for “01 – Alvenaria” ou “02 – Madeira para Construção”, então *dummy* igual a 1;
- (ii) *telhado de metal, telha, concreto ou madeira* – a variável original transformada em *dummy* foi “MATERIAL QUE PREDOMINA NA COBERTURA”; se a resposta for “01 – Telha Qualquer” ou “02 – Laje de Concreto” ou “03 – Madeira para Construção” ou “04 – Chapa Metálica”, então *dummy* igual a 1;
- (iii) *iluminação proveniente da rede pública (distribuidoras de eletricidade)* – a variável original transformada em *dummy* foi “ORIGEM DE ENERGIA ELÉTRICA” na POF (2002-2003) e “REDE GERAL DE ENERGIA ELÉTRICA” nas outras ondas;

- (iv) *água encanada* – a variável original transformada em *dummy* foi “PROVENIÊNCIA DA ÁGUA”; se a resposta for “01 – Rede Geral de Distribuição”, então *dummy* igual a 1; e
- (v) *banheiro com descarga* – a variável original transformada em *dummy* foi “ESCOADOURO SANITÁRIO”; se a resposta for “01 – Rede Geral de Esgoto ou Pluvial”, então *dummy* igual a 1.

g) Consumo de eletricidade (Ln Eletricidade em kWh/ano/domicílio) – é a variável dependente, é o que queremos compreender e prever na modelagem microeconômica proposta. Descreve o padrão de consumo energético das famílias. Assim como no caso das despesas com energia elétrica, a consumo de diferentes fontes energéticas possui bases de reporte diferentes na POF. A quantidade consumida considera a unidade de medida da *commodity* demandada – no caso específico da eletricidade, em kWh/trimestre. Dentre as opções disponíveis, escolhemos a variável “QUANTIDADE FINAL” e multiplicamos pelo “FATOR DE ANUALIZAÇÃO”. Esses valores consideram o ‘CÓDIGO DO ITEM’ e o ‘NÚMERO DO QUADRO’, referentes à *commodity* eletricidade discriminada no “Cadastro de Produtos” descrita anteriormente no item (b). O consumo de eletricidade de cada domicílio é então computado em logaritmo natural e em kWh/ano.

Por fim, o chamado **peso amostral**, apesar de não ser uma variável explanatória, também merece destaque. Ele é usado para obter estatísticas descritivas representativas da população. Pesquisas domiciliares, como a POF, são geralmente desenvolvidas de forma que diferentes famílias tenham diferentes probabilidades de inclusão na amostra. Pesos amostrais são atribuídos a cada observação para corrigir isso. De acordo com o relatório da POF [101](p. 26):

Cada domicílio pertencente à amostra da POF representa um determinado número de domicílios particulares permanentes da população (universo) de onde esta amostra foi selecionada. Com isso, a cada domicílio da amostra está associado um peso amostral ou fator de expansão que, atribuído às características investigadas pela pesquisa, permite a obtenção de estimativas das quantidades de interesse para o universo da pesquisa.

O peso é calculado para cada domicílio e atribuído a cada unidade de consumo e pessoa desse domicílio. Dessa forma, é possível calcular estimativas de totais para

qualquer variável investigada na pesquisa, seja para características de domicílio, de unidade de consumo ou de pessoa. A variável original utilizada é chamada “FATOR DE EXPANSÃO 2 (DOMICÍLIO) – USO P/ESTIMATIVAS”. Optou-se por não utilizar a escala de equivalência modificada da OCDE – Organização para a Cooperação e Desenvolvimento Econômico, mais comumente utilizada em estudos de países desenvolvidos.

3.1.2 Dados de *Cooling Degree Days wet bulb* (CDD_{wb})

O chamado *Cooling Degree Days* (CDD) é um indicador climático que, dentre outras abordagens, busca analisar o efeito da temperatura ambiente do ar no consumo de energia. O termo é definido como a soma cumulativa das diferenças positivas entre a média diária da temperatura ambiente do ar e uma temperatura base limite ao longo de um determinado período de tempo (por exemplo, mês ou ano) [195]. O indicador é comumente utilizado como uma *proxy* para calcular a demanda de energia para refrigeração de um espaço, de forma a garantir os níveis de conforto térmico em edifícios residenciais e comerciais [196,197]. Dessa forma, diversos estudos têm explorado tal indicador com o objetivo de entender os possíveis impactos do aumento da temperatura na demanda de energia destinada a refrigeração ambiente no setor de edificações [18,120,141,173].

Apesar do CDD fornecer uma medida comparativa do conforto térmico ambiente [198], configurando um indicador espacialmente explícito da demanda bruta de resfriamento ambiente, ele não contempla informações sobre o comportamento humano, posse de equipamentos e características dos edifícios, o que, caso abordado, resultaria em uma estimativa mais precisa das necessidades de energia para resfriamento [18].

O CDD possui uma variante chamada CDD de bulbo úmido (*CDD wet bulb* ou CDD_{wb}). Essencialmente, o CDD_{wb} incrementa a temperatura ambiente do ar, também conhecida como temperatura de bulbo seco (T_d) ao contabilizar a Umidade Relativa (rh), chegando assim na chamada de temperatura de bulbo úmido (T_{wb}). A T_{wb} considera a sensação térmica, melhor representado climas quentes e úmidos [197]. Quando a umidade relativa é 100%, as medições de temperatura do bulbo seco e do bulbo úmido coincidem; caso contrário, a temperatura do bulbo úmido e, conseqüentemente, o CDD_{wb} , são sempre mais baixos [194]. Ao incorporar rh , o CDD_{wb} é responsável por um melhor limite

termodinâmico na transferência de calor metabólica humana [199], particularmente relevante para localidades úmidas, como as encontradas no Brasil [197,200,201].

Tendo isso em vista, o CDD de bulbo úmido é preferido como dado climático a ser utilizado como entrada nos diferentes modelos microeconômicos desenvolvidos nesta tese. Os valores de CDD_{wb} são selecionados da base de dados contida em MISTRY [202]. Tal base de dados é a única com série temporal histórica global de alta resolução em nível de células (*grid-cell*) com base em múltiplas temperaturas base limite, oferecendo, assim, aplicações em uma ampla gama de zonas climáticas e ambientes de conforto térmico [202]. Os dados de graus-dias derivam de temperaturas sub-diárias do *Global Land Data Assimilation System (GLDAS)*³³ [203]. O conjunto de dados chamado “CEI_0p25_1970_2016” inclui CDD mensal e anual calculado usando temperatura de bulbo úmido com resolução em célula a $0,25^\circ \times 0,25^\circ$ (cerca de 27 km x 27 km no equador), cobrindo 47 anos no período 1970-2016 [202].

Para conhecimento, o cálculo do CDD_{wb} executado por MISTRY [202], utiliza uma equação adaptada da *American Society of Heating, Refrigerating and Air Conditioning* (traduzido livremente como Sociedade Americana de Aquecimento, Refrigeração e Condicionamento do Ar) [195], apresentada na **Equação (3.1)**:

$$CDD_{wb} = \sum_{i=1}^N (T_{wb} - T_{base})^+ \quad (3.1)$$

Onde:

T_{base} = representativo de um valor limite para o uso de ar-condicionado em °C,

+ = indica que apenas valores positivos são considerados para soma ao longo do período de tempo N (normalmente meses ou anos).

De acordo com MISTRY [202], a T_{base} varia entre estudos que usam a metodologia do CDD, mas normalmente assume valores entre 18°C e 25°C. De forma

³³ O GLDAS é um produto de dados de reanálise de alta resolução global de nova geração desenvolvido em conjunto *National Aeronautics and Space Administration (NASA)*, o *Goddard Space Flight Center (GSFC)* e o *National Centers for Environmental Prediction (NCEP)* [275].

conservadora, a base de dados utiliza uma temperatura de referência igual a 24°C. Porém, como T_d e T_{wb} são ambos medidos em °C, geralmente para uma determinada condição ambiental, deve-se notar que, por definição, T_{wb} é inferior a T_d . Conseqüentemente, o CDD_{wb} acumulado mensal ou anual também registra graus-dia (*degree-days*) mais baixos em comparação ao CDD (que se baseia em T_d). Portanto, a temperatura de referência escolhida neste estudo pode ser considerada equivalente a uma T_{base} mais alta se medida em uma escala de bulbo seco. Para uma discussão detalhada e mais detalhes sobre a base de dados utilizada, os leitores são orientados a consultar MISTRY [202],

Os valores de CDD_{wb} coletados em *grid-cell* são então agregados espacialmente ao nível de estrato geográfico fornecido pela POF, com intuito de unificar as diferentes bases de dados utilizadas. Esse procedimento de unificação da base de dados climática com dados socioeconômicos é realizado de acordo com a metodologia de PAVANELLO *et al.* [194].

Assim, primeiro, as médias climatológicas de longo prazo do CDD_{wb} em graus-dias são calculadas utilizando as médias anuais fornecidas por MISTRY [202], começando em 1970 até o ano em que a POF foi realizada. Como, no Brasil, cada onda da pesquisa é conduzida ao longo de dois anos, foi considerado o ano em que as entrevistas foram iniciadas, 2002, 2008 e 2016³⁴. O longo período de dados é justificado pela recomendação da Organização Meteorológica Mundial (*World Meteorological Organization*), que preconiza o uso de um período médio de 30 anos para definir linha de base climática ou média climatológica [140].

Em segundo, os dados climáticos são mesclados com a base de microdados da POF, em nível estadual (Unidades da Federação), por tipo de estrato geográfico – unidade administrativa mais baixa em que é possível localizar geograficamente o domicílio. Para isso, os dados de CDD_{wb} são agregados a partir do nível *grid-cell* para os quatro níveis de estrato geográfico (áreas rurais, municípios das capitais, região metropolitana e outros municípios urbanos) e posteriormente agrupados em níveis estaduais, isso: (i) dentro dos limites administrativos, considerando arquivos de formato geoespacial; e (ii) utilizando

³⁴ A última onda da POF (2017-2018) conta com os dados climáticos até o ano de 2016. Último ano disponível na base de dados utilizada.

rotinas em R. Por fim, os dados de graus-dia são ponderados pela população usando os limites dos estratos geográficos.

O resumo das informações gerais dos dados climáticos utilizados na modelagem econométrica é disponibilizado na **Tabela 4**, enquanto os dados de CDD_{wb} utilizados para cada onda da POF são apresentados na **Seção 4.1.2** do capítulo dos resultados.

Tabela 4. Informações gerais sobre a base de dados climática utilizada na análise microeconométrica

Fonte dos dados	"CEI_0p25_1970_2016" [202]
Dados originais/não-tratados (<i>raw data</i>)	Temperatura (°C) de três em três horas [203] agregada em temperatura diária
Variável climática	Média de longo prazo de CDD_{wb}
Frequência	Anual
Resolução espacial	Resolução em célula a $0,25^\circ \times 0,25^\circ$ (cerca de 27 km x 27 km no equador) agregada em Estrato Geográfico por Unidades da Federação
Período de observação	1970-2016

Fonte: Elaboração própria com base em PAVANELLO *et al.* [194]

3.2 Modelagem microeconométrica

O processamento e análise dos microdados da POF e dados do CDD_{wb} realizados na seção anterior possibilitaram a realização de uma análise microeconométrica através de diferentes modelos.

No âmbito da microeconometria moderna, modelos utilizam-se da regressão para estudar a relação de dependência estatística entre uma variável dependente Y e uma matriz de regressores X^{35} , também chamadas de variáveis independentes. Logo, o propósito de uma análise econométrica é a predição condicional de Y dados valores de X (para mais detalhes sobre teoria econométrica consultar GUJARATI & PORTER [79] e, para particularidades da microeconometria moderna ver CAMERON & TRIVEDI [75]).

³⁵ Quando em negrito é usualmente interpretado como uma matriz.

No caso específico desta tese, a modelagem microeconômica busca identificar os principais impulsionadores da demanda residencial de eletricidade e estimar seu peso relativo na determinação da demanda. Em outras palavras, o objetivo principal é prever a demanda de eletricidade do setor residencial brasileiro (Y) a partir de diferentes fatores socioeconômicos e climáticos (X) e, ao mesmo tempo, entender o efeito marginal desses diferentes fatores na determinação da demanda.

Grande parte da dificuldade em se realizar uma análise microeconômica está relacionada à escolha entre dezenas de modelos, formas funcionais e estimadores disponíveis. Garantir a escolha adequada para o objetivo em questão é uma tarefa complexa, que requer um conhecimento teórico profundo. Adicionalmente ao processo de escolha, se faz indispensável uma série de testes estatísticos e de robustez para assegurar a confiabilidade dos resultados gerados pela modelagem. Em razão disso, este capítulo inclui boa parte da teoria microeconômica como justificativa das escolhas praticadas nesta proposta metodológica e para melhor compreensão acerca da análise proposta.

Consequente, nesta seção, serão apresentados os modelos microeconômicos desenvolvidos, as técnicas de estimação de parâmetros utilizadas em cada um deles, os principais testes realizados para garantir a adequação e funcionalidade dos modelos e os testes de robustez dos parâmetros estimados.

A **Figura 14** apresenta um fluxograma com as diferentes etapas da modelagem econométrica utilizado como guia nesta tese. Conforme o fluxograma, a análise microeconômica realizada tem início na demonstração da teoria econômica utilizada como base nos modelos estruturais, especificada na seção a seguir.

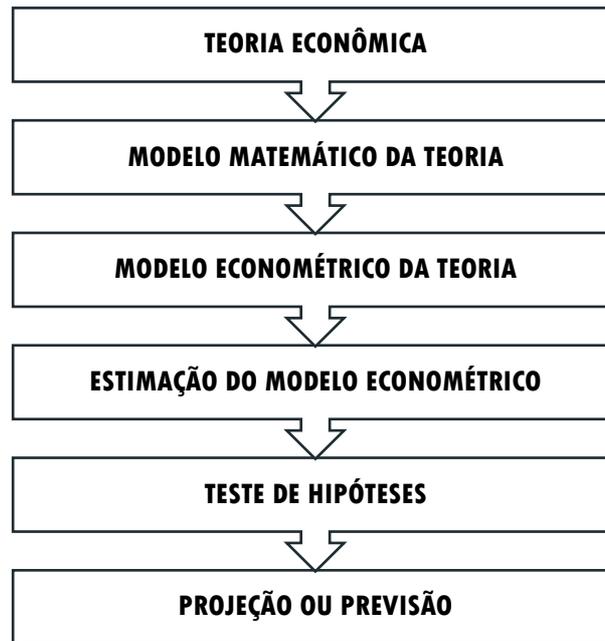


Figura 14. Anatomia da modelagem econométrica

Fonte: Elaboração própria com base em GUJARATI & PORTER [79]

3.2.1 Fundamentos econômicos, matemáticos e econométricos

Os modelos microeconômicos desenvolvidos nesta tese são categorizados como **modelos estruturais**. Modelos baseados na abordagem estrutural³⁶, diferentemente dos **modelos de forma reduzida**³⁷, dependem fortemente da teoria econômica e da inferência casual. Nesse tipo de abordagem, a teoria econômica: desempenha papel dominante na especificação do modelo; é usada para guiar a seleção de regressores, reduzindo significativamente o número de regressores potenciais; e influencia na escolha do procedimento de estimação [75]. No caso aqui apresentado, foi utilizada como base a teoria da produção doméstica³⁸.

³⁶ Modelos estruturais buscam identificar e estimar parâmetros fundamentais, às vezes chamados parâmetros profundos (ou estruturais), que caracterizam gostos e preferências individuais e/ou relações tecnológicas [75].

³⁷ Na outra extremidade do espectro encontra-se a abordagem de forma reduzida, investigações empíricas que fazem muito menos uso da teoria econômica. Seu objetivo é modelar a relação (ou relações) entre variáveis de resposta de interesse condicionalmente a variáveis que o pesquisador considera como dadas, ou exógenas (endogeneidade versus exogeneidade). O ponto essencial é que a análise de forma reduzida nem sempre leva em consideração todas as interdependências causais. É um modelo de regressão em que o foco está na previsão de y dados regressores x , e não na interpretação causal dos parâmetros de regressão [75].

³⁸ Para melhor entendimento da teoria e uma análise mais detalhada, ver BECKER [276] e DEATON & MUELLBAUER [204]; e consultar DUBIN [277] e FLAIG [278] para uma aplicação da teoria da produção doméstica à análise da demanda de eletricidade [42].

Segundo a teoria da produção doméstica, a demanda residencial de eletricidade é derivada da demanda por serviços energéticos. As famílias não demandam eletricidade para consumo direto, mas sim para o consumo de uma série de bens e serviços finais (condicionamento térmico, luz, água quente, comida preparada etc.). Como tal, a eletricidade pode ser considerada um bem intermediário, adquirido como insumo para obter outros bens úteis para as famílias [42-44].

A teoria econômica é fundamental na especificação do modelo. Assim, o modelo de FILIPPINI [42]³⁹ foi escolhido e adaptado para a análise proposta. De acordo com tal modelo, para produzir o chamado “bem energético composto” (X), as famílias combinam eletricidade (E), combustível alternativo (F) e equipamento de capital (eletrodomésticos) (K), segundo a função de produção descrita na **Equação (3.2)**:

$$X = X(E, F, K) \quad (3.2)$$

Supõe-se também que as famílias possuem uma função de utilidade com as propriedades usuais de diferenciabilidade e curvatura (do inglês *differentiability* e *curvature*). Para mais, a utilidade das famílias não pode ser obtida independentemente de qualquer um desses itens contidos na **Equação (3.2)** [42-44]. Consequentemente, a família tem uma função de utilidade que depende da quantidade do bem energético composto (X), da quantidade adquirida de um bem numérico composto (Y), que fornece utilidade direta, e das características domiciliares que influenciam suas preferências (Z), por exemplo, socioeconômicas e geográficas.

A função de utilidade da família é descrita na **Equação (3.3)**, também adaptada de FILIPPINI [42].

$$U = U(X, Y; Z) \quad (3.3)$$

³⁹ A literatura sobre a demanda residencial de eletricidade foi bem desenvolvida na década de 1990 e ampliada por FILIPPINI *et al.* usando preço/renda e condições climáticas como variáveis explicativas.

Conforme apontado por DEATON & MUELLBAUE [204], o processo de decisão da família demonstrado anteriormente pode ser modelado matematicamente em cada período como um problema de otimização em dois estágios. No primeiro estágio, o consumidor se comporta como uma empresa, minimizando os custos de produção do bem energético, enquanto, no segundo estágio, maximiza sua utilidade. O problema para o consumidor na primeira fase é descrito matematicamente segundo a **Equação (3.4)**:

$$\begin{aligned}
 & \text{Min } p^E E + p^F F + p^K K \\
 & \text{s. t} \\
 & X = X(E, F, K)
 \end{aligned}
 \tag{3.4}$$

Onde p^e é o preço da eletricidade, p^F é o preço do combustível alternativo, e p^K é o preço do estoque de equipamentos. Como resultado, a função de custo é obtida através de:

$$C = C(p^E E + p^F F + p^K K, X)
 \tag{3.5}$$

Aplicando o Lema de Shepard [205], obtemos a demanda derivada dos insumos, então, para eletricidade, temos:

$$\begin{aligned}
 E &= \frac{\partial C(p^E, p^F, p^K, X)}{\partial p^E} \\
 &= E(p^E, p^F, p^K, X)
 \end{aligned}
 \tag{3.6}$$

No segundo estágio, a família maximiza sua utilidade, sujeita à sua restrição orçamentária,

$$\begin{aligned}
& \text{Max } U(X, Y; Z) \\
& \text{s. t} \\
& C(p^E, p^F, p^K, X) + Y = R
\end{aligned} \tag{3.7}$$

Onde R é o nível de renda familiar. Resolvendo esse problema, obtemos as funções de demanda dos bens X e Y . No caso do bem energético composto (**Equação (3.8)**):

$$X^* = X^*(p^E, p^F, p^K, R; Z) \tag{3.8}$$

Finalmente, substituindo essa função de demanda na função de demanda derivada da eletricidade, temos:

$$\begin{aligned}
E &= E(p^E, p^F, p^K, X^*(p^E, p^F, p^K, R; Z)) \\
&= E(p^E, p^F, p^K, R; Z)
\end{aligned} \tag{3.9}$$

Após definir a função de demanda de eletricidade (**Equação (3.9)**), é possível especificar a forma funcional econométrica para estimá-la. Embora não haja consenso na literatura sobre a forma funcional mais adequada, a maioria dos estudos microeconômicos que utilizam equações de demanda individual de energia adotam a forma linear logarítmica [43]. Assim, optamos por seguir a literatura convencional (como por exemplo FILIPPINI & PACHAURI [122], ARTHUR *et al.* [206] e ZHOU & TENG [69] e LIU *et al.* [82]) e assumir relacionamento linear nos parâmetros⁴⁰.

Portanto, os modelos desenvolvidos neste trabalho consistem em funções lineares nos parâmetros com equações logarítmicas para o consumo de eletricidade. A principal

⁴⁰ Quando utilizado o termo “modelo linear”, estamos nos referindo a modelos com parâmetros lineares e/ou que possam ser transformados de modo que tenham parâmetros lineares, podendo ou não ter variáveis não-lineares. Em contrapartida, se o modelo é não-linear nos parâmetros, é caracterizado como de regressão não-linear (nos parâmetros), mesmo com variáveis lineares [79].

consequência disso é que os coeficientes a serem estimados equivalem a elasticidades⁴¹ (quando a variável dependente e a variável explanatória estão em forma de logaritmo) ou semielasticidades⁴² (quando a variável dependente está em forma de logaritmo, e, a variável explanatória, em forma linear) [42,79].

É importante ressaltar que microdados de preço de eletrodomésticos pagos pelas famílias estão na maioria dos casos indisponíveis e, quando disponíveis nas pesquisas domiciliares, como a POF, são pouco confiáveis. Logo, em concordância com HALVORSEN [207] e FILIPPINI [42], os preços dos eletrodomésticos foram considerados constantes e excluídos do modelo sem causar viés na estimativa.

Da mesma forma, dados de preço de gás natural ou GLP (gás liquefeito de petróleo) – possíveis substitutos para eletricidade –, também foram deixados fora da análise, uma vez que o uso de tais fontes implicaria em uma mudança de equipamento para prover o mesmo serviço energético. De acordo com CABRAL *et al.* [208], dois bens são substitutos quando a variação do preço de um bem gera variação proporcional na demanda do outro bem, sem a necessidade de troca de equipamento ou tecnologia para estabelecer a substituição de um bem pelo outro. Eletricidade e gás natural/GLP não são considerados bens substitutos no Brasil, uma vez que, caso ocorra aumento do preço da eletricidade, o aumento na demanda de gás natural/GLP só seria possível através de troca de tecnologia, o que no curto prazo pode não ser economicamente viável para o consumidor [208].

Ademais, este trabalho utiliza uma abordagem de equilíbrio parcial, pois, assim como no caso da base de dados do recente estudo brasileiro guiado por PEREIRA UHR *et al.* (PEREIRA UHR, SQUARIZE CHAGAS, *et al.*, 2019^a), a estrutura de microdados disponível na POF não permite a realização de uma análise sistêmica que considere o consumo de eletricidade e todos seus substitutos, o que possibilitaria um modelo de Equilíbrio Geral Computável, conhecido como CGE (*Computable General Equilibrium*, em inglês).

⁴¹ Uma variação percentual no regressando para uma variação percentual do regressor. Isso só se aplica se o regressor for quantitativo [79].

⁴² Variação percentual no regressando para uma variação unitária do regressor. Isso só se aplica se o regressor for quantitativo [79].

Nas seções a seguir, são detalhadas as configurações dos modelos microeconômicos desenvolvidos nesta tese.

3.2.2 Modelagem da heterogeneidade

Como apontado no **Capítulo 2**, uma base de microdados sugere alto nível de desagregação e, conseqüentemente, manifesta o problema da heterogeneidade [75-79]. Logo, uma variedade de abordagens para modelar heterogeneidade coexiste na microeconometria. Contudo, a escolha da abordagem depende diretamente da natureza da base de dados utilizada como entrada.

Dados de corte transversal (em inglês, *cross-section data*) possuem uma ou mais variáveis coletadas no mesmo ponto do tempo [79]. Em outras palavras, são obtidos observando um conjunto de variáveis W , para a amostra S_t em algum t . Embora seja geralmente impraticável amostrar todas as famílias simultaneamente, todos os dados são considerados uma fotografia das características de cada indivíduo, que é um subconjunto da população e usado para fazer inferências sobre a mesma [75].

Os modelos *cross-section* são considerados **modelos estáticos**, ou seja, diferentemente dos **modelos dinâmicos**, não são capazes de capturar a dependência intertemporal [75-79]. A ausência de dinâmica é uma suposição comum nesse tipo de análise, o que implicitamente gera um **equilíbrio estocástico**, com o desvio do equilíbrio sendo representado por perturbações aleatórias serialmente independentes [75].

Tais limitações potenciais de uma análise *cross-section* podem ser superadas caso dados longitudinais estejam disponíveis. As principais vantagens potenciais dos dados longitudinais, também chamados de dados em painel no caso da análise micro, em comparação aos dados transversais surgem da capacidade de observar os indivíduos ao longo do tempo ($t > 1$). Isso torna possível controlar a heterogeneidade interindividual não-observada, as diferenças nas condições iniciais e a dependência dinâmica dos resultados. No entanto, em muitos casos, dados de painel genuínos não estão disponíveis [75].

Esse é o caso da POF, base de dados utilizada nos modelos microeconômicos desenvolvidos nesta tese. A POF, como abordado na **Seção 3.1.1**, coleta uma grande amostra anual de microdados de despesas familiares no Brasil, mas, a cada ano da pesquisa, famílias diferentes são entrevistadas [186]. Como resultado, o que se observa

são várias seções transversais repetidas⁴³. Nesses casos, as respostas dos questionários são derivadas de uma série de pesquisas de amostras independentes, onde independência significa que cada indivíduo aparece em apenas um ano da pesquisa. Como o *design* da amostra não busca reter as mesmas unidades ao longo dos anos, conseqüentemente as informações sobre a dependência dinâmica do comportamento individual são perdidas, tornando inviável a criação de um painel genuíno [75].

Conseqüentemente, devido à natureza *cross-section* dos dados de entrada socioeconômicos, esta tese aborda modelos que lidam com a heterogeneidade observada diretamente e que, portanto, pode ser controlada.

De acordo com FILIPPINI [42], no que diz respeito à escolha da técnica econométrica, apesar dos diversos tipos de modelos com foco em dados *cross-section* (ou seja, heterogeneidade entre indivíduos) serem encontrados na literatura, a alternativa de modelar a heterogeneidade observada por meio de **variáveis binárias** é uma das três abordagens mais amplamente utilizadas. A seção a seguir detalha o modelo com variáveis binárias escolhido para a análise microeconômica.

3.2.2.1 Modelos de análise de covariância

Frequentemente, a variável dependente (regressando) de modelos de regressão é influenciada não só pelas variáveis quantitativas/proporcionais (como renda, produto, preços, custos, altura, temperatura etc.), mas também por variáveis de natureza essencialmente qualitativa ou escala nominal (como gênero, raça, cor, religião, nacionalidade, região geográfica etc.). “Tais variáveis são conhecidas ainda como variáveis indicadoras, de categoria, qualitativas ou binárias (*dummies*)” [79] (p. 288).

As **variáveis *dummies*** são um dispositivo para classificar dados em categorias mutuamente excludentes. Em geral, indicam a presença ou ausência de uma “qualidade”

⁴³ Além disso, se apenas um painel muito curto estiver disponível (por exemplo, $T=2$), os dados de seções transversais repetidas são atraentes se puderem gerar uma amostra maior e mais rica (modelo *pooling*). Para um modelo de efeitos aleatórios, dados de seção transversal repetidos não representam desafios. Simplesmente realiza-se uma regressão combinada de y_{it} em x_{it} , e a inferência estatística é realmente simplificada, pois a correção é necessária apenas para heterocedasticidade, visto que aqui os erros são independentes tanto de i quanto de t . No entanto, em um modelo de efeitos fixos, a regressão combinada leva a estimativas de parâmetros inconsistentes. Além disso, métodos alternativos, como a estimativa dentro ou nas primeiras diferenças, são inviáveis se os indivíduos forem observados em apenas um ponto no tempo. Isto posto, dados de seção transversal repetidos são usados para construir pseudo-painéis, ou dados de painel sintéticos, que têm algumas das vantagens dos dados de painel genuínos, mais notavelmente a capacidade de controlar para efeitos fixos [75].

ou atributo e por isso são essencialmente variáveis nominais, sem escala natural de medida, que assumem valores zero ou um, em que um indica a presença (ou posse) do atributo em questão, e, zero, sua ausência [79].

Modelos de análise de covariância (ANCOVA) misturam o uso de variáveis independentes quantitativas e qualitativas. São, portanto, uma extensão dos modelos de análise de variância, conhecidos como ANOVA⁴⁴, uma vez que incluem – além de avaliação da relação estatística entre um regressando quantitativo e regressores qualitativos – um método de controle estatístico dos efeitos de regressores quantitativos, chamados **covariáveis** ou variáveis de controle [75,79].

Nesse tipo de modelo, se uma variável qualitativa tem m categorias, é recomendado introduzir $m-1$ *dummies* para evitar a **armadilha da variável binária**, que pode resultar em uma situação de colinearidade perfeita ou **multicolinearidade perfeita**, que será abordada mais à frente. Com essa estratégia, é possível controlar a heterogeneidade observada de variáveis qualitativas comparando a **categoria de controle**⁴⁵ – categoria para a qual nenhuma variável binária é atribuída –, também chamada categoria-base, de comparação, de referência ou categoria omitida, às outras categorias nominais atribuídas. Nesse caso, o valor do intercepto representa o valor médio da categoria de referência, e os coeficientes ligados às *dummies* são chamados de coeficientes diferenciais de intercepto, pois têm a função de informar quanto a categoria que recebe o valor um difere do coeficiente do intercepto da categoria de controle [79].

Sendo assim, e com base na suposição teórica de que a demanda de eletricidade residencial depende da renda das famílias, do preço da eletricidade, e de um conjunto de covariáveis que representam características socioeconômicas e condições climáticas (**Equação (3.9)**), a função logarítmica para o regressando é utilizada para definir o **modelo de demanda de eletricidade residencial**, a ser estimado para cada um dos três últimos anos da POF, segundo a **Equação (3.10)**:

⁴⁴ ANOVA é um tipo de modelo de regressão que contém regressores de natureza exclusivamente *dummy*. Tais modelos são utilizados para avaliar o significado estatístico da relação entre um regressando quantitativo y e regressores qualitativos d . São, por essa característica, usados para comparar as diferenças nos valores médios de dois ou mais grupos ou categorias [79].

⁴⁵ Quando a variável qualitativa em questão possui mais de uma categoria, a escolha da categoria de controle fica estritamente a cargo do pesquisador, mas geralmente a escolha do referencial é ditada por determinado problema [79].

$$\ln(Y_i) = \alpha_0 + \beta_1 \ln I_i + \beta_2 \ln P_i + \beta_3 CDD_{wb_i} + \boldsymbol{\gamma} (\ln I_i \times \mathbf{D}_i) + \mathbf{X}_i \boldsymbol{\beta} + \epsilon_i \quad (3.10)$$

$$i = 1, \dots, N$$

Onde:

i = domicílio como representante da família (também chamada de *household*);

y_i = consumo de eletricidade da família i (kWh/ano);

α_0 = termo constante (intercepto da curva de demanda);

β_1 = elasticidade-renda da demanda de eletricidade;

I_i = renda da família i (BRL₂₀₁₇/ano);

β_2 = elasticidade-preço da demanda de eletricidade;

P_i = preço da eletricidade pago pela família i (BRL₂₀₁₇/kWh);

β_3 = semi-elasticidade da demanda de eletricidade associada à variável CDD_{wb} ;

CDD_{wb_i} = média anual de graus-dias considerando a temperatura de bulbo;

$\boldsymbol{\gamma}$ = vetor de coeficientes angulares diferenciais⁴⁶ associado ao efeito multiplicativo da renda com *dummy* para decis de renda ($\ln I_i \times \mathbf{D}_i$);

$\ln I_i \times \mathbf{D}_i$ = termo interativo ou efeito multiplicativo relacionado à renda da família ith e ao fato dela pertencer decil dth ;

\mathbf{X}_i = matriz de covariáveis;

$\boldsymbol{\beta}$ = vetor dos coeficientes a serem estimados que identifica os efeitos das variáveis controle na demanda de eletricidade; e

ϵ_i = termo de erro aleatório.

3.2.2.2 Inferência estatística

Após a especificação do modelo econométrico (**Equação (3.10)**), é possível definir o estimador que será utilizado na **estimação dos parâmetros** do modelo. A estimativa numérica dos parâmetros fornece conteúdo empírico à função de demanda de

⁴⁶ Também chamado de deslocador do coeficiente angular, indica o efeito da introdução da forma interativa, variável *dummy versus* variável ordinal/quantitativa [79], ou, neste caso específico, o efeito da família ith pertencer ao decil dth multiplicado por X (renda). Ou seja, o quanto a elasticidade-renda das famílias que pertencem ao decil dth difere daquelas da categoria de controle.

eletricidade. Esse é o primeiro passo do processo de **inferência estatística**, que também consiste no chamado **teste de hipóteses**.

O método dos Mínimos Quadrados Ordinários – MQO ou OLS (do inglês *Ordinary Least Squares*) – é adotado no processo de estimação dos parâmetros. Basicamente, ele fornece estimativas únicas dos coeficientes (melhor ajuste possível do modelo) de tal forma que, para qualquer conjunto de dados, a soma dos quadrados das diferenças entre o valor estimado e os dados observados seja a menor possível. Em outras palavras, minimiza a soma do valor absoluto dos resíduos, levando ao estimador de menores desvios absolutos (minimizar $\sum \hat{\epsilon}_i$) (para entender melhor sobre o método, ler CAMERON & TRIVEDI [75] e GUJARATI & PORTER [79]).

Segundo GUJARATI & PORTER [79], o MQO tem propriedades estatísticas bastante atraentes, o que fez com se tornasse um dos métodos de análise de regressão mais poderosos e difundidos na literatura. O MQO é compatível com o modelo ANCOVA escolhido.

Sob as hipóteses do modelo clássico de regressão linear, é necessário demonstrar que os estimadores desses parâmetros satisfazem algumas propriedades estatísticas desejáveis. Os estimadores precisam ser **BLUE**⁴⁷ (do inglês, *best linear unbiased estimator*), ou seja, devem ser não viesados (ou não tendenciosos) e ter variância mínima [79].

Pelo **Teorema de Gauss-Markov**, para garantir que o estimador é BLUE, ao estimar a regressão por MQO, é preciso que as premissas do MCRL⁴⁸ (modelo clássico de regressão linear) sejam respeitadas, o que nem sempre é o caso. Muitas vezes, modelos ou amostras violam alguma ou algumas premissas do MCRL, fazendo com que o estimador MQO deixe de ser BLUE. Nesses casos, é necessário substituir o MQO por outro que seja robusto ao relaxamento das premissas. As fontes mais comuns de violação de premissas são: a multicolinearidade, a heterocedasticidade, a autocorrelação e os erros de especificação do modelo [79].

⁴⁷ Melhor estimador linear não viesado (MELNT).

⁴⁸ Para entender melhor sobre o Teorema de Gauss e todas as hipóteses do MCRL, consulte [79].

Existem diferentes testes que foram aplicados para garantir um estimador BLUE, mas como argumentam CAMERON & TRIVEDI [75] (p. 425)⁴⁹, em uma tradução livre para o português: “modelagem econométrica é composta por um ciclo inicial de especificação do modelo, estimação, checagem de diagnósticos e reespecificação do modelo.”

Um ponto importante a ressaltar é que virtualmente toda inferência estatística realizada em uma modelagem microeconômica é baseada na **Teoria Assintótica**. Esta trata do que acontece a uma estatística ou estimador quando o tamanho da amostra se torna muito grande, o que é o caso não só para estimadores não-lineares, mas também para estimadores lineares, como o MQO e **Variável Instrumental** (*Instrumental Variable* – IV), com **erro padrão robusto** [76].

Nesse caso, os testes estatísticos seguem uma distribuição assintoticamente **padrão normal** (Z) em vez de uma distribuição **t de Student** $t(n)$ e uma distribuição qui-quadrada $[x^2(h)]$ no lugar de $F(h,n)$. No entanto, a mudança no tipo de distribuição é relativamente insignificante, ganhando importância somente nos casos em que $n < 30$. Assim, as duas distribuições são consideradas idênticas para $n \rightarrow \infty$ ⁵⁰. Para dados *cross-section*, n representa o grau de liberdade que é definido pelo total de observações N menos o número de regressores utilizados (k), onde h representa o número de restrições [76].

A seguir, uma explicação dos principais testes realizados na modelagem de dados transversais.

3.2.2.2.1 *Teste de heterocedasticidade (Breusch-Pagan Test)*

Segundo CAMERON & TRIVEDI [75], para modelos microeconômicos *cross-section* típicos que se utilizam de MQO, os termos de erro do modelo (ϵ_i) são geralmente heterocedásticos e muitos problemas derivam disso. Em outras palavras, a variância do termo de erro não é mínima, pois ϵ_i varia em função do regressor, o que contraria uma das premissas de um estimador BLUE. Desse modo, o primeiro passo do teste de

⁴⁹ No original: “*Econometric modeling is composed of a cycle of initial model specification, estimation, diagnostic checks, and model respecification.*”

⁵⁰ A distribuição t tem caudas mais longas, levando a valores p e valores críticos maiores do que o normal padrão em níveis convencionais de significância, como 0,05.

hipóteses para garantir um estimador BLUE e inferências estatísticas válidas sobre a população foi verificar a hipótese de homocedasticidade.

Os modelos foram testados para a hipótese de homocedasticidade através do **Teste Breusch-Pagan** [209]. A hipótese nula (H_0) do teste é a presença de homocedasticidade, e seu resultado será apresentado na **Seção 4.2.1.2.1**, no capítulo de resultados. Contudo, é importante destacar que o detalhamento sobre a formulação e interpretação dos testes estatísticos foge do escopo desta tese. Para entender melhor sobre testes de hipóteses, consultar GUJARATI & PORTER [79].

3.2.2.2.2 *Teste de especificação (Wald Test)*

O teste de Wald [210], na microeconometria, é a abordagem mais comum para decidir sobre a adequação/especificação de um modelo. Dentre os testes de hipótese, é o proeminente dentro da microeconometria [75].

O teste adapta-se a modelos com maior complexidade e determina se os dados suportam a necessidade desse novo modelo. É também capaz de testar variáveis omitidas. Apesar de testar a remoção de variáveis, o teste de especificação mais comum é incluir um regressor adicional e testar se ele é estatisticamente significativo [76]. A variável adicional pode ser:

- Nova variável;
- Transformação da variável (por exemplo, quadrática de idade); ou
- Termo de interação.

O teste de Wald é amplamente usado, porque *softwares* modernos, como o R, geralmente permitem a estimativa do modelo irrestrito, mesmo que seja mais complexo do que o modelo restrito. Além disso, com o avanço da computação, *softwares* modernos fornecem estimativas de matriz de variância robustas que permitem testes de Wald sob suposições de distribuição relativamente fracas. Assim, pode-se utilizá-lo em situações em que os erros são potencialmente heterocedásticos [75,76], razão pela qual foi o escolhido dentre os diferentes testes de especificação disponíveis. Sua H_0 indica que os coeficientes das variáveis testadas são iguais a zero. A melhor especificação do modelo baseada nos resultados do teste de Wald é observada na **Seção 4.2.1.2.2** no capítulo dos resultados.

O **Quadro 2** recapitula e descreve as variáveis independentes potenciais dos modelos, as quais já tiveram seu processamento demonstrado na **Seção 3.1**. Tais variáveis são consideradas potenciais, pois sua relevância estatística só é confirmada após a realização da inferência estatística, o que ajuda a definir se o regressor realmente pertence ao modelo final.

Quadro 2. Variáveis independentes potenciais da análise microeconômica

Nome da variável	Categoria controle/Unidade de medida
Ln Renda	Ln BRL ₂₀₁₇
Ln Preço _E	Ln BRL ₂₀₁₇ /kWh
CDD _{wb} médio	Média de graus-dias
Urbano	Urbano
Norte	Centro-Oeste
Nordeste	
Sul	
Sudeste	
Índice da <i>household</i>	1 = Alta qualidade
Residência própria	1 = Próprio
Tipo de domicílio	1 = Casa
Cômodos	Número de cômodos
Membros da família	Numeral
Raça	1= Branco
Idade	Anos
Sexo	1 = Homem
Anos de educação	Anos
AC	Numeral
Ventilador	
PC	
Micro-ondas	
TV	
Geladeira	
Freezer	
Máquina de lavar roupa	
Ferro de passar	
Rádio	
Máquina de costura	
Aspirador	
Chuveiro elétrico	
Decil 2	
Decil 3	
Decil 4	
Decil 5	
Decil 6	

Decil 7	
Decil 8	
Decil 9	
Decil 10	

Nota: Na última coluna do quadro, se a variável for qualitativa, ela tem uma categoria de controle. Caso contrário, coloca-se a unidade de medida da variável quantitativa.

Fonte: Elaboração própria

3.2.2.2.3 *Teste de multicolinearidade*

Os termos colinearidade e multicolinearidade estão relacionados à natureza da relação linear entre duas ou mais variáveis independentes (regressores). Caso exista uma relação linear exata entre dois regressores, por exemplo X_2 e X_3 , então eles são classificados como colineares ou linearmente dependentes. O mesmo acontece para a multicolinearidade quando nos referimos a mais de dois regressores. Por outro lado, a ausência de colinearidade significa que nenhum dos regressores pode ser expresso como uma combinação linear exata dos demais regressores do modelo [79].

Dessa forma, segundo GUJARATI & PORTER [79], a hipótese de ausência de multicolinearidade perfeita exige que se inclua na função de regressão populacional apenas aquelas variáveis que não sejam funções lineares exatas de uma ou mais variáveis do modelo. No entanto, na prática, quando coletamos dados para análises, nada garante a ausência de correlação⁵¹ entre regressores. De fato, na maior parte do trabalho aplicado, é quase impossível encontrar duas ou mais variáveis (econômicas) que não tenham algum tipo de correlação. O primordial aqui é que não exista uma relação linear exata entre regressores. Consequentemente, a multicolinearidade não exclui relações não-lineares exatas entre variáveis, garantindo a hipótese de ausência de multicolinearidade [75,79].

É possível verificar a correlação entre duas ou mais variáveis – hipótese de ausência de multicolinearidade – através da matriz de correlação, a qual tem seus resultados apresentados na **Seção 4.2.1.2.3**.

⁵¹ A análise de correlação tem como objetivo principal medir a força ou o grau de associação linear entre duas variáveis aleatórias. Consequentemente, o coeficiente de correlação (r) mede a força dessa associação linear e seu valor pode variar entre -1 e +1, posto que, caso duas variáveis aleatórias sejam estatisticamente independentes, o coeficiente de correlação entre elas é igual a zero [79].

3.2.3 Testes de robustez

Após garantir que os modelos escolhidos sejam os mais adequados às análises propostas, é recomendado garantir a robustez de seus parâmetros. Para o propósito desta tese, e de acordo com HUBER [211], “robustez” significa insensibilidade a pequenos desvios de premissas. Ou seja, busca-se garantir que o método de análise estatística utilizado seja robusto (não sensível) a pequenas violações/desvios das suposições originais. A situação mais típica refere-se a potenciais desvios da forma da distribuição de probabilidade assumida na análise. Contudo, pode estar também associado a outros tipos de exigências ou suposições, tais como independência, mesma distribuição ou procedimento de aleatorização. Logo, os métodos robustos têm o objetivo de minimizar o impacto sob as estimativas dos parâmetros, visando a resistência dos estimadores [211-213].

Isto posto, nesta seção são fornecidas evidências de que os modelos são robustos a uma variedade de fatores que podem confundir a estimativa ou levar a estimativas tendenciosas. Em particular, foram consideradas três fontes de problema que serão abordadas com mais detalhes a seguir: (i) existência de valores extremos (*outliers*); (ii) utilização do peso amostral; e (iii) endogeneidade do preço marginal.

3.2.3.1 Resistência aos outliers

O termo *outlier* (na língua inglesa) é o nome dado para observações extremas, isto é, observações que desviam consideravelmente do intervalo/alcance usual do dado. Esse tipo de observação pode surgir na base de dados por diferentes razões, como erro de digitação, erro de conversão e erro de medição [183]. *Outliers* são, portanto, possíveis erros ou observações aparentemente inconsistentes com as demais observações de um mesmo conjunto de dados.

O método dos MQO é sensível à presença de observações extremas, pois estas recebem um peso grande na estimativa de coeficientes. Assim, *outliers* podem levar a estimativas fortemente distorcidas dos coeficientes de regressão [183], e, mesmo que tais observações tenham sido reportadas corretamente na base de dados, não contendo nenhum dos erros mencionados anteriormente, é recomendável excluí-las ao testar a

robustez do modelo de MQO. Em outras palavras, um *outlier* é uma observação mal prevista pelo modelo [76,183].

Existem diversos métodos que auxiliam na detecção de *outliers*, como o método de Amplitude Interquartil⁵² (IQR, do inglês *Interquartile Range*) [214], representado graficamente pelo Diagrama de Caixa (*Boxplot*), o método Percentil, o método *Hampel filter*⁵³ [215], etc. No entanto, a escolha entre remover ou manter determinado *outlier* depende: (i) do contexto da análise; (ii) se os testes realizados no conjunto de dados são robustos para *outliers* ou não; e (iii) quão longe está o *outlier* de outras observações. Para guiar essa decisão, foram realizados testes com os diferentes critérios. Ao fim, o método Percentil foi escolhido devido à sua compatibilidade com o contexto da análise.

O método escolhido para detecção de *outliers*, como o próprio nome já indica, é baseado em percentis. O percentil corta o dado em 100 partes iguais por ordem crescente de dados. Por exemplo, caso o 99º percentil seja selecionado ($q_{0.99}$) como o limite superior, o dado será cortado de forma a gerar um valor de corte em que 1% das observações se encontre acima dele. Ao determinar o percentil inferior e superior, todas as observações acima ou abaixo do valor de corte (intervalo limite determinado pelos percentis) serão consideradas *outliers* potenciais [216].

Neste presente estudo, as variáveis relevantes para a remoção de *outliers* são: consumo de eletricidade (Ln Eletricidade), despesa com eletricidade (Ln Despesa_E) e preço da eletricidade (Ln Preço_E). Após testes com diferentes valores, os percentis 0,01% (limite inferior) e 99,9% (limite superior) foram selecionados para remoção da quantidade de eletricidade demandada e despesa com eletricidade.

Os percentis foram selecionados de forma a garantir que valores extremos fossem retirados, mas um grau de heterogeneidade significativo fosse mantido. A escolha dos valores também foi guiada por um critério secundário – a garantia de uma distribuição

⁵² O método IQR, comumente utilizado para remoção de *outliers*, avalia a dispersão de dados após ordená-los em ordem crescente. O intervalo interquartil é calculado com base no cálculo de quartis, sendo o primeiro quartil (inferior, $Q_1 = 25\%$ dos dados), o quartil intermediário (mediana, $Q_2 = 50\%$ dos dados), o terceiro quartil (superior, $Q_3 = 75\%$ dos dados), que estão ligados ao conceito de quantil, sendo 25% o ponto de ruptura desses estimadores. A diferença entre o quartil superior e o quartil inferior determina o intervalo interquartil.

⁵³ HAMPEL [215] sugeriu que os estimadores clássicos de locação e dispersão fossem substituídos pela mediana e o desvio absoluto mediano em torno da mediana, respectivamente.

normal do dado, também chamada distribuição gaussiana, compatível com bases de dados que tendem ao infinito. Histogramas foram utilizados como verificadores.

No caso do preço da eletricidade, o valor do percentil aplicado anteriormente não foi suficiente para garantir o critério secundário de distribuição normal do dado. Foi necessário selecionar valores de percentil mais agressivos, de 1% e 99%.

O processo de remoção de *outliers* foi realizado considerando as particularidades de cada um dos anos da POF. A **Seção 4.2.2** apresenta os resultados da estimação considerando a retirada dos *outliers*.

3.2.3.2 *Peso amostral*

A pesquisa microeconômica é geralmente realizada com base em dados coletados por meio de levantamento de uma amostra da população de interesse. A suposição estatística mais simples para dados de pesquisa é a amostragem aleatória simples (*simple random sampling* – SRS), em que cada membro da população tem a mesma probabilidade de ser incluído na amostra. Nesse caso, é razoável basear a inferência estatística na suposição de que os dados (Y_i, X_i) são independentes sobre i e identicamente distribuídos. Na prática, entretanto, o SRS quase nunca é a suposição correta para dados de pesquisa [75,76].

Em vez disso, esquemas alternativos de amostragem são usados para reduzir os custos de pesquisa e aumentar a precisão da estimativa para subgrupos da população que são de particular interesse. Por exemplo, uma pesquisa domiciliar pode primeiro dividir a população geograficamente em subgrupos, como vilas ou subúrbios, com diferentes taxas de amostragem. As entrevistas podem ser conduzidas em domicílios agrupados em pequenas áreas geográficas, como quarteirões da cidade. Os dados (Y_i, X_i) claramente não são mais *iid* [75,76].

Como já comentado na **Seção 3.1.1**, esse é o caso da POF. Dessa forma, a pesquisa atribui a cada observação um peso amostral que corrige as probabilidades, fazendo com que as observações se tornem representativas do universo [186].

Entre os objetivos desta tese está a realização de uma abordagem descritiva ou um resumo de dados, em que a regressão é então interpretada como uma estimativa dos coeficientes do censo. Além disso, queremos utilizá-la como uma ferramenta para

descrever respostas da população (**Capítulo 4**). Assim, de acordo com CAMERON & TRIVEDI [75,76], os pesos proporcionais devem ser utilizados na inferência estatística. Porém deve-se atentar que muitas pesquisas fornecem pesos de amostragem destinados a ser inversamente proporcionais à probabilidade de serem amostrados; nesse caso, esses pesos podem ser usados para obter estimadores imparciais das características da população. Isso pode ser corrigido por ponderação, usando pesos amostrais inversamente proporcionais à probabilidade de inclusão na amostra. Os pesos não precisam somar um, desde que divididos pela soma dos pesos [75].

A **Seção 4.2.2** apresenta os resultados da estimação considerando o peso amostral.

3.2.3.3 *O problema da endogeneidade do preço*

Uma definição ampla do termo **endogeneidade** diz que um regressor (X) é endógeno quando correlacionado com o termo de erro (ϵ). Quando são usados dados observacionais de seção transversal, a endogeneidade é muito provável de ocorrer e requer atenção. De acordo com GUJARATI & PORTER [79], se qualquer um dos regressores for endógeno, então, em geral, as estimativas dos MQO de todos os parâmetros de regressão são inconsistentes (a menos que o regressor exógeno não esteja correlacionado com o regressor endógeno). Assim, em uma abordagem utilizando MQO, o problema da endogeneidade leva a um estimador viesado, ou seja, o estimador não é BLUE.

Conforme FELL *et al.* [217], há duas possíveis fontes de endogeneidade de preço, a **simultaneidade** e o **erro de medição**, e, de acordo com ALBERINI & FILIPPINI [218], é preciso primeiro entender qual a variável preço mais apropriada a ser estimada, para que esta fonte de endogeneidade seja detectada e, posteriormente, enfrentada. Assim, ALBERINI & FILIPPINI [218] apontam três principais problemas relacionados à variável preço de energia:

1. Qual a variável preço mais apropriada a ser estimada;
2. Se a variável é endógena ou exógena; e
3. Se existe erro de medição.

Em relação à **escolha da variável preço mais apropriada**, segundo BORENSTEIN [219], existem três medidas possíveis no contexto de preço de

eletricidade ao consumidor final: preço marginal *ex post*⁵⁴, preço marginal esperado e preço médio *ex post* (Figura 15). O grande debate entre os pesquisadores, no entanto, circunda a escolha entre a utilização de preço médio *versus* preço marginal [220].

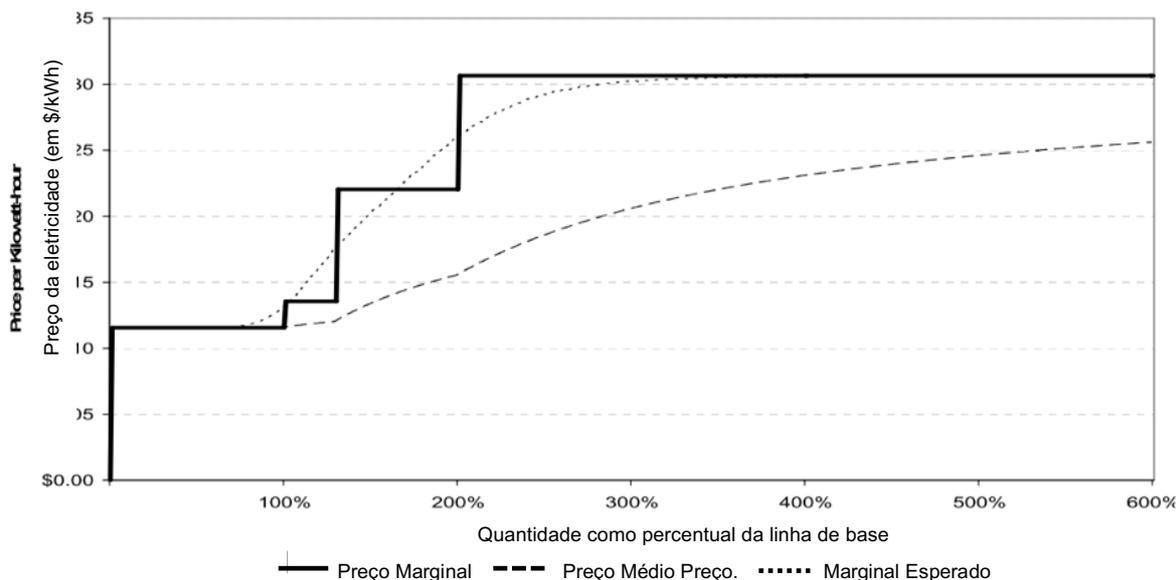


Figura 15. Exemplo ilustrativo de preço marginal, preço médio e preço marginal esperado

Fonte: Adaptado de BORENSTEIN [219]

De acordo com REISS & WHITE [221], quando concessionárias e distribuidoras de energia elétrica aplicam o esquema de **tarifa multipartes** (*multi-part tariff* ou *block pricing* ou *tiered pricing*), em que o preço pago pelo consumidor varia de acordo com a quantidade consumida (Figura 16), teoricamente o preço marginal é a variável mais apropriada. Por outro lado, quando o esquema de preço de eletricidade segue uma tarifa fixa⁵⁵, em que o valor pago pelo consumidor independe da quantidade consumida, não se justifica o uso do preço marginal, uma vez que ele resulta em um preço marginal linear e um preço médio constante entre diferentes níveis de consumo.

⁵⁴ Todas as referências a “preço marginal” e “preço médio” referem-se aqui ao preço com base no consumo *ex post* (para entender melhor, ler BORENSTEIN [219]).

⁵⁵ A prática da tarifa fixa uniforme pode ser questionada quanto à sua equidade e efeitos distributivos. Um consumidor que consome pouca eletricidade paga o mesmo que aquele que consome muita eletricidade, e residências de renda mais alta consomem mais eletricidade. No entanto, estudos mostram que a substituição de uma tarifa fixa por um esquema de tarifa bloco crescente não proporciona significativa redistribuição de renda na presença de uma tarifa social. Ademais, não está comprovado que este esquema sempre reduz o consumo residencial [222,223].

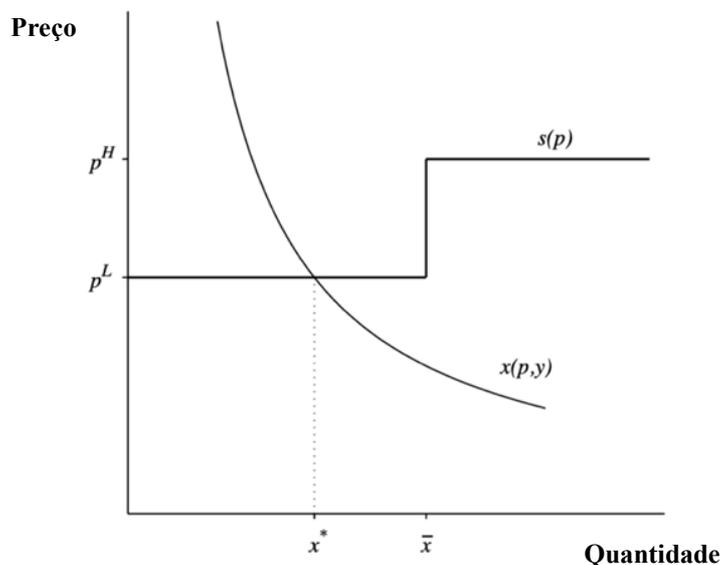


Figura 16. Exemplo ilustrativo de uma tarifa multipartes por bloco crescente

Fonte: Adaptado de REISS & WHITE [221]

A tarifa multipartes pode seguir uma tarifa por bloco crescente ou por bloco decrescente (descontos por volume). Geralmente, tarifas por bloco crescente são assim chamadas devido à sua natureza em escada, com um preço marginal constante até certa quantidade e um preço marginal mais alto para consumo acima dessa quantidade, refletindo um preço marginal não-linear. Em alguns casos, o esquema tem mais de um “degrau” em que o preço marginal aumenta [219]. Já no caso da tarifação pelo preço médio, a contribuição de cada consumidor para a receita adicional (acima da que é gerada pela tarifa volumétrica) é proporcional ao seu consumo [222,223].

Na presença de uma tarifa multipartes, seja por bloco crescente ou decrescente, a endogeneidade da variável preço depende de uma não-linearidade do esquema de preço marginal. Nesse caso, a **endogeneidade é resultado da simultaneidade** – determinação conjunta do equilíbrio de oferta e demanda. Assim, quando preço e quantidade estão em uma mesma equação de regressão, o preço será endógeno devido ao fato de que o uso da eletricidade e o preço desse determinado nível de uso são determinados ao mesmo tempo [217].

Como explicam FELL *et al.* [217], em um esquema de tarifas multipartes, P é função de Y , o que leva à endogeneidade do preço. Além disso, como Y é função de X ,

então, em uma especificação reduzida, P inclui também X . Tal viés não é limitado à variável preço, mas abrange todas as variáveis contidas na matriz das variáveis (X).

No entanto, quando o esquema de preços segue uma **tarifa fixa** – como é o caso brasileiro, que será melhor explicado mais à frente –, e a variável do preço é computada como a diferença entre despesa com eletricidade e quantidade consumida, consta uma **endogeneidade mecânica** que independe da não-linearidade do preço marginal. Nessa situação, o problema da endogeneidade não é considerado substancial [190].

Por outro lado, sempre que os preços por *iid* não estiverem disponíveis, uma agregação de preço é utilizada em detrimento do preço real pago pela família. Nesse caso, alguns autores recorrem, por exemplo, a preços estaduais agregados ou preços agregados por concessionárias/distribuidoras (como em ALBERINI *et al.* [220] e FELL *et al.* [217]), o que resulta em erros de medição e, conseqüentemente, caso o tamanho dos erros seja significativo, na **endogeneidade por erros de medição** [218].

A teoria econométrica padrão mostra que, quando um regressor é mal medido, e o erro de medição é clássico (ou seja, tem média zero e não está correlacionado com o verdadeiro regressor e com o termo de erro econométrico na regressão), o coeficiente de regressão estimado tende a zero. Aqui, isso faria a demanda parecer mais inelástica ao preço do que realmente é [218].

Apesar de ter conseqüências potencialmente graves sobre a elasticidade-preço estimada, a possibilidade de o preço da energia ser mal medido tem recebido pouca atenção na literatura [218]. Em dois estudos recentes que usam dados de nível familiar, ALBERINI *et al.* [220] e FELL *et al.* [217] discutem as implicações dos preços da energia que são medidos com um termo de erro e implementam diferentes abordagens para resolver esse problema. Os autores concluíram provisoriamente que a tendência resultante de erros de medição é modesta: cerca de 10-15%. Devido à falta de dados adicionais, não podemos obter instrumentos válidos que nos permitam abordar explicitamente o problema; no entanto, os achados de ALBERINI *et al.* [220] fornecem algum conforto de que nossas estimativas de elasticidade de preço e renda provavelmente não serão significativamente viesadas devido à medição de erros na variável de preço.

No caso de estimativa de demanda com preços marginais do tipo bloco crescente, o uso de uma única medida de preço marginal (por exemplo, preço marginal médio) como

um regressor, em vez da programação completa de preços marginais, torna a variável de preço endógena [190]. Consultar REISS & WHITE [221] para estimativa de demanda com preços de bloco crescente.

No caso brasileiro, o problema da endogeneidade induzido pela simultaneidade não é sustentável, pois as tarifas de energia são reguladas pelo governo no formato de tarifa fixa. No que diz respeito ao preço de eletricidade para consumidores residenciais (classe residencial denominada “subgrupo B1” e classe rural denominada “subgrupo B2”), a grande maioria paga uma tarifa fixa cobrada pela concessionária/distribuidora de energia e regulada pela Agência Nacional de Energia Elétrica – ANEEL [22,223]. Nesse sentido, como já comentado anteriormente, o preço não varia de acordo com a quantidade consumida [34], fazendo com que a endogeneidade não seja substancial.

Contudo, um pequeno grupo de consumidores enquadrados na “Subclasse Residencial Baixa Renda” são beneficiados por um esquema de tarifa por bloco decrescente chamado **Tarifa Social de Energia Elétrica – TSEE**. A TSEE foi criada pela Lei nº 10.438, de 26 de abril de 2002, sendo atualmente regulamentada pela Lei nº 12.212, de 20 de janeiro de 2010, e pelo Decreto nº 7.583, de 13 de outubro de 2011 [224]. Tais consumidores são beneficiados com a isenção do custeio da Conta de Desenvolvimento Energético (CDE) e do Programa de Incentivo às Fontes Alternativas de Energia Elétrica (PROINFA). Além dessas isenções, no restante da tarifa residencial são aplicados os descontos, de modo cumulativo, de acordo com a **Figura 17** [224]:

Parcela de consumo mensal de energia elétrica	Desconto	Tarifa para aplicação da redução
de 0 a 30 kWh	65%	B1 subclasse baixa renda
de 31 kWh a 100 kWh	40%	
de 101 kWh a 220 kWh	10%	
a partir de 221 kWh	0%	

Figura 17. Descontos no preço da eletricidade pago pelos consumidores de baixa renda beneficiados pela TSEE

Fonte: Elaboração própria com base em ANEEL [224]

Já as famílias indígenas e quilombolas que estejam inscritas no Cadastro Único e atendam aos requisitos recebem desconto de até 100%, conforme a tabela da **Figura 18** [224]:

Parcela de consumo mensal de energia elétrica	Desconto	Tarifa para aplicação da redução
de 0 a 50 kWh	100%	B1 subclasse baixa renda
de 51 kWh a 100 kWh	40%	
de 101 kWh a 220 kWh	10%	
a partir de 221 kWh	0%	

Figura 18. Descontos no preço da eletricidade pago pelos consumidores quilombolas e indígenas registrados no Cadastro Único

Fonte: Elaboração própria com base em ANEEL [224]

De acordo com ANEEL [224], os seguintes requisitos devem ser satisfeitos para obtenção dos benefícios da TSEE:

- Família inscrita no Cadastro Único para Programas Sociais do Governo Federal – Cadastro Único, com renda familiar mensal per capita menor ou igual a meio salário-mínimo nacional; ou
- Idosos com 65 (sessenta e cinco) anos ou mais ou pessoas com deficiência, que recebam o Benefício de Prestação Continuada da Assistência Social – BPC, nos termos dos arts. 20 e 21 da Lei nº 8.742, de 7 de dezembro de 1993; ou
- Família inscrita no Cadastro Único com renda mensal de até 3 (três) salários-mínimos, que tenha portador de doença ou deficiência (física, motora, auditiva, visual, intelectual e múltipla) cujo tratamento, procedimento médico ou terapêutico requeira o uso continuado de aparelhos, equipamentos ou instrumentos que, para o seu funcionamento, demandem consumo de energia elétrica.

Segundo dados da ANEEL [225], apenas uma média de aproximadamente 13% do total de consumidores de eletricidade em julho de 2018 – último mês de realização da POF – foram beneficiados com o sistema da TSEE, ou seja, menos de 15% do total dos consumidores residenciais participaram de um esquema de tarifas multipartes por bloco decrescente (**Tabela 5**). Portanto, assim como em SILVA *et al.* [191] e PEREIRA UHR *et al.* [34], foi assumido que a variável preço utilizada possui apenas uma endogeneidade mecânica irrelevante.

Tabela 5. Acompanhamento mensal por Unidade da Federação da TSEE no mês de julho de 2018

Unidade da Federação	Número de unidade consumidoras			Diferença mensal de receita solicitada (R\$)
	Residencial total	Baixa renda	% de Baixa renda/residencial total	
AC	209.788	31.115	14,83	779.445,40
AL	1.085.871	199.196	18,34	3.674.080,56
AM	858.484	103.718	12,08	2.874.074,64
AP	181.173	24.221	13,37	602.298,92
BA	5.240.626	1.096.463	20,92	21.367.154,52
CE	2.413.192	908.162	37,63	17.477.536,42
DF	938.751	6.876	0,73	190.848,65
ES	1.274.213	87.587	6,87	2.061.602,51
GO	2.530.081	201.348	7,96	4.761.505,19
MA	2.074.743	692.642	33,38	16.496.818,46
MG	7.212.900	595.302	8,25	13.733.877,73
MS	841.049	115.596	13,74	2.709.283,98
MT	1.080.198	122.638	11,35	3.161.460,24
PA	1.926.214	522.079	27,1	14.397.372,85
PB	1.351.316	388.384	28,74	7.664.343,43
PE	3.243.375	807.837	24,91	16.293.358,37
PI	1.124.826	324.400	28,84	6.747.820,48
PR	3.787.246	281.085	7,42	5.906.981,57
RJ	5.996.851	372.996	6,22	9.633.846,20
RN	1.250.818	282.031	22,55	5.512.272,96
RO	458.022	43.918	9,59	1.178.721,35
RR	132.007	17.093	12,95	411.257,52
RS	2.777.576	129.509	4,66	3.467.397,58
SC	2.498.391	43.894	1,76	1.181.235,72
SE	829.852	244.014	29,4	4.733.866,57
SP	17.805.641	941.726	5,29	21.705.500,55
TO	480.244	116.009	24,16	2.902.836,81
TOTAL BRASIL	69.603.448	8.699.839	12,49	191.626.799,18

Fonte: Elaboração própria com base em ANEEL [225]

Como já detalhado na **Seção 3.1.1**, o preço da eletricidade foi calculado em cada residência dividindo o total pago pela energia consumida. Conseqüentemente, estamos lidando com preço da eletricidade arcado pelo consumidor final. Assim, são considerados os custos reais da eletricidade residencial (taxas de geração, transmissão e distribuição), que são incorporados à tarifa de energia, mais os impostos e encargos nos níveis federal,

estadual e municipal, além de custos adicionais como o de “bandeiras tarifárias”, se houver. Não há aqui uma endogeneidade por erro de medição, pois não estamos fazendo uso de algum tipo de agregação; o preço utilizado é *hhid*.

Não obstante, segundo ALBERINI & FILIPPINI [218], devido à característica de bloco decrescente, seria interessante analisar a modalidade de tarifa por horário de uso (em inglês, *time-of-use rates*), conhecida no Brasil como bandeiras tarifárias. O **Sistema de Bandeiras Tarifárias** foi implementado no ano de 2015 no Brasil, contemplando todos os consumidores cativos das distribuidoras, exceto aqueles localizados em sistemas isolados. As diferentes modalidades do sistema indicam se haverá ou não acréscimo no valor da energia a ser repassada ao consumidor final, o que depende das condições de geração de eletricidade. Segundo ANEEL [226], cada bandeira apresenta as seguintes características⁵⁶:

- ***Bandeira verde***: condições favoráveis de geração de energia. A tarifa não sofre nenhum acréscimo;
- ***Bandeira amarela***: condições de geração menos favoráveis. A tarifa sofre acréscimo de R\$ 0,01343 R\$ 0,01874 para cada kWh consumido;
- ***Bandeira vermelha – Patamar 1***: condições mais custosas de geração. A tarifa sofre acréscimo de R\$ 0,04169 R\$ 0,03971 para cada kWh consumido; e
- ***Bandeira vermelha – Patamar 2***: condições ainda mais custosas de geração. A tarifa sofre acréscimo de R\$ 0,06243 R\$ 0,09492 para cada kWh consumido.

De acordo com ANEEL [227], além das diferentes bandeiras, o preço da eletricidade no Brasil conta com uma nova opção tarifária para as unidades consumidoras atendidas em baixa tensão (127, 220, 380 ou 440 Volts – grupo B): a chamada **Tarifa Branca**. Essa opção está disponível para consumidores residenciais (subgrupo B1) e para a classe rural (subgrupo B2), com exceção daqueles beneficiados pela TSEE. Diferente da modalidade convencional, que tem um único valor de tarifa, a nova modalidade possui valores diferentes ao longo do dia, possibilitando três valores de tarifa diferentes para os dias úteis [227]:

- ***Ponta***: tarifa mais elevada;

⁵⁶ Valores de quilowatt-hora referentes a outubro/2021.

- **Intermediário:** tarifa de valor intermediário; e
- **Fora Ponta:** tarifa de valor menor.

Os valores aplicados variam de acordo com os períodos (postos) [228]:

- **Horário (posto) de ponta:** período diário de 3h consecutivas, com exceção feita aos sábados, domingos e feriados nacionais;
- **Horário (posto) intermediário:** período de horas conjugadas ao horário de ponta, aplicado exclusivamente às unidades consumidoras que optem pela Tarifa Branca. Pode variar de 1h a 1h30 antes e depois do horário de ponta; e
- **Horário (posto) fora de ponta:** período diário composto pelas horas consecutivas e complementares aos horários de ponta e intermediário.

Nos fins de semana e feriados nacionais, o valor é sempre da tarifa “Fora de Ponta”, categoria com valor inferior ao valor da Tarifa Convencional. Ademais, cada distribuidora de eletricidade define seus próprios postos tarifários, sendo o processo de revisão tarifária periódica (a cada 4 ou 5 anos), de acordo com a Resolução Normativa (REN) nº 414/2010, art. 59, e os Procedimentos de Regulação Tarifária – PRORET [228,227].

No entanto, como regulamentado pela Resolução Normativa nº 733/2016, o consumidor pôde solicitar a adesão à Tarifa Branca somente a partir de 1º de janeiro de 2018, respeitando o cronograma de preferência, de modo a priorizar as solicitações com as seguintes características [227]:

- 1º de janeiro de 2018, para novas ligações e para unidades consumidoras com média anual de consumo mensal superior a 500 kWh;
- 1º de janeiro de 2019 para unidades consumidoras com média anual de consumo mensal superior a 250 kWh; e
- 1º de janeiro de 2020 para todas as unidades consumidoras.

Dessa forma, foi assumido que o período analisado da POF não capturou as tendências da tarifa por horário de uso, uma vez que ela ainda não estava em vigor para a maioria dos consumidores residenciais.

4 RESULTADOS E DISCUSSÃO

Este capítulo apresenta os resultados do procedimento metodológico retratado no **Capítulo 3**. Sua estrutura é um espelho do capítulo metodológico, onde: primeiro são apresentados os resultados do processamento e análise de dados da POF e do CDD_{wb} (**Seção 4.1**), ou seja, os resultados da análise estatística da base de dados utilizada; segundo, na **Seção 4.2**, são revelados os resultados da inferência estatística da modelagem microeconômica desenvolvida para esta tese, sendo apresentados os valores dos parâmetros dos principais modelos criados e os resultados de seus testes de hipótese e de robustez. Duas adições feitas neste capítulo em comparação ao anterior são as seções **4.3** e **4.4**. A **Seção 4.3** apresenta uma comparação entre os modelos *cross-section* microeconômicos desenvolvidos e abordada a escolha do modelo mais adequado para prever a demanda de eletricidade, enquanto a **Seção 4.4** demonstra a resposta do modelo frente a simulações com bases em cenários socioeconômicos e climáticos.

4.1 Análise estatística da base de dados

Após o processamento e unificação das duas bases de dados – socioeconômica (microdados das POFs) e climática (dados de temperatura e umidade relativa traduzidos CDD_{wb}) –, é possível apresentar a análise estatística e empírica dos dados transversais de entrada dos modelos microeconômicos. Enquanto a subseção **4.1.1** expõe a análise estatística da base de dados da POF, oferecendo uma contextualização do consumo de energia sob a ótica de diferentes grupos socioeconômicos, a subseção **4.1.2** explicita a análise estatística e espacial dos dados de CDD_{wb} .

4.1.1 Microdados da Pesquisa de Orçamentos Familiares (POF)

A **Tabela 6** apresenta a análise estatística dos dados da POF e sua evolução ao longo do período 2002-2018 através de estatísticas descritivas representativas da população. As variáveis são exibidas em valores percentuais de acordo com diferentes ondas da POF – à exceção da quantidade de eletricidade demandada, despesa com eletricidade, preço da eletricidade e renda das famílias, que são expressas tanto em valores correntes quanto na forma de logaritmo neperiano. Tal análise permite observar a

evolução das informações coletadas ao longo do período analisado e proporcionar uma melhor compreensão acerca dos hábitos das famílias e suas mudanças comportamentais históricas.

Tabela 6. Sumário estatístico das principais variáveis socioeconômicas e climáticas no período 2002-2018

Variável	POF (2002-2003)		POF (2008-2009)		POF (2017-2018)	
	Média	DP	Média	DP	Média	DP
Eletricidade (kWh/ano/domicílio)	1.766,52	1.323,02	1.788,95	1.655,63	1.956,01	1.551,76
Eletricidade (Ln kWh/ano/domicílio)	7,21	0,71	6,74	2,05	6,90	2,04
Despesa _E (BRL ₂₀₁₇ /ano/domicílio)	1.380,82	1.311,20	1.267,74	1.390,90	1.389,43	1.201,64
Despesa _E (Ln BRL ₂₀₁₇ /ano/domicílio)	6,78	1,01	6,31	2,02	6,54	1,98
Preço _E (BRL ₂₀₁₇ / kWh/ano)	0,71	0,26	0,66	0,50	0,66	0,30
Preço _E (Ln BRL ₂₀₁₇ / kWh/ano)	-0,43	0,47	-0,43	0,52	-0,37	0,33
Renda (BRL ₂₀₁₇ /ano/domicílio)	55.996,29	93.889,71	57.300,28	84.212,41	65.267,35	102.511,23
Renda (Ln BRL ₂₀₁₇ /ano/domicílio)	10,37	1,01	9,37	0,95	10,64	0,90
Acesso a eletricidade	0,959	0,197	0,982	0,133	0,995	0,070
Urbano (1 = Urbano)	0,847	0,360	0,855	0,352	0,862	0,345
Residência própria (1 = Próprio)	0,716	0,451	0,727	0,445	0,726	0,446
Tipo de domicílio (1 = Casa)	0,906	0,291	0,884	0,320	0,868	0,339
Nº de cômodos	5,803	2,293	5,984	2,287	5,980	2,086
Membros da família	3,634	1,834	3,302	1,650	3,008	1,489
Sexo (1 = Masculino)	0,737	0,441	0,691	0,462	0,582	0,493
Raça (1 = Branco)	0,532	0,499	0,492	0,500	0,441	0,496
Idade	45,818	15,415	47,757	15,650	50,042	15,737
Anos de educação	5,872	4,578	6,817	4,670	8,867	4,898
AC	0,009	0,094	0,086	0,279	0,204	0,403
Ventilador	0,597	0,493	0,618	0,486	0,764	0,427
Computador	0,130	0,337	0,284	0,450	0,560	0,669
Micro-ondas	0,181	0,385	0,279	0,448	0,549	0,499
TV	0,927	0,379	0,960	0,264	1,126	0,424
Geladeira	0,858	0,353	0,930	0,301	0,997	0,198
Freezer	0,166	0,372	0,138	0,344	0,124	0,330
Máquina de lavar roupa	0,384	0,487	0,452	0,497	0,648	0,479
Ferro	0,820	0,387	0,789	0,409	0,749	0,436
Rádio	0,361	0,522	0,387	0,486	0,275	0,447
Máquina de lavar louça*	0,001	0,031	0,023	0,149	0,026	0,158
Chuveiro elétrico	NA**	NA	0,628	0,483	0,662	0,475
Aspirador	0,112	0,315	0,123	0,327	NA	NA
Linha da pobreza	0,405	0,491	0,210	0,407	0,093	0,290
Linha da extrema pobreza	0,101	0,301	0,032	0,175	0,011	0,104
Índice da <i>household</i>	NA	NA	0,505	0,500	0,611	0,488

Nota: *Na POF (2002-2003) existem diferentes opções no inventário de bens duráveis referentes ao equipamento de lavar louça. Como o eletrodoméstico era relativamente novo na época, pode ter havido confusão nas respostas o que resultou no baixo percentual de posse. Para o cálculo deste estudo, consideramos os códigos do item iguais a “00403 - MAQUINA DE LAVAR PRATOS” e “00403 - MAQUINA DE LAVAR PRATOS (INVENTARIO)”.

**NA = “Não disponível”

Fonte: Elaboração própria com base em IBGE [188]

Como é possível observar pelo sumário estatístico (**Tabela 6**), o consumo de eletricidade anual das famílias brasileiras aumentou ao longo do período analisado, saindo de uma média familiar de 1.766,52 kWh/ano em 2002-2003 para 1.788,95 kWh/ano em 2008-2009, atingindo em 2017-2018 uma média de 1.956,01 kWh/ano. Isso equivale a um aumento na demanda de eletricidade de aproximadamente 10% no período. Os valores de consumo residencial de eletricidade são validados pelo relatório “Consumo Mensal de Energia Elétrica por Classe (regiões e subsistemas)” da Empresa de Pesquisa Energética – EPE [229], uma vez que estão na mesma ordem de grandeza.

A justificativa para tal crescimento se dá em parte pela melhora na renda das famílias, que será analisada mais à frente, mas também devido a um maior acesso a energia elétrica no período, principalmente em áreas rurais. Segundo os dados da POF, o Brasil conseguiu a universalização do acesso a energia elétrica em 2017-2018 (99% das residências), com aumento expressivo do acesso em áreas rurais, onde em 2002-2003 um total de 78% dos domicílios tinha acesso, percentual que aumentou para 89% em 2007-2008 e para 97% em 2017-2018. Tal evolução foi impulsionada pelo sucesso do programa “Luz para Todos” (LpT), que tinha como objetivo principal aumentar a taxa de eletrificação no país e, conseqüentemente, a universalização do acesso a energia elétrica, fornecendo energia a 10 milhões de pessoas até 2008, especialmente aquelas que viviam em áreas rurais [230]. O programa foi instituído pelo decreto N° 4873 em novembro de 2003 e coordenado pelo Ministério de Minas e Energia – MME [231]. Para mais detalhes sobre o programa, ver BEZERRA *et al.* [230].

Por outro lado, o preço da eletricidade caiu entre 2002-2008 e depois se manteve estável, com uma média de BRL₂₀₁₇ 0,66/kWh, enquanto a despesa elétrica teve um aumento contínuo proporcional ao peso e à quantidade consumida.

A renda média das famílias brasileiras cresceu no período analisado, considerando reais em valores correntes de 2017. Em 2002-2003 as famílias possuíam uma renda média anual de BRL₂₀₁₇ 55.996,29, que aumentou para BRL₂₀₁₇ 57.300,28 em 2008-2009 e, posteriormente, para BRL₂₀₁₇ 65.267,35 em 2017-2018. Isso equivale a um aumento de 16% na renda média anual familiar no período analisado. Tal melhora na condição de vida das famílias foi fomentada, dentre outras razões explicitadas anteriormente na **Seção 2.3**, por programas sociais governamentais, com destaque para o Bolsa Família (BF). O BF foi integrado a muitos outros programas, como o LpT. O governo entendeu que um

estipêndio mensal por si só não era suficiente para tirar a maioria desses indivíduos e suas famílias da pobreza extrema. Portanto, o processo de eletrificação foi uma das chaves importantes utilizadas para dar possibilidades a muitas famílias de aliviar a pobreza. Por isso, a eletricidade tem o papel de possibilitar o desenvolvimento quando integrada aos demais esforços sociais. Assim, em conjunto com o LpT, os benefícios do BF possibilitaram às famílias usufruir do benefício de energia elétrica, investindo em eletrodomésticos para estudos ou pequenos negócios familiares [232] [230].

Dessa maneira, a melhora na condição socioeconômica dos brasileiros resultou em um aumento da posse de equipamentos elétricos. Conforme mostram os resultados empíricos da **Tabela 6**, a televisão (TV) alcançou a universalização no período analisado, alcançando uma posse de 1,126, no período 2017-2018, enquanto a geladeira chegou perto de tal *status*, apresentando uma posse de 0,997 no mesmo período. Pode parecer estranho que a posse de TVs seja maior do que a de refrigeradores, contudo, há muitas evidências que sugerem que a TV é o primeiro e mais amplamente aparelho elétrico adquirido pelas famílias [56,57,233]. Além disso, é mais comum ter mais de uma TV por residência do que mais de uma geladeira. Fica claro na literatura, porém, que diferentes aparelhos apresentam taxas de penetração muito diferentes ao longo do tempo, cujas causas ainda não são bem compreendidas [58].

Por outro lado, alguns equipamentos foram perdendo a utilidade e se tornaram obsoletos, como rádio, ferro e freezer, sendo substituídos por outras tecnologias mais modernas ou simplesmente perdendo utilidade devido à mudança comportamental das famílias. O freezer apresentou queda na penetração ao longo dos anos, em grande parte por conta do fim da hiperinflação que rompeu com a necessidade de armazenamento de alimentos, com uma posse de 0,166 em 2002, caindo para 0,138 e depois para 0,124, respectivamente, em 2008 e 2017. O mesmo aconteceu com o ferro, apresentando uma posse de 0,820 em 2002, que diminuiu para 0,749 em 2017. Já o rádio apresentou um leve aumento de aproximadamente 7,2% entre 2002 e 2008, sendo depois reduzido para 0,275 em 2017-2018. Outro destaque é a posse de ar-condicionado (AC), que será detalhada à frente devido à relação com as mudanças climáticas.

Ademais, houve êxodo rural no período analisado, o que resultou em um aumento dos domicílios em áreas urbanas e, concomitantemente, em uma redução da proporção de domicílios do tipo casa, apesar de estes ainda representarem a maioria das residências.

Tanto a taxa de urbanização, como a proporção de casas possui um percentual de aproximadamente 86% em 2017-2018. Já o tamanho das famílias diminuiu de 3,634 em 2002-2003 para 3,008 em 2017-2018, enquanto o tamanho das residências (número de cômodos por domicílio) aumentou, alcançando a média de aproximadamente 5,98 em 2017-2018.

Outro dado importante sobre as características habitacionais é a situação da propriedade, ou seja, se a residência é própria ou não. Houve um aumento no percentual de residências próprias no período 2002-2018, alcançando 72% do total de residências. Um dos contribuidores para o avanço desse percentual é o programa **Minha Casa, Minha Vida (MCMV)**, do Governo Federal. O programa, que teve início em 2009, é a maior iniciativa de acesso à casa própria já criada no Brasil e busca facilitar a conquista da casa própria para as famílias de baixa renda, oferecendo condições de financiamento diferenciadas e atrativas de acordo com diferentes faixas de renda, tanto para moradias nas áreas urbanas como em áreas rurais. Ele é o maior programa habitacional da história do país e já beneficiou diversas famílias, contando com mais de cinco milhões de habitações contratadas, desde sua implementação até 2019 [234-236].

Contudo, esse alto valor percentual de residências próprias não significa que de fato todos os que responderam que o imóvel era próprio possuam imóvel próprio – quitado ou ainda pagando –, porque a maioria dos questionários de pesquisas domiciliares, como é o caso da POF, dá como opção de resposta o caso do imóvel ser próprio de algum morador. Dessa forma, existem entrevistados que moram em casa de parentes e domicílios com mais de uma família em uma mesma casa. Assim, o fato de a grande maioria dos domicílios ser classificada como própria não garante a solução do problema de **déficit habitacional**, que por definição engloba dados de domicílios precários, em coabitação e com elevado custo de aluguel [237].

Em relação às características do chefe da família, é observada uma melhora na expectativa de vida do brasileiro, em parte como reflexo de melhores condições sanitárias e da qualidade de vida e de entorno, atingindo uma média aproximada de 50 anos para os chefes das famílias em 2017-2018. O nível de educação também apresentou melhora, chegando próximo a nove anos de estudo para o chefe da família no último período analisado. Por fim, as características físicas dos chefes das famílias também se

modificaram ao longo do tempo, com uma redução, mas ainda predominância, de homens brancos no cargo.

Outra variável de grande relevância para este estudo é a linha de pobreza. De acordo com os resultados apresentados na **Tabela 6**, o número de famílias em situação de pobreza caiu drasticamente entre 2002-2018, chegando ao final do período com um quarto do percentual do ano base. No caso da extrema pobreza, essa redução foi ainda mais expressiva, culminando em menos de 0,1% no número de domicílios abaixo da linha de extrema pobreza. Destaca-se que as linhas de pobreza analisadas nesta tese representam, diferentemente dos dados apresentados pelo Banco Mundial [238], o número de domicílios com famílias consideradas pobres e extremamente pobres, e não o percentual da população. Contudo, quando considerada a população, chega-se a resultados em linha com os obtidos tanto pelo Banco Mundial [238] quanto pelo IBGE [101], que utiliza dados da PNAD-C (Pesquisa Nacional de Amostra por Domicílios Contínua) – **Tabela 7**.

Tabela 7. Percentual da população e das famílias em situação de pobreza e extrema pobreza ao longo das POFs

Linhas pobreza	POF (2002-2003)		POF (2008-2009)		POF (2017-2018)	
	População	Famílias	População	Famílias	População	Famílias
Pobreza	49,3%	40,5%	28,4%	21,0%	13,3%	9,3%
Extrema pobreza	14,8%	10,1%	4,9%	3,2%	1,7%	1,1%

Fonte: Elaboração própria com base em IBGE [188]

Apesar da melhora no padrão de vida da população brasileira e dos avanços sociais demonstrados empiricamente pelos dados da POF, que resultaram na retirada de milhares de famílias de situações de vulnerabilidade, há uma persistente disparidade de renda entre as famílias brasileiras. Destarte, enquanto é observada uma melhora na renda média das famílias, como mostra a **Tabela 6**, é possível observar também um alto desvio padrão da renda, que só aumentou ao longo do período analisado. Isso expressa uma forte discrepância em relação à renda média que é ratificado pela **Tabela 8**.

A **Tabela 8** delinea as classes de renda consideradas na modelagem microeconômica, apresentando a renda mínima, máxima e média por decil em diferentes anos e considerando uma categorização urbano *versus* rural. A diferenciação

entre domicílios na área urbana e rural é relevante, pois, como contemplado na tabela, famílias da área rural detêm aproximadamente metade da renda média das famílias urbanas. Além disso, tal diferenciação considera diferentes níveis de acessibilidade a fontes de energia e diferentes padrões socioculturais. A **Tabela 8** mostra que a classe de renda mais alta, decil 10, retém aproximadamente 40% do total da renda brasileira ao longo do período, em linha com os valores do IBGE [108] apresentados na **Seção 2.3**. Isso comprova a tenacidade da desigualdade de renda corroborada por outros índices também apresentados na **Seção 2.3**, como o IDH e o Índice Gini.

Tabela 8. Renda média no Brasil por decis considerando urbano *versus* rural no período 2002-2018
(em BRL₂₀₁₇/ano/domicílio)

Ano da POF	Decil	Urbano				Rural			
		Mínimo	Máximo	Média	Mediana	Mínimo	Máximo	Média	Mediana
2002-2003	D1	133,33	10.557,44	7.333,27	7.781,64	862,77	6.471,56	4.531,49	4.729,87
	D2	10.561,41	15.622,05	13.178,50	13.222,60	6.473,85	9.052,51	7.860,22	7.858,78
	D3	15.623,38	20.526,56	18.019,08	18.001,04	9.055,77	11.569,23	10.286,66	10.288,12
	D4	20.527,18	26.346,92	23.311,57	23.225,69	11.575,64	14.568,92	13.090,58	13.081,99
	D5	26.352,62	33.744,92	29.877,17	29.850,62	14.573,05	17.492,41	15.989,74	15.981,79
	D6	33.745,44	42.781,15	38.032,77	37.924,97	17.494,51	20.806,15	19.129,69	19.191,23
	D7	42.781,54	56.616,62	49.259,53	48.969,75	20.809,10	26.019,54	23.264,06	23.245,00
	D8	56.616,82	79.982,51	66.900,33	66.048,70	26.026,56	33.862,46	29.386,21	29.121,63
	D9	80.000,00	132.786,51	101.936,91	100.481,36	33.864,77	50.433,23	40.892,21	40.386,89
	D10	132.830,38	11.853.866,67	264.264,74	201.991,75	50.436,82	1.163.218,05	106.669,06	75.054,83
2008-2009	D1	0,00	12.699,31	8.955,60	9.587,16	862,14	7.089,52	4.852,69	5.081,59
	D2	12.699,72	18.272,48	15.494,22	15.496,97	7.090,55	10.557,52	8.958,89	9.056,53
	D3	18.272,90	23.381,38	20.817,97	20.785,80	10.559,38	13.212,41	11.843,76	11.786,02
	D4	23.382,00	28.933,45	26.060,04	26.036,43	13.225,45	16.216,76	14.661,55	14.590,64
	D5	28.934,28	36.398,48	32.438,84	32.322,31	16.217,17	19.949,59	18.105,21	18.113,55
	D6	36.398,69	45.785,59	40.820,56	40.688,60	19.952,07	23.623,45	21.688,70	21.691,36
	D7	45.788,28	58.970,90	51.953,55	51.779,73	23.626,14	28.714,76	26.017,98	25.933,50
	D8	58.980,83	80.196,00	68.617,04	68.237,11	28.715,38	37.243,24	32.608,44	32.495,38
	D9	80.202,00	130.947,93	100.931,10	98.419,07	37.260,21	53.759,59	44.288,83	43.668,87
	D10	130.955,59	2.425.224,83	254.777,83	197.328,40	53.818,76	1.996.465,45	108.861,83	77.864,49
2017-2018	D1	0,00	15.969,24	10.989,17	11.892,74	100,56	9.582,84	6.507,57	6.746,98
	D2	15.969,84	22.170,12	19.030,64	18.979,33	9.584,16	14.288,76	12.122,12	12.239,63
	D3	22.170,84	28.805,16	25.542,62	25.544,25	14.291,76	17.323,32	15.761,57	15.676,09
	D4	28.805,76	34.973,16	31.756,48	31.680,85	17.328,72	21.277,80	19.188,97	19.125,29
	D5	34.973,52	42.968,64	38.791,20	38.688,30	21.278,76	26.102,52	23.752,83	23.754,94
	D6	42.968,76	53.145,12	47.720,71	47.519,24	26.105,88	30.248,40	28.089,85	27.994,09
	D7	53.146,56	67.166,04	59.733,60	59.495,77	30.252,60	36.286,32	33.010,96	32.857,24
	D8	67.166,76	89.181,96	76.775,83	75.893,95	36.286,92	45.539,64	40.593,15	40.527,27
	D9	89.188,44	138.171,84	110.646,27	108.944,22	45.544,08	65.567,28	53.833,14	53.251,30
	D10	138.172,32	8.102.546,40	277.505,03	208.633,49	65.611,44	8.074.691,52	133.371,76	90.826,32

Fonte: Elaboração própria com base em IBGE [188]

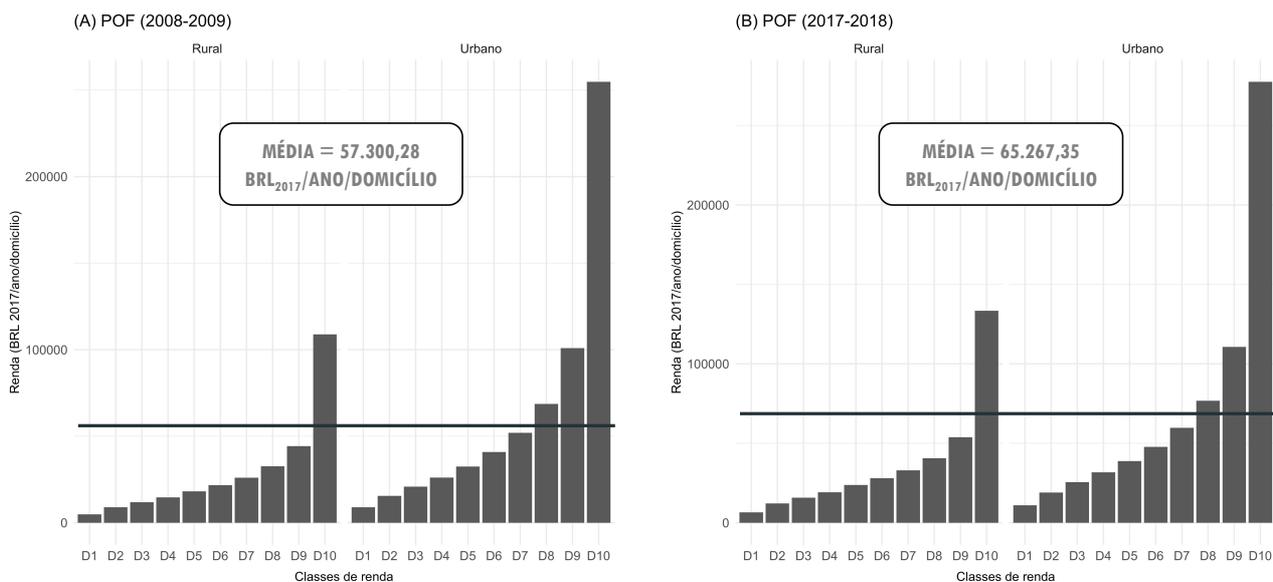


Gráfico 1. Renda média no Brasil por grupos socioeconômicos de acordo com POF (2008-2009) e POF (2017-2018) (BRL₂₀₁₇/ano/domicílio)

Fonte: Elaboração própria com base em IBGE [188]

A categorização das famílias brasileiras em diferentes classes de renda viabiliza o agrupamento e análise dos microdados de acordo com diferentes grupos socioeconômicos. Como resultado, é possível observar o padrão histórico de comportamento do total de 20 grupos, especificamente aquele relacionado ao consumo energético, e sua evolução ao longo do período.

É importante destacar que a POF (2002-2003) não contém as perguntas relativas às fontes de energia para cocção e aquecimento de água. Por esse motivo, optou-se por apresentar a evolução no período 2007-2018, o qual é considerado médio prazo, refletindo quase 10 anos de mudanças comportamentais. Resultados da POF (2002-2003) para posse de equipamentos e tecnologias de climatização estão disponibilizados no **Apêndice**.

Isto posto, o **Gráfico 2** apresenta a posse de eletrodomésticos para as duas ondas mais recentes da POF de acordo com os 20 grupos socioeconômicos criados. Os grupos consideram uma divisão em 10 classes de renda de acordo com decis e uma diferenciação entre domicílios urbanos e rurais. Segundo os dados do gráfico, o aumento da posse de eletrodomésticos em sua maioria acompanha o aumento da renda das famílias. Assim, como esperado, os decis mais ricos possuem maior posse de equipamentos elétricos. Adicionalmente, domicílios urbanos possuem maior posse de equipamentos em

comparação a domicílios rurais, em grande parte, refletindo a questão orçamentária (famílias urbanas retêm em média o dobro da renda das rurais), mas também como consequência do maior acesso a eletricidade nessas localidades. Aproximadamente 99% dos domicílios urbanos possuíam acesso a eletricidade no período 2017-2018 frente a 97% dos domicílios rurais. É importante destacar que o alto percentual em áreas rurais não significa uma boa confiabilidade no fornecimento de eletricidade. Pelo contrário, há evidências empíricas de baixa confiabilidade no fornecimento de energia em áreas rurais, principalmente em áreas isoladas [67].

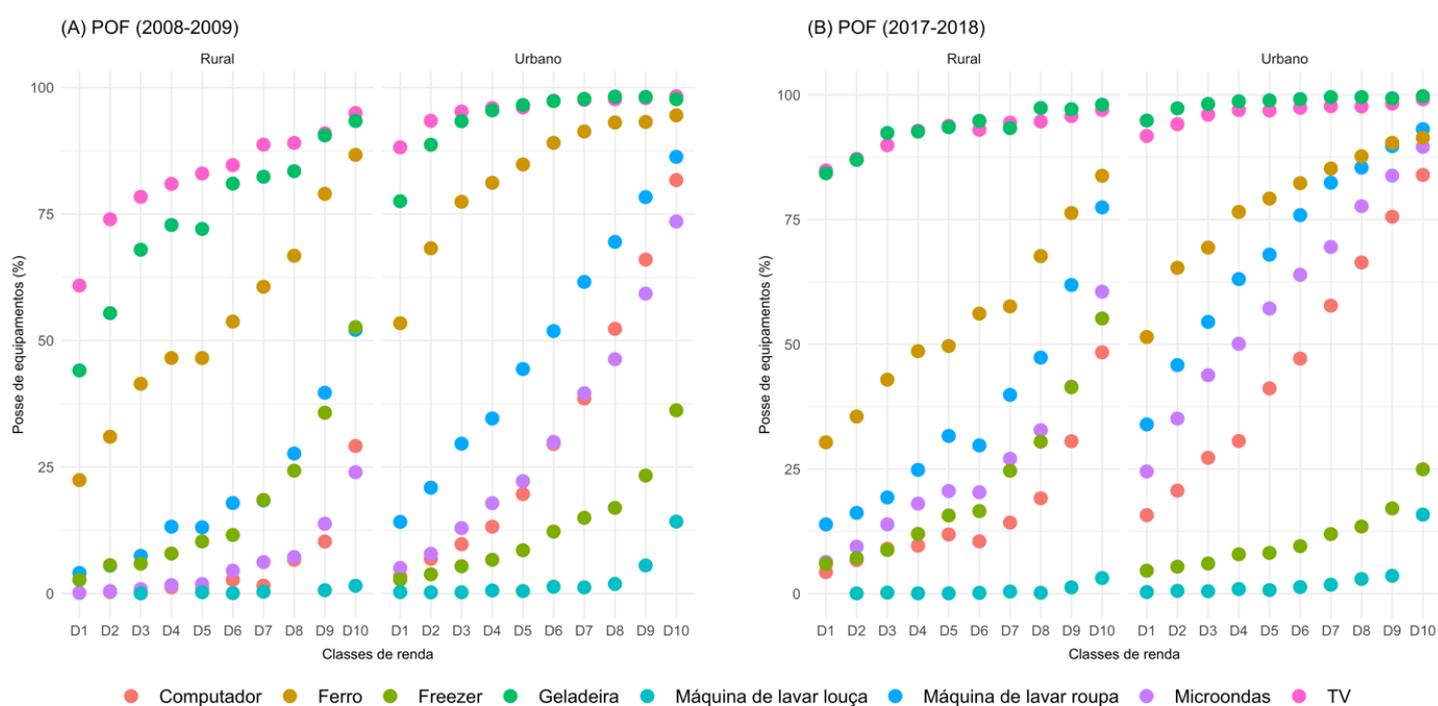


Gráfico 2. Posse de eletrodomésticos no Brasil por grupos socioeconômicos de acordo com POF (2008-2009) e POF (2017-2018)

Nota: Em 2008-2009, os decis 1,2,4 e 8 da área rural não apresentaram posse de máquina de lavar.

Fonte: Elaboração própria com base em IBGE [188]

A TV é o eletrodoméstico com maior posse nos dois períodos analisados. Em 2008-2009, o aparelho tinha maior posse média em comparação com a geladeira em todas as classes de renda da área rural, bem como nos decis mais pobres da área urbana (decis 1-4). Comparativamente, a posse média de geladeiras por decis ultrapassou a de TVs em 2017-2018, sendo os dois equipamentos os mais presentes nos lares brasileiros. Em contraste, a máquina de lavar louça é o eletrodoméstico de menor posse em todos os

grupos e nos diferentes anos da pesquisa, sendo reservadas apenas para os grupos de renda mais alta (decis 8-10) e, ainda assim, presentes em menos de 15% do decil urbano mais rico no período 2017-2018.

O computador é outro aparelho que merece destaque devido à sua relação com a renda média dos grupos. Como é possível observar nos anos 2008-2009, em domicílios urbanos ele apresenta um aumento de posse praticamente linear entre os decis, alcançando 0,85 de posse no decil mais rico da área urbana.

Podemos concluir, assim como RAO & UMMEL [58], que também realizou um estudo de caso sobre o Brasil, que diferentes aparelhos atingem a saturação em diferentes níveis de renda e em diferentes níveis de penetração. Existem assim características não-econômicas que ajudam a melhor compreender a posse de equipamento e, por isso, precisam ser melhor entendidas.

Devido à motivação desta tese e à importância das mudanças climáticas em sua contextualização, a posse de eletrodomésticos voltados à climatização ambiente recebe destaque no **Gráfico 3**. Observa-se um número persistente de famílias sem tecnologias de resfriamento ambiente (AC ou ventilador), o que indica maior vulnerabilidade dessas famílias ao aquecimento global, uma vez que não possuem os equipamentos necessários para se adaptarem à mudança do clima. Essa vulnerabilidade é menos presente nos decis mais altos, que possuem renda para arcar não só com o custo do equipamento, mas também com a despesa de eletricidade referente ao seu uso. O AC possui alto consumo energético e alto custo de aquisição [239,240]. Como alternativa, o ventilador apresenta custos de aquisição e de operação baixos e atinge quase 50% dos domicílios em todas as classes de renda no ano de 2017-2018.



Gráfico 3. Tecnologias de resfriamento ambiente no Brasil por grupos socioeconômicos de acordo com POF (2008-2009) e POF (2017-2018)

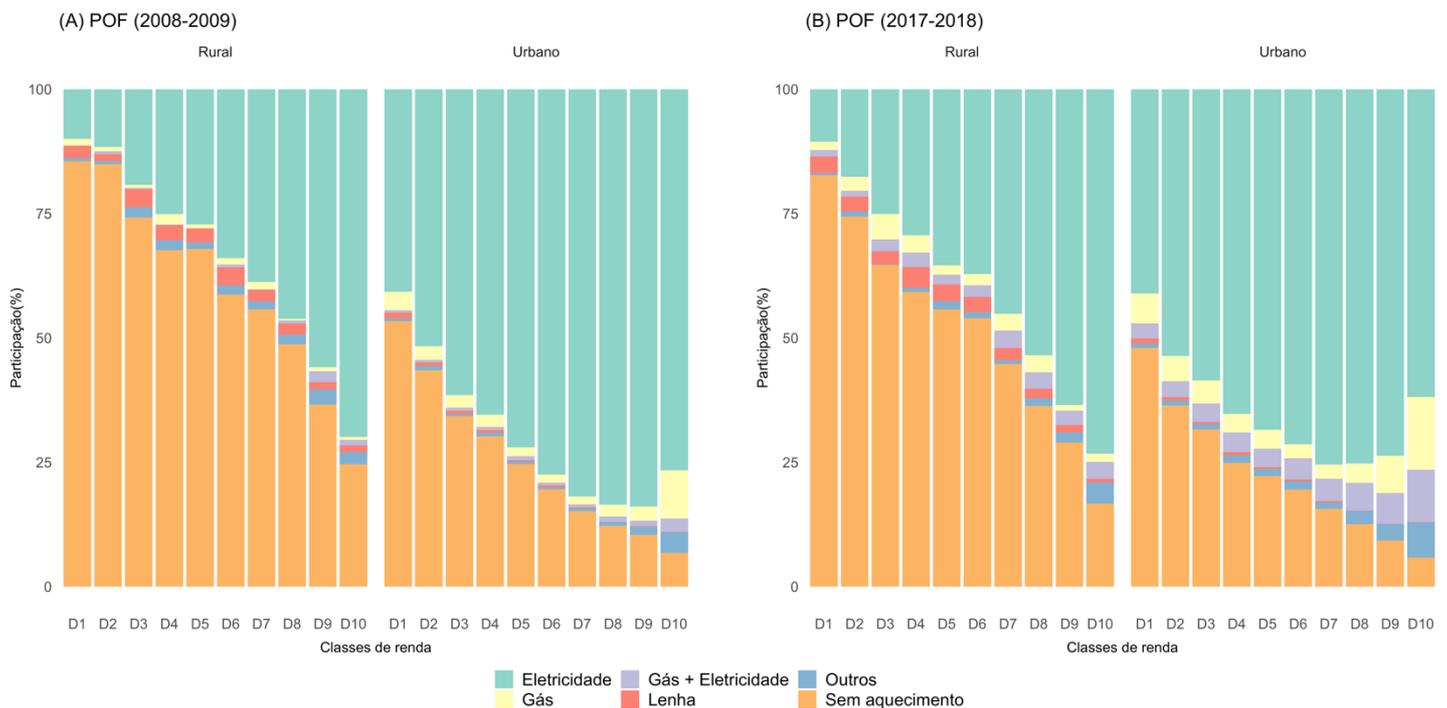
Fonte: Elaboração própria com base em IBGE [188]

Não obstante, equipamentos como o chuveiro e o fogão distinguem-se dos outros tipos uma vez que possuem diferentes opções de fontes de energia. Enquanto os equipamentos discutidos acima são majoritariamente elétricos e, assim, denominados eletrodomésticos, o chuveiro e o fogão não são necessariamente aparelhos elétricos. Dessa maneira, a escolha pela compra desses aparelhos depende fortemente do acesso a diferentes formas de energia para fornecimento do serviço final.

Logo, no caso desses serviços energéticos específicos, as trajetórias de transição energética são mais complexas. Nesses casos, é observado o fenômeno chamado “*energy stacking*”, traduzido para o português como “empilhamento de energia” ou “escada de energia”. Acontece que, com o aumento da renda familiar e a possibilidade de se utilizarem múltiplas fontes de energia para o mesmo serviço energético, soluções aprimoradas se tornam mais acessíveis, havendo uma tendência de empilhar várias fontes de energia [241,243]. À medida que a solução aprimorada está em conformidade com as práticas domésticas de uma classe social, a propriedade de eletrodomésticos aumenta, pois os ocupantes valorizam a posse desse eletrodoméstico. A chamada teoria da prática social (em inglês, *Social practise theory – SPT*) sugere que a posse de eletrodomésticos é

mais específica ao contexto do que meramente uma função da renda, e nem todos podem adquirir eletrodomésticos da mesma forma que a renda aumenta [64,244].

No caso do aquecimento da água do banho, o serviço energético pode ser provido por um chuveiro elétrico, solar, a gás ou até mesmo a lenha [245]. A participação de cada tipo de fonte de energia no aquecimento da água é revelada no **Gráfico 4**. A análise estatística realizada mostra que ainda há um grande percentual das famílias sem meios para aquecer a água do banho, o que em parte é explicado pelo clima mais quente e úmido, característico de algumas regiões brasileiras, como o Norte [239,240,245]. Ademais, entre os domicílios que aquecem água, majoritariamente o fazem através da eletricidade. A lenha como fonte de aquecimento de água se mantém presente na área rural, enquanto na área urbana é possível observar uma relevante presença de gás, principalmente do gás natural, devido ao maior acesso dos domicílios urbanos a tal fonte energética, que depende da rede de gás.



Enquanto a eletricidade é a fonte energética mais utilizada no aquecimento de água das residências brasileiras, o gás – principalmente o GLP – é predominante na cocção de alimentos. No caso da cocção, o empilhamento de energia é ainda mais nítido, principalmente em áreas urbanas, onde famílias chegam a “empilhar” três fonte de energia diferentes (gás, lenha e eletricidade), conforme **Gráfico 5**.

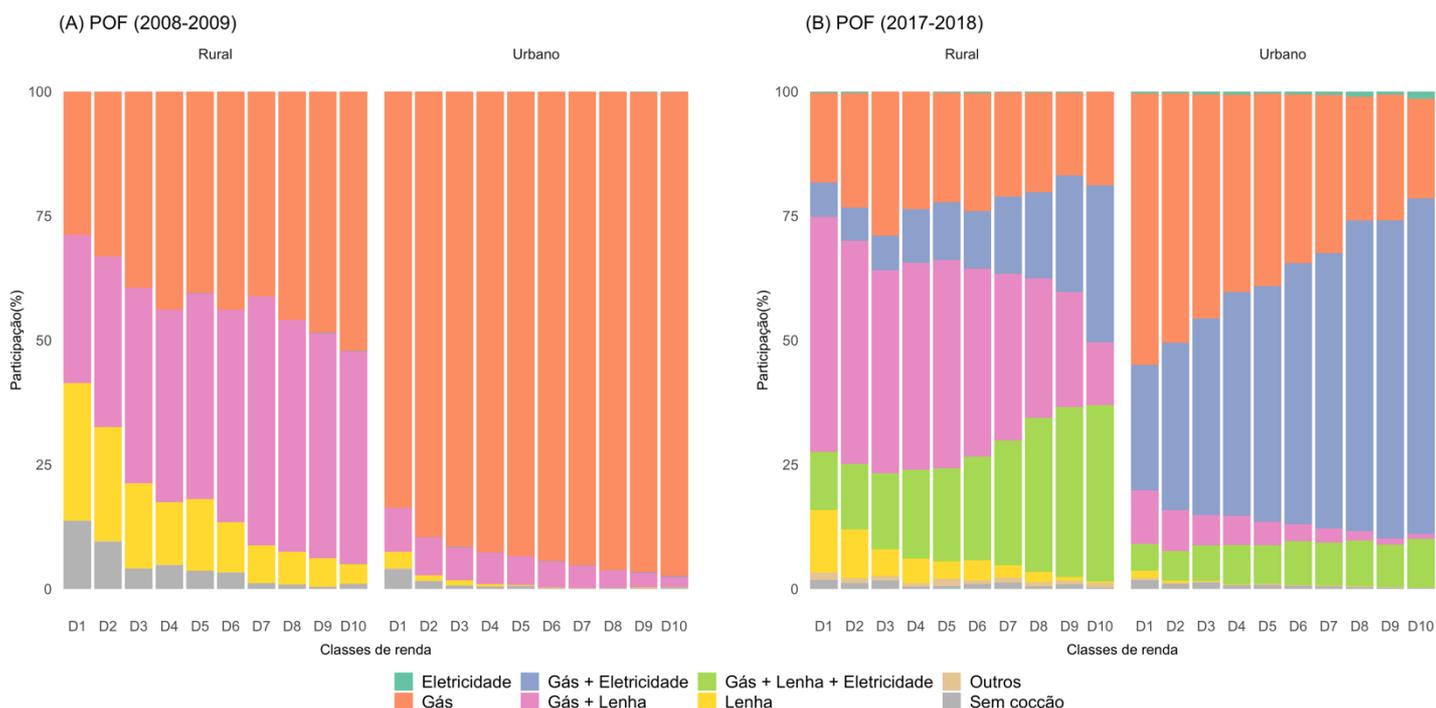


Gráfico 5. Fontes de energia para cocção no Brasil por grupos socioeconômicos de acordo com POF (2008-2009) e POF (2017-2018)

Nota: A categoria “Gás” refere-se tanto a gás natural quanto a GLP. A categoria “Lenha” refere-se tanto a lenha quanto a carvão/carvão vegetal.

Fonte: Elaboração própria com base em IBGE [188]

Olhando os diferentes grupos socioeconômicos, é possível perceber a forte presença da lenha em áreas rurais e principalmente nos decis mais pobres. Isso se dá em razão do baixo custo dos combustíveis em comparação com alternativas mais modernas. Segundo GIODA [65], o uso de lenha para cocção pela população de baixa renda parece estar diretamente associado ao preço do GLP, pois, em geral, a lenha utilizada por essa população é, em sua maioria, apanhada diretamente da terra. Assim, à medida que o preço do GLP aumenta, mais famílias recorrem ao uso da lenha, principalmente em áreas urbanas, onde ela é mais facilmente coletada sem custo financeiro. Ademais, apesar de o gás natural ter um custo mais baixo do que o do GLP, ele ainda é uma opção restrita, uma

vez que sua malha de distribuição ainda é bastante limitada [246]. Ressalta-se aqui que o aumento elevado no uso da eletricidade, observado no **Gráfico 5**, pode estar relacionado a um problema de interpretação dos respondentes ao questionário da POF. A desconfiança é que parte dessa eletricidade tenha sido captada pelo uso de micro-ondas e não pela utilização de fogões elétricos.

Historicamente, novas formas de energia, como o GLP e a eletricidade, vêm substituindo o uso da lenha [65]. No Brasil, a substituição da lenha pelo GLP foi resultado de um intenso processo de urbanização e intervenção governamental com base na regulação de preços e subsídios e programas de benefícios, como o Auxílio-Gás/Vale Gás (para mais informações ver MAZZONE *et al.* [247]). De acordo com COELHO *et al.* [248], as decisões relacionadas ao consumo de energia e ao tipo de combustível são fortemente influenciadas pela acessibilidade, *affordability* e conveniência do combustível. Os autores argumentam que, no que tange à cocção, a transição da lenha para combustíveis modernos como o GLP segue um padrão consistente no Brasil. Apesar dos esforços para promover a difusão de tecnologias menos poluentes e modernas, como fogões movidos a GLP e elétricos, MAZZONE *et al.* [67] argumentam que há uma demanda persistente por combustíveis tradicionais, especialmente nas áreas rurais. Os resultados de MAZZONE *et al.* [67] sugerem que a persistência do consumo de lenha para cozinhar está fortemente relacionada a indicadores culturais, como preferências alimentares, hábitos culinários, rituais, materiais da casa e conhecimento etnobotânico.

A substituição da lenha por energia moderna para cocção é um dos pilares da transição energética sustentável, além de sua grande importância na questão da saúde [67], dado que, a combustão incompleta de combustível sólido e de biomassa, como a lenha, gera gases voláteis e partículas respiráveis que estão associadas a doenças agudas e crônicas e aumento do risco de morte ⁵⁷ [249-252]. Dessa forma, projeção de demanda residencial de gás é de extrema importância para análise de cenários futuros de demanda residencial de energia. Além disso, o preço médio da revenda do botijão de gás (nome popular do barril de GLP) de 13kg aumentou de BRL 69,94 no início da pandemia da Covid-19, em março de 2020, para BRL 91,92 em julho de 2021 [253], gerando grande

⁵⁷ A poluição do ar doméstico é o fator de risco ambiental mais importante para doenças em todo o mundo [279]. De acordo com a Organização Mundial da Saúde (OMS), 3,8 milhões de pessoas morrem prematuramente por ano de doenças como pneumonia, doença isquêmica do coração, derrame e câncer de pulmão, que estão relacionadas à poluição doméstica do ar [280]. Efeitos na saúde da fumaça gerada pela queima de lenha são bem documentados, especialmente o impacto em mulheres, crianças e idosos [67].

oscilação na demanda do combustível. Contudo, devido à dificuldade em se obter dados confiáveis de consumo de gás na POF, esta tese optou por lidar apenas com o consumo de eletricidade.

Por fim, o **Gráfico 6** apresenta os diferentes padrões de consumo de eletricidade de acordo com os grupos socioeconômicos criados. Os domicílios rurais apresentam o maior crescimento médio no consumo de eletricidade comparado com os urbanos, considerando o período 2008-2018. Enquanto os domicílios mais ricos (decil 10) das áreas rurais obtiveram um aumento de 19% no consumo de eletricidade de 2008 para 2018, os das áreas urbanas mantiveram seu consumo estável. Em contrapartida, é observado um crescimento no consumo elétrico maior nos decis mais pobres, principalmente no decil 1, tanto nas áreas rurais como nas urbanas.

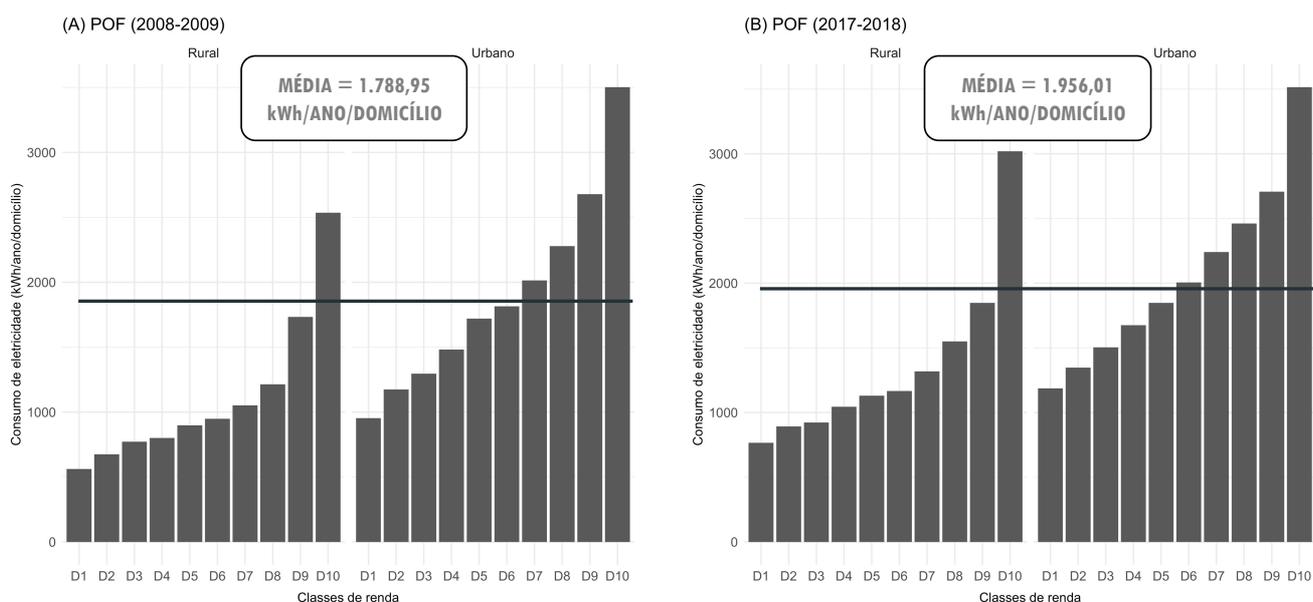


Gráfico 6. Consumo médio de eletricidade no Brasil por grupos socioeconômicos de acordo com POF (2008-2009) e POF (2017-2018)

Fonte: Elaboração própria com base em IBGE [188]

Os gráficos discutidos acima apresentam evidência empírica sobre a existência de diferentes grupos socioeconômicos com comportamentos e padrões de consumo heterogêneos. A seguir, é demonstrada empiricamente a heterogeneidade climática do país.

4.1.2 Dados de *Cooling Degree Days wet bulb* (CDD_{wb})

Esta seção apresenta a análise estatística dos dados climáticos utilizados como entrada nos modelos microeconômicos. Como comentado anteriormente, os dados climáticos de temperatura e umidade relativa são traduzidos em valores médios históricos de CDD_{wb} na base de dados utilizada [202]. É importante destacar que a análise estatística climática não utiliza o peso amostral, pois, usualmente, dados climáticos já são previamente ponderados pela população, como é o caso dos valores de CDD_{wb} utilizados nesta tese.

A **Tabela 9** revela os valores médios históricos de CDD_{wb} por estrato geográfico de cada Estado. Esses dados são utilizados como entrada nos modelos econométricos. Foram utilizados aproximadamente 88 valores de CDD_{wb} para cada período, garantindo assim uma maior variabilidade climática entre os domicílios, ideal para esse tipo de modelo.

Tabela 9. Sumário estatístico de dados climáticos históricos por Estados e Estrato Geográfico (valores para CDD_{wb} no período)

Estados	Estrato Geográfico*	1970-2002	1970-2008	1970-2016
11 Rondônia	Capital	525,92	553,50	563,76
	Outros Rurais	296,84	319,60	327,06
	Outros Urbanos	294,66	314,76	321,69
12 Acre	Capital	251,51	292,21	302,66
	Outros Rurais	295,47	331,78	340,71
	Outros Urbanos	303,79	340,13	349,40
13 Amazonas	Capital	399,26	431,88	434,17
	Outros Rurais	457,50	491,44	493,55
	Outros Urbanos	688,31	727,88	730,52
14 Roraima	Capital	636,17	688,13	696,32
	Outros Rurais	441,71	479,89	485,10
	Outros Urbanos	585,09	627,98	634,91
15 Pará	Capital	647,89	678,48	680,36
	Região Metropolitana	646,57	677,10	678,96
	Outros Rurais	616,56	643,17	646,78
	Outros Urbanos	647,71	672,60	676,16
16 Amapá	Capital	1033,57	1064,93	1074,02
	Outros Rurais	713,85	750,12	759,69
	Outros Urbanos	827,46	863,81	873,57
17 Tocantins	Capital	548,27	559,63	561,68
	Outros Rurais	423,31	434,09	436,46

		Outros Urbanos	410,11	421,20	423,48
		Capital	499,78	502,18	502,90
21	Maranhão	Outros Rurais	452,43	454,79	455,73
		Outros Urbanos	478,73	479,96	480,97
		Capital**	393,67	389,76	389,26
22	Piauí	Outros Rurais**	270,63	264,56	264,17
		Outros Urbanos**	301,54	295,25	294,85
		Capital	170,56	172,73	173,58
		Região Metropolitana	179,73	181,51	182,41
23	Ceará	Outros Rurais**	145,30	142,60	142,87
		Outros Urbanos**	144,23	140,68	140,85
		Capital	190,51	197,28	200,56
24	Rio Grande do Norte	Outros Rurais	187,38	187,99	190,50
		Outros Urbanos	204,08	203,63	206,23
		Capital	104,96	110,46	113,42
25	Paraíba	Outros Rurais**	88,59	87,20	88,55
		Outros Urbanos**	82,45	81,61	83,02
		Capital	97,78	103,17	105,96
26	Pernambuco	Região Metropolitana	101,09	106,18	108,97
		Outros Rurais**	49,60	47,78	48,48
		Capital	87,64	88,28	91,14
27	Alagoas	Outros Rurais**	84,92	81,39	83,62
		Outros Urbanos**	76,76	74,28	76,44
		Capital**	176,82	173,27	177,56
28	Sergipe	Outros Rurais**	113,67	107,92	110,82
		Outros Urbanos**	132,46	127,29	130,62
		Capital**	124,60	119,52	121,96
		Região Metropolitana**	126,30	120,90	123,18
29	Bahia	Outros Rurais**	55,52	51,73	52,63
		Outros Urbanos**	60,21	56,35	57,52
		Capital**	6,77	6,48	6,45
		Região Metropolitana**	9,81	9,51	9,52
31	Minas Gerais	Outros Rurais	45,20	46,12	46,99
		Outros Urbanos	50,52	51,84	52,83
		Capital	127,35	132,26	134,30
32	Espírito Santo	Outros Rurais	68,27	70,39	71,73
		Outros Urbanos	108,53	112,32	114,19
		Capital	25,04	27,44	28,55
		Região Metropolitana	50,15	53,33	54,82
33	Rio de Janeiro	Outros Rurais	60,38	63,13	64,40
		Outros Urbanos	47,77	50,16	51,34
		Capital	2,39	2,81	2,95
		Região Metropolitana	9,90	10,75	11,25
35	São Paulo	Outros Rurais	64,14	66,98	68,28
		Outros Urbanos	66,29	69,21	70,72
		Capital**	0,20	0,19	0,19
41	Paraná	Região Metropolitana	0,53	0,57	0,58
		Outros Rurais	25,49	28,45	29,13

		Outros Urbanos	24,12	27,12	27,78
		Capital	6,43	8,07	8,33
42	Santa Catarina	Outros Rurais	25,16	27,00	27,45
		Outros Urbanos	30,81	33,04	33,61
		Capital**	48,18	48,28	48,24
43	Rio Grande do Sul	Região Metropolitana	52,73	53,09	53,15
		Outros Rurais	39,16	40,29	40,69
		Outros Urbanos**	30,07	30,81	31,06
		Capital	73,93	78,96	80,73
50	Mato Grosso do Sul	Outros Rurais	192,34	199,75	202,80
		Outros Urbanos	198,10	205,62	208,67
		Capital	613,46	622,46	629,30
51	Mato Grosso	Outros Rurais	325,73	337,81	342,03
		Outros Urbanos	361,95	372,93	377,43
		Capital	54,44	60,26	61,41
52	Goiás	Outros Rurais	135,69	142,35	143,95
		Outros Urbanos	97,40	102,96	104,28
		Capital**	0,31	0,32	0,31
53	Distrito Federal	Outros Rurais**	0,92	0,96	0,96

Nota: *Considerando a classificação geográfica definida na POF (2008-2009). **Localidades que apresentam uma tendência histórica de resfriamento.

Fonte: Elaboração própria com base em MISTRY [197,202]

Por ser um país tropical, o Brasil é caracterizado por valores de CDD_{wb} relativamente altos. Segundo resultados obtidos, entre os valores mais altos das médias históricas de CDD_{wb} encontram-se Amapá, Amazonas, Pará e Rondônia. A capital do Amapá é a localidade com maior valor de CDD_{wb} , igual a 1074,02 graus-dias na média histórica para o período 1970-2016. Em contraste, Paraná e Santa Catarina apresentam os menores valores históricos, com a capital do Paraná com menor valor para o período 1970-2016, igual a 0,19 graus-dias. Como é possível perceber pela **Tabela 9** acima, algumas localidades apresentaram tendência de resfriamento no período considerado, o que pode ser justificado pela existência de microclimas. Tal tendência de resfriamento de alguns estratos geográficos não compromete a análise econométrica com modelos *cross-section*, posto que não há interdependência temporal, não são modelos dinâmicos e sim estáticos.

A **Figura 19** mostra uma visão espacial dos resultados de CDD_{wb} para os três períodos históricos analisados, agregados em Unidades da Federação. Em linha com outros estudos [18], a região Norte é a que apresenta os maiores valores de CDD_{wb} , refletindo uma maior temperatura em relação à média nacional, e, a região sul, os menores

valores. Dessa forma, é demonstrada a existência de heterogeneidade climática entre e dentro do país, evidenciando a presença de regiões com altos valores de CDD_{wb} .

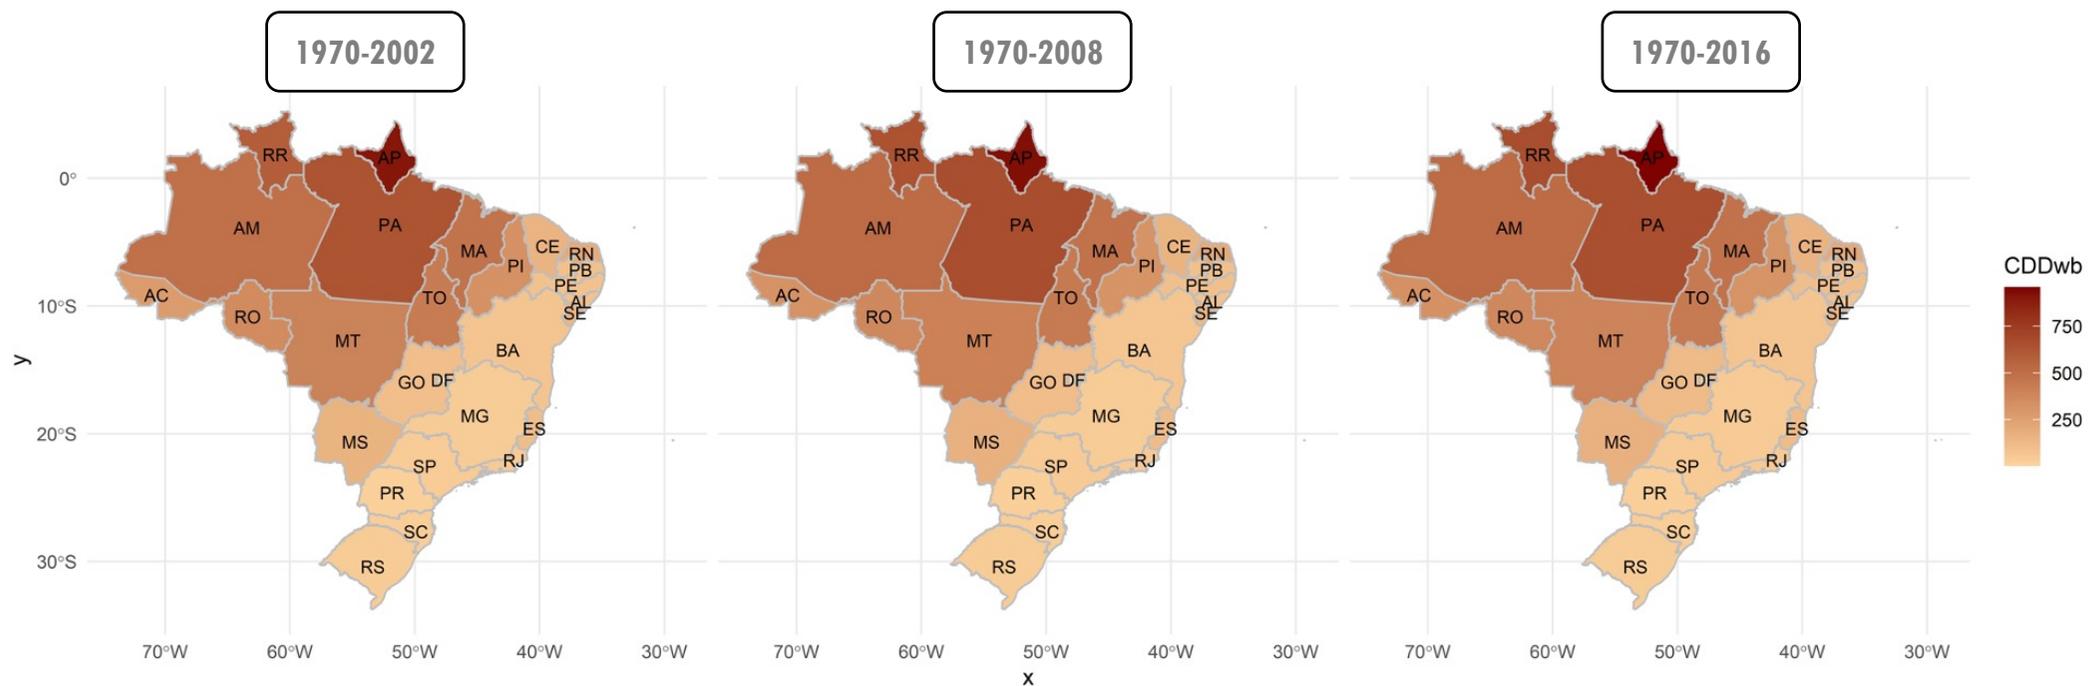


Figura 19. Médias históricas do CDD_{wb} em graus-dias, por Unidade da Federação para os diferentes períodos analisados

Fonte: Elaboração própria com base em MISTRY [202]

4.2 Modelagem microeconômica

Nesta seção, são apresentados e discutidos os resultados dos modelos microeconômicos desenvolvidos, ou seja, os resultados da inferência estatística e os testes de robustez realizados. Contudo, devido ao alto número de especificações desenvolvidas e testadas, são apresentados apenas os resultados das especificações mais relevantes para o presente estudo. Outros modelos e diferentes especificações são encontrados no **Apêndice**.

4.2.1 Modelagem da heterogeneidade

Nesta seção são apresentados os resultados da modelagem da heterogeneidade observada a partir de modelos com dados *cross-section* da POF.

4.2.1.1 Modelos de análise de covariância

Como já explicado no capítulo metodológico (especificamente na **Seção 3.2.2**), foram desenvolvidos três modelos ANCOVA, um para cada onda da POF. A seguir são descritos os resultados da inferência estatística desses modelos.

4.2.1.2 Inferência estatística

A inferência estatística permite calcular e discutir as elasticidades e semi-elasticidades das variáveis independentes selecionadas dos modelos ANCOVA. A seguir, os resultados dos testes de hipóteses e das estimações realizadas para os modelos.

4.2.1.2.1 Teste de heterocedasticidade (Breusch-Pagan Test)

O resultado do teste Breusch-Pagan no *software* R⁵⁸, considerando o “Modelo Base”⁵⁹ criado (sem o termo de interação), verificou um *p-valor* < 0.05 ⁶⁰, fazendo com

⁵⁸ Resultado retirado diretamente do *software* utilizando a função `bptest()`.

⁵⁹ O chamado Modelo Base é o modelo de especificação inicial criado levando em consideração o objetivo deste presente estudo. A partir dele são realizados os testes de hipóteses para se chegar ao modelo final.

⁶⁰ Segundo GUJARATI & PORTER [79] (p.142), o “valor p (o valor da probabilidade), também conhecida como nível de significância exato ou observado ou probabilidade exata de cometer um erro do Tipo I. Mais tecnicamente, o valor p é definido como o menor nível de significância em que uma hipótese nula pode ser rejeitada”.

que a hipótese nula H_0 (presença de homocedasticidade) seja rejeitada e confirmando a presença de heterocedasticidade.

Normalmente, mesmo que a suspeita de heterocedasticidade seja detectada, como foi o caso aqui, não é fácil corrigir o problema. Contudo, no caso de amostras grandes como a da POF, é possível obter os erros padrão ajustados para heterocedasticidade de White com base nos estimadores de MQO e conduzir inferência estatística com base neles. Tais erros são conhecidos como estimadores consistentes da matriz de covariância para heterocedasticidade (ou pela sigla HCCME, do inglês, *White's heteroskedastic-consistent covariance matrix estimator*), também chamados Erros Padrão Robustos⁶¹. O HCCME é utilizado na estimação e torna os erros robustos para heterocedasticidade, permitindo que o estimador seja BLUE. Os resultados da estimação dos parâmetros, considerando os modelos base especificados para cada onda da POF e o novo estimador, são apresentados na **Tabela 10**. Esses são considerados resultados intermediários, visto que ainda são necessários outros testes de hipóteses para a escolha da especificação final do modelo, abordada mais à frente.

⁶¹ Em estatística, o erro padrão mede a precisão de uma estimativa, ou seja, a confiabilidade de um estimador pontual. Ele é o desvio padrão da distribuição amostral do estimador, que é utilizada para fazer inferências sobre os valores dos parâmetros populacionais com base nos valores calculados dos estimadores baseados em uma ou mais amostras. Através do erro padrão é possível construir um intervalo em torno de um estimador pontual, de modo que esse intervalo tenha, por exemplo, 95% de probabilidade de incluir o verdadeiro valor do parâmetro. A amplitude do intervalo de confiança é proporcional ao erro padrão do estimador – quanto maior o erro padrão do estimador, maior é a incerteza da estimação do verdadeiro valor do parâmetro desconhecido [79].

Tabela 10. Sumário de regressão para cada ano da POF – Modelo Base

	POF (2002-2003)	POF (2008-2009)	POF (2017-2018)
Ln Renda	0,154*** (0,005)	0,122*** (0,005)	0,129*** (0,004)
Ln Preço _E	0,214*** (0,010)	-0,015* (0,008)	-0,098*** (0,010)
CDD _{wb} médio	0,0004*** (0,00003)	0,0003*** (0,00002)	0,0004*** (0,00002)
Urbano (1 = Urbano)	0,065*** (0,009)	0,026*** (0,008)	0,091*** (0,007)
Norte	-0,142*** (0,015)	-0,101*** (0,013)	-0,118*** (0,014)
Nordeste	-0,344*** (0,009)	-0,257*** (0,009)	-0,177*** (0,009)
Sul	0,010 (0,011)	0,141*** (0,011)	-0,020** (0,010)
Sudeste	-0,069*** (0,010)	0,027*** (0,009)	-0,038*** (0,009)
Residência própria (1 = Próprio)	-0,029*** (0,007)	-0,007 (0,007)	-0,017*** (0,006)
Índice da <i>household</i> (1 = Alta qualidade)	NA	0,051*** (0,006)	-0,001 (0,006)
Tipo de domicílio (1 = Casa)	-0,007 (0,012)	0,003 (0,010)	0,061*** (0,008)
Nº de cômodos	0,025*** (0,002)	0,022*** (0,002)	0,029*** (0,001)
Membros da família	0,033*** (0,002)	0,061*** (0,002)	0,076*** (0,002)
Sexo (1 = Masculino)	-0,0005 (0,007)	-0,015*** (0,006)	0,003 (0,005)
Raça (1 = Branco)	0,039*** (0,007)	0,028*** (0,006)	0,027*** (0,005)
Idade	0,001*** (0,0002)	0,002*** (0,0002)	0,002*** (0,0002)
Anos de educação	0,010*** (0,001)	0,011*** (0,001)	0,009*** (0,001)
AC	0,257*** (0,037)	0,227*** (0,011)	0,262*** (0,007)
Ventilador	0,054*** (0,007)	0,047*** (0,006)	0,081*** (0,006)
Computador	0,133*** (0,011)	0,140*** (0,008)	0,050*** (0,005)
Micro-ondas	0,091*** (0,010)	0,066*** (0,008)	0,103*** (0,006)
TV	0,042*** (0,009)	0,051*** (0,012)	0,026*** (0,006)
Geladeira	0,338*** (0,011)	0,290*** (0,012)	0,158*** (0,015)
Freezer	0,281*** (0,009)	0,243*** (0,009)	0,212*** (0,008)
Máquina de lavar roupa	0,106*** (0,008)	0,081*** (0,007)	0,116*** (0,006)
Ferro	0,062*** (0,009)	0,073*** (0,007)	0,016*** (0,006)
Rádio	-0,020*** (0,006)	-0,018*** (0,006)	-0,045*** (0,005)
Chuveiro elétrico	NA	0,104*** (0,008)	0,074*** (0,007)
Máquina de lavar louça	-0,024 (0,132)	0,026 (0,025)	0,037* (0,019)
Aspirador	0,002 (0,012)	0,011 (0,011)	NA
Intercepto	4,756*** (0,049)	4,786*** (0,046)	4,791*** (0,044)
Observações	39.469	48.732	49.734
R ²	0,464	0,408	0,392
R ² Ajustado	0,464	0,408	0,391

Nota: Níveis de significância (p-valor), * < 0,10; *** < 0,05; **** < 0,01; resultados com erros padrão robustos

Fonte: Elaboração própria

Do lado esquerdo da **Tabela 10** são observadas as variáveis independentes utilizadas em cada modelo *cross-section* base. Já do lado direito estão os resultados dos parâmetros, um indicativo de nível de significância do parâmetro (representado pelo símbolo do asterisco) e, entre parênteses, o valor do erro padrão robusto. O resultado “NA” significa que a variável não estava disponível no ano específico da POF e, por isso, não foi incluída no respectivo modelo.

No modelo *cross-section* para 2002-2003 foram consideradas 39.469 observações; nesse caso, domicílios brasileiros. Esse número se ampliou para 48.732

domicílios em 2008-2009 e para 49.734 em 2017-2018. O aumento da amostra ao longo dos anos reflete o aumento dos domicílios e da população brasileira no período analisado.

Outros componentes da tabela, os **coeficientes de determinação, R^2 e R^2 Ajustado (\bar{R}^2)**, são usualmente empregados como medidas da qualidade do ajustamento. Seu valor situa-se entre zero e um⁶², e, quanto mais próximo de um, melhor é o ajustamento. De acordo com GUJARATI & PORTER [79], R^2 mede a proporção da variação da variável dependente explicada pelo(s) regressor(es), enquanto o \bar{R}^2 é mais refinado, uma vez que é ajustado pelos graus de liberdade associados à soma de quadrados⁶³.

Os resultados apresentados na **Tabela 10** não são detalhados, já que tais valores sofrerão alterações ao longo da inferência estatística apresentada neste capítulo.

4.2.1.2.2 *Teste de especificação (Wald Test)*

Os resultados da estimação dos cinco modelos intermediários (com erros padrão robustos), testados para a especificação de Wald no *software* R⁶⁴, são apresentados na **Tabela 11**. A tabela apresenta os resultados de diferentes modelos para o período 2017-2018. Tais modelos, Modelo de 1 à 6, diferem fundamentalmente na escolha das variáveis de controle, que podem ser retiradas, adicionadas, transformadas ou combinadas (termo de interação), sendo o Modelo 6 o de especificação preferencial. O importante, nesse caso, é garantir que a alteração na especificação do modelo apresente um resultado no *Wald Test* equivalente a um *p-valor* < 0.05 , que significa que a especificação do modelo alternativo melhorou o ajuste em relação ao modelo anterior.

⁶² Caso o R^2 seja igual a 1, a linha de regressão ajustada explicará 100% da variação da variável dependente (Y). Ao contrário, se for igual a 0, o modelo não explicará nada da variação de Y [79].

⁶³ Para número de regressores em uma regressão maior que 1, $\bar{R}^2 < R^2$, pois, à medida que o número de variáveis independentes aumenta, \bar{R}^2 aumenta menos que R^2 (para mais detalhes, ver GUJARATI & PORTER [79]).

⁶⁴ Função utilizada no *software* R: `waldtest()`.

Tabela 11. Sumário de regressão da POF (2017-2018) – Especificação do modelo e escolha de variáveis controle

	Modelo (1)	Modelo (2)	Modelo (3)	Modelo (4)	Modelo (5)
Ln Renda	0,129*** (0,004)	0,129*** (0,004)	0,129*** (0,004)	0,128*** (0,004)	0,040*** (0,012)
Ln Preço _E	-0,098*** (0,010)	-0,098*** (0,010)	-0,098*** (0,010)	-0,096*** (0,010)	-0,094*** (0,010)
CDD _{wb} médio	0,0004*** (0,00002)	0,0004*** (0,00002)	0,0004*** (0,00002)	0,0004*** (0,00002)	0,0004*** (0,00002)
Urbano (1 = Urbano)	0,091*** (0,007)	0,092*** (0,007)	0,092*** (0,007)	0,096*** (0,007)	0,149*** (0,009)
Norte	-0,118*** (0,014)	-0,120*** (0,014)	-0,120*** (0,014)	-0,118*** (0,014)	-0,115*** (0,014)
Nordeste	-0,177*** (0,009)	-0,179*** (0,009)	-0,179*** (0,009)	-0,177*** (0,009)	-0,174*** (0,009)
Sul	-0,020** (0,010)	-0,021** (0,010)	-0,022** (0,010)	-0,026*** (0,010)	-0,024** (0,010)
Sudeste	-0,038*** (0,009)	-0,039*** (0,009)	-0,039*** (0,009)	-0,037*** (0,009)	-0,034*** (0,009)
Residência própria (1 = Próprio)	-0,017*** (0,006)	–	–	–	–
Índice da <i>household</i> (1 = Alta qualidade)	-0,001 (0,006)	-0,00002 (0,006)	–	–	–
Tipo de domicílio (1 = Casa)	0,061*** (0,008)	0,058*** (0,008)	0,058*** (0,008)	0,056*** (0,008)	0,061*** (0,008)
Nº de cômodos	0,029*** (0,001)	0,029*** (0,001)	0,029*** (0,001)	0,029*** (0,001)	0,027*** (0,001)
Membros da família	0,076*** (0,002)	0,076*** (0,002)	0,076*** (0,002)	0,076*** (0,002)	0,075*** (0,002)
Sexo (1 = Masculino)	0,003 (0,005)	0,003 (0,005)	–	–	–
Raça (1 = Branco)	0,027*** (0,005)	0,027*** (0,005)	0,027*** (0,005)	0,027*** (0,005)	0,026*** (0,005)
Idade	0,002*** (0,0002)	0,002*** (0,0002)	0,002*** (0,0002)	0,002*** (0,0002)	0,002*** (0,0002)
Anos de educação	0,009*** (0,001)	0,009*** (0,001)	0,009*** (0,001)	0,009*** (0,001)	0,009*** (0,001)
AC	0,262*** (0,007)	0,261*** (0,007)	0,261*** (0,007)	0,262*** (0,007)	0,258*** (0,007)
Ventilador	0,081*** (0,006)	0,081*** (0,006)	0,081*** (0,006)	0,079*** (0,006)	0,078*** (0,006)
Computador	0,050*** (0,005)	0,050*** (0,005)	0,050*** (0,005)	0,050*** (0,005)	0,047*** (0,005)
Micro-ondas	0,103*** (0,006)	0,103*** (0,006)	0,103*** (0,006)	0,104*** (0,006)	0,103*** (0,006)
TV	0,026*** (0,006)	0,025*** (0,006)	0,025*** (0,006)	0,023*** (0,006)	0,023*** (0,006)
Geladeira	0,158*** (0,015)	0,158*** (0,015)	0,158*** (0,015)	0,157*** (0,015)	0,158*** (0,015)
Freezer	0,212*** (0,008)	0,212*** (0,008)	0,212*** (0,008)	0,209*** (0,008)	0,204*** (0,008)
Máquina de lavar roupa	0,116*** (0,006)	0,116*** (0,006)	0,116*** (0,006)	0,116*** (0,006)	0,115*** (0,006)
Ferro	0,016*** (0,006)	0,015** (0,006)	0,015** (0,006)	0,013** (0,006)	0,014** (0,006)
Rádio	-0,045*** (0,005)	-0,045*** (0,005)	-0,045*** (0,005)	–	–
Chuveiro Elétrico	0,074*** (0,007)	0,074*** (0,007)	0,074*** (0,007)	0,072*** (0,007)	0,071*** (0,007)
Máquina de lavar louça	0,037* (0,019)	0,037* (0,019)	0,037* (0,019)	0,038** (0,019)	0,037* (0,019)
Ln Renda X Decil 2			–	–	0,001 (0,001)
Ln Renda X Decil 3			–	–	0,003* (0,001)
Ln Renda X Decil 4			–	–	0,007*** (0,002)
Ln Renda X Decil 5			–	–	0,009*** (0,002)
Ln Renda X Decil 6			–	–	0,011*** (0,002)
Ln Renda X Decil 7			–	–	0,012*** (0,002)
Ln Renda X Decil 8			–	–	0,015*** (0,002)
Ln Renda X Decil 9			–	–	0,017*** (0,003)
Ln Renda X Decil 10			–	–	0,024*** (0,003)
Intercepto	4,791*** (0,044)	4,798*** (0,044)	4,799*** (0,044)	4,802*** (0,044)	5,602*** (0,107)
Observações	49.734	49.734	49.734	49.734	49.734
R ²	0,392	0,392	0,392	0,391	0,392
R ² Ajustado	0,391	0,391	0,391	0,390	0,392

Nota: Níveis de significância (p-valor), * < 0,10; *** < 0,05; **** < 0,01; resultados com erros padrão robustos

Fonte: Elaboração própria

A decisão de alterar a especificação de modelos econométricos é guiada, *a priori*, tanto pelo sinal e valor do coeficiente das variáveis controle como pelo seu nível de significância. Em alguns ramos da teoria econométrica, como os da bioestatística, é habitual incluir no modelo econométrico apenas variáveis controle com nível de significância usualmente alto ($p\text{-valor} < 0,05$). Contudo, no caso de modelos microeconômicos isso não é trivial. Em vez disso, segundo CAMERON & TRIVEDI [76], na microeconometria é bastante comum adicionar regressores estatisticamente insignificantes ($p\text{-valor} > 0,05$), caso a teoria econômica ou a prática convencional inclua a variável como controle. Isso reduz a probabilidade de inconsistência nos parâmetros estimados devido ao viés de variáveis omitidas, às custas de uma redução na precisão da estimação [76]. Dessa forma, a escolha das variáveis controle adicionadas ao modelo tem o objetivo de obter uma estimativa não viesada e precisa do interesse do efeito causal. Como apontado por PAVANELLO *et al.* [194], não incluir este rico conjunto de características socioeconômicas das famílias/domicílios afetaria significativamente as elasticidades da renda e do CDD_{wb} .

Assim, o processo de especificação teve início no “Modelo Base” já apresentado na **Tabela 10**. A primeira decisão em relação à especificação do modelo é a retirada do regressor “Residência própria” (Modelo 1), pois, estudos como PAVANELLO *et al.* [194] apontam empiricamente um efeito positivo entre posse da residência e consumo de eletricidade, dado que residências próprias estão na maioria dos casos relacionadas com maior renda média domiciliar. Apesar de outros estudos, como TAALE & KYEREMEH [12], apontarem o oposto, justificado pela relutância de melhoras e maiores investimentos estruturais em residências não próprias, optou-se pela remoção da variável.

No Modelo 2, optou-se pela retirada da *dummy* “Índice da *household*”. Era esperado que domicílios classificados como de “alta qualidade” consumissem mais energia do que os categorizados como de “baixa qualidade”, que indicam uma condição de entorno e uma qualidade de vida das famílias pior, o que não foi verificado devido ao sinal negativo do regressor. Adicionalmente, seu efeito marginal é quase nulo e não apresentou relevância estatística para a base de dados da POF (2017-2018).

Já no Modelo 3, houve a retirada da variável “Sexo”. Além de apresentar um efeito marginal baixo, indicando que o fato de o chefe da família ser homem não altera

expressivamente o consumo de eletricidade da residência em comparação com os domicílios chefiados por mulheres, o seu nível de significância também é baixo.

Em relação à posse de eletrodomésticos, foi retirada a variável “Rádio” (Modelo 4), por apresentar um sinal que é, em princípio, contraintuitivo. Como verificado na **Tabela 11**, a presença de uma unidade a mais de aparelho de rádio em uma residência resulta, de acordo com os modelos 1-3, em um consumo médio de eletricidade menor. Uma possível explicação para esse efeito inesperado é o perfil mais conservador das famílias que tradicionalmente escutam rádios.

Por fim, o Modelo 5 é o selecionado como o de especificação preferencial e verificado através de resultados do *Wald Test*. Neste, além de terem sido retiradas as variáveis comentadas acima, introduziu-se o termo de interação – mencionado na **Equação (3.10)** do capítulo metodológico –, que representa o efeito multiplicativo entre a renda e *dummy* para decis de renda. É interessante notar que a adição de um novo controle com “Ln Renda X Decil”, acarreta uma significativa redução no resultado da elasticidade-renda atribuída a variável “Ln Renda”. A elasticidade-renda dos modelos 1-4 para o período 2017-2018 é de aproximadamente 0,129, o que significa que, em média, ao ter sua renda aumentada em 1%, o consumo de eletricidade do domicílio aumentará respectivamente em 0,129%, *ceteris paribus*. Ademais, é observado um *p-valor* < 0,01 para a variável renda, apontando um alto nível de significância.

No entanto, com a adição do termo interativo entre renda e decil, o coeficiente representativo da elasticidade-renda da variável “Ln Renda” cai de aproximadamente 0,129 para 0,04, e a estimação do coeficiente perde precisão, embasado por um erro padrão maior no Modelo 6 em comparação com os outros. Isso ocorre, porque parte do efeito marginal da renda passa a ser controlada pelos termos de interação.

É importante compreender o que significa a introdução do termo interativo no modelo. Sua inclusão faz com que exista um controle da elasticidade-renda de acordo com os decis, através do vetor de coeficientes angulares diferenciais, ou deslocador do coeficiente angular. No modelo considerado, a categoria de controle é o decil 1 (domicílios mais pobres)⁶⁵. Como consequência, o novo valor da elasticidade-renda do

⁶⁵ O decil 1 foi escolhido como categoria controle por ser o grupo de consumidores de energia com menor demanda de eletricidade, sendo considerado consumo médio elétrico mínimo.

Modelo 6, representada pela variável “Ln Renda”, passa a representar a elasticidade-renda da categoria de referência (domicílios pertencentes ao decil 1).

Dessa maneira, os termos de interação são utilizados para estudar como as estimativas de elasticidade mudam com os níveis de renda. As novas elasticidades-renda definidas pelos coeficientes angulares diferenciais são discutidas na **Seção 4.3**, onde é apresentado o modelo final.

Além disso, ao escolher a melhor especificação para o modelo de regressão, é usual na econometria atentar para os resultados do R^2 e do \bar{R}^2 , embora tais indicadores sejam tão relevantes na microeconometria [76]. Aliás, é bem comum modelos *cross-section* apresentarem valores baixos para tais medidas, com valores próximos a 30%, como é o caso dos cinco modelos apresentados, com valores de \bar{R}^2 próximos a 39%.

Ademais, segundo GUJARATI & PORTER [79], não se deve cair no jogo de maximização do \bar{R}^2 , pois o objetivo na análise de regressão não é obter um valor alto *per se*, mas sim obter estimativas confiáveis dos verdadeiros coeficientes de regressão para a população e fazer inferências estatísticas a respeito deles. Portanto, ainda de acordo com os autores, a preocupação analítica deve estar focada na relevância lógica ou teórica das variáveis explanatórias em relação à variável dependente e em sua significância estatística, o que foi feito aqui.

O mesmo procedimento de especificação das variáveis foi realizado para as três ondas da POF; as tabelas com os resultados intermediários tanto para a base de dados POF (2002-2003) quanto da POF (2008-2009) são apresentadas no **Apêndice**. Para mais, na **Tabela 12** são encontrados os resultados dos modelos preferenciais para cada onda da POF. Como é possível perceber, cada período apresentou uma especificação preferencial diferente, devido a uma melhor adaptação à base de dados *cross-section* disponível para seu respectivo período. Por exemplo, no caso da POF (2008-2009) a variável controle “Índice da *household*” apresenta um coeficiente positivo com efeito relevante e estatisticamente significativo. Isso indica que residências categorizadas como de “alta qualidade” (*dummy* igual a um) consomem mais eletricidade do que as classificadas como de “baixa qualidade” (*dummy* igual a zero).

Tabela 12. Sumário de regressão para cada onda da POF – Modelo de especificação preferencial

	POF (2002-2003)	POF (2008-2009)	POF (2017-2018)
Ln Renda	0,034** (0,017)	0,050*** (0,014)	0,040*** (0,012)
Ln Preço _E	0,214*** (0,010)	-0,014* (0,008)	-0,094*** (0,010)
CDD _{wb} médio	0,0004*** (0,00003)	0,0003*** (0,00002)	0,0004*** (0,00002)
Urbano (1 = Urbano)	0,131*** (0,012)	0,073*** (0,011)	0,149*** (0,009)
Norte	-0,146*** (0,015)	-0,102*** (0,013)	-0,115*** (0,014)
Nordeste	-0,348*** (0,009)	-0,258*** (0,009)	-0,174*** (0,009)
Sul	0,005 (0,011)	0,140*** (0,011)	-0,024** (0,010)
Sudeste	-0,074*** (0,010)	0,025*** (0,009)	-0,034*** (0,009)
Residência própria (1 = Próprio)	-	-	-
Índice da <i>household</i> (1 = Alta qualidade)	NA	0,053*** (0,006)	-
Tipo de domicílio (1 = Casa)	-0,005 (0,012)	0,006 (0,010)	0,061*** (0,008)
Nº de cômodos	0,024*** (0,002)	0,021*** (0,002)	0,027*** (0,001)
Membros da família	0,033*** (0,002)	0,060*** (0,002)	0,075*** (0,002)
Sexo (1 = Masculino)	-	-	-
Raça (1 = Branco)	0,038*** (0,007)	0,027*** (0,006)	0,026*** (0,005)
Idade	0,001*** (0,0002)	0,002*** (0,0002)	0,002*** (0,0002)
Anos de educação	0,010*** (0,001)	0,011*** (0,001)	0,009*** (0,001)
AC	0,252*** (0,036)	0,221*** (0,011)	0,258*** (0,007)
Ventilador	0,053*** (0,007)	0,048*** (0,006)	0,078*** (0,006)
Computador	0,123*** (0,011)	0,135*** (0,008)	0,047*** (0,005)
Micro-ondas	0,085*** (0,010)	0,064*** (0,008)	0,103*** (0,006)
TV	0,043*** (0,009)	0,051*** (0,012)	0,023*** (0,006)
Geladeira	0,343*** (0,011)	0,294*** (0,012)	0,158*** (0,015)
Freezer	0,274*** (0,009)	0,236*** (0,009)	0,204*** (0,008)
Máquina de lavar roupa	0,101*** (0,008)	0,080*** (0,007)	0,115*** (0,006)
Ferro	0,063*** (0,009)	0,074*** (0,007)	0,014** (0,006)
Rádio	-	-	-
Chuveiro Elétrico	NA	0,102*** (0,008)	0,071*** (0,007)
Máquina de lavar louça	-	0,025 (0,025)	0,037* (0,019)
Aspirador	-	0,004 (0,011)	NA
Ln Renda X Decil 2	0,003* (0,002)	0,003** (0,001)	0,001 (0,001)
Ln Renda X Decil 3	0,005*** (0,002)	0,003 (0,002)	0,003* (0,001)
Ln Renda X Decil 4	0,010*** (0,002)	0,007*** (0,002)	0,007*** (0,002)
Ln Renda X Decil 5	0,014*** (0,003)	0,007*** (0,002)	0,009*** (0,002)
Ln Renda X Decil 6	0,016*** (0,003)	0,009*** (0,002)	0,011*** (0,002)
Ln Renda X Decil 7	0,019*** (0,003)	0,011*** (0,003)	0,012*** (0,002)
Ln Renda X Decil 8	0,025*** (0,004)	0,012*** (0,003)	0,015*** (0,002)
Ln Renda X Decil 9	0,028*** (0,004)	0,016*** (0,003)	0,017*** (0,003)
Ln Renda X Decil 10	0,034*** (0,005)	0,021*** (0,004)	0,024*** (0,003)
Intercepto	5,775*** (0,144)	5,397*** (0,118)	5,602*** (0,107)
Observações	39.469	48.732	49.734
R ²	0,465	0,409	0,392
R ² Ajustado	0,465	0,409	0,392

Nota: Níveis de significância (p-valor), * < 0,10; *** < 0,05; **** < 0,01; resultados com erros padrão robustos

Fonte: Elaboração própria

No caso do modelo *cross-section* para a POF (2002-2003), são verificados alguns resultados peculiares. Estranhamente, a elasticidade-preço apresentou um efeito positivo, enquanto a máquina de lavar e o aspirador apresentaram efeitos marginais negativos.

Antes de justificar a causa desses efeitos adversos, é preciso entender se eles permanecerão com a introdução de novos testes.

4.2.1.2.3 Teste de Multicolinearidade

Os resultados da matriz de correlação⁶⁶ para cada onda da POF permitem testar a presença de multicolinearidade nos modelos ANCOVA desenvolvidos. A matriz mostra os coeficientes de correlação entre variáveis quantitativas. A linha com valores iguais a um, indo do canto superior esquerdo para o canto inferior direito, é a diagonal principal, o que mostra que cada variável sempre se correlaciona perfeitamente com ela mesma. Quando o coeficiente de correlação se aproxima de um⁶⁷, nota-se um aumento no valor de uma variável quando a outra também aumenta, ou seja, há uma relação linear positiva. A matriz é simétrica, sendo a correlação mostrada acima da diagonal principal uma imagem espelhada daquelas abaixo da diagonal principal, motivo pelo qual optou-se por apresentar apenas os resultados abaixo da diagonal principal.

A **Figura 20** apresenta a matriz de correlação para o modelo *cross-section* de 2017-2018. Os valores em azul indicam uma relação linear positiva entre duas variáveis, enquanto a cor vermelha mostra uma relação negativa. Como é possível observar pelos resultados da matriz, não há nenhum indicativo de forte correlação entre variáveis (valores acima de 0,70). A maioria das variáveis possuem o coeficiente de correlação entre 0,00 e 0,30, positivo ou negativo, o que indica uma correlação desprezível. Algumas exceções, variáveis relacionadas à renda, apresentam valores próximos a 0,40, o que não é preocupante, pois que apenas indicam uma correlação moderada. É o caso do número de cômodos da residência, anos de educação do chefe da família e posse de equipamento

⁶⁶ A correlação busca entender como uma variável se comporta num cenário em que outra está variando, visando identificar se existe alguma relação entre a variabilidade de ambas. Embora não implique em causalidade, o coeficiente de correlação exprime em números essa relação, ou seja, quantifica a relação entre as variáveis aleatórias.

Os dados utilizados para calcular correlações contêm N.A.s. Existem várias estratégias para lidar com a ausência de valores ao calcular matrizes de correlação. Optou-se por realizar o cálculo da correlação usando todos os dados não perdidos para as duas variáveis, assumindo que os dados estão faltando completamente ao acaso.

⁶⁷ De acordo com MEGHANATHAN [281], os níveis de correlação são definidos, considerando valores em módulos, por,

- Correlação muito forte: 0,80 até 1,00
- Correlação forte: 0,60 até 0,79
- Correlação moderada - 0,40 até 0,59
- Correlação fraca: 0,20 até 0,39
- Correlação muito fraca: 0,00 até 0,19

de AC, computador, micro-ondas e máquina de lavar roupa. Já era esperado que algumas dessas variáveis fossem relacionadas com a renda, visto que elas refletem um melhor padrão de vida. Contudo, não foi verificada a presença de multicolinearidade perfeita, pois a matriz não apresentou nenhuma correlação muito forte (acima de 0,90).

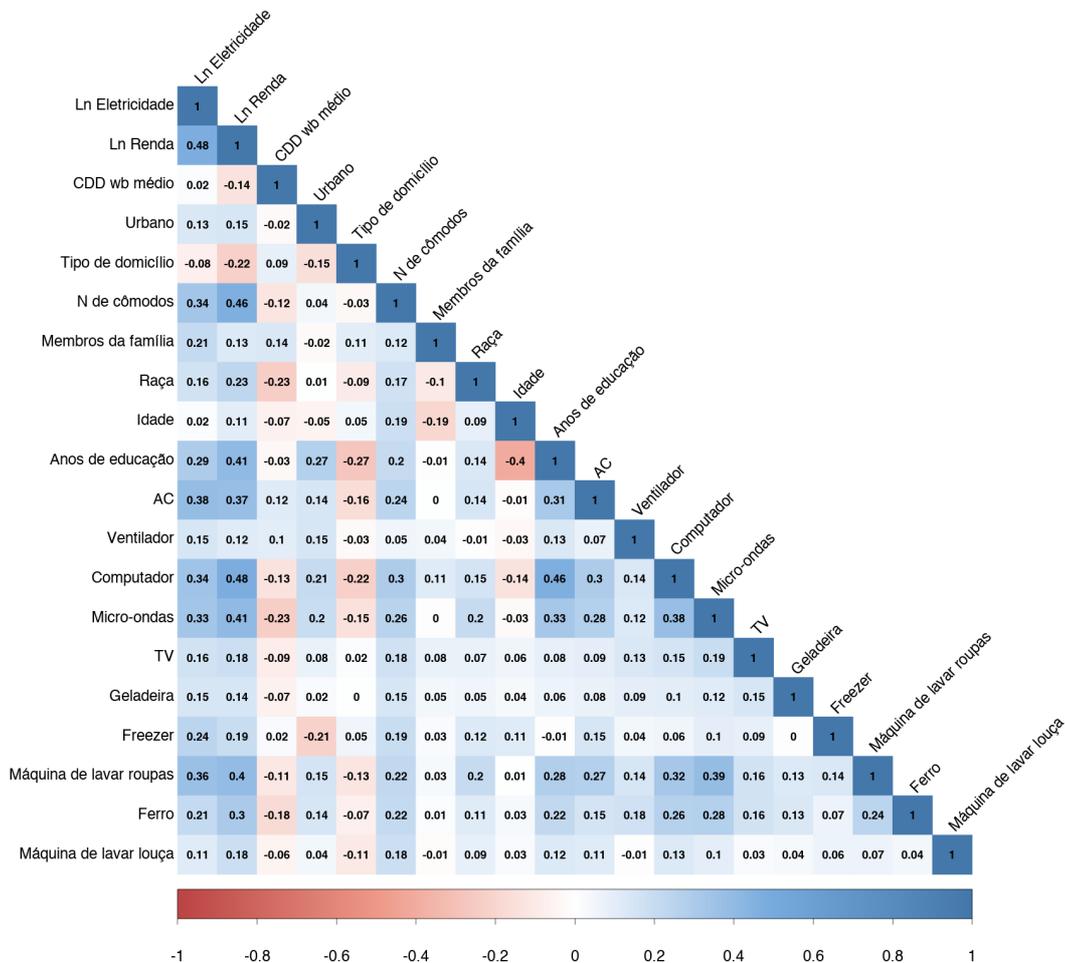


Figura 20. Matriz de correlação da POF (2017-2018)

Fonte: Elaboração própria

Para mais, a variável que representa os valores médios de CDD_{wb} destaca-se devido à sua correlação negativa com algumas variáveis, como posse de chuveiro elétrico, computador, micro-ondas, máquina de lavar roupa e ferro. Nesses casos, trata-se de uma correlação espúria⁶⁸, ou seja, que pode ocorrer por pura coincidência ou devido a uma

⁶⁸ Uma relação espúria é uma relação estatística existente entre duas variáveis, entre as quais, contudo, não existe nenhuma relação causa-efeito. Essa relação estatística pode ocorrer por pura coincidência ou por

terceira variável. No mais, as variáveis que intuitivamente deveriam apresentar uma relação positiva, AC e ventilador, a tiveram.

As **Figura 21** e **Figura 22** contêm as matrizes de correlação das POFs (2008-2009) e (2002-2003), respectivamente. Os resultados do coeficiente de correlação seguem a mesma lógica da POF (2017-2018), indicando a ausência de multicolinearidade perfeita.

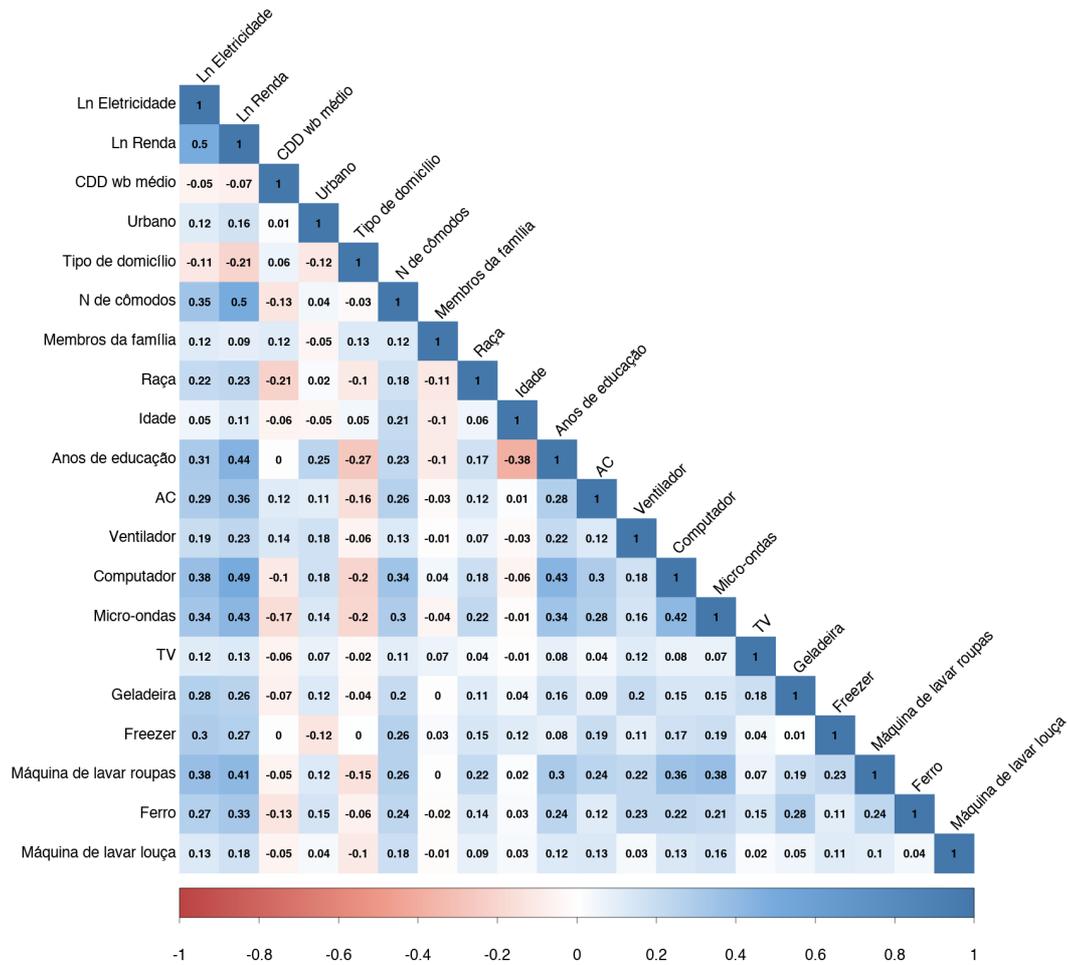


Figura 21. Matriz de correlação da POF (2008-2009)

Fonte: Elaboração própria

causa de uma terceira variável. Se temos duas variáveis (x e y) que caminham juntas de maneira evolutiva ao longo do tempo, elas podem não ser correlacionadas entre si, e esse caminhar pode acontecer em função de um processo estacionário (z) que ‘aglutina’ o caminhar dessas variáveis no tempo.

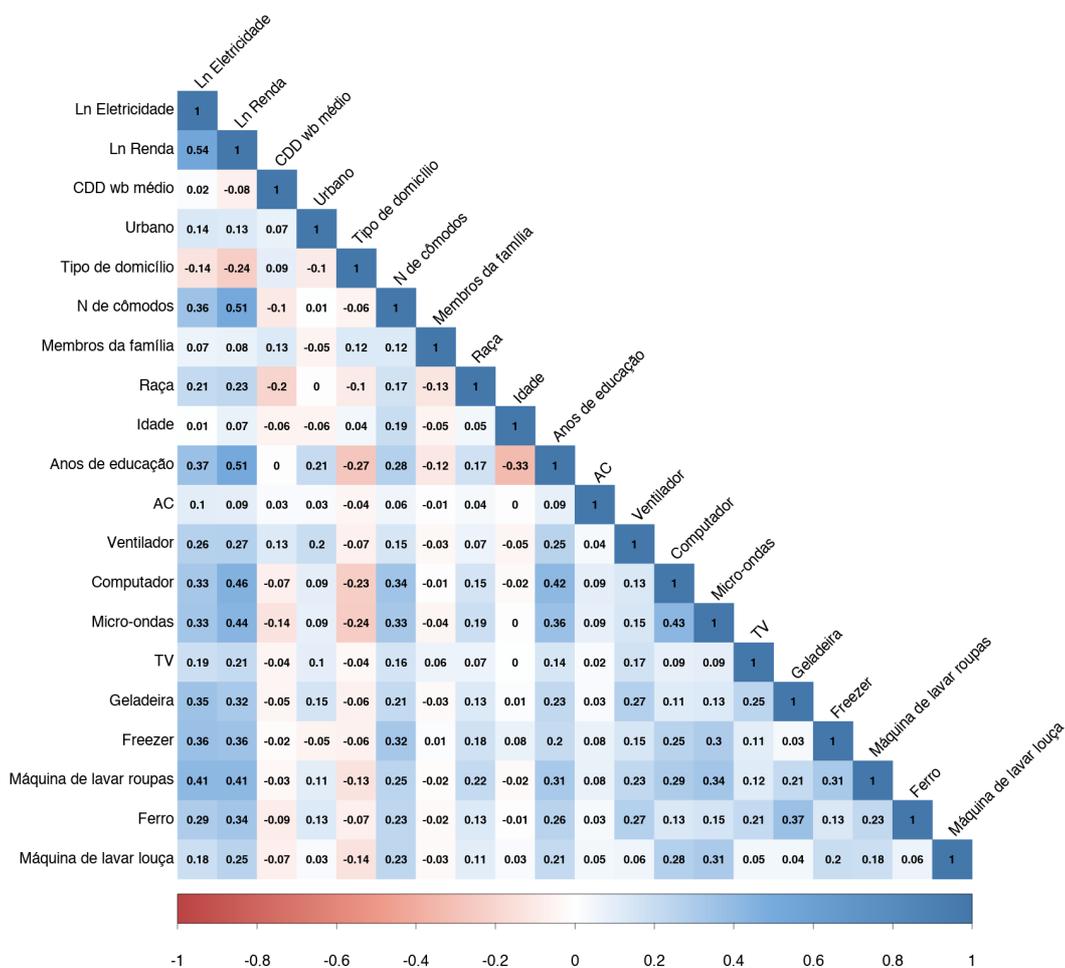


Figura 22. Matriz de correlação da POF (2002-2003)

Fonte: Elaboração própria

4.2.2 Teste de robustez

Como já comentado na **Seção 3.2.3**, são realizados diferentes testes de robustez para os modelos ANCOVA *cross-section* de cada onda da POF. Como apontado por CORTON *et al.* [254], uma forma de verificar resultados é apresentar modelos alternativos. Assim, foram desenvolvidos três modelos alternativos para cada onda da POF para testar a robustez a uma série de fatores, incluindo: i) presença de *outliers*; (ii) existência do peso amostral; e (iii) efeito conjunto (*outliers* e peso amostral). O teste de robustez para uma possível endogeneidade do preço da eletricidade não foi realizado,

pois, como já detalhado na **Seção 3.2.3.3**, o problema não é relevante para o caso brasileiro.

A **Tabela 13** apresenta os resultados dos parâmetros para os modelos alternativos do período 2017-2018. Como é possível observar, as estimativas são robustas à série de fatores que podem afetá-las adversamente.

Tabela 13. Sumário de regressão da POF (2017-2018) – Teste de Robustez

	Modelo (6)	Outliers	Peso amostral	Peso amostral + Outliers
Ln Renda	0,040*** (0,012)	0,032*** (0,012)	0,042** (0,016)	0,032** (0,016)
Ln Preço _E	-0,094*** (0,010)	-0,023** (0,010)	-0,121*** (0,012)	-0,061*** (0,012)
CDD _{wb} médio	0,0004*** (0,00002)	0,0004*** (0,00002)	0,0004*** (0,00003)	0,0003*** (0,00003)
Urbano (1 = Urbano)	0,149*** (0,009)	0,137*** (0,009)	0,163*** (0,012)	0,156*** (0,011)
Norte	-0,115*** (0,014)	-0,094*** (0,013)	-0,117*** (0,018)	-0,094*** (0,017)
Nordeste	-0,174*** (0,009)	-0,168*** (0,009)	-0,151*** (0,012)	-0,141*** (0,012)
Sul	-0,024** (0,010)	-0,020** (0,010)	0,001 (0,012)	0,002 (0,012)
Sudeste	-0,034*** (0,009)	-0,038*** (0,008)	0,032*** (0,011)	0,031*** (0,011)
Tipo de domicílio (1 = Casa)	0,061*** (0,008)	0,058*** (0,008)	0,080*** (0,011)	0,078*** (0,011)
Nº de cômodos	0,027*** (0,001)	0,026*** (0,001)	0,023*** (0,002)	0,023*** (0,002)
Membros da família	0,075*** (0,002)	0,076*** (0,002)	0,091*** (0,002)	0,091*** (0,002)
Raça (1 = Branco)	0,026*** (0,005)	0,023*** (0,005)	0,026*** (0,007)	0,026*** (0,007)
Idade	0,002*** (0,0002)	0,002*** (0,0002)	0,002*** (0,0002)	0,002*** (0,0002)
Anos de educação	0,009*** (0,001)	0,008*** (0,001)	0,009*** (0,001)	0,009*** (0,001)
AC	0,258*** (0,007)	0,251*** (0,007)	0,227*** (0,008)	0,220*** (0,008)
Ventilador	0,078*** (0,006)	0,079*** (0,006)	0,071*** (0,008)	0,070*** (0,008)
Computador	0,047*** (0,005)	0,047*** (0,004)	0,046*** (0,006)	0,046*** (0,006)
Micro-ondas	0,103*** (0,006)	0,100*** (0,006)	0,100*** (0,008)	0,101*** (0,007)
TV	0,023*** (0,006)	0,019*** (0,006)	0,023*** (0,007)	0,021*** (0,007)
Geladeira	0,158*** (0,015)	0,153*** (0,015)	0,121*** (0,018)	0,113*** (0,018)
Freezer	0,204*** (0,008)	0,204*** (0,008)	0,184*** (0,010)	0,183*** (0,010)
Máquinas de lavar roupa	0,115*** (0,006)	0,114*** (0,006)	0,126*** (0,008)	0,126*** (0,008)
Ferro	0,014** (0,006)	0,015** (0,006)	0,005 (0,008)	0,004 (0,008)
Chuveiro elétrico	0,071*** (0,007)	0,067*** (0,007)	0,074*** (0,010)	0,073*** (0,010)
Máquina de lavar louça	0,037* (0,019)	0,049*** (0,018)	0,080*** (0,025)	0,084*** (0,024)
Ln Renda X Decil 2	0,001 (0,001)	0,001 (0,001)	0,001 (0,002)	0,001 (0,002)
Ln Renda X Decil 3	0,003* (0,001)	0,004*** (0,001)	0,002 (0,002)	0,002 (0,002)
Ln Renda X Decil 4	0,007*** (0,002)	0,008*** (0,002)	0,006*** (0,002)	0,006*** (0,002)
Ln Renda X Decil 5	0,009*** (0,002)	0,010*** (0,002)	0,009*** (0,003)	0,009*** (0,002)
Ln Renda X Decil 6	0,011*** (0,002)	0,012*** (0,002)	0,010*** (0,003)	0,011*** (0,003)
Ln Renda X Decil 7	0,012*** (0,002)	0,013*** (0,002)	0,011*** (0,003)	0,012*** (0,003)
Ln Renda X Decil 8	0,015*** (0,002)	0,016*** (0,002)	0,013*** (0,003)	0,014*** (0,003)
Ln Renda X Decil 9	0,017*** (0,003)	0,018*** (0,003)	0,014*** (0,004)	0,016*** (0,003)
Ln Renda X Decil 10	0,024*** (0,003)	0,025*** (0,003)	0,021*** (0,004)	0,022*** (0,004)
Intercepto	5,602*** (0,107)	5,751*** (0,104)	5,537*** (0,146)	5,699*** (0,143)
Observações	49.734	48.549	49.734	48.549
R ²	0,392	0,398	0,400	0,401
R ² Ajustado	0,392	0,398	0,400	0,401

Nota: Níveis de significância (p-valor), * < 0,10; *** < 0,05; **** < 0,01; resultados com erros padrão robustos

Fonte: Elaboração própria

De forma a verificar se os valores extremos alteram substancialmente a magnitude das estimativas de elasticidade, foi criado o modelo alternativo “*Outliers*”. Tal modelo desconsidera os valores extremos de acordo com a metodologia de percentil abordada na **Seção 3.2.3.1**. Isso resulta em uma queda no número de observações de 49.743 no Modelo 6 (modelo de especificação preferencial) para 48.549 no modelo alternativo –

sendo retirado da amostra um total de 1.194 observações com valores extremos. A influência desses *outliers* nas estimativas de elasticidade é particularmente importante devido aos valores discrepantes ou implausíveis presentes na amostra, principalmente no caso do preço da eletricidade na POF (2002-2003). Como consequência, o modelo “*Outliers*” apresentou elasticidade-preço e renda menores em valor absoluto do que o modelo original. Apesar da redução do efeito marginal, foi mantida sua qualidade. Como era esperado, devido à presença de um maior percentual de valores extremos em relação à amostra, no caso da elasticidade-preço a redução foi um pouco maior – de -0,094 para -0,023 – e agora estatisticamente significativo ao nível de 0,05 ou nível de confiança de 95%.

Em contrapartida, no caso do modelo alternativo “Peso amostral”, as amostras foram corrigidas de modo que os resultados da estimação fossem representativos do universo da população, como já explicado na **Seção 3.2.3.2**. Como resultado, houve aumento nos valores absolutos dos coeficientes de renda e preço em comparação com o Modelo 6, permanecendo, contudo, próximos ao nível de magnitude do modelo de especificação preferencial. Em relação às variáveis controle, ocorreram algumas alterações. As variáveis controle geográficas referentes às regiões Sul e Sudeste tiveram alteração de sinal, e o Sul perdeu relevância estatística considerando a categoria controle, o Centro-Oeste. Adicionalmente, o termo interativo “Ln Renda X Decil 3” também perdeu relevância estatística. Algo similar aconteceu no teste de robustez de CORTON *et al.* [254], que também analisou o caso brasileiro. Essas alterações não são graves e, por isso, não colocam em xeque a robustez do modelo.

Por fim, o modelo chamado “Peso amostral + *Outliers*” combina os dois critérios dos modelos comentados acima. Nesse caso, a elasticidade-renda e a elasticidade-preço mantêm sua qualidade e magnitude. Dessa vez, o coeficiente climático (CDD_{wb} médio) apresenta redução de efeito marginal, e, assim como no caso do modelo “Peso amostral”, as *dummies* Sul e Sudeste apresentam alteração de sinal em relação ao Modelo 6, além de o termo interativo “Ln Renda X Decil 3” também perder relevância estatística.

No geral, através da verificação de robustez são apresentadas evidências de que os resultados não são significativamente afetados por uma variedade de fatores tendenciosos. Dessa maneira, os testes robustos garantem a validade da pesquisa a partir de resultados gerais robustos e consistentes.

Dado o objetivo desta tese de apresentar uma análise microeconômica representativa da população, optou-se pela utilização do modelo “Peso amostral + *Outliers*” tanto para a comparação dos diferentes períodos da POF como para a realização das projeções. Os modelos finais são apresentados e discutidos na seção a seguir.

4.3 Comparação entre os modelos

Após a realização dos testes de hipóteses e de robustez, é possível comparar e analisar os resultados dos modelos finais *cross-section* desenvolvidos para cada uma das três ondas da POF, para posteriormente selecionar o modelo mais adequado para prever a demanda de eletricidade. Os modelos são chamados pelo período de referência dos microdados utilizados – POF (2002-2003), POF (2008-2009) e POF (2017-2018). Os resultados da estimação dos modelos finais são encontrados na **Tabela 14**.

Tabela 14. Sumário de regressão para cada onda da POF – Modelo Final (com peso amostral e sem outliers)

	POF (2002-2003)	POF (2008-2009)	POF (2017-2018)
Ln Renda	0,060*** (0,023)	0,061** (0,024)	0,032** (0,016)
Ln Preço _E	0,287*** (0,012)	-0,038*** (0,012)	-0,061*** (0,012)
CDD _{wb} médio	0,0004*** (0,00003)	0,0001*** (0,00003)	0,0003*** (0,00003)
Urbano (1 = Urbano)	0,088*** (0,016)	0,109*** (0,017)	0,156*** (0,011)
Norte	-0,217*** (0,018)	-0,099*** (0,017)	-0,094*** (0,017)
Nordeste	-0,347*** (0,012)	-0,266*** (0,013)	-0,141*** (0,012)
Sul	0,015 (0,013)	0,080*** (0,013)	0,002 (0,012)
Sudeste	-0,007 (0,012)	0,060*** (0,011)	0,031*** (0,011)
Índice da <i>household</i> (1 = Alta qualidade)	NA	0,036*** (0,010)	-
Tipo de domicílio (1 = Casa)	0,028 (0,017)	0,035** (0,015)	0,078*** (0,011)
Nº de cômodos	0,019*** (0,002)	0,017*** (0,002)	0,023*** (0,002)
Membros da família	0,046*** (0,003)	0,076*** (0,003)	0,091*** (0,002)
Raça (1 = Branco)	0,032*** (0,010)	0,025*** (0,009)	0,026*** (0,007)
Idade	0,001*** (0,0003)	0,003*** (0,0003)	0,002*** (0,0002)
Anos de educação	0,010*** (0,001)	0,011*** (0,001)	0,009*** (0,001)
AC	0,196*** (0,040)	0,201*** (0,016)	0,220*** (0,008)
Ventilador	0,040*** (0,010)	0,051*** (0,009)	0,070*** (0,008)
Computador	0,116*** (0,017)	0,132*** (0,011)	0,046*** (0,006)
Micro-ondas	0,091*** (0,015)	0,086*** (0,011)	0,101*** (0,007)
TV	0,046*** (0,014)	0,035** (0,017)	0,021*** (0,007)
Geladeira	0,329*** (0,017)	0,289*** (0,017)	0,113*** (0,018)
Freezer	0,233*** (0,013)	0,211*** (0,012)	0,183*** (0,010)
Máquina de lavar roupa	0,095*** (0,012)	0,106*** (0,010)	0,126*** (0,008)
Ferro	0,077*** (0,014)	0,079*** (0,011)	0,004 (0,008)
Chuveiro elétrico	NA	0,105*** (0,014)	0,073*** (0,010)
Máquina de lavar louça	-	0,088*** (0,030)	0,084*** (0,024)
Aspirador	-	-0,002 (0,014)	NA
Ln Renda X Decil 2	0,0001 (0,002)	0,002 (0,002)	0,001 (0,002)
Ln Renda X Decil 3	0,003 (0,003)	0,001 (0,003)	0,002 (0,002)
Ln Renda X Decil 4	0,005 (0,003)	0,005* (0,003)	0,006*** (0,002)
Ln Renda X Decil 5	0,007* (0,004)	0,004 (0,003)	0,009*** (0,002)
Ln Renda X Decil 6	0,009** (0,004)	0,006 (0,004)	0,011*** (0,003)
Ln Renda X Decil 7	0,010** (0,004)	0,006 (0,004)	0,012*** (0,003)
Ln Renda X Decil 8	0,015*** (0,005)	0,007 (0,005)	0,014*** (0,003)
Ln Renda X Decil 9	0,018*** (0,005)	0,010* (0,005)	0,016*** (0,003)
Ln Renda X Decil 10	0,019*** (0,007)	0,012** (0,006)	0,022*** (0,004)
Intercepto	5,613*** (0,193)	5,243*** (0,209)	5,699*** (0,143)
Observações	38.553	47.582	48.549
R ²	0,480	0,432	0,401
R ² Ajustado	0,480	0,432	0,401

Nota: Níveis de significância (p-valor), * < 0,10; *** < 0,05; **** < 0,01; resultados com erros padrão robustos

Fonte: Elaboração própria

Os primeiros resultados observados na **Tabela 14** são a elasticidade-renda e a elasticidade-preço nos diferentes modelos, parâmetros de forte interesse econômico. Quanto à elasticidade-preço da demanda de eletricidade, devido à comprovação empírica e à teoria econômica, é de se esperar que seja negativa, ou seja, que um aumento percentual do preço da eletricidade resulte em uma redução percentual da eletricidade

demandada, considerando tudo mais constante. Essa elasticidade negativa esperada é observada tanto no modelo POF (2017-2018) quanto no modelo POF (2008-2009), com valores iguais a -0,061 e -0,038, respectivamente. Nesse caso, o aumento de 1% no preço médio da eletricidade gera uma redução média de 0,061% no consumo elétrico domiciliar em 2017-2018 e de 0,038% em 2008-2009, *ceteris paribus*. Ambos os resultados apresentam relevância estatística, com intervalo de confiança de 99%. O fato de a elasticidade-preço no modelo POF (2017-2018) ser mais negativa que a do modelo POF (2008-2009) indica uma demanda mais elástica ao preço, isto é, consumidores respondem mais a variações do preço considerando a onda mais recente da POF. Já no caso do modelo POF (2002-2003), a elasticidade-preço apresenta um efeito marginal positivo contraintuitivo.

A demanda mais elástica ao preço na POF mais recente pode ser justificada devido a existência de um componente relacionado a usos mais supérfluos, descolados das necessidades básicas e mais relacionados a renda, como o aumento no uso de aparelhos atrelados ao entretenimento e principalmente ao maior uso de AC.

Como indicam os resultados das elasticidades, a função demanda dos modelos POF (2008-2009) e POF (2017-2018) satisfazem as expectativas econômicas *a priori*, já que usualmente a elasticidade-preço é negativa, enquanto a elasticidade-renda é positiva. Como demonstrado, o mesmo não ocorre com o modelo POF (2002-2003). Uma justificativa para tal é o fato da base de dados do período 2002-2003 não ter apresentado uma distribuição normal da variável preço, típica de uma base de dados longa com tendência ao infinito, mesmo após a remoção de valores extremos, o que pode estar gerando deturpações na estimativa.

Por outro lado, as elasticidades-renda variam entre 0,032 e 0,061 entre os modelos. Isso significa que um aumento de 1% na renda média das famílias mais pobres aumenta seu consumo médio de energia elétrica em torno de 0,032% a 0,061%, *ceteris paribus*. Os coeficientes referentes à variável “Ln Renda”, como já colocado, representam as elasticidades-renda dos domicílios pertencentes ao decil 1 – categoria de controle. Em contrapartida, os coeficientes atribuídos aos termos interativos são os deslocadores de coeficientes angulares que devem ser adicionados ao coeficiente angular da variável controle. Como resultado, a elasticidade-renda dos domicílios mais ricos (decil 10) varia entre 0,054 e 0,079, dependendo do ano da POF, enquanto a do decil 2, entre 0,033 e

0,063. O que corrobora a hipótese de heterogeneidade no padrão de consumo de energia entre grupos de renda.

Cabe aqui notar que, com o aumento da renda dos mais pobres e a retirada de famílias da situação de pobreza e extrema pobreza ao longo do período 2002-2018, a demanda elétrica do decil 1 se torna menos elástica comparando o modelo POF (2008-2009) com o POF (2017-2018). Esse resultado está em linha com ZHU *et al.* [255] e CABRAL *et al* [160]. Os autores argumentam que à medida que a economia cresce, a demanda de eletricidade é gradualmente satisfeita, levando à redução das elasticidades de renda.

Em paralelo, devido ao agravamento da desigualdade de renda, verificado na análise estatística da POF (**Seção 4.1.1**), os coeficientes angulares diferenciais dos diferentes decis do modelo POF (2017-2018) ganham relevância estatística com intervalo de confiança de 99% a partir do decil 3, o que não é observado para as ondas anteriores. Adicionalmente, o fato de o termo interativo dos decis 1 e 2 não apresentar relevância estatística no modelo POF (2017-2018), significa que não é possível concluir a um intervalo confiança de pelo menos 90%, que tais grupos possuem uma elasticidade-renda estatisticamente significativa quando comparados ao decil 1, o que indica um perfil de consumo de eletricidade similar nos três decis mais pobres.

Em resumo, a elasticidades-renda aumenta gradativamente com o decil de renda, conseqüentemente, as elasticidades-renda são ligeiramente maiores para grupos com renda mais alta, o que significa que as famílias mais ricas respondem mais ao aumento de renda do que as famílias pobres. Em outras palavras, a demanda de eletricidade dos mais ricos no Brasil é ligeiramente mais elástica do que a dos mais pobres.

Esse resultado empírico pode gerar estranhamento se comparado com outros resultados, principalmente vindo de países desenvolvidos [71], que apresentaram demandas mais elásticas para os pobres em comparação aos ricos. Contudo, SANTOS *et al.* [35] apresentam uma análise de caso para o Brasil e também encontram elasticidades-renda da demanda elétrica mais altas conforme mais alto for o decil. Ademais, SILVA *et al.* [191] também chegam a conclusões similares em uma análise de Portugal, outro país com significativas disparidades econômicas.

Assim, tal resultado pode ser explicado pelas grandes disparidades de renda no Brasil, intensificadas ao longo do período analisado, o que conduz a maiores propensões marginais de consumo para grupos de rendimentos mais elevados.

No geral, esse resultado corrobora o fato de eletricidade ser um bem essencial, para o qual se espera uma elasticidade-renda positiva e menor que um. As elasticidades preço e renda (em valor absoluto) estimadas pelos modelos são estatisticamente menores que um, o que implica em uma demanda de energia elétrica inelástica tanto em relação ao preço quanto à renda. Uma demanda inelástica significa que aumentos no preço ou na renda, *ceteris paribus*, resultam em um aumento menos que proporcional na demanda de eletricidade, em linha com a literatura brasileira [31-34,136,169] e internacional [42,43,122,182].

A característica inelástica da demanda elétrica em relação a renda e preço é mais facilmente validada pela literatura do que a magnitude dos valores encontrados nos modelos desenvolvidos. Diferenças metodológicas e escassez de estudos brasileiros com microdados – a grande maioria utiliza dados agregados – dificulta a comparação dos valores *per se*. Estimativas de elasticidade da renda e preço podem variar bastante entre estudos microeconômicos devido ao conjunto de covariáveis incluídas nos modelos [256]. Contudo, é importante destacar que parte do efeito marginal da renda está sendo capturado por variáveis correlacionadas.

Apesar de absorverem parte do efeito da renda, variáveis indiretamente relacionadas à riqueza, como condições de moradia e educação, desempenham um papel importante nos modelos desenvolvidos, com efeitos marginais estatisticamente significativos. Não contabilizar explicitamente tais características socioeconômicas de uma família pode distorcer significativamente as estimativas da contribuição marginal de renda e clima.

Como explicado anteriormente, as elasticidades são referentes a relações log-log. Já no caso de relações log-linear (variável dependente em forma de logaritmo e variáveis explanatórias em forma linear), temos semi-elasticidades. A semi-elasticidade fornece a variação percentual ou relativa na variável dependente para uma variação de unidade no valor da variável explanatória quantitativa. É o caso das seguintes variáveis: número de cômodos, membros da família, idade e anos de educação do chefe da família, posse de

diferentes equipamentos, como AC, ventilador, computador, micro-ondas, TV, geladeira, freezer, máquina de lavar roupa, ferro, máquina de lavar louça etc.

As semi-elasticidades das variáveis quantitativas citadas possuem efeito marginal positivo no consumo de eletricidade nos três modelos. Em outras palavras, ao aumentar em uma unidade a quantidade de alguma dessas variáveis, por exemplo, os anos de educação do chefe da família ou a quantidade de computadores em uma residência, a demanda de eletricidade sofre uma variação percentual positiva referente ao valor do coeficiente da variável. Um aumento de um ano de estudo na educação do chefe da família aumenta em média 0,009% seu consumo de eletricidade, considerando o modelo POF (2017-2018).

No entanto, quando a variável explanatória é uma variável *dummy*, o coeficiente atribuído a tal é um intercepto diferencial, como já mencionado durante o procedimento metodológico. É possível interpretar o coeficiente de um regressor binário diretamente pelo dispositivo sugerido por HALVORSEN & PALMQUIST [257]. Calcula-se o antilogaritmo do coeficiente binário estimado, subtrai-se um e multiplica-se o resultado por 100. Isto posto, no modelo POF (2017-2018), as residências urbanas têm um consumo médio de eletricidade aproximadamente 15,6% maior do que as residências rurais. Casas demandam em média 7,8% mais do que um apartamento ou outro tipo de domicílio. Se o chefe da família for branco, o consumo elétrico é, em média, 2,6% maior comparado a chefes não-brancos. Por fim, em relação às características regionais, em comparação com a categoria base, o Centro-Oeste, o Norte consome em média 9,4% a menos, o Nordeste, 14,1% a menos, o Sul, 0,2% a menos e, o Sudeste, 3,1% a mais. A mesma lógica pode ser aplicada para 2008-2009 e para 2002-2003.

Dessa forma, as *dummies* servem como instrumento de classificação de dados, pois dividem a amostra em vários subgrupos com base nas qualidades ou atributos, controlando, assim, a heterogeneidade observada. Elas implicitamente permitem que se calculem regressões para cada subgrupo.

No caso de modelos com variáveis *dummy*, o valor do intercepto representa o valor médio da variável dependente da categoria referência. Assim, no caso dos modelos criados, o valor do intercepto corresponde ao consumo de eletricidade em logaritmo neperiano das categorias de referência, ou seja, apartamentos localizados em áreas rurais, do Centro-Oeste, com chefe da família não-branco no caso modelo POF (2017-2018).

Esse valor é igual a 5,613 no modelo POF (2002-2003), 5,243 no modelo POF (2008-2009) e 5,699 no modelo POF (2017-2018). Como o modelo apresenta diversas formas de controle, é preciso considerar todas as *dummies* com valor igual a zero na interpretação do intercepto.

Por fim, o coeficiente da variável explanatória CDD_{wb} , utilizada como *proxy* do clima, aponta um efeito climático marginal pequeno, porém significativo a um nível de confiança de 99% para os três modelos. O coeficiente angular da variável CDD_{wb} é uma semi-elasticidade. Conseqüentemente, um aumento de uma unidade, nesse caso, aumento de um grau-dia no CDD_{wb} , acarreta um aumento entre 0,0001% e 0,0004% no consumo de eletricidade.

É importante ressaltar que os modelos desenvolvidos captam efeito do clima através da chamada **margem intensiva**, isto é, como o consumo de eletricidade aumenta com a temperatura dado o estoque de equipamentos corrente [90]. Nesse caso, o consumo de eletricidade aumenta com o aumento da temperatura porque as famílias usam mais o ar-condicionado. Os modelos não consideram a margem extensiva, já comentada anteriormente. Assim, dado que a posse de ar-condicionado ainda é relativamente baixa, 20% na média para o período 2017-2018, as famílias – principalmente as mais pobres – têm pouca capacidade de reagir à mudança do clima. Comparativamente, outros eletrodomésticos atrelados ao clima, como ventiladores e refrigeradores são amplamente utilizados, contudo, estudos empíricos indicam que o AC é o aparelho de uso mais relevante para adaptação ao aquecimento global [25,90].

Conseqüentemente, os modelos desenvolvidos apontam que o clima contribui para o aumento do consumo de eletricidade, mas a renda por si só explica grande parte desse aumento. Dessa maneira, o efeito do clima é secundário e baixo quando desacoplado da renda, em outras palavras, a renda tem um papel comparativamente mais importante do que o clima na demanda de eletricidade.

No Brasil, como comprovado pelo **Gráfico 3**, o acesso ao ar-condicionado ainda é altamente desigual, indicando que a capacidade de uma família de se adaptar às mudanças climáticas por meio do uso de energia está ligada às suas condições socioeconômicas. Isso significa, que as famílias respondem positivamente ao clima com base em sua renda, dado que só é possível se adaptar ao clima em determinado nível de renda. Tais resultados estão em linha com outros estudos [25,90,194].

Em contraste, como apontado por DE CIAN *et al.* [25], os resultados de países mais desenvolvidos sugerem que as condições climáticas desempenham um papel relativamente maior em comparação com a renda [25,170,258], uma vez que, em média, os países industrializados estão acima do limite de renda no qual as elasticidades CDD aumentam.

Os resultados dos coeficientes discutidos anteriormente são considerados de curto prazo, dado que ao controlar a demanda de energia por características de estoque de capital, a demanda torna-se mais inelástica [256].

A teoria e o trabalho empírico distinguem entre elasticidades de preço de curto e longo prazo. As elasticidades de curto prazo mantêm fixo o estoque de bens duráveis que consomem energia, já as de longo prazo vêm de modelos em que o estoque de capital pode se ajustar [256]. Uma alternativa plausível para criar elasticidades de longo prazo é utilizar modelos estáticos que omitem estoque de capital. Assim, ao omitir a posse de aparelhos consumidores de energia o modelo captura a resposta de longo prazo do uso de eletricidade ao clima e à renda [20,194,256]. Não incluir a posse de aparelhos elétricos significa presumir que eles podem mudar com o tempo, e o efeito das mudanças nessas variáveis é então, implicitamente capturado pelo coeficiente da variável climática como da renda.

Em resultado, a **Tabela 15** mostra os parâmetros estimados considerando modelos de curto e longo prazo para a POF (2017-2018), ou melhor, com e sem posse de equipamentos. O modelo POF (2017-2018) foi selecionado, pois devido à sua base de dados mais atual, ele consegue captar, apesar de estáticos, perfis de consumo de eletricidade mais recentes no Brasil. Como era esperado, a renda – em todos seus níveis – e o clima se tornam mais elásticos no modelo de LP, pois passam a captar o efeito da posse de equipamentos elétricos.

**Tabela 15. Sumário de regressão para POF (2017-2018) – Modelo Final escolhido para projeções:
Longo Prazo versus Curto Prazo**

	POF (2017-2018) - CP	POF (2017-2018) - LP
Ln Renda	0,030 [†] (0,016)	0,046 ^{***} (0,018)
Ln Preço _E	-0,061 ^{***} (0,012)	-0,045 ^{***} (0,013)
CDD _{wb} médio	0,0003 ^{***} (0,00003)	0,0004 ^{***} (0,00003)
Urbano (1 = Urbano)	0,160 ^{***} (0,011)	0,228 ^{***} (0,012)
Norte	-0,126 ^{***} (0,017)	-0,141 ^{***} (0,017)
Nordeste	-0,184 ^{***} (0,010)	-0,234 ^{***} (0,010)
Sul	-0,0004 (0,012)	0,070 ^{***} (0,012)
Sudeste	0,027 ^{**} (0,011)	0,026 ^{**} (0,011)
Tipo de domicílio (1 = Casa)	0,085 ^{***} (0,011)	0,072 ^{***} (0,011)
Nº de cômodos	0,023 ^{***} (0,002)	0,037 ^{***} (0,002)
Membros da família	0,090 ^{***} (0,002)	0,091 ^{***} (0,003)
Raça (1 = Branco)	0,027 ^{***} (0,007)	0,047 ^{***} (0,007)
Idade	0,002 ^{***} (0,0002)	0,002 ^{***} (0,0003)
Anos de educação	0,009 ^{***} (0,001)	0,016 ^{***} (0,001)
AC	0,219 ^{***} (0,008)	–
Ventilador	0,068 ^{***} (0,008)	–
Computador	0,047 ^{***} (0,006)	–
Micro-ondas	0,104 ^{***} (0,007)	–
TV	0,023 ^{***} (0,007)	–
Geladeira	0,117 ^{***} (0,018)	–
Freezer	0,185 ^{***} (0,010)	–
Máquina de lavar roupa	0,130 ^{***} (0,008)	–
Ferro	0,010 (0,007)	–
Máquina de lavar louça	0,075 ^{***} (0,024)	–
Ln Renda X Decil 2	0,002 (0,002)	0,004 ^{**} (0,002)
Ln Renda X Decil 3	0,003 (0,002)	0,006 ^{***} (0,002)
Ln Renda X Decil 4	0,007 ^{***} (0,002)	0,013 ^{***} (0,002)
Ln Renda X Decil 5	0,010 ^{***} (0,002)	0,017 ^{***} (0,003)
Ln Renda X Decil 6	0,011 ^{***} (0,003)	0,020 ^{***} (0,003)
Ln Renda X Decil 7	0,013 ^{***} (0,003)	0,023 ^{***} (0,003)
Ln Renda X Decil 8	0,014 ^{***} (0,003)	0,026 ^{***} (0,003)
Ln Renda X Decil 9	0,016 ^{***} (0,003)	0,030 ^{***} (0,004)
Ln Renda X Decil 10	0,022 ^{***} (0,004)	0,038 ^{***} (0,005)
Intercepto	5,760 ^{***} (0,143)	5,719 ^{***} (0,156)
Observações	48.549	48.549
R ²	0,400	0,340
R ² Ajustado	0,399	0,340

Nota: Níveis de significância (p-valor), * < 0,10; *** < 0,05; **** < 0,01; resultados com erros padrão robustos

Fonte: Elaboração própria

4.4 Sensibilidade do modelo: o papel da renda e do clima na demanda residencial de eletricidade

Os modelos POF (2017-2018) de curto e longo prazo são selecionados para prever o consumo de eletricidade dos domicílios brasileiros, considerando primeiramente, os valores observados das variáveis previsoras no período 2017-2018. Como resultado, o **Gráfico 7** compara a distribuição do consumo de eletricidade previsto pelo modelo microeconômico da POF (2017-2018) de curto e longo prazo, com os valores observados na base de dados do ano correspondente.

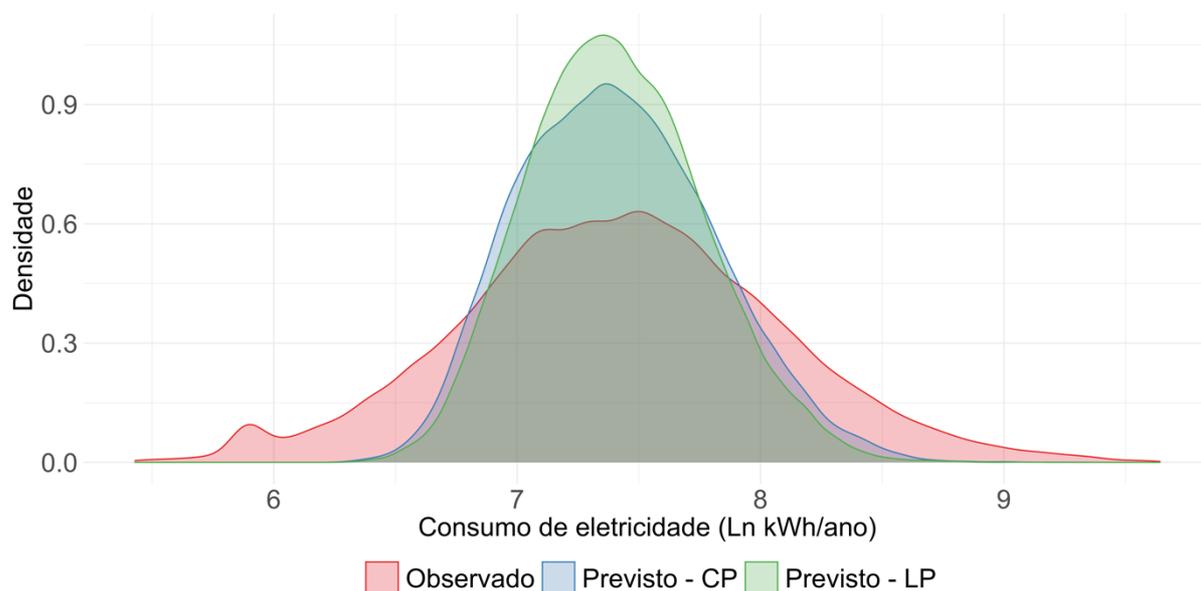


Gráfico 7. Consumo de eletricidade domiciliar previsto pelos modelos da POF (2017-2018) de curto e longo prazo versus resultados observados no período 2017-2018

Fonte: Elaboração própria

As previsões dos modelos da POF (2017-2018) expostas no **Gráfico 7** mostram boa concordância dos dados de referência com resultados previstos pelo modelo de curto prazo e concordância razoável com o de longo prazo. Como esperado, devido à natureza dos modelos econométricos, os valores previstos se concentram mais ao redor da média em comparação aos valores observados, o que é especialmente verdade para o modelo de longo prazo. Apesar disso, tanto o modelo de curto como o de longo prazo possuem capacidades preditivas satisfatórias.

Para mais, é possível utilizar as estimativas dos parâmetros dos modelos de regressão para investigar sua sensibilidade a cenários de política e mudanças nas covariáveis [13,79,169]. Em outras palavras, é possível analisar como alterações nos valores de variáveis importantes incluídas no modelo de regressão impactam a demanda domiciliar de eletricidade no Brasil.

Diante disso, três simulações foram aplicadas ao modelo de longo prazo para analisar como a demanda domiciliar de eletricidade responde a diferentes cenários socioeconômicos e climáticos. Dentre as simulações são analisadas as respostas do modelo a: (i) ritmos de crescimento econômico; (ii) graus de distribuição de renda; e (iii) mudanças no clima (temperatura e umidade).

As simulações foram embasadas em premissas de cenários já existentes na literatura, no entanto, esses cálculos não têm o objetivo de fornecer previsões definitivas de valores futuros. Os resultados das simulações são indicativos da ordem de magnitude dos impactos da renda e do clima na demanda brasileira residencial de eletricidade; também ajudam a entender modelo é preditivo nas condições de uso pretendido⁶⁹. Nas seções a seguir são definidas as premissas das simulações e demonstrados seus resultados.

4.4.1 Ritmos de crescimento econômico

Para analisar a resposta da demanda elétrica domiciliar brasileira – através do modelo POF (2017-2018) de longo prazo – a diferentes ritmos de crescimento econômico, tomamos como base os *Shared Socioeconomic Pathways* (SSPs). Os SSPs⁷⁰ fazem parte de uma nova estrutura de cenários e foram estabelecidos pela comunidade de pesquisadores de mudanças climáticas para facilitar a análise integrada. Eles foram desenvolvidos como um esforço comunitário para representar diferentes desafios de mitigação e adaptação. Existem cinco SSPs (SSP1 a SSP5⁷¹), que descrevem os principais

⁶⁹ A validação de modelos se refere ao processo de confirmação de que o modelo realmente atinge seu propósito pretendido. Na maioria das situações, isso envolverá a confirmação de que o modelo é preditivo nas condições de uso pretendido [282]. Ainda, de acordo com BONA *et al.* [283], o processo de validação se destina a comparar as previsões do modelo com um conjunto de dados do mundo real para avaliação da precisão do modelo e capacidade preditiva.

⁷⁰ Os SSPs são nomeados com base em uma metáfora de uma estrada ou caminho, a fim de enfatizar que eles se destinam a descrever a evolução das tendências de desenvolvimento global e regional ao longo do tempo, ao invés de fotografias estáticas das condições em um determinado momento. Para uma descrição completa das narrativas, ver [259].

⁷¹ De acordo com [259]:

desenvolvimentos globais plausíveis e internamente consistentes sobre os possíveis desdobramentos das variáveis socioeconômicas ao longo do século [259]. Eles são baseados em cinco narrativas diferentes que descrevem desenvolvimentos socioeconômicos alternativos [260].

Dessa maneira, a partir de projeções dadas pelos cinco SSPs é possível assumir novos valores de renda – variável explicativa – e, assim, explorar a resposta do modelo ao consumo domiciliar de eletricidade, *ceteris paribus*. O cálculo dos novos valores da variável renda é baseado em PAVANELLO *et al.* [194]. Os autores definem uma taxa de crescimento econômico representativo do ano 2040, a partir de uma média de longo prazo do Produto Interno Bruto (PIB)⁷² entre 2020-2060. Dessa maneira, os ritmos de crescimento são simulados supondo que a renda das famílias brasileiras aumentará na mesma taxa de crescimento do PIB referente a cada SSP, mantendo todas as outras covariáveis fixas, com seus valores observados na POF (2017-2018). As taxas de crescimento acumulado da renda entre 2020-2060 do SSP1 ao SSP5 é de, respectivamente, 146%, 123%, 112%, 79% e 175%.

Isto posto, o **Gráfico 8** expõe a renda domiciliar média em termos absolutos por classes de renda e de acordo com os diferentes cenários socioeconômicos. Os cenários alternativos fornecem a nova renda segundo ritmos de crescimento apontados pelos SSPs, definidos anteriormente. Já o cenário base, chamado BL (do inglês *baseline*), devido à característica estática do modelo, representa a renda observada na POF (2017-2018). Como definido pelas premissas dos cenários, os SSP1 e SSP5 são os que apresentam maiores valores de renda média domiciliar em todas as classes de renda. Em terceiro

SSP1 (*Sustainability – Taking the Green Road*): Futuro sustentável e mais igualitário, fortalecimento do bem-estar, baixas desigualdades, cooperação internacional, perspectiva favorável para energia renovável e demanda de energia relativamente baixa;

SSP2 (*Middle of the Road*): Manutenção de padrões históricos (social, econômico e tecnológico), estabilidade política, desenvolvimento e crescimento da renda ocorrem de maneira desigual, e desenvolvimento sustentável é lento;

SSP3 (*Regional Rivalry – A Rocky Road*): Nacionalismo ressurgente, desenvolvimento econômico lento, baixa prioridade internacional em questões ambientais leva a forte degradação ambiental;

SSP4 (*Inequality – A Road Divided*): Aumento das desigualdades, estratificação entre os países e dentro deles, crescimento econômico moderado em países industrializados e de renda média e incerteza nos mercados de combustíveis fósseis; e

SSP5 (*Fossil-fueled Development – Taking the Highway*): Rápido crescimento da economia global, forte dependência de combustíveis fósseis e falta de preocupação ambiental global.

⁷² As projeções de PIB foram extraídas da base de dados oficial dos SSPs, disponível em <https://tntcat.iiasa.ac.at/SspDb/>.

lugar, temos o SSP2 seguido pelo SSP3. Dentre os cenários socioeconômicos alternativos ao BL, o SSP4 é o que apresenta menor renda, em linha com sua narrativa.

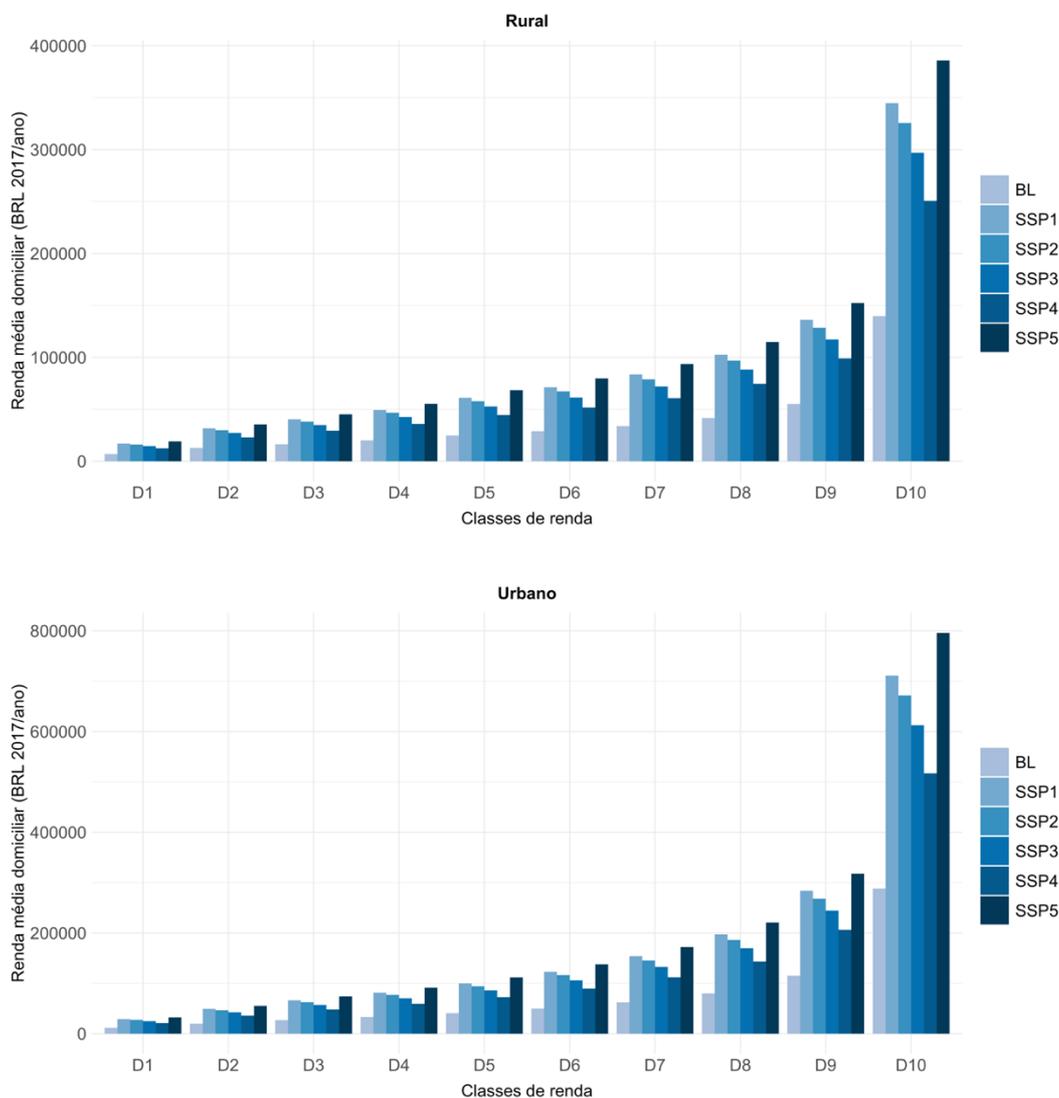


Gráfico 8. Renda média domiciliar por classes de renda e cenários socioeconômicos

Fonte: Elaboração própria

Para prever a demanda de eletricidade a nível doméstico e de acordo com os diferentes cenários socioeconômicos, calibramos o modelo POF (2017-2018) de longo prazo com as rendas atualizadas, mantendo todas as outras covariáveis com seus valores históricos, observados no período 2017-2018. Como é possível perceber pelo **Gráfico 9**, apesar de um expressivo aumento da renda – na média, o dobro da renda observada –, há

um pequeno aumento no consumo de eletricidade a depender do SSP e do decil. Seguindo o comportamento da renda, o SSP5 é o que apresenta maior crescimento na demanda de eletricidade em relação ao cenário base, enquanto o SSP4 apresenta o menor crescimento.

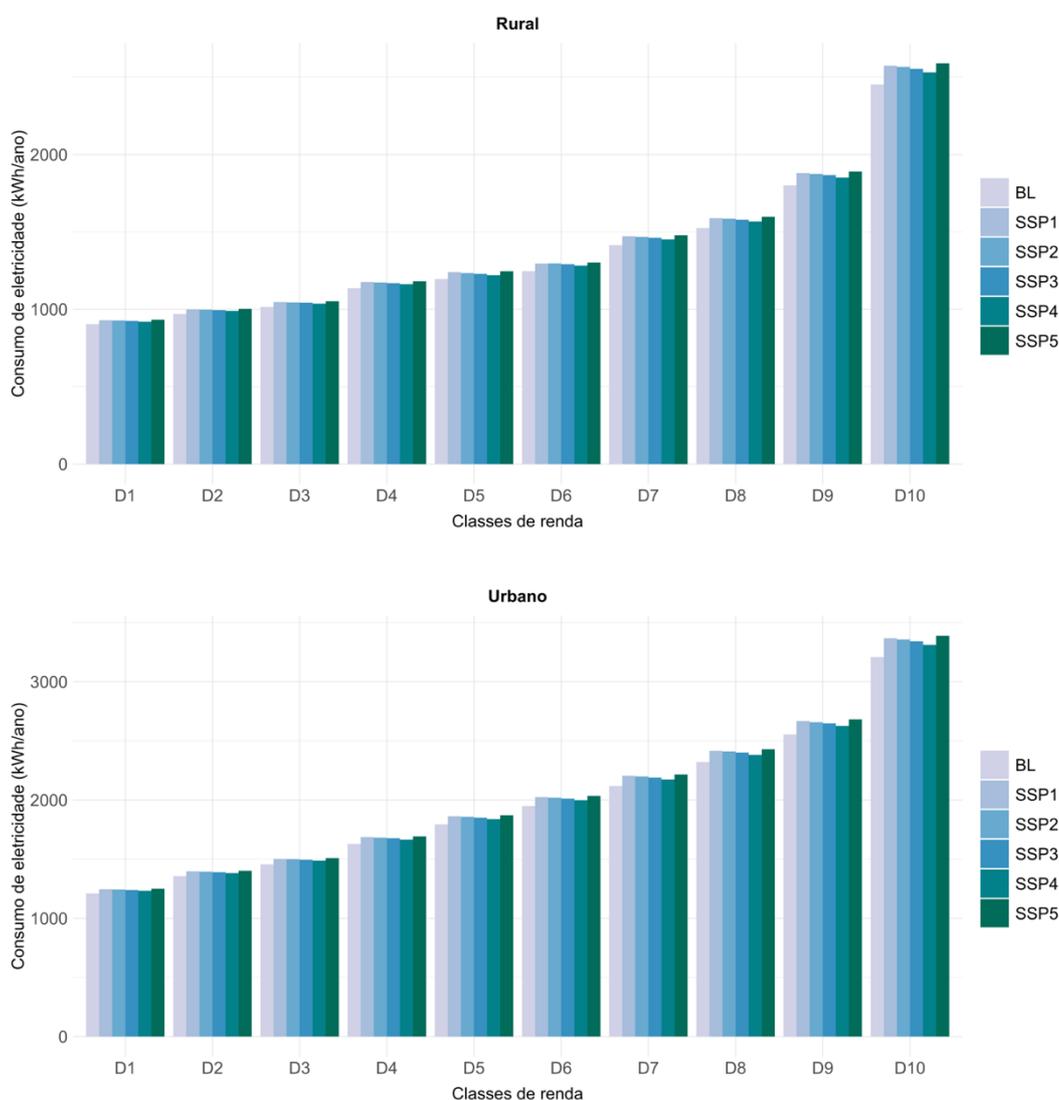


Gráfico 9. Demanda domiciliar média de eletricidade por classes de renda e de acordo com diferentes cenários socioeconômicos (kWh/ano)

Fonte: Elaboração própria

É importante destacar que as previsões sobre a demanda de eletricidade, de acordo com os diferentes cenários, foram calculadas a nível domiciliar e, posteriormente, agregadas de acordo com os grupos de renda.

Já era esperado que o crescimento da demanda de eletricidade fosse menor do que o da renda, devido à inelasticidade da renda verificada nos resultados da **Seção 4.3**. Contudo, outro fator a se destacar é que o efeito marginal da renda é verificado como baixo, uma vez que outras variáveis correlacionadas com a renda captam parte do seu efeito.

É possível verificar as variáveis socioeconômicas explanatórias que captam parte do efeito da renda nas matrizes de correlação apresentadas na **Seção 4.2.1.2.3**. Apesar dessa captura, como já demonstrado, não há nenhuma correlação forte entre as variáveis, o que poderia resultar em um problema de colinearidade ou multicolinearidade.

Não obstante, um resultado interessante da simulação é derivado da comparação entre a parte da população mais pobre (decil 1) e a mais rica (decil 10) no Brasil. Como percebido pelo **Gráfico 10**, que apresenta o aumento da demanda de eletricidade em relação ao cenário BL de acordo com os diferentes SSPs, o aumento em termos absolutos das de uma família pobre é bastante inferior ao de uma família rica. Isso é verdade para todos os cenários socioeconômicos alternativos.

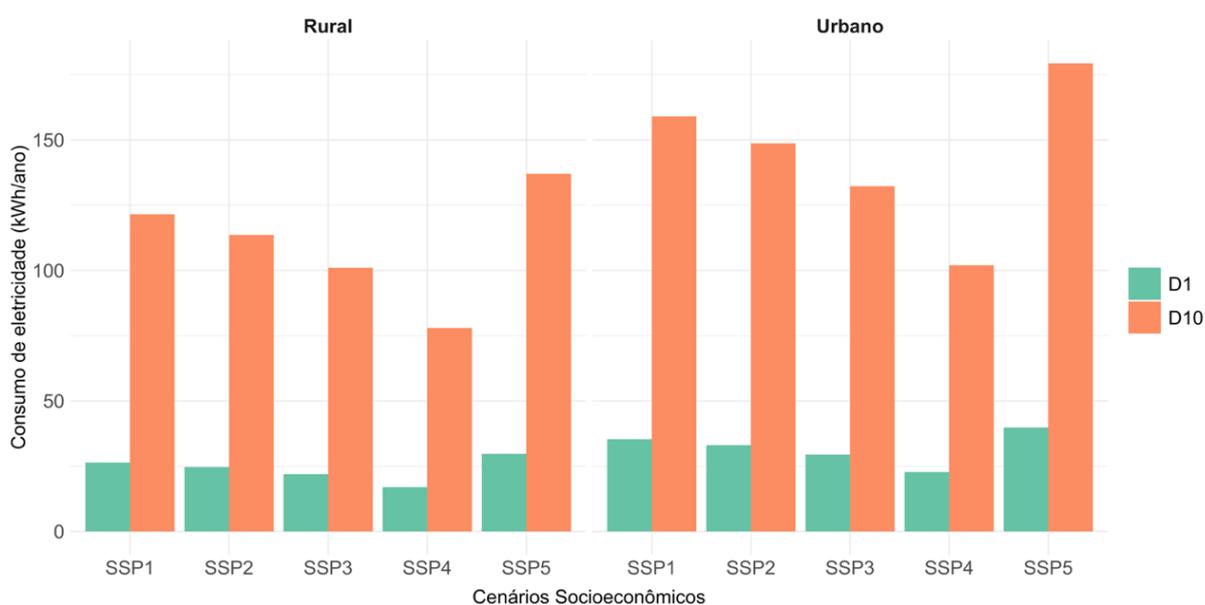


Gráfico 10. Variação no consumo de eletricidade dos mais pobres (D1) e mais ricos (D10) de acordo com os cenários socioeconômicos dos SSPs

Fonte: Elaboração própria

Esses resultados, demonstram que o modelo realmente atinge seu uso pretendido ao apresentar repostas heterogêneas no consumo de eletricidade das famílias brasileira, padrão de comportamento que é capturado através dos coeficientes angulares diferenciais por decis – diferentes elasticidades-renda por decil – e do intercepto diferencial da *dummy* urbano.

A discussão qualitativa das simulações não é o intuito deste trabalho, contudo, cabe notar que os resultados apresentados corroboram as conclusões de RAO & UMMEL [58], que argumenta que o desafio no aumento da demanda de energia não está na erradicação da pobreza e sim no enriquecimento dos já ricos.

Por fim, é possível perceber pelo **Gráfico 11** que as curvas de distribuição de renda para os cenários de SSPs são deslocadas para o lado direito da abscissa do gráfico, o que significa uma maior renda média nos cenários alternativos, principalmente no SSP1. Entretanto, por falta de dados mais apropriados na base de dados dos SSPs, estes representam um padrão de distribuição da renda fixo, ou seja, os cenários aqui criados a partir dos SSPs não foram testados para capturar diferentes graus de distribuição de renda; a curva não fica nem mais concentrada na média, nem mais dispersa.

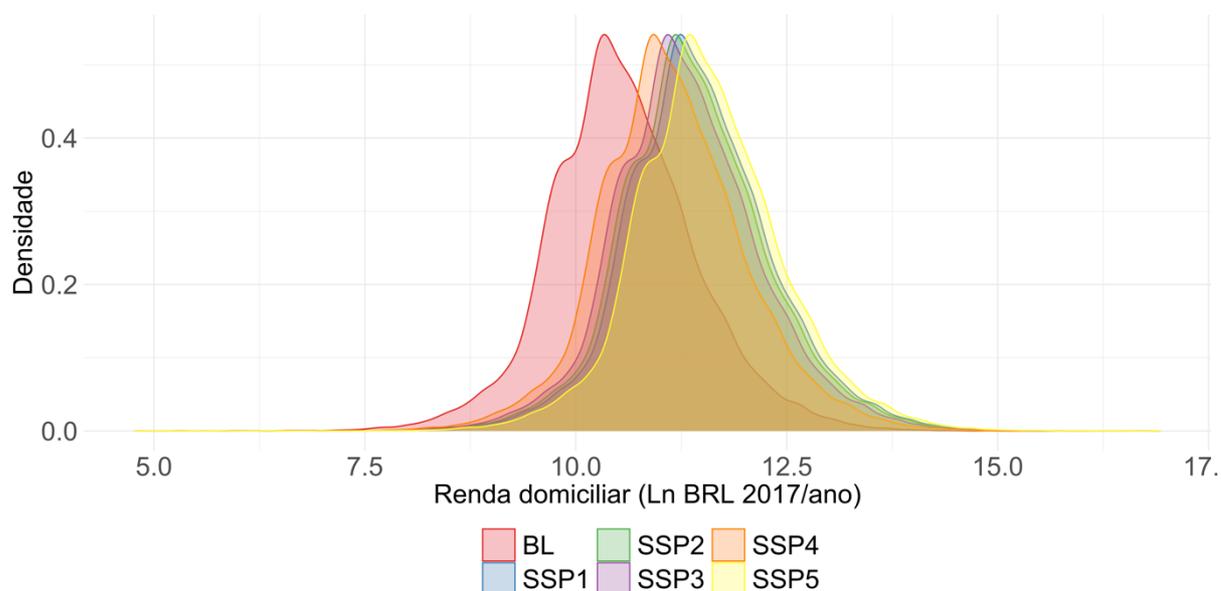


Gráfico 11. Distribuição da renda domiciliar de acordo com os cenários socioeconômicos

Fonte: Elaboração própria

Conseqüentemente, optamos por seguir com outra simulação relacionada a cenários socioeconômicos, dessa vez considerando diferentes graus de distribuição de renda.

4.4.2 Graus de distribuição de renda

A segunda simulação proposta para validação do modelo também aborda cenários socioeconômicos, mas, diferentemente da primeira simulação, realizada com os SSPs, vai além, ao apresentar padrões de distribuição de renda alternativos ao BL.

Para isso, são criados dois cenários de distribuição de renda com base nos resultados de GARAFFA *et al.* [261], que apresentam impactos econômicos distributivos nos decis de renda, de acordo com diferentes arranjos para reciclagem de receitas advindas de uma eventual precificação de carbono no Brasil. Assim, utilizamos a premissa de que a renda dos decis do nosso cenário base (dados de renda observados na POF 2017-2018) segue o comportamento indicado pelos cenários chamados de “EXT” e “POV”⁷³ de GARAFFA *et al.* [261]. Tais cenários foram selecionados por beneficiarem os decis de renda mais pobres, com o objetivo de colaborar na erradicação da pobreza e extrema pobreza no Brasil.

Por conveniência, os nomes dos cenários de distribuição de renda simulados neste trabalho são os mesmo encontrados no estudo de GARAFFA *et al.* [261]. Na **Tabela 16**, são apresentadas as mudanças relativas na renda para cada cenário e de acordo com decis para o ano de 2030. Os dois cenários de distribuição de renda beneficiam economicamente os decis mais pobres e penalizam os mais ricos, enquanto mantêm constantes as outras variáveis explanatórias do modelo.

⁷³ Em POV e EXT, as receitas de carbono são distribuídas apenas para famílias com renda total abaixo da linha de pobreza e abaixo da linha de extrema pobreza, definidas pelo Banco Mundial [99] [100].

Tabela 16. Mudança em % na renda dos decis de acordo com cenários de distribuição de renda

Decis de renda	POV	EXT
1	17,98	42,20
2	7,51	1,93
3	3,38	0,12
4	1,22	-0,05
5	0,33	-0,11
6	0,01	-0,13
7	-0,11	-0,14
8	-0,15	-0,16
9	-0,17	-0,17
10	-0,19	-0,19
Média	0,26	0,26

Fonte: Elaboração própria com base em GARAFFA *et al.* [261]

A natureza de modelos microeconômicos, como o modelo POF (2017-2018), permite o acesso a toda a distribuição dos dados. Conseqüentemente, é possível alterar qualquer distribuição das covariáveis utilizadas na previsão do consumo de eletricidade. Dessa maneira, o **Gráfico 12** mostra os diferentes cenários de distribuição de renda considerados na simulação.

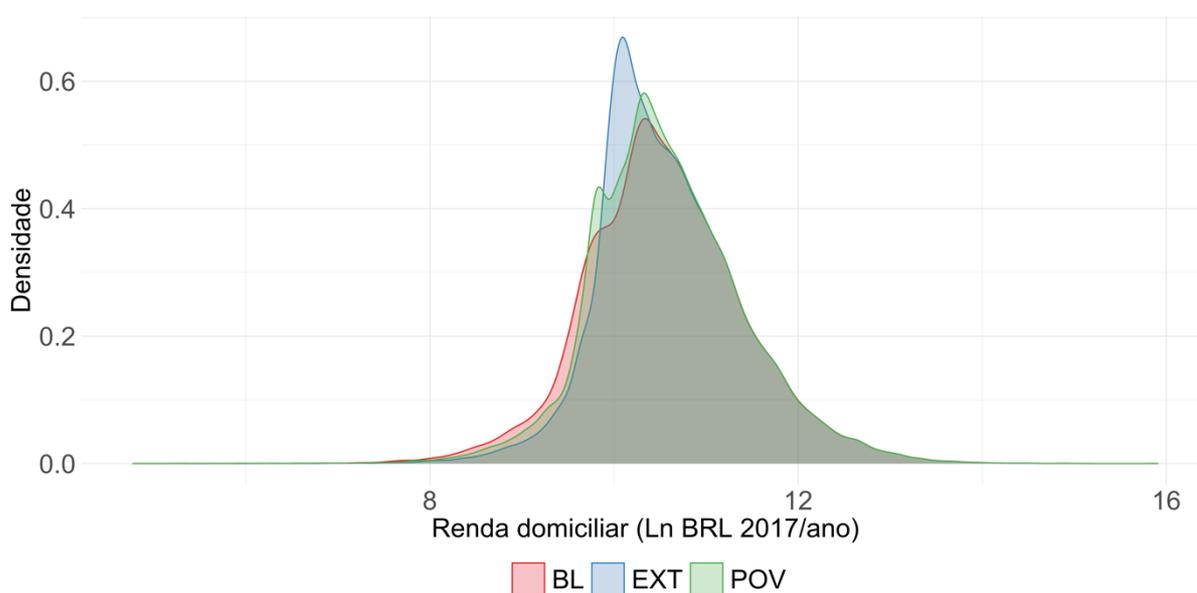


Gráfico 12. Distribuição da renda domiciliar de acordo com os cenários de distribuição de renda

Fonte: Elaboração própria

Como é possível observar, o cenário BL é o de maior desigualdade econômica, pois apresenta uma curva de distribuição de renda mais dispersa em comparação às outras duas. No mais, o cenário EXT é mais eficiente em termos de igualdade de renda, dado que a sua curva de distribuição está mais concentrada na média do que os cenários POV e BL.

A resposta heterogênea do modelo é exemplificada pelo **Gráfico 13**. O consumo de eletricidade dos decis 1 e 10 apresentam uma variação baixa, reflexo – dentre outros fatores – da baixa variação de renda do decil 10, que praticamente se mantém estável nos cenários distributivos, com uma sutil queda, e uma baixa elasticidade-renda do decil 1.

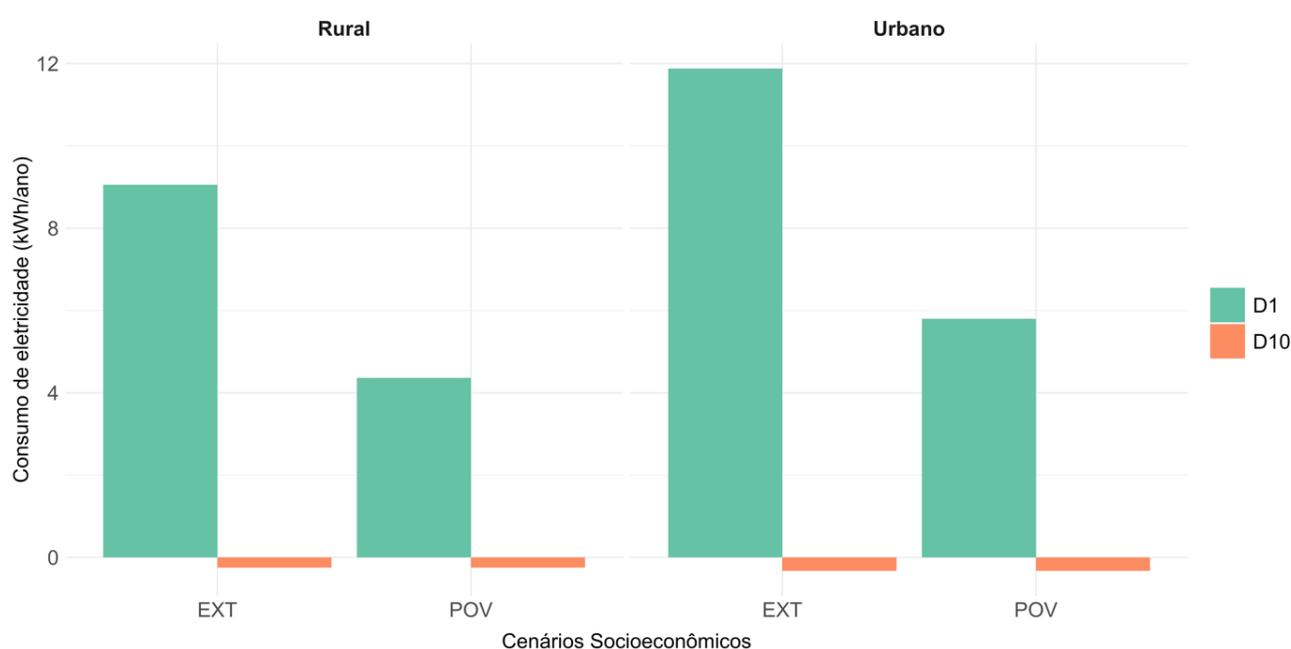


Gráfico 13. Variação no consumo de eletricidade dos mais pobres (D1) e mais ricos (D10) de acordo com os cenários socioeconômicos POV e EXT

Fonte: Elaboração própria

É importante ressaltar que, apesar de termos controle sobre toda a distribuição de renda, o modelo responde melhor a grupos socioeconômicos definidos pelas covariáveis. Como explicado na **Seção 3.2.2**, o modelo POF (2017-2018), assim como todos os outros desenvolvidos nesta tese, opera com variáveis *dummies* por grupo, onde as covariáveis utilizam *dummies* por grupo de indivíduos que compartilham uma mesma característica. Seria necessário um coeficiente diferente para cada domicílio, caso o objetivo fosse obter

respostas diferentes para toda a distribuição, o que é inviável no caso de modelos lineares, devido à proliferação extrema de coeficientes.

No entanto, o objetivo desta simulação é mostrar que o modelo não só captura bem a resposta heterogênea relacionada ao consumo de eletricidade das famílias e a magnitude da resposta, como também é capaz de lidar com diferentes graus de distribuição das covariáveis, principalmente se definidas pelas *dummies* por grupo consideradas no modelo.

4.4.3 Mudanças de clima (temperatura e umidade)

Para finalizar as simulações, são propostos cenários climáticos baseados nos *Representative Concentration Pathways* (RCPs). Os RCPs⁷⁴ são trajetórias de forçamento radiativo⁷⁵ total futuras que têm sido usados como dado de entrada por modelos climáticos que geram projeções de temperatura e outras variáveis climáticas. Existem quatro⁷⁶ RCPs nomeados de acordo com seu nível de forçamento radiativo em 2100 e baseados em

⁷⁴ RCPs não são cenários novos e totalmente integrados, ou seja, não são um pacote completo de projeções socioeconômicas, de emissões e climáticas. Eles são um conjunto consistente de projeções de componentes do forçamento radiativo que servem como entrada para a modelagem climática, escala de padrões e modelagem química atmosférica. Como tal, eles impulsionam o desenvolvimento de cenários na comunidade científica a partir das quais as incertezas sobre o futuro socioeconômico, climático e de impacto podem ser exploradas. Portanto, eles constituíram apenas o início do processo paralelo de desenvolvimento de novos cenários para o quinto Relatório de Avaliação do IPCC. Ao fazer isso, os RCPs visam fornecer uma linha analítica consistente entre as comunidades [262].

⁷⁵ As estimativas de forçamento radiativo são baseadas na emissão de GEE e outros agentes forçantes (BC, OC, CH₄, Enxofre, NO_x, VOC, CO e NH₃), mas não incluem impactos diretos do uso da terra (albedo) ou forçamento de aerossóis. São quatro caminhos independentes desenvolvidos por quatro grupos de modelagem individuais. As diferenças entre os RCPs não devem ser interpretadas diretamente como resultado da política climática ou de desenvolvimentos socioeconômicos específicos. Quaisquer diferenças podem ser atribuídas em parte às diferenças entre os modelos e às premissas dos cenários (científicos, econômicos e tecnológicos). Isso é particularmente relevante para elementos de cenário que são apenas indiretamente acoplados às metas de forçamento radiativo, como uso/cobertura da terra e emissões de poluentes atmosféricos [262].

⁷⁶ RCP 2.6 (IMAGE): A via de emissão é representativa para cenários na literatura que levam a níveis de concentração de GEE muito baixos. É um cenário denominado de “pico”; seu nível de forçamento radiativo atinge primeiro um valor em torno de 3,1 W/m² em meados do século, retornando a 2,6 W/m² em 2100. Para atingir esses níveis de forçamento radiativo, as emissões de GEE (indiretamente, as emissões de poluentes atmosféricos) são reduzidas substancialmente ao longo do tempo [284];

RCP 4.5 (MiniCAM): É um cenário de estabilização em que o forçamento radiativo total é estabilizado antes de 2100 pelo emprego de uma gama de tecnologias e estratégias para reduzir as emissões de gases de efeito estufa [285];

RCP 6.0 (AIM): É um cenário de estabilização em que o forçamento radiativo total é estabilizado após 2100 sem ultrapassagem pelo emprego de uma gama de tecnologias e estratégias para reduzir as emissões de GEE [286]; e

RCP 8.5 (MESSAGE): É caracterizado pelo aumento das emissões de GEE ao longo do tempo, representativas de cenários na literatura que levam a altos níveis de concentração de GEE. Os *drivers* do cenário subjacente e o caminho de desenvolvimento resultante são baseados no cenário A2R [287];

cenários selecionados de quatro times de modelagens/modelos – IES/AIM, IIASA/MESSAGE, PNNL/MiniCAM e PBL/IMAGE [262].

Utilizamos as taxas de crescimento de CDD_{wb} calculadas por PAVANELLO *et al.* [194], considerando os RCPs 4,5 [263] e 8,5 [264]. Os novos valores de CDD_{wb} são então, calculados a partir destas taxas de crescimento, em nível estadual mais o Distrito Federal. A **Figura 23** apresenta os mapas com os novos valores médios de CDD_{wb} por Unidades da Federação de acordo com diferentes cenários climáticos. É importante destacar, que ao utilizarmos o modelo POF (2017-2018) de longo prazo para esta simulação, o cenário base (BL) climático, representa os valores históricos observados no período 1970-2016, apresentados na **Seção 4.1.2**.

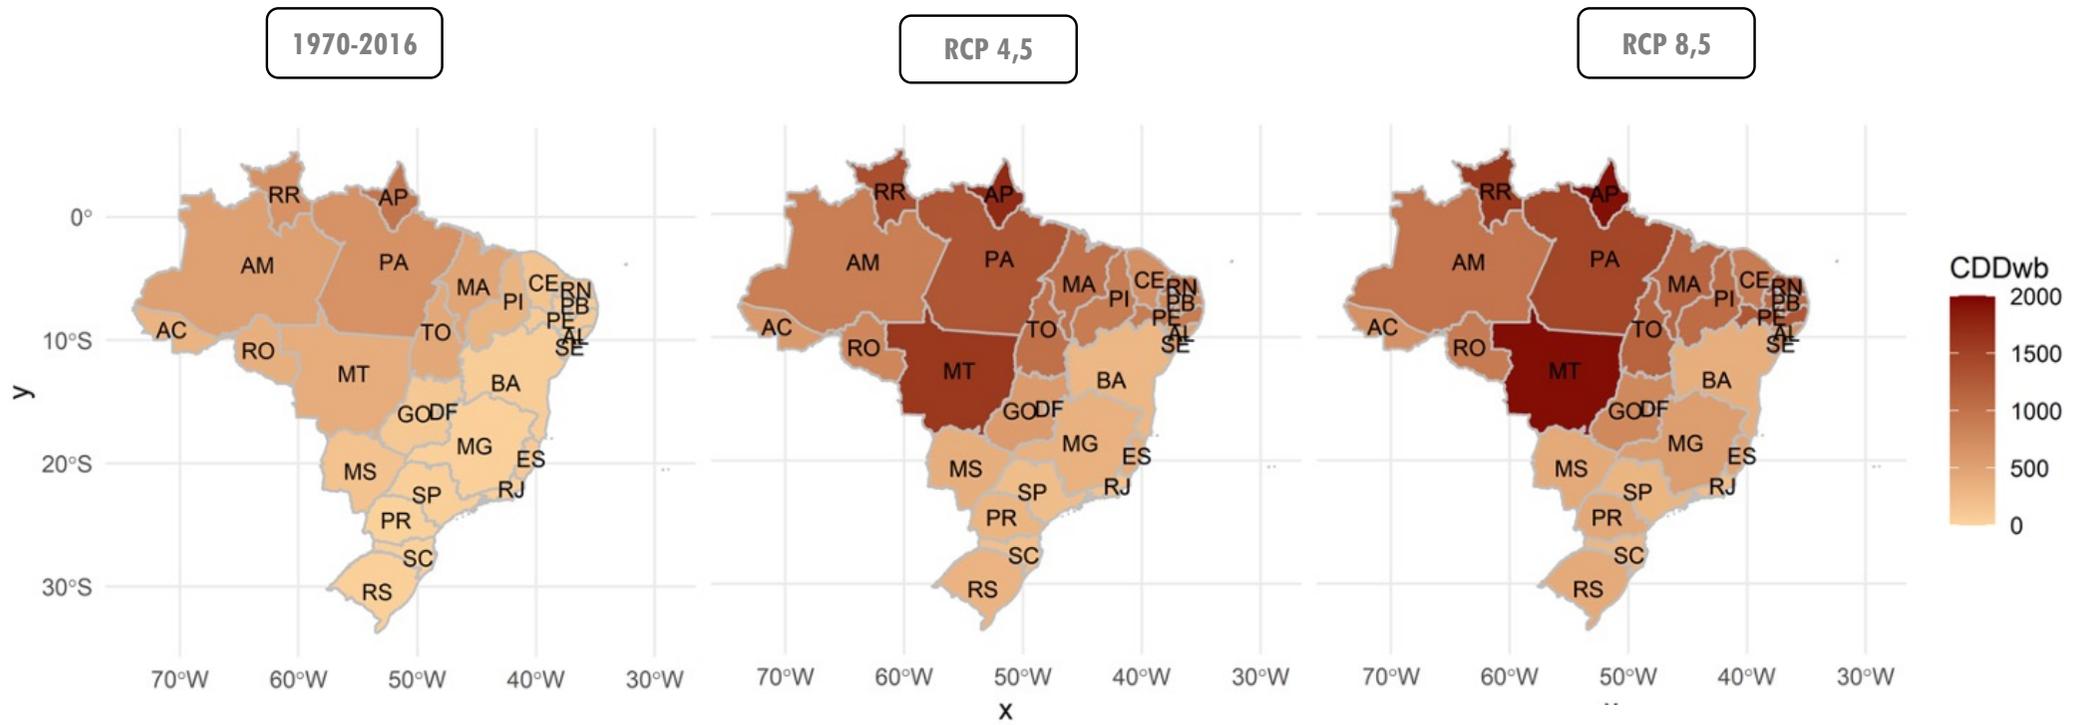


Figura 23. Média de CDD_{wb} em graus-dias por Unidades da Federação de acordo com diferentes cenários climáticos

Fonte: Elaboração própria

Como é percebido pelo mapa, os cenários climáticos alternativos apresentam maiores valores de CDD_{wb} , principalmente no RCP 8,5, em linha com as premissas dos RCPs. Dessa maneira, a mudança climática – indicada por alterações de temperatura e umidade – demonstra uma tendência de aquecimento, o que implica em uma necessidade de adaptação das famílias ao novo clima.

Em razão a heterogeneidade climática observada nos cenários, diferentes grupos socioeconômicos sofrem de diferentes formas as consequências da mudança do clima. Neste sentido, a vulnerabilidade das famílias ao aquecimento global depende, entre outros fatores, da localização de seu domicílio.

Assim, o **Gráfico 14** apresenta as respostas das famílias no consumo elétrico domiciliar frente aos diferentes cenários climáticos de aquecimento global representados por valores mais altos de CDD_{wb} , *ceteris paribus*. Similar ao caso da simulação de graus de distribuição de renda, os cenários climáticos possibilitam a alteração da distribuição do CDD_{wb} de acordo com diferentes taxas de crescimento por Unidades da Federação. Consequentemente, o modelo capta essa heterogeneidade climática/demográfica, o que resulta em diferentes níveis de consumo médio de eletricidade por domicílios de acordo com as Unidades da Federação e outros fatores socioeconômicos definidos pela covariáveis, que, no entanto, foram mantidos constantes. Como verificado, o Mato Grosso é estado com maior crescimento no consumo de eletricidade em kWh/ano/domicílio.

Destarte, apesar do Amapá ter apresentado maiores valores de CDD_{wb} no cenário BL, os cenários alternativos indicam que o Mato Grosso sofrerá mais com as mudanças climáticas e assim, sua população é mais vulnerável ao clima do que os residentes de Amapá.

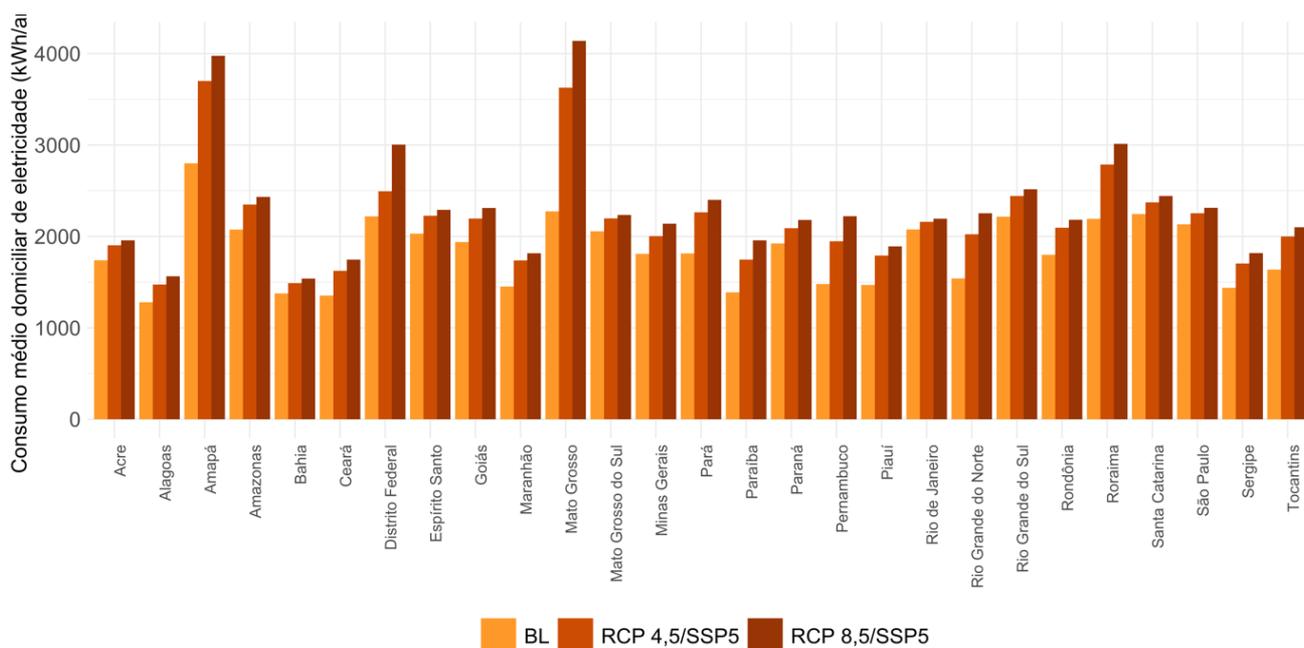


Gráfico 14. Consumo de eletricidade domiciliar médio de acordo com Unidade da Federação e cenários climáticos (kWh/ano/domicílio)

Fonte: Elaboração própria

Em suma, as simulações realizadas demonstram as magnitudes dos efeitos do clima e da renda no consumo de eletricidade residencial no Brasil. A real magnitude do impacto varia de acordo com diferentes suposições feitas em relação aos cenários – nível de mudança das variáveis de influência. Contudo, é demonstrado que as mudanças podem acarretar impactos significativos na demanda elétrica domiciliar, o que varia também de acordo com o grupo socioeconômico o qual o domicílio pertence.

Os resultados sugerem que as mudanças climáticas e consequentemente a necessidade de adaptação ao aquecimento global, assim como políticas e desenvolvimento futuros que impactam o nível de renda das famílias, influenciam de forma heterogênea, a demanda elétrica domiciliar no Brasil.

Dessa forma, embora seja previsto um aumento no consumo de energia elétrica residencial para as próximas décadas, como já abordado no **Capítulo 2**, o nível desse crescimento será em grande parte determinado pelo efeito combinado de diferentes covariáveis capturadas pelo modelo. Sendo assim, a renda e o clima, são duas dessas variáveis, mas não as únicas.

5 CONCLUSÕES

Atualmente, os dois desafios globais urgentes enfrentados pela humanidade são a desigualdade socioeconômica e as mudanças climáticas [21]. Tais reverses são ainda graves em países do Sul Global, como o Brasil, conhecidos pela alta disparidade de renda e pela vulnerabilidade climática justificada pelo clima quente na maior parte do ano, o que intensifica a necessidade de adaptação à mudança do clima.

Contudo, grande parte dos modelos utilizados para explorar as políticas e ações de mitigação e adaptação do clima têm uma capacidade limitada de representar os pobres e vulneráveis [21], assim como a heterogeneidade climática dentro dos países. Isso ocorre porque a maioria dos modelos são muito agregados para lidar com esse tipo de estratificação [129]. Ademais, apesar da relevância de tal representação em países em desenvolvimento, ainda mais escassos são os estudos que abordam esses países.

Pesquisas recentes destacam que há uma necessidade crescente sobre a necessidade de modelos irem além do “consumidor médio representativo” para melhor incorporar a heterogeneidade social e climática em modelos energéticos [23]. Isso significa uma representação mais realista dos padrões de demanda de energia e uma melhor compreensão sobre os impulsionadores da demanda energética, nos permitindo obter *insights* mais confiáveis sobre como as mudanças nesses impulsionadores provavelmente afetarão a demanda de energia futura. Essas informações são importantes tanto para os formuladores de políticas quanto para os pesquisadores.

Neste contexto, esta tese teve como objetivo principal o desenvolvimento de um modelo microeconômico de demanda residencial para o Brasil, capaz de capturar os impactos da heterogeneidade socioeconômica e das condições climáticas sobre a demanda de eletricidade. A abordagem microeconômica utilizada permite investigar o comportamento do consumidor domiciliar e controlar a heterogeneidade observada a partir de diferentes características socioeconômicas e fatores climáticos, possibilitando, dessa forma, uma compreensão mais profunda sobre os principais impulsionadores da demanda elétrica brasileira.

Foram desenvolvidos três modelos microeconômicos de curto prazo de corte transversal com representatividade nacional, utilizando como entrada uma combinação

de: (i) microdados socioeconômicos da Pesquisa de Orçamentos Familiares (POF); e (ii) dados históricos de *Cooling Degree Days wet bulb* (CDD_{wb}), usados como *proxy* do clima. Os modelos são chamados pelo período de referência dos microdados utilizados, as três ondas mais recentes da pesquisa domiciliar: POF (2002-2003), POF (2008-2009) e POF (2017-2018). Ademais, são modelos estruturais, estáticos de equilíbrio parcial e baseados em FILIPPINI [42].

Através do processamento e análise estatística detalhada dos microdados da POF foi possível contextualizar consumo de energia sob a ótica de 20 grupos socioeconômicos (decis de renda e uma diferenciação urbano e rural) ao longo do período 2002-2018 e comprovar a presença de padrões de consumo heterogêneos. A análise dos dados climáticos de CDD_{wb} ratificou a heterogeneidade climática e a presença de microclimas no Brasil, com maiores valores de CDD_{wb} no norte do país, com destaque para o Amapá, e menores valores no Paraná, no sul do Brasil.

Os resultados desta tese são baseados em modelos *cross-section* de análise de covariância, estimados por Mínimos Quadrados Ordinários (MQO) com estimadores consistentes da matriz de covariância para heterocedasticidade e robustos a fatores tendenciosos. Em particular, os modelos são consistentes à presença de *outliers* e à existência do peso amostral. Ademais, foi verificado que o problema da endogeneidade do preço da eletricidade não é relevante para o caso estudado, dado que a maioria dos consumidores de eletricidade segue um esquema de tarifa fixa regulamentada pelo governo brasileiro.

A inferência estatística apresentou elasticidade-preço negativa e elasticidade-renda positiva para os modelos finais POF (2008-2009) e POF (2017-2018), ambas com valores menores que um, em módulo, o que implica em uma demanda de energia elétrica inelástica tanto em relação ao preço quanto à renda, em linha com as literaturas nacional e internacional. Tal resultado corrobora o fato de a eletricidade ser um bem essencial para famílias, com escassez de produtos substitutos, sugerindo que uma política para redução do consumo apenas por meio de aumento de tarifas não seria eficaz para o caso brasileiro.

No caso da elasticidade-renda, os modelos contam com um termo interativo que controla a elasticidade-renda de acordo com decis renda, sendo a categoria de controle o decil 1, representando os domicílios mais pobres. Como consequência, é possível avaliar

como as estimativas de elasticidade mudam, não só ao longo dos anos, mas também com os níveis de renda.

Foram encontradas elasticidades-renda ligeiramente maiores para grupos com renda mais alta, o que significa que a demanda de eletricidade dos mais ricos no Brasil é ligeiramente mais elástica com relação à renda do que a dos mais pobres. Tal resultado, contrário à literatura internacional baseada em países desenvolvidos, pode ser explicado pelas grandes disparidades de renda no Brasil que foram intensificadas ao longo do período analisado.

A análise que considera decis de renda mostra uma diferença clara entre as respostas de famílias de baixa renda e de alta renda sobre a demanda de eletricidade. Portanto, é crucial incluir esse tipo de análise, muitas vezes ignorado na literatura, especialmente para fins de formulação de políticas. Ignorar as diferenças entre as respostas de grupos de renda distintos pode levar a efeitos distributivos adversos.

Os resultados vão além da esfera econômica; outras variáveis do tipo *dummy* relacionadas às características socioeconômicas das famílias também fazem parte do modelo e servem como instrumento de classificação de dados, pois dividem a amostra em vários subgrupos com base nas qualidades ou atributos, controlando, assim, a heterogeneidade observada. Elas implicitamente permitem que se calculem regressões para cada subgrupo. Adicionalmente, observaram-se semi-elasticidades positivas para uma série de covariáveis quantitativas consideradas.

O modelo empírico também sustenta as expectativas e revela que o consumo de eletricidade das famílias brasileiras é impactado por condições climáticas heterogêneas, representadas neste estudo por valores de CDD_{wb} . Apesar de significativo a um nível de confiança de 99%, o efeito marginal do clima é ainda pequeno, mesmo para a última onda. Uma justificativa é que a posse de ar-condicionado – aparelho mais relevante para adaptação ao aquecimento global – é ainda relativamente baixa no país, principalmente nas famílias mais pobres, o que resulta em uma baixa capacidade de adaptação à mudança do clima. Dessa maneira, o efeito do clima é secundário e baixo quando desacoplado da renda, em outras palavras, a renda tem um papel comparativamente mais importante do que o clima na demanda de eletricidade.

Em suma, os modelos indicam que as diferenças relativas às características econômicas, geográficas, habitacionais, climáticas e familiares explicam uma parte significativa da variação nas necessidades energéticas dos domicílios brasileiros. Não considerar explicitamente tais características domiciliares pode influenciar significativamente no viés das estimativas da contribuição marginal de renda e clima.

Esses resultados são de grande importância para o governo e algumas comunidades de pesquisa. Ao identificar os fatores que levam à heterogeneidade da elasticidade da demanda de eletricidade residencial, os pesquisadores podem obter uma compreensão mais profunda das características da demanda de eletricidade residencial. Com base no entendimento das características do consumo domiciliar de eletricidade, o governo tem a oportunidade de fazer políticas mais eficazes, focadas nos grupos mais vulneráveis.

Para mais, as estimativas dos parâmetros do modelo POF (2017-2018) de longo prazo, que omite estoque de capital, foram utilizadas para analisar como alterações nos valores de variáveis importantes incluídas no modelo de regressão impactam a demanda domiciliar de eletricidade no Brasil. Três simulações a partir de mudanças de covariáveis foram realizadas para analisar as respostas do modelo a diferentes cenários socioeconômicos e climáticos, já existentes na literatura, como os *Shared Socioeconomic Pathways* (SSPs) e *Representative Concentration Pathways* (RCPs).

Embora as simulações não tenham o objetivo de fornecer previsões definitivas de valores futuros de demanda de eletricidade, são bons indicativos da ordem de magnitude das possíveis mudanças nas necessidades elétricas das famílias, dadas as mudanças nos valores de algumas variáveis independentes importantes, neste caso renda e CDD_{wb} . Embora o aumento no consumo de energia elétrica seja inevitável nos próximos anos, o nível de aumento será em grande parte determinado pelo efeito combinado das mudanças em algumas das variáveis explicativas importantes que foram identificadas nesta tese.

Apesar do modelo ter cumprido seu propósito pretendido – a contabilização da heterogeneidade socioeconômica e climática no consumo de eletricidade das famílias brasileiras –, como qualquer modelo matemático que tenta representar a realidade, possui limitações que devem ser reconhecidas.

Primeiramente, o modelo analisa apenas a demanda residencial elétrica não sendo capaz de investigar outras fontes de energia como gás e lenha, devido a limitação de dados.

Por ser um modelo empírico estático, captura padrões de consumo baseado em tendências históricas observadas na base de dados e, por isso, não assimila rupturas estruturais e tendências comportamentais futuras dos grupos socioeconômicos, o que é um limitador em cenários de longo prazo. Isso seria de grande valor considerando a importância que o realismo comportamental tem ganhado na pesquisa energética. Entender a diferença entre padrões de consumo e comportamento é relevante nesse quesito. A modelagem do comportamento, também entendido como estilo de vida, está na fronteira do conhecimento.

Apesar da análise microeconômica apresentar tanto elasticidades de curto como de longo prazo, os modelos focam na margem intensiva. Isso significa que o modelo é capaz de entender como o aumento na posse de equipamento afeta a demanda de eletricidade, tanto no curto prazo através das variáveis relacionadas à posse, como no longo prazo, sendo capturado pela renda e pelo clima. Contudo, não prevê como mudança nas covariáveis, por exemplo a renda, pode acarretar a compra de eletrodoméstico, cuja posse e uso aumentam a demanda por eletricidade. Em consequência, se utilizado para projeções futuras, o modelo provavelmente vai subestimar a demanda elétrica. Modelos como Logit e Probit, baseados em DUBIN & MCFADDEN [265], podem ser uma solução.

Adicionalmente, pelo fato de os modelos serem estáticos, eles não são capazes de capturar a dependência intertemporal. A característica estática é dada pela natureza da base de dados socioeconômica utilizada, que não possibilita a criação de um painel genuíno. No entanto, essa limitação de uma análise *cross-section* pode ser superada se seções transversais repetidas estiverem disponíveis. Nesses casos, dados de seção transversal repetidos podem ser aplicados na construção de pseudo-painéis, ou dados de painel sintéticos, que têm algumas das vantagens dos dados de painel genuínos, mais notavelmente a mesma capacidade de controlar para efeitos fixos [75].

Os pseudo-painéis são viáveis a partir da conversão dos dados de nível individual em dados de nível de coortes/grupos (em inglês, *cohorts*). Assim, embora as despesas familiares individuais não possam ser rastreadas ao longo do tempo, como é o caso da

base de dados socioeconômica da POF, é possível fazer isso para *cohorts* de indivíduos [266,267]. O uso dessa alternativa permite a captura da heterogeneidade não-observada, que foi mostrada de extrema relevância para o caso brasileiro. Estudos futuros que avancem nessa direção são encorajados.

Por fim, seria de extrema relevância aprimorar os modelos de demanda desenvolvidos nesta tese para se tornarem modelos satélites, através de *soft link*, de Modelos de Análise Integrada, mais conhecido como IAM (*Integrated Assessment Models*), de modo que feedbacks macroeconômicos de um sistema de energia maior possam ser capturados.

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] IEA, World Energy Outlook 2020, Paris, 2020. <https://www.iea.org/reports/world-energy-outlook-2020>.
- [2] OECD/IEA, The Future of Cooling: Opportunities for energy-efficient air conditioning, 2018. <https://www.iea.org/reports/the-future-of-cooling>.
- [3] IEA, World Energy Outlook 2019, Paris, 2019. <https://www.iea.org/reports/world-energy-outlook-2019%0Ahttps://www.iea.org/reports/world-energy-outlook-2019%0Ahttps://webstore.iea.org/download/summary/2467?fileName=Japanese-Summary-WEO2019.pdf>.
- [4] A. Invidiata, E. Ghisi, Impact of climate change on heating and cooling energy demand in houses in Brazil, *Energy Build.* 130 (2016) 20–32. <https://doi.org/10.1016/j.enbuild.2016.07.067>.
- [5] M. Davide, E. De Cian, A. Bernigaud, Building a framework to understand the energy needs of adaptation, *Sustain.* 11 (2019). <https://doi.org/10.3390/su11154085>.
- [6] E. De Cian, I. Sue Wing, Global Energy Consumption in a Warming Climate, *Environ. Resour. Econ.* 72 (2019) 365–410. <https://doi.org/10.1007/s10640-017-0198-4>.
- [7] R. Fouquet, *Heat, Power and Light*, Edward Elgar Publishing, 2008. <https://econpapers.repec.org/RePEc:elg:eebook:4061>.
- [8] K. Yeager, F. Dayo, B. Fisher, R. Fouquet, A. Gilau, H.-H. Rogner, M. Haug, R. Hosier, A. Miller, S. Schnitteger, N. Lustig, Energy and Economy, in: *Global Energy Assessment Writing Team (Ed.), Glob. Energy Assess. Towar. a Sustain. Futur.*, Cambridge University Press, Cambridge, 2012: pp. 385–422. <https://doi.org/DOI: 10.1017/CBO9780511793677.012>.
- [9] X. Zheng, C. Wei, P. Qin, J. Guo, Y. Yu, F. Song, Z. Chen, Characteristics of residential energy consumption in China: Findings from a household survey, *Energy Policy.* 75 (2014) 126–135. <https://doi.org/10.1016/j.enpol.2014.07.016>.
- [10] R. V. Jones, A. Fuertes, K.J. Lomas, The socio-economic, dwelling and appliance related factors affecting electricity consumption in domestic buildings, *Renew. Sustain. Energy Rev.* 43 (2015) 901–917. <https://doi.org/10.1016/j.rser.2014.11.084>.
- [11] B. Anderson, S. Lin, A. Newing, A.B. Bahaj, P. James, Electricity consumption and household characteristics: Implications for census-taking in a smart metered future, *Comput. Environ. Urban Syst.* 63 (2017) 58–67. <https://doi.org/10.1016/j.compenvurbsys.2016.06.003>.

- [12] F. Taale, C. Kyeremeh, Drivers of households' electricity expenditure in Ghana, *Energy Build.* 205 (2019) 109546. <https://doi.org/10.1016/j.enbuild.2019.109546>.
- [13] S. Pachauri, An analysis of cross-sectional variations in total household energy requirements in India using micro survey data, *Energy Policy.* 32 (2004) 1723–1735. [https://doi.org/10.1016/S0301-4215\(03\)00162-9](https://doi.org/10.1016/S0301-4215(03)00162-9).
- [14] D.H.W. Li, L. Yang, J.C. Lam, Impact of climate change on energy use in the built environment in different climate zones - A review, *Energy.* 42 (2012) 103–112. <https://doi.org/10.1016/j.energy.2012.03.044>.
- [15] J.A. Dirks, W.J. Gorrissen, J.H. Hathaway, D.C. Skorski, M.J. Scott, T.C. Pulsipher, M. Huang, Y. Liu, J.S. Rice, Impacts of climate change on energy consumption and peak demand in buildings: A detailed regional approach, *Energy.* 79 (2015) 20–32. <https://doi.org/10.1016/j.energy.2014.08.081>.
- [16] A. Kitous, J. Després, Assessment of the impact of climate change on residential energy demand for heating and cooling, 2018. <https://doi.org/10.2760/96778>.
- [17] I. Andrić, M. Koc, S.G. Al-Ghamdi, A review of climate change implications for built environment: Impacts, mitigation measures and associated challenges in developed and developing countries, *J. Clean. Prod.* 211 (2019) 83–102. <https://doi.org/10.1016/j.jclepro.2018.11.128>.
- [18] P. Bezerra, F. da Silva, T. Cruz, M. Mistry, E. Vasquez-Arroyo, L. Magalar, E. De Cian, A.F.P. Lucena, R. Schaeffer, Impacts of a warmer world on space cooling demand in Brazilian households, *Energy Build.* 234 (2021) 110696. <https://doi.org/10.1016/j.enbuild.2020.110696>.
- [19] M. Poblete-Cazenave, S. Pachauri, A model of energy poverty and access: Estimating household electricity demand and appliance ownership, *Energy Econ.* 98 (2021) 105266. <https://doi.org/10.1016/j.eneco.2021.105266>.
- [20] G. Depaula, R. Mendelsohn, Development and the Impact of Climate Change on Energy Demand: Evidence from Brazil, *Clim. Chang. Econ.* 1 (2010) 187–208. <https://doi.org/10.1142/S2010007810000157>.
- [21] N.D. Rao, B.J. van Ruijven, K. Riahi, V. Bosetti, Improving poverty and inequality modelling in climate research, *Nat. Clim. Chang.* 7 (2017) 857. <https://doi.org/10.1038/s41558-017-0004-x>.
- [22] T. Ekholm, V. Krey, S. Pachauri, K. Riahi, Determinants of household energy consumption in India, *Energy Policy.* 38 (2010) 5696–5707. <https://doi.org/10.1016/j.enpol.2010.05.017>.
- [23] D.L. McCollum, C. Wilson, H. Pettifor, K. Ramea, V. Krey, K. Riahi, C. Bertram, Z. Lin, O.Y. Edelenbosch, S. Fujisawa, Improving the behavioral realism of global integrated assessment models: An application to consumers' vehicle choices, *Transp. Res. Part D Transp. Environ.* 55 (2017) 322–342. <https://doi.org/10.1016/j.trd.2016.04.003>.

- [24] J.I. Mikayilov, A. Darandary, R. Alyamani, F.J. Hasanov, H. Alatawi, Regional heterogeneous drivers of electricity demand in Saudi Arabia: Modeling regional residential electricity demand, *Energy Policy*. 146 (2020) 111796. <https://doi.org/10.1016/j.enpol.2020.111796>.
- [25] E. De Cian, F. Pavanello, T. Randazzo, M.N. Mistry, M. Davide, Households' adaptation in a warming climate. Air conditioning and thermal insulation choices, *Environ. Sci. Policy*. 100 (2019) 136–157. <https://doi.org/10.1016/j.envsci.2019.06.015>.
- [26] IBGE, Síntese de indicadores sociais : uma análise das condições de vida da população brasileira : 2018, Rio de Janeiro, 2018. <https://biblioteca.ibge.gov.br/visualizacao/livros/liv101629.pdf>.
- [27] M.C. NERI, A escalada da desigualdade - Qual foi o Impacto da Crise sobre a Distribuição de Renda e a Pobreza?, Rio de Janeiro, 2019. <https://www.cps.fgv.br/cps/bd/docs/A-Escalada-da-Desigualdade-Marcelo-Neri-FGV-Social.pdf>.
- [28] UNDP, Human Development Report 2016: Human Development for Everyone, 2017. <http://www.br.undp.org/content/dam/brazil/docs/RelatoriosDesenvolvimento/undp-br-HDR16 Report.pdf>.
- [29] UNDP, Human Development Indices and Indicators: 2018 Statistical Update, 2018. http://hdr.undp.org/sites/default/files/2018_human_development_statistical_update.pdf
http://www.hdr.undp.org/sites/default/files/2018_human_development_statistical_update.pdf
<http://hdr.undp.org/en/2018-update>.
- [30] UNDP, Human development report 2019 : Beyond income, beyond averages, beyond today: Inequalities in human development in the 21st century, New York, 2020.
- [31] T.A. Andrade, W.J.A. Lobão, Elasticidade renda e preço da demanda residencial de energia elétrica no Brasil, Rio de Janeiro, 1997. https://www.ipea.gov.br/portal/images/stories/PDFs/TDs/td_0489.pdf.
- [32] C.A.J. Schmidt, M.A. Lima M, A Demanda por Energia Elétrica no Brasil, *Rev. Bras. Econ.* 58 (2004) 67–98. <http://dx.doi.org/10.1590/S0034-71402004000100004>.
- [33] M.J.C. Villareal, J.M.L. Moreira, Household consumption of electricity in Brazil between 1985 and 2013, *Energy Policy*. 96 (2016) 251–259. <https://doi.org/10.1016/j.enpol.2016.04.030>.
- [34] D. de A. Pereira Uhr, A.L. Squarize Chagas, J.G. Ziero Uhr, Estimation of elasticities for electricity demand in Brazilian households and policy implications, *Energy Policy*. 129 (2019) 69–79. <https://doi.org/10.1016/j.enpol.2019.01.061>.

- [35] C. Santos, M. Weiss, G. Zimmermann, Heterogeneity and the Energy Consumption of Brazilian Households: A Structural Analysis, *Brazilian Rev. Econom.* 39 (2019). <https://doi.org/10.12660/bre.v39n12019.76943>.
- [36] R-Project, What is R? Introduction to R, (2021). <https://www.r-project.org/about.html> (accessed January 27, 2021).
- [37] C. Cohen, M. Lenzen, R. Schaeffer, Energy requirements of households in Brazil, *Energy Policy*. 33 (2005) 555–562. <https://doi.org/10.1016/j.enpol.2003.08.021>.
- [38] M. Lenzen, M. Wier, C. Cohen, H. Hayami, S. Pachauri, R. Schaeffer, A comparative multivariate analysis of household energy requirements in Australia, Brazil, Denmark, India and Japan, *Energy*. 31 (2006) 181–207. <https://doi.org/10.1016/j.energy.2005.01.009>.
- [39] M. Lenzen, R. Schaeffer, J. Karstensen, G.P. Peters, Drivers of change in Brazil's carbon dioxide emissions, *Clim. Change*. 121 (2013) 815–824. <https://doi.org/10.1007/s10584-013-0930-1>.
- [40] M.W. de Abreu, Padrões de consumo de energia em países em desenvolvimento: uma análise de decomposição estrutural para o Brasil, Universidade Federal do Rio de Janeiro, 2020. <http://repositorio.unan.edu.ni/2986/1/5624.pdf>.
- [41] P.R.R. Rochedo, Development of a Global Integrated Energy Model to Evaluate the Brazilian Role in Climate Change Mitigation Scenarios, Universidade Federal do Rio de Janeiro, 2016. http://www.ppe.ufrj.br/ppe/production/tesis/pedro_rochedo.pdf.
- [42] M. Filippini, Swiss residential demand for electricity, *Appl. Econ. Lett.* 6 (1999) 533–538. <https://doi.org/10.1080/135048599352880>.
- [43] X. Labandeira, J.M. Labeaga, X. López-Otero, Estimation of elasticity price of electricity with incomplete information, *Energy Econ.* 34 (2012) 627–633. <https://doi.org/10.1016/j.eneco.2011.03.008>.
- [44] B. Lin, Y. Wang, Analyzing the elasticity and subsidy to reform the residential electricity tariffs in China, *Int. Rev. Econ. Financ.* 67 (2020) 189–206. <https://doi.org/10.1016/j.iref.2020.01.005>.
- [45] IEA, Statistics report: Key World Energy Statistics 2020, 2020. https://webstore.iea.org/download/direct/4035%0Ahttp://data.iea.org/payment/products/103-world-energy-statistics-and-balances-2018-edition-coming-soon.aspx%0Ahttps://www.oecd-ilibrary.org/energy/key-world-energy-statistics-2020_295f00f5-en.
- [46] EPE, Balanço Energético Nacional 2020: Ano base 2019, Rio de Janeiro, 2020. https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-479/topico-528/BEN2020_sp.pdf.

- [47] H. Allcott, A. Collard-Wexler, S.D. O’Connell, How do electricity shortages affect industry? Evidence from India, *Am. Econ. Rev.* 106 (2016) 587–624. <https://doi.org/10.1257/aer.20140389>.
- [48] P.J. Gertler, O. Shelef, C.D. Wolfram, A. Fuchs, The demand for energy-using assets among the world’s rising middle classes, *Am. Econ. Rev.* 106 (2016) 1366–1401. <https://doi.org/10.1257/aer.20131455>.
- [49] A. Köberle, Implementation of Land Use in an Energy System Model to Study the Long-Term Impacts of Bioenergy in Brazil and its Sensitivity to the Choice of Agricultural Greenhouse Gas Emission Factors, Universidade Federal do Rio de Janeiro, 2018. <http://ppe.ufrj.br/ppe/production/tesis/aKoberle.pdf>.
- [50] E.L. La Rovere, C. Gesteira, C. Grottera, W. Wills, Pathways to deep decarbonization in Brazil, 2015. http://deepdecarbonization.org/wp-content/uploads/2015/12/DDPP_BRA.pdf.
- [51] F. Du, J. Zhang, H. Li, J. Yan, S. Galloway, K.L. Lo, Modelling the impact of social network on energy savings, *Appl. Energy*. 178 (2016) 56–65. <https://doi.org/10.1016/j.apenergy.2016.06.014>.
- [52] S. Hu, D. Yan, S. Guo, Y. Cui, B. Dong, A survey on energy consumption and energy usage behavior of households and residential building in urban China, *Energy Build.* 148 (2017) 366–378. <https://doi.org/10.1016/j.enbuild.2017.03.064>.
- [53] B. Jaffar, T. Oreszczyn, R. Raslan, A. Summerfield, Understanding energy demand in Kuwaiti villas: Findings from a quantitative household survey, *Energy Build.* 165 (2018) 379–389. <https://doi.org/10.1016/j.enbuild.2018.01.055>.
- [54] F. Belaïd, D. Roubaud, E. Galariotis, Features of residential energy consumption: Evidence from France using an innovative multilevel modelling approach, *Energy Policy*. 125 (2019) 277–285. <https://doi.org/10.1016/j.enpol.2018.11.007>.
- [55] E. Residential, E.U.S.E. By, I. Bottom-up, Explaining Residential International Bottom-Up, *Energy*. (1985) 341–405.
- [56] H. Nakagami, Lifestyle change and energy use in Japan: Household equipment and energy consumption, *Energy*. 21 (1996) 1157–1167. [https://doi.org/10.1016/0360-5442\(96\)00071-0](https://doi.org/10.1016/0360-5442(96)00071-0).
- [57] L.F. Cabeza, D. Urge-Vorsatz, M.A. McNeil, C. Barreneche, S. Serrano, Investigating greenhouse challenge from growing trends of electricity consumption through home appliances in buildings, *Renew. Sustain. Energy Rev.* 36 (2014) 188–193. <https://doi.org/10.1016/j.rser.2014.04.053>.
- [58] N.D. Rao, K. Ummel, White goods for white people? Drivers of electric appliance growth in emerging economies, *Energy Res. Soc. Sci.* 27 (2017) 106–116. <https://doi.org/10.1016/j.erss.2017.03.005>.
- [59] P. Tiwari, Architectural, Demographic, and Economic Causes of Electricity

- Consumption in Bombay, *J. Policy Model.* 22 (2000) 81–98. [https://doi.org/10.1016/s0161-8938\(98\)00003-9](https://doi.org/10.1016/s0161-8938(98)00003-9).
- [60] B. Halvorsen, B.M. Larsen, Norwegian residential electricity demand—a microeconomic assessment of the growth from 1976 to 1993, *Energy Policy.* 29 (2001) 227–236. [https://doi.org/10.1016/S0301-4215\(00\)00106-3](https://doi.org/10.1016/S0301-4215(00)00106-3).
- [61] K. Louw, B. Conradie, M. Howells, M. Dekenah, Determinants of electricity demand for newly electrified low-income African households, *Energy Policy.* 36 (2008) 2812–2818. <https://doi.org/10.1016/j.enpol.2008.02.032>.
- [62] D. Brounen, N. Kok, J.M. Quigley, Residential energy use and conservation: Economics and demographics, *Eur. Econ. Rev.* 56 (2012) 931–945. <https://doi.org/10.1016/j.euroecorev.2012.02.007>.
- [63] P. Wyatt, A dwelling-level investigation into the physical and socio-economic drivers of domestic energy consumption in England, *Energy Policy.* 60 (2013) 540–549. <https://doi.org/10.1016/j.enpol.2013.05.037>.
- [64] R. Debnath, R. Bardhan, M. Sunikka-Blank, Discomfort and distress in slum rehabilitation: Investigating a rebound phenomenon using a backcasting approach, *Habitat Int.* 87 (2019) 75–90. <https://doi.org/10.1016/j.habitatint.2019.03.010>.
- [65] A. Gioda, Residential fuelwood consumption in Brazil: Environmental and social implications, *Biomass and Bioenergy.* 120 (2019) 367–375. <https://doi.org/10.1016/j.biombioe.2018.11.014>.
- [66] B. Behera, D.B. Rahut, A. Jeetendra, A. Ali, Household collection and use of biomass energy sources in South Asia, *Energy.* 85 (2015) 468–480. <https://doi.org/10.1016/j.energy.2015.03.059>.
- [67] A. Mazzone, T. Cruz, P. Bezerra, Firewood in the forest : Social practices, culture, and energy transitions in a remote village of the Brazilian Amazon, *Energy Res. Soc. Sci.* 74 (2021) 101980. <https://doi.org/10.1016/j.erss.2021.101980>.
- [68] S. Pachauri, L. Jiang, The household energy transition in India and China, *Energy Policy.* 36 (2008) 4022–4035. <https://doi.org/10.1016/j.enpol.2008.06.016>.
- [69] S. Zhou, F. Teng, Estimation of urban residential electricity demand in China using household survey data, *Energy Policy.* 61 (2013) 394–402. <https://doi.org/10.1016/j.enpol.2013.06.092>.
- [70] M. Zeyringer, S. Pachauri, E. Schmid, J. Schmidt, E. Worrell, U.B. Morawetz, Analyzing grid extension and stand-alone photovoltaic systems for the cost-effective electrification of Kenya, *Energy Sustain. Dev.* 25 (2015) 75–86. <https://doi.org/10.1016/j.esd.2015.01.003>.
- [71] J. Harold, J. Cullinan, S. Lyons, The income elasticity of household energy demand: a quantile regression analysis, *Appl. Econ.* 49 (2017) 5570–5578. <https://doi.org/10.1080/00036846.2017.1313952>.

- [72] S.C. Bhattacharyya, G.R. Timilsina, Modelling energy demand of developing countries: Are the specific features adequately captured?, *Energy Policy*. 38 (2010) 1979–1990. <https://doi.org/10.1016/j.enpol.2009.11.079>.
- [73] J. Langevin, J.L. Reyna, S. Ebrahimigharehbaghi, N. Sandberg, P. Fennell, G. N’ageli, J. Laverge, M. Delghust, E. Mata, M. Van Hove, J. Webster, F. Federico, M. Jakob, C. Camarasa, Developing a common approach for classifying building stock energy models, 133 (2020). <https://doi.org/10.1016/j.rser.2020.110276>.
- [74] L.G. Swan, V.I. Ugursal, Modeling of end-use energy consumption in the residential sector: A review of modeling techniques, *Renew. Sustain. Energy Rev.* 13 (2009) 1819–1835. <https://doi.org/10.1016/j.rser.2008.09.033>.
- [75] A.C. Cameron, P.K. Trivedi, *Microeconometrics: Methods and Applications*, Cambridge University Press, New York, 2005. https://www.m-culture.go.th/mculture_th/download/king9/Glossary_about_HM_King_Bhumibol_Adulyadej's_Funeral.pdf.
- [76] A.C. Cameron, P.K. Trivedi, *Microeconometrics Using Stata*, A Stata Press Publication, Texas, 2009.
- [77] J. Emmerling, M. Tavoni, Representing inequalities in integrated assessment modeling of climate change, *One Earth*. 4 (2021) 177–180. <https://doi.org/10.1016/j.oneear.2021.01.013>.
- [78] S. Silva, I. Soares, C. Pinho, Electricity residential demand elasticities: Urban versus rural areas in Portugal, *Energy*. 144 (2018) 627–632. <https://doi.org/10.1016/j.energy.2017.12.070>.
- [79] D.N. Gujarati, D.C. Porter, *Econometria Básica*, Quinta Edi, Porto Alegre, 2011.
- [80] T.B. Johansson, N. Nakicenovic, A. Patwardhan, L. Gomez-Echeverri, D.J. Arent, R. Banerjee, S.M. Benson, D.H. Bouille, A. Brew-Hammond, A. Cherp, S.T. Coelho, L. Emberson, M.J. Figueroa, A. Grubler, K. He, M. Jaccard, S.K. Ribeiro, S. Karekezi, E.D. Larson, Z. Li, S. McDade, L.K. Mytelka, S. Pachauri, K. Riahi, J. Rockström, H.-H. Rogner, J. Roy, R.N. Schock, R. Sims, K.R. Smith, W.C. Turkenburg, D. Ürge-Vorsatz, F. von Hippel, K. Yeager, Technical Summary, in: *Global Energy Assessment Writing Team (Ed.), Glob. Energy Assess. Towar. a Sustain. Futur.*, Cambridge University Press, Cambridge, 2012: pp. 31–94. <https://doi.org/DOI: 10.1017/CBO9780511793677.006>.
- [81] M. Bazilian, R. Pielke, Jr, Making Energy Access Meaningful, *Issues Sci. Technol.* 29 (2013) 74–79. <http://scholar.google.com/scholar?hl=en&btnG=Search&q=intitle:Making+Energy+Access+Meaningful#0>.
- [82] Y. Liu, Y. Gao, Y. Hao, H. Liao, The relationship between residential electricity consumption and income: A piecewise linear model with panel data, *Energies*. 9 (2016) 1–11. <https://doi.org/10.3390/en9100831>.

- [83] N.D. Rao, Poverty eradication and climate change : Is there a conflict ?, IIASA. (2014) 8–10. <http://blog.iiasa.ac.at/2014/08/27/poverty-eradication-and-climate-change-is-there-a-conflict/> (accessed November 10, 2017).
- [84] W.F. Lamb, N.D. Rao, Human development in a climate-constrained world: What the past says about the future, *Glob. Environ. Chang.* 33 (2015) 14–22. <https://doi.org/10.1016/j.gloenvcha.2015.03.010>.
- [85] A. Ribas, A.F.P. Lucena, R. Schaeffer, Bridging the energy divide and securing higher collective well-being in a climate-constrained world, *Energy Policy*. 108 (2017) 435–450. <https://doi.org/10.1016/j.enpol.2017.06.017>.
- [86] N.D. Rao, J. Min, Less global inequality can improve climate outcomes, *Wiley Interdiscip. Rev. Clim. Chang.* 9 (2018) 1–6. <https://doi.org/10.1002/wcc.513>.
- [87] N.D. Rao, J. Min, A. Mastrucci, Energy requirements for decent living in India, Brazil and South Africa, *Nat. Energy*. 4 (2019) 1025–1032. <https://doi.org/10.1038/s41560-019-0497-9>.
- [88] C. Wolfram, O. Shelef, P.J. Gertler, How will energy demand develop in the developing world?, NBER Work. Pap. No. (2012).
- [89] M. Auffhammer, C.D. Wolfram, Powering up China: Income distributions and residential electricity consumption, *Am. Econ. Rev.* 104 (2014) 575–580. <https://doi.org/10.1257/aer.104.5.575>.
- [90] L.W. Davis, P.J. Gertler, Contribution of air conditioning adoption to future energy use under global warming, *Proc. Natl. Acad. Sci. U. S. A.* 112 (2015) 5962–5967. <https://doi.org/10.1073/pnas.1423558112>.
- [91] S. Dhanaraj, V. Mahambare, P. Munjal, From Income to Household Welfare: Lessons from Refrigerator Ownership in India, *J. Quant. Econ.* 16 (2018) 573–588. <https://doi.org/10.1007/s40953-017-0084-5>.
- [92] D.A. Dang, H.A. La, Does electricity reliability matter? Evidence from rural Viet Nam, *Energy Policy*. 131 (2019) 399–409. <https://doi.org/10.1016/j.enpol.2019.04.036>.
- [93] G.V. de T.L. Ataíde, P.C. Borja, Justiça social e ambiental em saneamento básico: um olhar sobre experiências de planejamento municipais, *Ambient. Soc.* 20 (2017) 61–78. http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1414-753X2017000300061&lng=en&tlng=en.
- [94] N.D. Rao, S. Pachauri, Energy access and living standards: some observations on recent trends, *Environ. Res. Lett.* 12 (2017) 025011. <https://doi.org/10.1088/1748-9326/aa5b0d>.
- [95] United Nations, Transformando Nosso Mundo: A Agenda 2030 para o Desenvolvimento Sustentável, 2015. http://www.un.org/ga/search/view_doc.asp?symbol=A/RES/70/1&Lang=E.

- [96] UFMS, UFMS vincula projetos de pesquisa a Objetivos de Desenvolvimento Sustentável (ODS), da ONU, (2018). <https://www.ufms.br/ufms-vincula-projetos-de-pesquisa-objetivos-de-desenvolvimento-sustentavel-ods-da-onu/> (accessed August 17, 2021).
- [97] F.H.G. Ferreira, S. Chen, A. Dabalén, Y. Dikhanov, N. Hamadeh, D. Jolliffe, A. Narayan, E.B. Prydz, A. Revenga, P. Sangraula, U. Serajuddin, N. Yoshida, A global count of the extreme poor in 2012: data issues, methodology and initial results, *J. Econ. Inequal.* 14 (2016) 141–172. <https://doi.org/10.1007/s10888-016-9326-6>.
- [98] World Bank, *Monitoring Global Poverty: Report of the Commission on Global Poverty*, Washington, 2017. <https://doi.org/10.1596/978-1-4648-0961-3>.
- [99] World Bank, *Poverty and shared prosperity 2020: Reversals of fortune*, Washington, 2020. <https://doi.org/10.1038/302765a0>.
- [100] World Bank, *Projected poverty impacts of COVID-19 (coronavirus)*, 2020. <http://pubdocs.worldbank.org/en/461601591649316722/Projected-poverty-impacts-of-COVID-19.pdf>.
- [101] IBGE, *Síntese de indicadores sociais : uma análise das condições de vida da população brasileira : 2019, 2019*. <https://doi.org/10.1017/CBO9781107415324.004>.
- [102] D. Jolliffe, E.B. Prydz, Estimating international poverty lines from comparable national thresholds, *J. Econ. Inequal.* 14 (2016) 185–198. <https://doi.org/10.1007/s10888-016-9327-5>.
- [103] The World Bank, *A richer array of international poverty lines*, (2017). <http://blogs.worldbank.org/developmenttalk/richer-array-international-poverty-lines> (accessed December 6, 2017).
- [104] The World Bank, *Monitoring Global Poverty: Report of the Commission on Global Poverty*, 2017. <https://doi.org/10.1596/978-1-4648-0961-3>.
- [105] GTSC A2030, *Relatório Luz da Sociedade Civil da Agenda 2030 de Desenvolvimento Sustentável: Síntese II*, 2018. https://brasilnaagenda2030.files.wordpress.com/2018/07/relatorio-sicc81ntese_final_download.pdf.
- [106] World Bank, *Poverty headcount ratio at national poverty lines (% of population)*, (2021). https://data.worldbank.org/indicator/SI.POV.NAHC?end=2019&most_recent_year_desc=false&start=1985&type=points&view=chart (accessed August 10, 2021).
- [107] S. Rocha, Poverty upsurge in 2015 and the rising trend in regional and age inequality among the poor in Brazil, *Nov. Econ.* 29 (2019) 249–275. <https://doi.org/10.1590/0103-6351/3992>.

- [108] IGBE, Síntese de indicadores sociais : uma análise das condições de vida da população brasileira : 2020, 2020. <https://biblioteca.ibge.gov.br/visualizacao/livros/liv101760.pdf>.
- [109] ILO, Women and men in the informal economy: a statistical picture, Geneva, 2018. <https://doi.org/10.1179/bac.2003.28.1.018>.
- [110] CAIXA, Auxílio Emergencial 2021: Um suporte financeiro do Governo Federal para trabalhadores informais, (2021). <https://www.caixa.gov.br/auxilio/auxilio2021/Paginas/default.aspx> (accessed April 27, 2021).
- [111] M.C. NERI, Covid, Classes Econômicas e o Caminho do Meio: Crônica da Crise até Agosto de 2020, Rio de Janeiro, 2020. <https://www.cps.fgv.br/cps/CovidClasses/>.
- [112] M.C. NERI, Qual foi o Impacto Imediato da Pandemia do Covid sobre as Classes Econômicas Brasileiras?, Rio de Janeiro, 2020. <https://cps.fgv.br/pesquisas/qual-foi-o-impacto-imediato-da-pandemia-do-covid-sobre-classes-economicas-brasileiras>.
- [113] B.J. van Ruijven, J. Schers, D.P. van Vuuren, Model-based scenarios for rural electrification in developing countries, *Energy*. 38 (2012) 386–397. <https://doi.org/10.1016/j.energy.2011.11.037>.
- [114] S. Pachauri, B.J. Van Ruijven, Y. Nagai, K. Riahi, D.P. Van Vuuren, A. Brew-Hammond, N. Nakicenovic, Pathways to achieve universal household access to modern energy by 2030, *Environ. Res. Lett.* 8 (2013). <https://doi.org/10.1088/1748-9326/8/2/024015>.
- [115] F. Kemausuor, E. Adkins, I. Adu-Poku, A. Brew-Hammond, V. Modi, Electrification planning using Network Planner tool: The case of Ghana, *Energy Sustain. Dev.* 19 (2014) 92–101. <https://doi.org/10.1016/j.esd.2013.12.009>.
- [116] D. Mentis, M. Howells, H. Rogner, A. Korkovelos, C. Arderne, E. Zepeda, S. Siyal, C. Taliotis, M. Bazilian, A. De Roo, Y. Tanvez, A. Oudalov, E. Scholtz, Lighting the World: the first application of an open source, spatial electrification tool (OnSSET) on Sub-Saharan Africa, *Environ. Res. Lett.* 12 (2017). <https://doi.org/10.1088/1748-9326/aa7b29>.
- [117] A.G. Dagnachew, P.L. Lucas, A.F. Hof, D.P. van Vuuren, Trade-offs and synergies between universal electricity access and climate change mitigation in Sub-Saharan Africa, *Energy Policy*. 114 (2018) 355–366. <https://doi.org/10.1016/j.enpol.2017.12.023>.
- [118] F. Urban, R.M.J. Benders, H.C. Moll, Modelling energy systems for developing countries, *Energy Policy*. 35 (2007) 3473–3482. <https://doi.org/10.1016/j.enpol.2006.12.025>.
- [119] C. Grottera, C. Barbier, A. Sanches-Pereira, M.W. de Abreu, C. Uchôa, L.G.

- Tudeschini, J.M. Cayla, F. Nadaud, A.O. Pereira, C. Cohen, S.T. Coelho, Linking electricity consumption of home appliances and standard of living: A comparison between Brazilian and French households, *Renew. Sustain. Energy Rev.* (2018). <https://doi.org/10.1016/j.rser.2018.06.063>.
- [120] V. Daioglou, B.J. van Ruijven, D.P. van Vuuren, Model projections for household energy use in developing countries, *Energy*. 37 (2012) 601–615. <https://doi.org/10.1016/j.energy.2011.10.044>.
- [121] S. Pachauri, A. Mueller, A. Kemmler, D. Spreng, On Measuring Energy Poverty in Indian Households, 32 (2004) 2083–2104. <https://doi.org/10.1016/j.worlddev.2004.08.005>.
- [122] M. Filippini, S. Pachauri, Elasticities of electricity demand in urban Indian households, *Energy Policy*. 32 (2004) 429–436. [https://doi.org/10.1016/S0301-4215\(02\)00314-2](https://doi.org/10.1016/S0301-4215(02)00314-2).
- [123] M.N. Rao, B.S. Reddy, Variations in energy use by Indian households: An analysis of micro level data, *Energy*. 32 (2007) 143–153. <https://doi.org/10.1016/j.energy.2006.03.012>.
- [124] B. van Ruijven, F. Urban, R.M.J. Benders, H.C. Moll, J.P. van der Sluijs, B. de Vries, D.P. van Vuuren, Modeling Energy and Development: An Evaluation of Models and Concepts, *World Dev.* 36 (2008) 2801–2821. <https://doi.org/10.1016/j.worlddev.2008.01.011>.
- [125] G.D.M. Jannuzzi, L. Schipper, The structure of electricity demand in the Brazilian household sector, *Energy Policy*. 19 (1991) 879–891. [https://doi.org/10.1016/0301-4215\(91\)90013-E](https://doi.org/10.1016/0301-4215(91)90013-E).
- [126] C. Achão, R. Schaeffer, Decomposition analysis of the variations in residential electricity consumption in Brazil for the 1980-2007 period: Measuring the activity, intensity and structure effects, *Energy Policy*. 37 (2009) 5208–5220. <https://doi.org/10.1016/j.enpol.2009.07.043>.
- [127] R. Hoffmann, Mensuração da desigualdade e da pobreza no Brasil, in: *Desigual. e Pobr. No Bras.*, IPEA, 2000.
- [128] R. Hoffmann, M.G. Ney, A recente queda da desigualdade de renda no Brasil : análise de dados da PNAD , do Censo Demográfico e das Contas Nacionais, *Economica*. 10 (2008) 7–39.
- [129] B.J. van Ruijven, D.P. van Vuuren, B.J.M. de Vries, M. Isaac, J.P. van der Sluijs, P.L. Lucas, P. Balachandra, Model projections for household energy use in India, *Energy Policy*. 39 (2011) 7747–7761. <https://doi.org/10.1016/j.enpol.2011.09.021>.
- [130] IIASA, MESSAGE-Access, (2018). <http://www.iiasa.ac.at/web/home/research/researchPrograms/Energy/MESSAGE-Access.en.html>.

- [131] S. Pachauri, N.D. Rao, C. Cameron, Outlook for modern cooking energy access in Central America, *PLoS One*. 13 (2018). <https://doi.org/10.1371/journal.pone.0197974>.
- [132] C. Cameron, S. Pachauri, N.D. Rao, D. McCollum, J. Rogelj, K. Riahi, Policy trade-offs between climate mitigation and clean cook-stove access in South Asia, *Nat. Energy*. 1 (2016) 1–5. <https://doi.org/10.1038/nenergy.2015.10>.
- [133] L.G. Tudeschini, Income inequality and its impacts on the Brazilian household carbon footprint, Universidade de São Paulo, 2018.
- [134] A. Sanches-Pereira, L.G. Tudeschini, S.T. Coelho, Evolution of the Brazilian residential carbon footprint based on direct energy consumption, *Renew. Sustain. Energy Rev.* 54 (2016) 184–201. <https://doi.org/10.1016/j.rser.2015.09.024>.
- [135] E. Ghisi, S. Gosch, R. Lamberts, Electricity end-uses in the residential sector of Brazil, *Energy Policy*. 35 (2007) 4107–4120. <https://doi.org/10.1016/j.enpol.2007.02.020>.
- [136] D. de A.P. Uhr, A.L.S. Chagas, J.G.Z. Uhr, Demand for Residential Energy in Brazil Revisited: A Dynamic Panel Data Approach, *Empir. Econ. Lett.* 16 (2017) 747–753. <http://www.eel.my100megs.com/volume-16-number-8.htm>.
- [137] S.G. Yalew, M.T.H. van Vliet, D.E.H.J. Gernaat, F. Ludwig, A. Miara, C. Park, E. Byers, E. De Cian, F. Piontek, G. Iyer, I. Mouratiadou, J. Glynn, M. Hejazi, O. Dessens, P. Rochedo, R. Pietzcker, R. Schaeffer, S. Fujimori, S. Dasgupta, S. Mima, S.R.S. da Silva, V. Chaturvedi, R. Vautard, D.P. van Vuuren, Impacts of climate change on energy systems in global and regional scenarios, *Nat. Energy*. 5 (2020) 794–802. <https://doi.org/10.1038/s41560-020-0664-z>.
- [138] F. Pietro Colelli, E. De Cian, Cooling demand in integrated assessment models: A methodological review, *Environ. Res. Lett.* 15 (2020). <https://doi.org/10.1088/1748-9326/abb90a>.
- [139] A. Levesque, R.C. Pietzcker, L. Baumstark, S. De Stercke, A. Grübler, G. Luderer, How much energy will buildings consume in 2100? A global perspective within a scenario framework, *Energy*. 148 (2018) 514–527. <https://doi.org/10.1016/j.energy.2018.01.139>.
- [140] Z.J. Zhai, J.M. Helman, Climate change: Projections and implications to building energy use, *Build. Simul.* 12 (2019) 585–596. <https://doi.org/10.1007/s12273-019-0509-5>.
- [141] B.J. van Ruijven, E. De Cian, I. Sue Wing, Amplification of future energy demand growth due to climate change, *Nat. Commun.* 10 (2019) 1–12. <https://doi.org/10.1038/s41467-019-10399-3>.
- [142] N. Zhang, H. Wang, J. Gallagher, Q. Song, V.W.Y. Tam, H. Duan, A dynamic analysis of the global warming potential associated with air conditioning at a city scale: an empirical study in Shenzhen, China, *Environ. Impact Assess. Rev.* 81

- (2020) 106354. <https://doi.org/10.1016/j.eiar.2019.106354>.
- [143] M. Waite, E. Cohen, H. Torbey, M. Piccirilli, Y. Tian, V. Modi, Global trends in urban electricity demands for cooling and heating, *Energy*. 127 (2017) 786–802. <https://doi.org/10.1016/j.energy.2017.03.095>.
- [144] D.J. Sailor, A.A. Pavlova, Air conditioning market saturation and long-term response of residential cooling energy demand to climate change, *Energy*. 28 (2003) 941–951. [https://doi.org/10.1016/S0360-5442\(03\)00033-1](https://doi.org/10.1016/S0360-5442(03)00033-1).
- [145] E. Akpinar-Ferrand, A. Singh, Modeling increased demand of energy for air conditioners and consequent CO2 emissions to minimize health risks due to climate change in India, *Environ. Sci. Policy*. 13 (2010) 702–712. <https://doi.org/10.1016/j.envsci.2010.09.009>.
- [146] M. Auffhammer, E.T. Mansur, Measuring climatic impacts on energy consumption: A review of the empirical literature, *Energy Econ*. 46 (2014) 522–530. <https://doi.org/10.1016/j.eneco.2014.04.017>.
- [147] N.S. Diffenbaugh, M. Burke, Global warming has increased global economic inequality, *Proc. Natl. Acad. Sci. U. S. A.* 116 (2019) 9808–9813. <https://doi.org/10.1073/pnas.1816020116>.
- [148] M. Kalkuhl, L. Wenz, The impact of climate conditions on economic production. Evidence from a global panel of regions, *J. Environ. Econ. Manage.* 103 (2020) 102360. <https://doi.org/10.1016/j.jeem.2020.102360>.
- [149] N. Taconet, A. Méjean, C. Guivarch, Influence of climate change impacts and mitigation, *Clim. Change*. (2020).
- [150] A. Mastrucci, E. Byers, S. Pachauri, N.D. Rao, Improving the SDG energy poverty targets : Residential cooling needs in the Global South, *Energy Build.* 186 (2019) 405–415. <https://doi.org/10.1016/j.enbuild.2019.01.015>.
- [151] R. Mendelsohn, A. Dinar, L. Williams, The distributional impact of climate change on rich and poor countries, *Environ. Dev. Econ.* 11 (2006) 159. <https://doi.org/10.1017/S1355770X05002755>.
- [152] E. De Cian, A.F. Hof, G. Marangoni, M. Tavoni, D.P. Van Vuuren, Alleviating inequality in climate policy costs: An integrated perspective on mitigation, damage and adaptation, *Environ. Res. Lett.* 11 (2016). <https://doi.org/10.1088/1748-9326/11/7/074015>.
- [153] S. Hallegatte, J. Rozenberg, Climate change through a poverty lens, *Nat. Clim. Chang.* 7 (2017) 250–256. <https://doi.org/10.1038/nclimate3253>.
- [154] S. Hsiang, R. Kopp, A. Jina, J. Rising, M. Delgado, S. Mohan, D.J. Rasmussen, R. Muir-Wood, P. Wilson, M. Oppenheimer, K. Larsen, T. Houser, Estimating economic damage from climate change in the United States, *Science* (80-.). 356 (2017) 1362–1369. <https://doi.org/10.1126/science.aal4369>.

- [155] S. Hallegatte, M. Bangalore, L. Bonzanigo, M. Fay, T. Kane, U. Narloch, J. Rozenberg, D. Treguer, A. Vogt-Schilb, *Shock Waves: managing the Impacts of Climate Change on Poverty*, Washington, 2016. http://www.journals.cambridge.org/abstract_S0022112081001535.
- [156] B.C. O'Neill, E. Kriegler, K. Riahi, K.L. Ebi, S. Hallegatte, T.R. Carter, R. Mathur, D.P. van Vuuren, A new scenario framework for climate change research: the concept of shared socioeconomic pathways, *Clim. Change*. 122 (2014) 387–400. <https://doi.org/10.1007/s10584-013-0905-2>.
- [157] B. Soergel, E. Kriegler, B.L. Bodirsky, N. Bauer, M. Leimbach, A. Popp, Combining ambitious climate policies with efforts to eradicate poverty, *Nat. Commun.* (under Rev. (2020) 1–12. <https://doi.org/10.1038/s41467-021-22315-9>.
- [158] E. de P.E. EPE, *Uso de Ar Condicionado no Setor Residencial Brasileiro: Perspectivas e contribuições para o avanço em eficiência energética*, Nota Técnica EPE 030/2018 -. (2018) 43. http://epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-341/NT_EPE_030_2018_18Dez2018.pdf.
- [159] EPE, *Nota Técnica EPE 030/2018 - Uso de Ar Condicionado no Setor Residencial Brasileiro: Perspectivas e contribuições para o avanço em eficiência energética*, 2018. http://epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-341/NT_EPE_030_2018_18Dez2018.pdf.
- [160] J.D.A. Cabral, M.V.D.F. Cabral, A.O.P. Júnior, Elasticity estimation and forecasting: An analysis of residential electricity demand in Brazil, *Util. Policy*. 66 (2020) 101108. <https://doi.org/10.1016/j.jup.2020.101108>.
- [161] J.L. Reyna, M. V. Chester, Energy efficiency to reduce residential electricity and natural gas use under climate change, *Nat. Commun.* 8 (2017) 1–12. <https://doi.org/10.1038/ncomms14916>.
- [162] P. Shen, Impacts of climate change on U.S. building energy use by using downscaled hourly future weather data, *Energy Build.* 134 (2017) 61–70. <https://doi.org/10.1016/j.enbuild.2016.09.028>.
- [163] Z.J. Zhai, J.M. Helman, Climate change: Projections and implications to building energy use - SM, *Build. Simul.* 12 (2019) 585–596. <https://doi.org/10.1007/s12273-019-0509-5>.
- [164] A. Jiang, Y. Zhu, A. Elsafty, M. Tumeo, Effects of Global Climate Change on Building Energy Consumption and Its Implications in Florida, *Int. J. Constr. Educ. Res.* 14 (2018) 22–45. <https://doi.org/10.1080/15578771.2017.1280104>.
- [165] M. Jakubcionis, J. Carlsson, Estimation of European Union residential sector space cooling potential, *Energy Policy*. 101 (2017) 225–235. <https://doi.org/10.1016/j.enpol.2016.11.047>.

- [166] M. Olonscheck, A. Holsten, J.P. Kropp, Heating and cooling energy demand and related emissions of the German residential building stock under climate change, *Energy Policy*. 39 (2011) 4795–4806. <https://doi.org/10.1016/j.enpol.2011.06.041>.
- [167] D. Sánchez-García, D. Bienvenido-Huertas, M. Trisancho-Carvajal, C. Rubio-Bellido, Adaptive comfort control implemented model (ACCIM) for energy consumption predictions in dwellings under current and future climate conditions: A case study located in Spain, *Energies*. 12 (2019). <https://doi.org/10.3390/en12081498>.
- [168] I.G. Dino, C. Meral Akgül, Impact of climate change on the existing residential building stock in Turkey: An analysis on energy use, greenhouse gas emissions and occupant comfort, *Renew. Energy*. 141 (2019) 828–846. <https://doi.org/10.1016/j.renene.2019.03.150>.
- [169] V. Frontuto, Forecasting household consumption of fuels: A multiple discrete-continuous approach, *Appl. Energy*. 240 (2019) 205–214. <https://doi.org/10.1016/j.apenergy.2019.01.262>.
- [170] T. Randazzo, E. De Cian, M.N. Mistry, Air conditioning and electricity expenditure: The role of climate in temperate countries, *Econ. Model*. 90 (2020) 273–287. <https://doi.org/10.1016/j.econmod.2020.05.001>.
- [171] X. Wang, D. Chen, Z. Ren, Global warming and its implication to emission reduction strategies for residential buildings, *Build. Environ*. 46 (2011) 871–883. <https://doi.org/10.1016/j.buildenv.2010.10.016>.
- [172] J. Li, L. Yang, H. Long, Climatic impacts on energy consumption: Intensive and extensive margins, *Energy Econ*. 71 (2018) 332–343. <https://doi.org/10.1016/j.eneco.2018.03.010>.
- [173] W.Y. Fung, K.S. Lam, W.T. Hung, S.W. Pang, Y.L. Lee, Impact of urban temperature on energy consumption of Hong Kong, *Energy*. 31 (2006) 2623–2637. <https://doi.org/10.1016/j.energy.2005.12.009>.
- [174] M. Zhang, K. Zhang, W. Hu, B. Zhu, P. Wang, Y.M. Wei, Exploring the climatic impacts on residential electricity consumption in Jiangsu, China, *Energy Policy*. 140 (2020) 111398. <https://doi.org/10.1016/j.enpol.2020.111398>.
- [175] Y. Li, W.A. Pizer, L. Wu, Climate change and residential electricity consumption in the Yangtze River Delta, China, *Proc. Natl. Acad. Sci. U. S. A*. 116 (2019) 472–477. <https://doi.org/10.1073/pnas.1804667115>.
- [176] R.L. Hwang, C.Y. Lin, K.T. Huang, Spatial and temporal analysis of urban heat island and global warming on residential thermal comfort and cooling energy in Taiwan, *Energy Build*. 152 (2017) 804–812. <https://doi.org/10.1016/j.enbuild.2016.11.016>.
- [177] G. Falchetta, M.N. Mistry, The role of residential air circulation and cooling demand for electrification planning: Implications of climate change in sub-

- Saharan Africa, Energy Econ. (2021).
<https://doi.org/10.1016/j.eneco.2021.105307>.
- [178] A. Levesque, R.C. Pietzcker, L. Baumstark, S. De Stercke, A. Grübler, G. Luderer, How much energy will buildings consume in 2100? A global perspective within a scenario framework- SM, Energy. (2015).
- [179] E. Byers, M. Gidden, D. Leclere, J. Balkovic, P. Burek, K. Ebi, P. Greve, D. Grey, P. Havlik, A. Hillers, N. Johnson, T. Kahil, V. Krey, S. Langan, N. Nakicenovic, R. Novak, M. Obersteiner, S. Pachauri, A. Palazzo, S. Parkinson, N.D. Rao, J. Rogelj, Y. Satoh, Y. Wada, B. Willaarts, K. Riahi, Global exposure and vulnerability to multi-sector development and climate change hotspots, Environ. Res. Lett. 13 (2018). <https://doi.org/10.1088/1748-9326/aabf45>.
- [180] M. Isaac, D.P. van Vuuren, Modeling global residential sector energy demand for heating and air conditioning in the context of climate change, Energy Policy. 37 (2009) 507–521. <https://doi.org/10.1016/j.enpol.2008.09.051>.
- [181] L. Hollanda, V. Pina Dias, J. Dutra, A Microdata Approach to Household Electricity Demand in Brazil, Getulio Vargas Found. (2012) 1–16. <http://bibliotecadigital.fgv.br/ocs/index.php/sbe/EBE10/paper/viewFile/2221/1092>.
- [182] I.M. Trotter, T.F. Bolkesjø, J.G. Féres, L. Hollanda, Climate change and electricity demand in Brazil: A stochastic approach, Energy. 102 (2016) 596–604. <https://doi.org/10.1016/j.energy.2016.02.120>.
- [183] C. Hanck, M. Arnold, A. Gerber, M. Schmelzer, Introduction to Econometrics with R, 2019.
- [184] C.P. Adams, Learning Microeconometrics with R, First Edit, CRC Press, Oxon, 2021.
- [185] CETIC.BR, Bases de microdados, (2021). <https://cetic.br/pt/microdados/> (accessed February 4, 2021).
- [186] IBGE, Pesquisa de Orçamentos Familiares 2017 - 2018: Primeiros Resultados, Rio de Janeiro, 2019. <http://scholar.google.com/scholar?hl=en&btnG=Search&q=intitle:Pesquisa+de+Or?amentos+Familiares#0>.
- [187] IBGE, Pesquisa de Orçamentos Familiares - POF: O que é, (2021). <https://www.ibge.gov.br/estatisticas/sociais/protecao-social/9050-pesquisa-de-orcamentos-familiares.html?=&t=o-que-e> (accessed February 4, 2021).
- [188] IBGE, Pesquisa de Orçamentos Familiares - POF: Microdados, (2021).
- [189] C. Grottera, C. Barbier, A. Sanches-Pereira, M.W. de Abreu, C. Uchôa, L.G. Tudeschini, J.M. Cayla, F. Nadaud, A.O. Pereira, C. Cohen, S.T. Coelho, Linking electricity consumption of home appliances and standard of living: A comparison

- between Brazilian and French households, *Renew. Sustain. Energy Rev.* 94 (2018) 877–888. <https://doi.org/10.1016/j.rser.2018.06.063>.
- [190] C.K.B. Krishnamurthy, B. Kriström, A cross-country analysis of residential electricity demand in 11 OECD-countries, *Resour. Energy Econ.* 39 (2015) 68–88. <https://doi.org/10.1016/j.reseneeco.2014.12.002>.
- [191] S. Silva, I. Soares, C. Pinho, Electricity demand response to price changes: The Portuguese case taking into account income differences, *Energy Econ.* 65 (2017) 335–342. <https://doi.org/10.1016/j.eneco.2017.05.018>.
- [192] World Bank, How does the World Bank classify countries?, (2017). <https://datahelpdesk.worldbank.org/knowledgebase/articles/378834-how-does-the-world-bank-classify-countries> (accessed December 6, 2017).
- [193] C. da C.L. Achão, Análise de estrutura de consumo de energia pelo setor residencial brasileiro, Universidade Federal do Rio de Janeiro, 2003.
- [194] F. Pavanello, E. De Cian, M. Davide, T. Cruz, P. Borges, D. Jagu, S. Renner, R. Schaeffer, A.F.P. Lucena, Air-Conditioning and the Adaptation Cooling Deficit in Emerging Economies, *Nat. Commun.* (under Rev. (n.d.)).
- [195] ASHRAE Handbook, Fundamentals (I-P Edition), Inch-Pound, American Society of Heating, Refrigerating and Air-Conditioning Engineers, 2005. <https://shop.iccsafe.org/media/wysiwyg/material/8950P203-toc.pdf>.
- [196] T. Atalla, S. Gualdi, A. Lanza, A global degree days database for energy-related applications, *Energy*. 143 (2018) 1048–1055. <https://doi.org/10.1016/j.energy.2017.10.134>.
- [197] M.N. Mistry, Historical global gridded degree-days: A high-spatial resolution database of CDD and HDD, *Geosci. Data J.* 6 (2019) 214–221. <https://doi.org/10.1002/gdj3.83>.
- [198] Y. Petri, K. Caldeira, Impacts of global warming on residential heating and cooling degree-days in the United States, *Sci. Rep.* 5 (2015) 1–14. <https://doi.org/10.1038/srep12427>.
- [199] S.C. Sherwood, M. Huber, An adaptability limit to climate change due to heat stress, *Proc. Natl. Acad. Sci. U. S. A.* 107 (2010) 9552–9555. <https://doi.org/10.1073/pnas.0913352107>.
- [200] L. Guan, Preparation of future weather data to study the impact of climate change on buildings, *Build. Environ.* 44 (2009) 793–800. <https://doi.org/10.1016/j.buildenv.2008.05.021>.
- [201] G. Krese, M. Prek, V. Butala, Analysis of building electric energy consumption data using an improved cooling degree day method, *J. Mech. Eng.* 58 (2012) 107–114. <https://doi.org/10.5545/sv-jme.2011.160>.

- [202] M.N. Mistry, A high-resolution global gridded historical dataset of climate extreme indices, *Data*. 4 (2019) 1–11. <https://doi.org/10.3390/data4010041>.
- [203] M. Rodell, P.R. Houser, U. Jambor, J. Gottschalck, K. Mitchell, C.J. Meng, K. Arsenault, B. Cosgrove, J. Radakovich, M. Bosilovich, J.K. Entin, J.P. Walker, D. Lohmann, D. Toll, The Global Land Data Assimilation System, *Bull. Am. Meteorol. Soc.* 85 (2004) 381–394. <https://doi.org/10.1175/BAMS-85-3-381>.
- [204] A. Deaton, J. Muellbauer, *Economics and consumer behavior*, First Edit, Cambridge University Press, Cambridge, 1980. <https://b-ok.lat/book/2513722/d1696b>.
- [205] H.R. Varian, *Microeconomics analysis*, Third Edit, Norton & Company, 1992. <https://b-ok.lat/book/466026/ac5bba>.
- [206] M. de F.S.R. Arthur, C.A. Bond, B. Willson, Estimation of elasticities for domestic energy demand in Mozambique, *Energy Econ.* 34 (2012) 398–409. <https://doi.org/10.1016/j.eneco.2011.08.006>.
- [207] R. Halvorsen, Residential Demand for Electric Energy, *Rev. Econ. Stat.* 57 (1975) 12–18. <https://doi.org/10.2307/1937858>.
- [208] J. de A. Cabral, M.V. de Freitas Cabral, A.O. Pereira Júnior, Elasticity estimation and forecasting: An analysis of residential electricity demand in Brazil, *Util. Policy.* 66 (2020) 101108. <https://doi.org/10.1016/j.jup.2020.101108>.
- [209] T.S. Breusch, A.R. Pagan, A Simple Test for Heteroscedasticity and Random Coefficient Variation, *Econometrica.* 47 (1979) 1287–1294. <https://sci-hub.se/10.2307/1911963>.
- [210] A. Wald, Tests of Statistical Hypotheses Concerning Several Parameters When the Number of Observations, *Trans. Am. Math. Soc.* 54 (1943) 426–482. <https://www.pp.rhul.ac.uk/~cowan/stat/wald1943.pdf>.
- [211] P.J. Huber, *Robust Statistical Procedures*, Second Edi, CBMS-NSF regional conference series in applied mathematics ;, Bayreuth, 1996. <https://b-ok.org/book/687006/ea17c1/>.
- [212] S. Heritier, E. Cantoni, S. Copt, M.-P. Victoria-Feser, *Robust Methods in Biostatistics*, First Edit, John Wiley & Sons Ltd Registered, Chichester, 2009. http://books.google.com/books?id=a8bUjWJsTx8C&pg=PA110&dq=bootstrapping+techniques&hl=en&ei=Pd-jTPmsF5SR4Ab-6LSKDQ&sa=X&oi=book_result&ct=result&resnum=6&ved=0CEAQ6AEwBTgU#v=onepage&q=bootstrapping+techniques&f=false.
- [213] N.B. Barbieri, *Estimação Robusta para o Modelo de Regressão Logística*, Universidade Federal do Rio Grande do Sul, 2012. <https://www.lume.ufrgs.br/bitstream/handle/10183/66470/000871732.pdf?sequence=1>.

- [214] J.W. Tukey, *Eploratory Data Analysis*, Addison-Wesley Publishing Company, 1977. <https://b-ok.org/book/1080770/7342f1>.
- [215] F.R. Hampel, The Influence Curve and its Role in Robust Estimation, *J. Am. Stat. Assoc.* 69 (1974) 383–393. <https://doi.org/10.1080/01621459.1974.10482962>.
- [216] D.M. Hawkins, *Identification of Outliers*, First Edit, Chapman & Hall, London, 1980. <https://doi.org/10.2307/2530182>.
- [217] H. Fell, S. Li, A. Paul, A new look at residential electricity demand using household expenditure data, *Int. J. Ind. Organ.* 33 (2014) 37–47. <https://doi.org/10.1016/j.ijindorg.2014.02.001>.
- [218] A. Alberini, M. Filippini, Response of residential electricity demand to price: The effect of measurement error, *Energy Econ.* 33 (2011) 889–895. <https://doi.org/10.1016/j.eneco.2011.03.009>.
- [219] S. Borenstein, To what electricity price do consumers respond? Residential demand elasticity under increasing-block pricing, Prelim. Draft April. (2009) 1–37. http://faculty.haas.berkeley.edu/borenste/download/NBER_SI_2009.pdf.
- [220] A. Alberini, W. Gans, D. Velez-lopez, Residential consumption of gas and electricity in the U . S . : The role of prices and income, *Energy Econ.* 33 (2011) 870–881. <https://doi.org/10.1016/j.eneco.2011.01.015>.
- [221] P.C. Reiss, M.W. White, Household Electricity Demand, Revisited, *Rev. Econ. Stud.* 72 (2005) 853–883. <https://doi.org/10.1111/0034-6527.00354>.
- [222] ANEEL, Ranking nacional de tarifas residenciais (Grupo B1), (2017). <http://www.aneel.gov.br/ranking-das-tarifas> (accessed May 8, 2017).
- [223] ANEEL, Ranking das Tarifas, (2021).
- [224] ANEEL, Tarifa Social de Energia Elétrica - TSEE, (2021).
- [225] ANEEL, Indicadores da Distribuição, (2021). <https://www.aneel.gov.br/indicadores-da-distribuicao> (accessed February 7, 2021).
- [226] ANEEL, Bandeiras Tarifárias, (2021). <https://www.aneel.gov.br/bandeiras-tarifarias> (accessed February 7, 2021).
- [227] ANEEL, Tarifa Branca, (2021). <https://www.aneel.gov.br/tarifa-branca> (accessed February 7, 2021).
- [228] ANEEL, Postos Tarifários, (2021).
- [229] EPE, Consumo Mensal de Energia Elétrica por Classe (regiões e subsistemas), (2021). <https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/Consumo-mensal-de-energia-eletrica-por-classe-regioes-e->

subsistemas (accessed May 31, 2021).

- [230] P.B.D.S. Bezerra, C.L. Callegari, A. Ribas, A.F.P. Lucena, J. Portugal-Pereira, A. Koberle, A. Szklo, R. Schaeffer, The power of light: Socio-economic and environmental implications of a rural electrification program in Brazil, *Environ. Res. Lett.* 12 (2017). <https://doi.org/10.1088/1748-9326/aa7bdd>.
- [231] Presidência da República, DECRETO Nº 4.873, DE 11 DE NOVEMBRO DE 2003, (2003). http://www.planalto.gov.br/CCIVIL_03/decreto/2003/D4873.htm (accessed February 23, 2021).
- [232] IPEA, Bolsa Família Program : a decade of social inclusion in Brazil (Executive Summary), Brasília, 2014. https://www.ipea.gov.br/portal/images/stories/PDFs/140321_pbf_sumex_ingles.pdf.
- [233] J.A. Rosas-Flores, D. Rosas-Flores, D.M. Gálvez, Saturation, energy consumption, CO2 emission and energy efficiency from urban and rural households appliances in Mexico, *Energy Build.* 43 (2011) 10–18. <https://doi.org/10.1016/j.enbuild.2010.08.020>.
- [234] A.P.M. Peixoto, D.C. de Holanda, M.Q.B. Chaves, Caderno 1: Análise de custos referenciais - qualificação da inserção urbana, 2017. http://www.minhacasaminhavida.gov.br/images/stories/ArquivosSNH/ArquivosPDF/Publicacoes/caderno1_analise_de_custos_referenciais.pdf.
- [235] Governo Federal, Programa Minha Casa, Minha Vida (MCMV), (2020). <https://www.gov.br/mdr/pt-br/assuntos/habitacao/minha-casa-minha-vida/programa-minha-casa-minha-vida-mcmv> (accessed May 25, 2021).
- [236] CAIXA, Minha Casa, Minha Vida, (2021). <https://www.caixa.gov.br/voce/habitacao/minha-casa-minha-vida/paginas/default.aspx> (accessed May 25, 2021).
- [237] Fundação João Pinheiro, Déficit habitacional no Brasil 2015, Belo Horizonte, 2018. <http://www.fjp.mg.gov.br/index.php/docman/cei/559-deficit-habitacional-2011-2012/file>.
- [238] World Bank, PovcalNet, (2021). <http://iresearch.worldbank.org/PovcalNet/povOnDemand.aspx> (accessed June 1, 2021).
- [239] A.F.P. de Lucena, B. Machado, E.M.V. Arroyo, M.F.C. Rodriguez, M.C. e S. Chagas, R. Garaffa, R.F.C. Miranda, R.M. de A. Neto, R.E.G. Mahecha, T.B. Cruz, Modelagem setorial de opções de baixo carbono para o setor de edificações, in: Opções Mitigação Emiss. GEE Em Setores-Chave Do Bras., MCTI, ONU Meio Ambiente, Brasília, 2017. https://antigo.mctic.gov.br/mctic/export/sites/institucional/ciencia/SEPED/clima/arquivos/projeto_opcoes_mitigacao/publicacoes/Setor-Edificacoes.pdf.

- [240] R.E. González-Mahecha, A.F.P. Lucena, R. Garaffa, R.F.C. Miranda, M. Chávez-Rodriguez, T. Cruz, P. Bezerra, R. Rathmann, Greenhouse gas mitigation potential and abatement costs in the Brazilian residential sector, *Energy Build.* 184 (2019). <https://doi.org/10.1016/j.enbuild.2018.11.039>.
- [241] R. Kowsari, H. Zerriffi, Three dimensional energy profile: A conceptual framework for assessing household energy use., *Energy Policy.* 39 (2011) 7505–7517. <https://doi.org/10.1016/j.enpol.2011.06.030>.
- [242] B. Van Der Kroon, R. Brouwer, P.J.H. Van Beukering, The energy ladder: Theoretical myth or empirical truth? Results from a meta-analysis, *Renew. Sustain. Energy Rev.* 20 (2013) 504–513. <https://doi.org/10.1016/j.rser.2012.11.045>.
- [243] I. Bisaga, P. Parikh, To climb or not to climb? Investigating energy use behaviour among Solar Home System adopters through energy ladder and social practice lens, *Energy Res. Soc. Sci.* 44 (2018) 293–303. <https://doi.org/10.1016/j.erss.2018.05.019>.
- [244] E. Shove, M. Pantzar, M. Watson, *The Dynamics of Social Practice: Everyday Life and How it Changes*, (2012). <https://doi.org/10.4135/9781446250655>.
- [245] T. Cruz, R. Schaeffer, A.F.P. Lucena, S. Melo, R. Dutra, Solar water heating technical-economic potential in the household sector in Brazil, *Renew. Energy.* 146 (2020). <https://doi.org/10.1016/j.renene.2019.06.085>.
- [246] EPE, *Série Estudos da Demanda de energia - Nota Técnica DEA 13/15: Demanda de Energia 2050*, Rio de Janeiro, 2016. [https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-227/topico-458/DEA 13-15 Demanda de Energia 2050.pdf](https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-227/topico-458/DEA%2013-15%20Demanda%20de%20Energia%202050.pdf).
- [247] A. Mazzone, R. Rathmann, A.F.P. Lucena, R. Schaeffer, *Energy Safety Net - Brazil Case Study*, 2020. <https://www.seforall.org/system/files/2020-03/ESN-Brazil-SEforAL.pdf>.
- [248] S.T. Coelho, A. Sanches-Pereira, L.G. Tudeschini, J. Goldemberg, The energy transition history of fuelwood replacement for liquefied petroleum gas in Brazilian households from 1920 to 2016, *Energy Policy.* 123 (2018) 41–52. <https://doi.org/10.1016/J.ENPOL.2018.08.041>.
- [249] K.R. Smith, J.M. Samet, I. Romieu, N. Bruce, Indoor air pollution in developing countries and acute lower respiratory infections in children, *Thorax.* 55 (2000) 518–532. <https://doi.org/10.1136/thorax.55.6.518>.
- [250] K.H. Kim, S.A. Jahan, E. Kabir, A review of diseases associated with household air pollution due to the use of biomass fuels, *J. Hazard. Mater.* 192 (2011) 425–431. <https://doi.org/10.1016/j.jhazmat.2011.05.087>.
- [251] N. Bruce, M. Dherani, R. Liu, H.D. Hosgood, A. Sapkota, K.R. Smith, K. Straif, Q. Lan, D. Pope, Does household use of biomass fuel cause lung cancer? A systematic review and evaluation of the evidence for the GBD 2010 study, *Thorax.*

- 70 (2015) 433–441. <https://doi.org/10.1136/thoraxjnl-2014-206625>.
- [252] L.G. Hooper, Y. Dieye, A. Ndiaye, A. Diallo, C.S. Sack, V.S. Fan, K.M. Neuzil, J.R.O. Id, Traditional cooking practices and preferences for stove features among women in rural Senegal : Informing improved cookstove design and interventions, *PLoS One*. (2018) 1–15. <https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0206822>.
- [253] ANP, CSA: SLP (Sistema de Levantamento de Preços), (2021). <https://preco.anp.gov.br/> (accessed August 3, 2021).
- [254] M.L. Corton, A. Zimmermann, M.A. Phillips, The low cost of quality improvements in the electricity distribution sector of Brazil, *Energy Policy*. 97 (2016) 485–493. <https://doi.org/10.1016/j.enpol.2016.07.052>.
- [255] X. Zhu, L. Li, K. Zhou, X. Zhang, S. Yang, A meta-analysis on the price elasticity and income elasticity of residential electricity demand, *J. Clean. Prod.* 201 (2018) 169–177. <https://doi.org/10.1016/j.jclepro.2018.08.027>.
- [256] M. Miller, A. Alberini, Sensitivity of price elasticity of demand to aggregation, unobserved heterogeneity, price trends, and price endogeneity: Evidence from U.S. Data, *Energy Policy*. 97 (2016) 235–249. <https://doi.org/10.1016/j.enpol.2016.07.031>.
- [257] R. Halvorsen, R. Palmquist, The Interpretation of Dummy Variables in Semilogarithmic Equations, *Am. Econ. Rev.* 70 (1980) 474–475. <https://econpapers.repec.org/RePEc:aea:aecrev:v:70:y:1980:i:3:p:474-75>.
- [258] G.Y. Yun, K. Steemers, Behavioural, physical and socio-economic factors in household cooling energy consumption, *Appl. Energy*. 88 (2011) 2191–2200. <https://doi.org/10.1016/j.apenergy.2011.01.010>.
- [259] B.C. O'Neill, E. Kriegler, K.L. Ebi, E. Kemp-Benedict, K. Riahi, D.S. Rothman, B.J. van Ruijven, D.P. van Vuuren, J. Birkmann, K. Kok, M. Levy, W. Solecki, The roads ahead: Narratives for shared socioeconomic pathways describing world futures in the 21st century, *Glob. Environ. Chang.* 42 (2017) 169–180. <https://doi.org/https://doi.org/10.1016/j.gloenvcha.2015.01.004>.
- [260] K. Riahi, D.P. Van Vuuren, E. Kriegler, J. Edmonds, B.C.O. Neill, S. Fujimori, N. Bauer, K. Calvin, R. Dellink, O. Fricko, W. Lutz, A. Popp, J. Crespo, S. Kc, M. Leimbach, L. Jiang, T. Kram, S. Rao, J. Emmerling, K. Ebi, T. Hasegawa, P. Havlik, F. Humpenöder, L. Aleluia, D. Silva, S. Smith, E. Stehfest, V. Bosetti, J. Eom, D. Gernaat, T. Masui, J. Rogelj, J. Stre, L. Drouet, V. Krey, G. Luderer, M. Harmsen, K. Takahashi, L. Baumstark, J.C. Doelman, M. Kainuma, Z. Klimont, G. Marangoni, H. Lotze-campen, M. Obersteiner, A. Tabeau, M. Tavoni, The Shared Socioeconomic Pathways and their energy , land use , and greenhouse gas emissions implications : An overview, *Glob. Environ. Chang.* 42 (2017) 153–168. <https://doi.org/10.1016/j.gloenvcha.2016.05.009>.
- [261] R. Garaffa, B.S.L. Cunha, T. Cruz, P. Bezerra, A.F.P. Lucena, A.C. Gurgel,

- Distributional effects of carbon pricing in Brazil under the Paris Agreement, *Energy Econ.* 101 (2021) 105396. <https://doi.org/10.1016/j.eneco.2021.105396>.
- [262] IIASA, RCP Database (version 2.0), (2021). <https://tntcat.iiasa.ac.at/RcpDb/dsd?Action=htmlpage&page=welcome> (accessed July 11, 2021).
- [263] A.M. Thomson, K. V Calvin, S.J. Smith, G.P. Kyle, A. Volke, P. Patel, S. Delgado-arias, B. Bond-lamberty, M.A. Wise, L.E. Clarke, J.A. Edmonds, RCP4 . 5 : a pathway for stabilization of radiative forcing by 2100, (2011) 77–94. <https://doi.org/10.1007/s10584-011-0151-4>.
- [264] K. Riahi, S. Rao, V. Krey, C. Cho, V. Chirkov, G. Fischer, G. Kindermann, N. Nakicenovic, P. Rafaj, RCP 8.5-A scenario of comparatively high greenhouse gas emissions, *Clim. Change.* 109 (2011) 33–57. <https://doi.org/10.1007/s10584-011-0149-y>.
- [265] J.A. Dubin, D.L. Mcfadden, L. Mcfadden, *An Econometric Analysis of Residential Electric Appliance Holdings and Consumption* Published by : The Econometric Society Stable URL : <http://www.jstor.org/stable/1911493> Your use of the JSTOR archive indicates your acceptance of JSTOR ' s Terms and Condi, 52 (2009) 345–362.
- [266] M. Browning, A. Deaton, M. Irish, *A Profitable Approach to Labor Supply and Commodity Demands over the Life-Cycle*, *Econometrica.* 53 (1985) 503–542. http://www.princeton.edu/~deaton/downloads/A_Profitable_Approach_to_Labor_Supply_and_Commodity_Demands.pdf.
- [267] A. Deaton, Panel data from time series of cross-sections, *J. Econom.* 30 (1985) 109–126. [https://doi.org/10.1016/0304-4076\(85\)90134-4](https://doi.org/10.1016/0304-4076(85)90134-4).
- [268] A. Mazzone, T. Cruz, P. Bezerra, R. Rathmann, A.F.P. Lucena, R. Schaeffer, A. Szklo, A multidimensionalidade da pobreza no Brasil: um olhar sobre as políticas públicas e desafios da pobreza energética, *RBE.* 27 (2021). <https://doi.org/10.47168/rbe.v27i3.644>.
- [269] M.G. Prina, G. Manzolini, D. Moser, B. Nastasi, W. Sparber, Classification and challenges of bottom-up energy system models - A review, *Renew. Sustain. Energy Rev.* 129 (2020) 109917. <https://doi.org/10.1016/j.rser.2020.109917>.
- [270] B.K. Sovacoo, M.H. Dworkin, *Global Energy Justice: Problems, Principles, and Practices*, Cambridge University Press, Cambridge, 2014. <https://doi.org/10.1017/CBO9781107323605>.
- [271] B.K. Sovacool, D.J. Hess, R. Cantoni, Energy transitions from the cradle to the grave: A meta-theoretical framework integrating responsible innovation, social practices, and energy justice, *Energy Res. Soc. Sci.* 75 (2021). <https://doi.org/10.1016/j.erss.2021.102027>.
- [272] ODM Brasil, *Os Objetivos de Desenvolvimento do Milênio*, (2021).

- <http://www.odmbrasil.gov.br/os-objetivos-de-desenvolvimento-do-milenio>
(accessed April 27, 2021).
- [273] CAIXA, Bolsa Família, (2021). <https://www.caixa.gov.br/programas-sociais/bolsa-familia/paginas/default.aspx> (accessed February 23, 2021).
- [274] W. Belik, Estudo sobre a cadeia de alimentos, 2020. https://www.imaflora.org/public/media/biblioteca/estudocadeiaalimentos__14.10.2020.pdf.
- [275] L. Ji, G.B. Senay, J.P. Verdin, Evaluation of the Global Land Data Assimilation System (GLDAS) air temperature data products, *J. Hydrometeorol.* 16 (2015) 2463–2480. <https://doi.org/10.1175/JHM-D-14-0230.1>.
- [276] G.S. Becker, A theory of the allocation of time, *Econ. J.* 75 (1965) 493–517.
- [277] J.A. Dubin, Consumer durable choice and the demand for electricity, ELSEVIER SCIENCE PUBLISHERS B.V., Amsterdam, 1985. <https://doi.org/10.1016/b978-0-444-87766-6.70019-7>.
- [278] G. Flaig, Household production and the short- and long-run demand for electricity, *Energy Econ.* 12 (1990) 116–121. [https://doi.org/10.1016/0140-9883\(90\)90045-H](https://doi.org/10.1016/0140-9883(90)90045-H).
- [279] K.R. Smith, N. Bruce, K. Balakrishnan, H. Adair-Rohani, J. Balmes, Z. Chafe, M. Dherani, H.D. Hosgood, S. Mehta, D. Pope, E. Rehfuess, Millions dead: How do we know and what does it mean? Methods used in the comparative risk assessment of household air pollution, *Annu. Rev. Public Health.* 35 (2014) 185–206. <https://doi.org/10.1146/annurev-publhealth-032013-182356>.
- [280] WHO, Air pollution, (2021).
- [281] N. Meghanathan, Assortativity Analysis of Real-World Network Graphs based on Centrality Metrics, *Comput. Inf. Sci.* 9 (2016) 7. <https://doi.org/10.5539/cis.v9n3p7>.
- [282] D. van der Merwe, R. Gehring, J.L. Buur, Chapter 8 - Toxicokinetics in Veterinary Toxicology, in: R.C.B.T.-V.T. (Third E. Gupta (Ed.), Academic Press, 2018: pp. 133–143. <https://doi.org/https://doi.org/10.1016/B978-0-12-811410-0.00008-8>.
- [283] E. Bona, P.H. Março, P. Valderrama, Chapter 4 - Chemometrics Applied to Food Control, in: A.M. Holban, A.M.B.T.-F.C. and B. Grumezescu (Eds.), *Handb. Food Bioeng.*, Academic Press, 2018: pp. 105–133. <https://doi.org/https://doi.org/10.1016/B978-0-12-811445-2.00004-0>.
- [284] D.P. Van Vuuren, M.G.J. Den Elzen, P.L. Lucas, B. Eickhout, B.J. Strengers, B. Van Ruijven, S. Wonink, R. Van Houdt, Stabilizing greenhouse gas concentrations at low levels: An assessment of reduction strategies and costs, *Clim. Change.* 81 (2007) 119–159. <https://doi.org/10.1007/s10584-006-9172-9>.

- [285] L.E. Clarke, J.A. Edmonds, H.D. Jacoby, H.M. Pitcher, J.M. Reilly, R.G. Richels, Scenarios of greenhouse gas emissions and atmospheric concentrations, 2007.
- [286] et al Fujino J, Nair R, Kainuma M, Multi-gas Mitigation Analysis on Stabilization Scenarios Using Aim Global Model, *Energy J.* 27 (2006) 343–353. <http://www.jstor.org/stable/23297089>.
- [287] K. Riahi, A. Grübler, N. Nakicenovic, Scenarios of long-term socio-economic and environmental development under climate stabilization, *Technol. Forecast. Soc. Change.* 74 (2007) 887–935. <https://doi.org/10.1016/j.techfore.2006.05.026>.

APÊNDICE

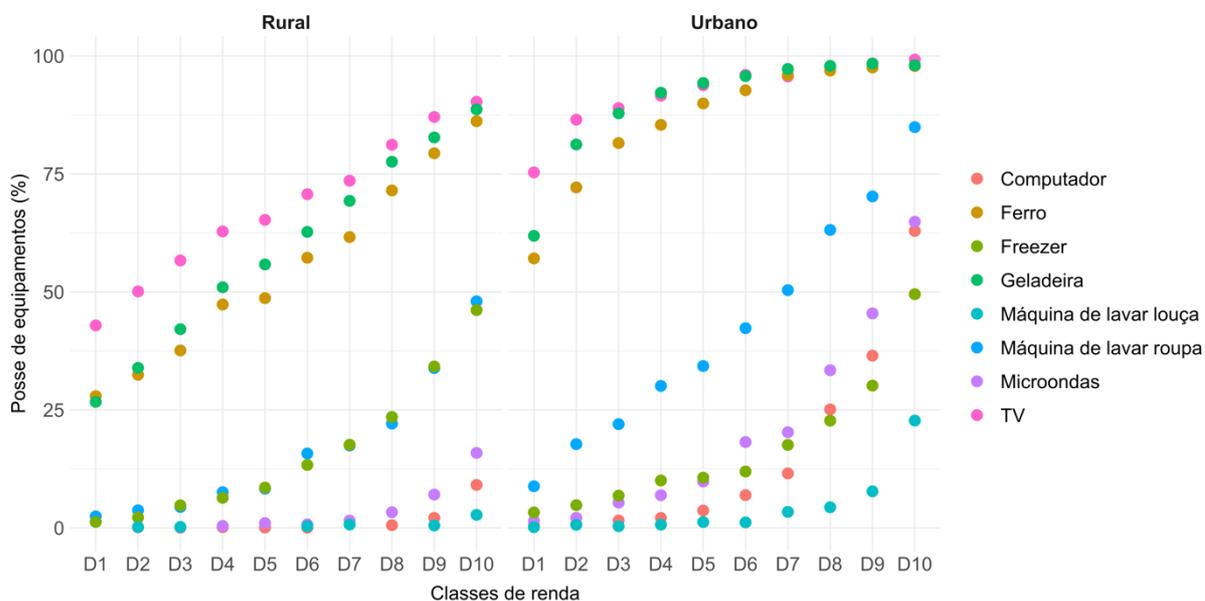


Figura 24.A. Posse de eletrodomésticos no Brasil por grupos socioeconômicos de acordo com POF (2002-2003)

Fonte: Elaboração própria com base em IBGE [188]

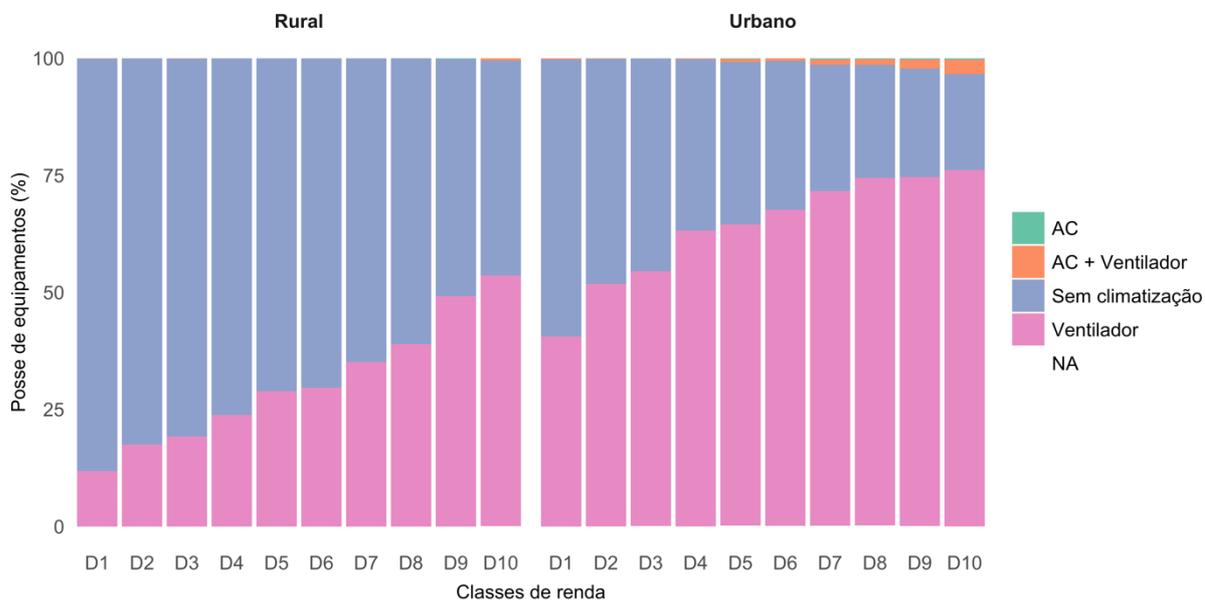


Figura 25.A. Tecnologias de resfriamento ambiente no Brasil por grupos socioeconômicos de acordo com POF (2002-2003)

Fonte: Elaboração própria com base em IBGE [188]

Tabela 17.A. Sumário de regressão da POF (2008-2009) – Especificação do modelo e escolha de variáveis controle

	Modelo (1)	Modelo (2)	Modelo (3)	Modelo (4)	Modelo (5)	Modelo (6)
Ln Renda	0,122*** (0,005)	0,122*** (0,005)	0,123*** (0,005)	0,120*** (0,005)	0,120*** (0,005)	0,050*** (0,014)
Ln Preço _{OE}	-0,015* (0,008)	-0,015* (0,008)	-0,015* (0,008)	-0,015* (0,008)	-0,014* (0,008)	-0,014* (0,008)
CDD _{wb} médio	0,0003*** (0,00002)	0,0003*** (0,00002)	0,0003*** (0,00002)	0,0003*** (0,00002)	0,0003*** (0,00002)	0,0003*** (0,00002)
Urbano (1 = Urbano)	0,026*** (0,008)	0,026*** (0,008)	0,041*** (0,008)	0,028*** (0,008)	0,029*** (0,008)	0,073*** (0,011)
Norte	-0,101*** (0,013)	-0,101*** (0,013)	-0,102*** (0,013)	-0,101*** (0,013)	-0,102*** (0,013)	-0,102*** (0,013)
Nordeste	-0,257*** (0,009)	-0,257*** (0,009)	-0,257*** (0,009)	-0,258*** (0,009)	-0,257*** (0,009)	-0,258*** (0,009)
Sul	0,141*** (0,011)	0,140*** (0,011)	0,136*** (0,011)	0,141*** (0,011)	0,138*** (0,011)	0,140*** (0,011)
Sudeste	0,027*** (0,009)	0,026*** (0,009)	0,041*** (0,009)	0,026*** (0,009)	0,024*** (0,009)	0,025*** (0,009)
Residência própria (1 = Próprio)	-0,007 (0,007)	-	-	-	-	-
Índice da <i>household</i> (1 = Alta qualidade)	0,051*** (0,006)	0,051*** (0,006)	-	0,052*** (0,006)	0,052*** (0,006)	0,053*** (0,006)
Tipo de domicílio (1 = Casa)	0,003 (0,010)	0,003 (0,010)	-0,006 (0,010)	0,002 (0,010)	0,002 (0,010)	0,006 (0,010)
Nº de cômodos	0,022*** (0,002)	0,022*** (0,002)	0,022*** (0,002)	0,022*** (0,002)	0,022*** (0,002)	0,021*** (0,002)
Membros da família	0,061*** (0,002)	0,061*** (0,002)	0,061*** (0,002)	0,061*** (0,002)	0,061*** (0,002)	0,060*** (0,002)
Sexo (1 = Masculino)	-0,015*** (0,006)	-0,015*** (0,006)	-0,017*** (0,006)	-	-	-
Raça (1 = Branco)	0,028*** (0,006)	0,028*** (0,006)	0,028*** (0,006)	0,028*** (0,006)	0,028*** (0,006)	0,027*** (0,006)
Idade	0,002*** (0,0002)	0,002*** (0,0002)	0,002*** (0,0002)	0,002*** (0,0002)	0,002*** (0,0002)	0,002*** (0,0002)
Anos de educação	0,011*** (0,001)	0,011*** (0,001)	0,012*** (0,001)	0,012*** (0,001)	0,012*** (0,001)	0,011*** (0,001)
AC	0,227*** (0,011)	0,227*** (0,011)	0,225*** (0,011)	0,227*** (0,011)	0,227*** (0,011)	0,221*** (0,011)
Ventilador	0,047*** (0,006)	0,047*** (0,006)	0,046*** (0,006)	0,047*** (0,006)	0,047*** (0,006)	0,048*** (0,006)
Computador	0,140*** (0,008)	0,140*** (0,008)	0,143*** (0,008)	0,140*** (0,008)	0,140*** (0,008)	0,135*** (0,008)
Micro-ondas	0,066*** (0,008)	0,066*** (0,008)	0,069*** (0,008)	0,066*** (0,008)	0,067*** (0,008)	0,064*** (0,008)
TV	0,051*** (0,012)	0,051*** (0,012)	0,051*** (0,012)	0,051*** (0,012)	0,051*** (0,012)	0,051*** (0,012)
Geladeira	0,290*** (0,012)	0,290*** (0,012)	0,290*** (0,012)	0,290*** (0,012)	0,290*** (0,012)	0,294*** (0,012)
Freezer	0,243*** (0,009)	0,242*** (0,009)	0,240*** (0,009)	0,242*** (0,009)	0,241*** (0,009)	0,236*** (0,009)
Máquina de lavar roupa	0,081*** (0,007)	0,081*** (0,007)	0,082*** (0,007)	0,081*** (0,007)	0,081*** (0,007)	0,080*** (0,007)
Ferro	0,073*** (0,007)	0,073*** (0,007)	0,073*** (0,007)	0,073*** (0,007)	0,072*** (0,007)	0,074*** (0,007)
Rádio	-0,018*** (0,006)	-0,018*** (0,006)	-0,019*** (0,006)	-0,019*** (0,006)	-	-
Chuveiro Elétrico	0,104*** (0,008)	0,104*** (0,008)	0,107*** (0,008)	0,103*** (0,008)	0,103*** (0,008)	0,102*** (0,008)
Máquina de lavar louça	0,026 (0,025)	0,026 (0,025)	0,027 (0,025)	0,026 (0,025)	0,026 (0,025)	0,025 (0,025)
Aspirador	0,011 (0,011)	0,010 (0,011)	0,010 (0,011)	0,010 (0,011)	0,009 (0,011)	0,004 (0,011)
Ln Renda X Decil 2	-	-	-	-	-	0,003** (0,001)
Ln Renda X Decil 3	-	-	-	-	-	0,003 (0,002)
Ln Renda X Decil 4	-	-	-	-	-	0,007*** (0,002)
Ln Renda X Decil 5	-	-	-	-	-	0,007*** (0,002)
Ln Renda X Decil 6	-	-	-	-	-	0,009*** (0,002)
Ln Renda X Decil 7	-	-	-	-	-	0,011*** (0,003)
Ln Renda X Decil 8	-	-	-	-	-	0,012*** (0,003)
Ln Renda X Decil 9	-	-	-	-	-	0,016*** (0,003)
Ln Renda X Decil 10	-	-	-	-	-	0,021*** (0,004)
Intercepto	4,786*** (0,046)	4,787*** (0,046)	4,781*** (0,046)	4,786*** (0,046)	4,785*** (0,046)	5,397*** (0,118)
Observações	48.732	48.732	48.732	48.732	48.732	48.732
R ²	0,408	0,408	0,408	0,408	0,408	0,409
R ² Ajustado	0,408	0,408	0,407	0,408	0,408	0,409

Nota: Níveis de significância (p-valor), * < 0,10; *** < 0,05; **** < 0,01; resultados com erros padrão robustos

Fonte: Elaboração própria

Tabela 18.A. Sumário de regressão da POF (2002-2003) – Especificação do modelo e escolha de variáveis controle

	Modelo (1)	Modelo (2)	Modelo (3)	Modelo (4)	Modelo (5)	Modelo (6)	Modelo (7)
Ln Renda	0,154*** (0,005)	0,153*** (0,005)	0,153*** (0,005)	0,153*** (0,005)	0,153*** (0,005)	0,153*** (0,005)	0,034** (0,017)
Ln Preço _E	0,214*** (0,010)	0,215*** (0,010)	0,215*** (0,010)	0,215*** (0,010)	0,215*** (0,010)	0,215*** (0,010)	0,214*** (0,010)
CDD _{wb} médio	0,0004*** (0,00003)						
Urbano (1 = Urbano)	0,065*** (0,009)	0,066*** (0,009)	0,066*** (0,009)	0,067*** (0,009)	0,067*** (0,009)	0,067*** (0,009)	0,131*** (0,012)
Norte	-0,142*** (0,015)	-0,144*** (0,015)	-0,144*** (0,015)	-0,143*** (0,015)	-0,143*** (0,015)	-0,143*** (0,015)	-0,146*** (0,015)
Nordeste	-0,344*** (0,009)	-0,346*** (0,009)	-0,346*** (0,009)	-0,346*** (0,009)	-0,346*** (0,009)	-0,346*** (0,009)	-0,348*** (0,009)
Sul	0,010 (0,011)	0,008 (0,011)	0,008 (0,011)	0,006 (0,011)	0,006 (0,011)	0,006 (0,011)	0,005 (0,011)
Sudeste	-0,069*** (0,010)	-0,070*** (0,010)	-0,070*** (0,010)	-0,072*** (0,010)	-0,072*** (0,010)	-0,072*** (0,010)	-0,074*** (0,010)
Residência própria (1 = Próprio)	-0,029*** (0,007)	-	-	-	-	-	-
Tipo de domicílio (1 = Casa)	-0,007 (0,012)	-0,010 (0,012)	-0,010 (0,012)	-0,010 (0,012)	-0,010 (0,012)	-0,010 (0,012)	-0,005 (0,012)
Nº de cômodos	0,025*** (0,002)	0,025*** (0,002)	0,025*** (0,002)	0,025*** (0,002)	0,025*** (0,002)	0,025*** (0,002)	0,024*** (0,002)
Membros da família	0,033*** (0,002)	0,033*** (0,002)	0,033*** (0,002)	0,033*** (0,002)	0,033*** (0,002)	0,033*** (0,002)	0,033*** (0,002)
Sexo (1 = Masculino)	-0,0005 (0,007)	-0,001 (0,007)	-	-	-	-	-
Raça (1 = Branco)	0,039*** (0,007)	0,039*** (0,007)	0,039*** (0,007)	0,040*** (0,007)	0,040*** (0,007)	0,040*** (0,007)	0,038*** (0,007)
Idade	0,001*** (0,0002)						
Anos de educação	0,010*** (0,001)	0,010*** (0,001)	0,010*** (0,001)	0,010*** (0,001)	0,010*** (0,001)	0,010*** (0,001)	0,010*** (0,001)
AC	0,257*** (0,037)	0,258*** (0,037)	0,258*** (0,037)	0,259*** (0,037)	0,257*** (0,036)	0,257*** (0,036)	0,252*** (0,036)
Ventilador	0,054*** (0,007)	0,054*** (0,007)	0,054*** (0,007)	0,054*** (0,007)	0,054*** (0,007)	0,054*** (0,007)	0,053*** (0,007)
Computador	0,133*** (0,011)	0,133*** (0,011)	0,133*** (0,011)	0,132*** (0,011)	0,132*** (0,011)	0,132*** (0,011)	0,123*** (0,011)
Micro-ondas	0,091*** (0,010)	0,091*** (0,010)	0,091*** (0,010)	0,090*** (0,010)	0,090*** (0,010)	0,090*** (0,010)	0,085*** (0,010)
TV	0,042*** (0,009)	0,042*** (0,009)	0,042*** (0,009)	0,041*** (0,009)	0,041*** (0,009)	0,041*** (0,009)	0,043*** (0,009)
Geladeira	0,338*** (0,011)	0,336*** (0,011)	0,336*** (0,011)	0,337*** (0,011)	0,337*** (0,011)	0,337*** (0,011)	0,343*** (0,011)
Freezer	0,281*** (0,009)	0,280*** (0,009)	0,280*** (0,009)	0,279*** (0,009)	0,279*** (0,009)	0,279*** (0,009)	0,274*** (0,009)
Máquina de lavar roupa	0,106*** (0,008)	0,105*** (0,008)	0,105*** (0,008)	0,105*** (0,008)	0,105*** (0,008)	0,105*** (0,008)	0,101*** (0,008)
Ferro	0,062*** (0,009)	0,061*** (0,009)	0,061*** (0,009)	0,061*** (0,009)	0,061*** (0,009)	0,061*** (0,009)	0,063*** (0,009)
Rádio	-0,020*** (0,006)	-0,019*** (0,006)	-0,019*** (0,006)	-	-	-	-
Máquina de lavar louça	-0,024 (0,132)	-0,028 (0,132)	-0,028 (0,132)	-0,031 (0,132)	-	-	-
Aspirador	0,002 (0,012)	0,001 (0,012)	0,001 (0,012)	-0,0002 (0,012)	-0,0002 (0,012)	-	-
Ln Renda X Decil 2	-	-	-	-	-	-	0,003* (0,002)
Ln Renda X Decil 3	-	-	-	-	-	-	0,005*** (0,002)
Ln Renda X Decil 4	-	-	-	-	-	-	0,010*** (0,002)
Ln Renda X Decil 5	-	-	-	-	-	-	0,014*** (0,003)
Ln Renda X Decil 6	-	-	-	-	-	-	0,016*** (0,003)
Ln Renda X Decil 7	-	-	-	-	-	-	0,019*** (0,003)
Ln Renda X Decil 8	-	-	-	-	-	-	0,025*** (0,004)
Ln Renda X Decil 9	-	-	-	-	-	-	0,028*** (0,004)
Ln Renda X Decil 10	-	-	-	-	-	-	0,034*** (0,005)
Intercepto	4,756*** (0,049)	4,762*** (0,049)	4,762*** (0,049)	4,763*** (0,049)	4,763*** (0,049)	4,763*** (0,049)	5,775*** (0,144)
Observações	39.469	39.469	39.469	39.469	39.469	39.469	39.469
R ²	0,464	0,464	0,464	0,464	0,464	0,464	0,465
R ² Ajustado	0,464	0,463	0,463	0,463	0,463	0,463	0,465

Nota: Níveis de significância (p-valor), * < 0,10; *** < 0,05; **** < 0,01; resultados com erros padrão robustos

Fonte: Elaboração própria

Tabela 19.A. Sumário de regressão da POF (2008-2009) – Teste de Robustez

	Modelo (6)	Outliers	Peso amostral	Peso amostral + Outliers
Ln Renda	0,050*** (0,014)	0,041*** (0,013)	0,074*** (0,025)	0,061** (0,024)
Ln PreçoE	-0,014* (0,008)	0,061*** (0,008)	-0,099*** (0,013)	-0,038*** (0,012)
CDD _{wb} médio	0,0003*** (0,00002)	0,0003*** (0,00002)	0,0002*** (0,00003)	0,0001*** (0,00003)
Urbano (1 = Urbano)	0,073*** (0,011)	0,077*** (0,011)	0,101*** (0,017)	0,109*** (0,017)
Norte	-0,102*** (0,013)	-0,075*** (0,013)	-0,125*** (0,017)	-0,099*** (0,017)
Nordeste	-0,258*** (0,009)	-0,243*** (0,009)	-0,272*** (0,013)	-0,266*** (0,013)
Sul	0,140*** (0,011)	0,140*** (0,011)	0,073*** (0,013)	0,080*** (0,013)
Sudeste	0,025*** (0,009)	0,038*** (0,009)	0,043*** (0,012)	0,060*** (0,011)
Tipo de domicílio (1 = Casa)	0,053*** (0,006)	0,053*** (0,006)	0,041*** (0,010)	0,036*** (0,010)
Nº de cômodos	0,006 (0,010)	0,009 (0,010)	0,032** (0,015)	0,035** (0,015)
Membros da família	0,021*** (0,002)	0,019*** (0,002)	0,019*** (0,002)	0,017*** (0,002)
Raça (1 = Branco)	0,060*** (0,002)	0,059*** (0,002)	0,077*** (0,003)	0,076*** (0,003)
Idade	0,027*** (0,006)	0,028*** (0,006)	0,024*** (0,009)	0,025*** (0,009)
Anos de educação	0,002*** (0,0002)	0,002*** (0,0002)	0,002*** (0,0003)	0,003*** (0,0003)
AC	0,011*** (0,001)	0,011*** (0,001)	0,012*** (0,001)	0,011*** (0,001)
Ventilador	0,221*** (0,011)	0,210*** (0,011)	0,205*** (0,016)	0,201*** (0,016)
Computador	0,048*** (0,006)	0,043*** (0,006)	0,050*** (0,009)	0,051*** (0,009)
Micro-ondas	0,135*** (0,008)	0,130*** (0,007)	0,131*** (0,011)	0,132*** (0,011)
TV	0,064*** (0,008)	0,061*** (0,008)	0,092*** (0,011)	0,086*** (0,011)
Geladeira	0,051*** (0,012)	0,049*** (0,012)	0,043** (0,018)	0,035** (0,017)
Freezer	0,294*** (0,012)	0,280*** (0,011)	0,293*** (0,017)	0,289*** (0,017)
Máquina de lavar roupa	0,236*** (0,009)	0,228*** (0,009)	0,217*** (0,012)	0,211*** (0,012)
Ferro	0,080*** (0,007)	0,083*** (0,007)	0,105*** (0,010)	0,106*** (0,010)
Chuveiro elétrico	0,074*** (0,007)	0,071*** (0,007)	0,078*** (0,011)	0,079*** (0,011)
Máquina de lavar louça	0,102*** (0,008)	0,099*** (0,008)	0,115*** (0,015)	0,105*** (0,014)
Aspirador	0,025 (0,025)	0,020 (0,024)	0,091*** (0,031)	0,088*** (0,030)
Ln Renda X Decil 2	0,004 (0,011)	0,003 (0,011)	0,004 (0,015)	-0,002 (0,014)
Ln Renda X Decil 3	0,003** (0,001)	0,003* (0,001)	0,003 (0,002)	0,002 (0,002)
Ln Renda X Decil 4	0,003 (0,002)	0,003** (0,002)	0,0005 (0,003)	0,001 (0,003)
Ln Renda X Decil 5	0,007*** (0,002)	0,007*** (0,002)	0,006* (0,003)	0,005* (0,003)
Ln Renda X Decil 6	0,007*** (0,002)	0,007*** (0,002)	0,004 (0,004)	0,004 (0,003)
Ln Renda X Decil 7	0,009*** (0,002)	0,009*** (0,002)	0,006 (0,004)	0,006 (0,004)
Ln Renda X Decil 8	0,011*** (0,003)	0,012*** (0,002)	0,006 (0,004)	0,006 (0,004)
Ln Renda X Decil 9	0,012*** (0,003)	0,013*** (0,003)	0,006 (0,005)	0,007 (0,005)
Ln Renda X Decil 10	0,016*** (0,003)	0,016*** (0,003)	0,009* (0,006)	0,010* (0,005)
Intercepto	0,021*** (0,004)	0,022*** (0,004)	0,012* (0,007)	0,012** (0,006)
Observações	5,397*** (0,118)	5,550*** (0,111)	5,060*** (0,216)	5,243*** (0,209)
R ²	48.732	47.582	48.732	47.582
R ² Ajustado	0,409	0,419	0,422	0,432

Nota: Níveis de significância (p-valor), * < 0,10; *** < 0,05; **** < 0,01; resultados com erros padrão robustos

Fonte: Elaboração própria

Tabela 20.A. Sumário de regressão da POF (2002-2003) – Teste de Robustez

	Modelo (7)	Outliers	Peso amostral	Peso amostral + Outliers
Ln Renda	0,034** (0,017)	0,047*** (0,017)	0,046** (0,023)	0,060*** (0,023)
Ln PreçoE	0,214*** (0,010)	0,203*** (0,009)	0,305*** (0,013)	0,287*** (0,012)
CDD _{wb} médio	0,0004*** (0,00003)	0,0004*** (0,00002)	0,0004*** (0,00003)	0,0004*** (0,00003)
Urbano (1 = Urbano)	0,131*** (0,012)	0,125*** (0,012)	0,091*** (0,016)	0,088*** (0,016)
Norte	-0,146*** (0,015)	-0,133*** (0,015)	-0,234*** (0,018)	-0,217*** (0,018)
Nordeste	-0,348*** (0,009)	-0,342*** (0,009)	-0,354*** (0,012)	-0,347*** (0,012)
Sul	0,005 (0,011)	0,009 (0,011)	0,011 (0,013)	0,015 (0,013)
Sudeste	-0,074*** (0,010)	-0,074*** (0,010)	-0,005 (0,013)	-0,007 (0,012)
Tipo de domicílio (1 = Casa)	-0,005 (0,012)	-0,008 (0,012)	0,034** (0,017)	0,028 (0,017)
Nº de cômodos	0,024*** (0,002)	0,024*** (0,002)	0,018*** (0,003)	0,019*** (0,002)
Membros da família	0,033*** (0,002)	0,032*** (0,002)	0,046*** (0,003)	0,046*** (0,003)
Raça (1 = Branco)	0,038*** (0,007)	0,037*** (0,006)	0,031*** (0,010)	0,032*** (0,010)
Idade	0,001*** (0,0002)	0,001*** (0,0002)	0,001*** (0,0003)	0,001*** (0,0003)
Anos de educação	0,010*** (0,001)	0,010*** (0,001)	0,009*** (0,001)	0,010*** (0,001)
AC	0,252*** (0,036)	0,223*** (0,035)	0,219*** (0,044)	0,196*** (0,040)
Ventilador	0,053*** (0,007)	0,058*** (0,007)	0,039*** (0,010)	0,040*** (0,010)
Computador	0,123*** (0,011)	0,120*** (0,011)	0,123*** (0,017)	0,116*** (0,017)
Micro-ondas	0,085*** (0,010)	0,082*** (0,010)	0,097*** (0,015)	0,091*** (0,015)
TV	0,043*** (0,009)	0,041*** (0,009)	0,046*** (0,014)	0,046*** (0,014)
Geladeira	0,343*** (0,011)	0,341*** (0,011)	0,326*** (0,017)	0,329*** (0,017)
Freezer	0,274*** (0,009)	0,273*** (0,009)	0,233*** (0,013)	0,233*** (0,013)
Máquina de lavar roupa	0,101*** (0,008)	0,098*** (0,007)	0,096*** (0,012)	0,095*** (0,012)
Ferro	0,063*** (0,009)	0,066*** (0,009)	0,078*** (0,014)	0,077*** (0,014)
Ln Renda X Decil 2	0,003* (0,002)	0,002 (0,002)	0,002 (0,002)	0,0001 (0,002)
Ln Renda X Decil 3	0,005*** (0,002)	0,004** (0,002)	0,004 (0,003)	0,003 (0,003)
Ln Renda X Decil 4	0,010*** (0,002)	0,009*** (0,002)	0,006* (0,003)	0,005 (0,003)
Ln Renda X Decil 5	0,014*** (0,003)	0,012*** (0,003)	0,010** (0,004)	0,007* (0,004)
Ln Renda X Decil 6	0,016*** (0,003)	0,015*** (0,003)	0,011*** (0,004)	0,009** (0,004)
Ln Renda X Decil 7	0,019*** (0,003)	0,017*** (0,003)	0,013*** (0,004)	0,010** (0,004)
Ln Renda X Decil 8	0,025*** (0,004)	0,022*** (0,003)	0,018*** (0,005)	0,015*** (0,005)
Ln Renda X Decil 9	0,028*** (0,004)	0,025*** (0,004)	0,022*** (0,005)	0,018*** (0,005)
Ln Renda X Decil 10	0,034*** (0,005)	0,029*** (0,005)	0,024*** (0,007)	0,019*** (0,007)
Intercepto	5,775*** (0,144)	5,665*** (0,143)	5,740*** (0,194)	5,613*** (0,193)
Observações	39.469	38.553	39.469	38.553
R ²	0,465	0,464	0,488	0,48
R ² Ajustado	0,465	0,464	0,488	0,48

Nota: Níveis de significância (p-valor), * < 0,10; ** < 0,05; *** < 0,01; resultados com erros padrão robustos

Fonte: Elaboração própria