

**DESENVOLVIMENTO DE UM MODELO BASEADO EM AGENTES PARA
ANÁLISE DO CONSUMO DA CARNE BOVINA NO BRASIL**

Maíra Tavares e Silva

Dissertação de Mestrado 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 Mestre em Planejamento
Energético.

Orientadores: Joana Correia de Oliveira de
Portugal Pereira

Bruno Scola Lopes da Cunha

Rio de Janeiro

Agosto de 2022

DESENVOLVIMENTO DE UM MODELO BASEADO EM AGENTES PARA
ANÁLISE DO CONSUMO DA CARNE BOVINA NO BRASIL

Maíra Tavares e Silva

DISSERTAÇÃO 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 MESTRE EM
CIÊNCIAS EM PLANEJAMENTO ENERGÉTICO.

Orientadores: Joana Correia de Oliveira de Portugal Pereira

Bruno Scola Lopes da Cunha

Aprovada por: Profa. Joana Correia de Oliveira de Portugal Pereira

Prof. Bruno Scola Lopes da Cunha

Profa. Bettina Susanne Hoffmann

Prof. José Gustavo Feres

RIO DE JANEIRO, RJ - BRASIL

AGOSTO DE 2022

Silva, Maíra Tavares e

Desenvolvimento de um Modelo Baseado em Agentes para Análise do Consumo da Carne Bovina no Brasil/
Maíra Tavares e Silva – Rio de Janeiro: UFRJ/COPPE,
2022.

X, 135 p.: il.; 29,7 cm.

Orientadores: Joana Correia de Oliveira de Portugal
Pereira

Bruno Scola Lopes da Cunha

Dissertação (Mestrado) – UFRJ/ COPPE/ Programa de
Planejamento Energético, 2022.

Referências Bibliográficas: p. 103-122.

1. Modelo Baseado em Agentes. 2. Mudanças Climáticas. 3. Precificação de Emissões. 4. Mudança de Estilo de Vida. I. Pereira, Joana Correia de Oliveira de Portugal. II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Planejamento Energético. III. Título.

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

**DESENVOLVIMENTO DE UM MODELO BASEADO EM AGENTES PARA
ANÁLISE DO CONSUMO DA CARNE BOVINA NO BRASIL**

Maíra Tavares e Silva

Agosto/2022

Orientadores: Joana Correia de Oliveira de Portugal Pereira

Bruno Scola Lopes da Cunha

Programa: Planejamento Energético

Diversos estudos têm reunido evidências sobre o potencial das mudanças de estilo de vida para a redução das emissões de GEE. Os modelos de avaliação integrados são ferramentas amplamente utilizadas pela comunidade científica para lidar com a problemática das mudanças climáticas, porém apresentam dificuldade de captar a heterogeneidade e irracionalidade dos consumidores ao modelar mudanças pelo lado da demanda. Modelos Baseados em Agentes (ABMs) são apontados como uma das soluções promissoras para este problema. Tendo em vista o debate sobre a mudança de hábitos alimentares como medida de mitigação de emissões, em destaque a redução do consumo de carne bovina e o protagonismo do Brasil neste contexto, esta dissertação tem o objetivo de desenvolver um ABM para simular o consumo carne bovina da população brasileira. Resultados indicam que o modelo foi capaz de reproduzir o padrão consumo analisado e captar a heterogeneidade da população em relação a este comportamento. Ao aplicar o aumento do preço, indivíduos de classes média e baixa tiveram maior impacto na redução do consumo do que a classe alta refletindo como políticas podem impactar a população de diferentes formas ao considerar a heterogeneidade.

Abstract of Dissertation presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

DEVELOPMENT OF AN AGENT BASED MODEL FOR THE ANALYSIS OF BEEF CONSUMPTION IN BRAZIL

Maíra Tavares e Silva

August/2022

Advisors: Joana Correia de Oliveira de Portugal Pereira

Bruno Scola Lopes da Cunha

Department: Energy Planning

Several studies have shown a large amount of evidence concerning the potential of lifestyle changes to reduce GHG emissions. Integrated assessment models are tools widely used by the scientific community to deal with the issue of climate change, but they present difficulty in capturing the heterogeneity and irrationality of consumers when modeling changes on the demand side. Agent-Based Models (ABMs) are pointed out as one of the promising solutions to this problem. Given the relevancy of the debate on dietary change as an important emission mitigation measure, where bovine meat stands out as a key component, and Brazil's protagonist role in this context, this dissertation has the objective of developing an ABM to simulate the Brazilian beef consumption. Results indicate that the model was able to reproduce the consumption pattern analyzed and capture the heterogeneity of the population in relation to this behavior. When applying the price increase, individuals from the middle and lower classes had a greater impact on reducing consumption than the upper class reflecting how policies can impact the population in different ways when considering heterogeneity.

ÍNDICE

1	Introdução	1
2	Modelagem baseada em agentes de dietas alimentares	5
2.1	Contexto histórico	5
2.2	Princípios da modelagem	8
2.3	Aplicações da modelagem	16
3	Metodologia	21
3.1	Coleta e tratamento das bases de dados	21
3.1.1	Microdados da Pesquisa de Orçamentos Familiares	22
3.1.2	Mudanças Climáticas na Percepção dos Brasileiros.....	34
3.1.3	Índice de Preços ao Consumidor Amplo	36
3.1.4	Base Territorial - Setores Censitários do Censo Demográfico de 2010	37
3.1.5	Disponibilidade Interna de Carne no Brasil	39
3.2	Componentes e base teórica da modelagem baseada em agentes	41
3.3	Estratégia de implementação do modelo	43
3.4	Implementação do modelo baseado em agentes	46
3.4.1	Módulo 1: Provável preocupação com o meio ambiente	49
3.4.2	Módulo 2: Probabilidade de realizar uma refeição fora de casa....	49
3.4.3	Módulo 3: Probabilidade de consumir carne bovina em uma refeição	51
3.4.4	Módulo 4: Probabilidade da quantidade de carne bovina a ser consumida	52
3.4.5	Implementação do código.....	53
3.5	Análise de sensibilidade.....	62
4	Resultados.....	63

4.1	Módulo 1: Provável preocupação com o meio ambiente	63
4.2	Módulo 2: Probabilidade de realizar uma refeição fora de casa	68
4.3	Módulo 3: Probabilidade de consumir carne bovina em uma refeição.....	72
4.4	Módulo 4: Probabilidade da quantidade de carne bovina a ser consumida	76
4.5	Resultados dos Modelo	81
4.6	Análise de Sensibilidade	82
5	Discussão dos resultados	88
6	Considerações Finais	96
7	Referências Bibliográficas.....	102
	ANEXOS	122

LISTA DE FIGURAS

Figura 1: Componentes de um modelo ABM típico.....	8
Figura 2: Topologias do ABM.....	11
Figura 3: Descritores do tradutor “aquisição alimentar” e seu reagrupamento em uma nova descrição	33
Figura 4: Estrutura do modelo ABM	45
Figura 5: Guia da Interface do modelo desenvolvido no <i>Netlogo</i>	48
Figura 6: Distribuição normal da quantidade de carne bovina consumida por refeição por individuo	52
Figura 7: Frequência das respostas à pergunta “O quanto você considera que está preocupado(a) com o meio ambiente atualmente?” considerando: A) população geral B) macrorregião; C) situação de domicílio; D) gênero; E) faixa etária; F) nível de escolaridade; G) Classe de renda.....	64
Figura 8: Frequência das respostas à pergunta “O quanto você considera que está preocupado(a) com o meio ambiente atualmente?” considerando a combinação das variáveis macrorregião, gênero e nível de escolaridade.....	67
Figura 9: Distribuição da quantidade de carne bovina consumida por indivíduo em uma refeição considerando: A) média global no Brasil B) macrorregião; C) situação de domicílio; D) gênero; E) faixa etária; F) nível de escolaridade; G) Classe de renda; H) Tipo de refeição; I) Dia da refeição; J) Lugar da refeição. Os triângulos marcam as médias e as áreas coloridas a distribuição da quantidade de carne consumida em uma refeição.	77
Figura 10: Validação dos resultados do modelo.....	82
Figura 11: Análise de sensibilidade sobre a preocupação com o meio ambiente.....	84
Figura 12: Análise de sensibilidade do preço da carne bovina.....	84
Figura 13: Análise de sensibilidade do preço da carne bovina: média de gramas de carne bovina consumida por dia por pessoa de 2017 a 2020 por grupos considerando: A) macrorregião; B) situação de domicílio; C) gênero; D) classe renda; E) faixa etária; F) ocupação.	86

Figura 14: Análise de sensibilidade do preço da carne bovina: variação percentual da média de gramas de carne bovina consumida por dia por pessoa de 2017 a 2020 por grupos considerando: A) macrorregião; B) situação de domicílio; C) gênero; D) classe renda; E) faixa etária; F) ocupação 87

Figura 15: Distribuição da quantidade de carne bovina consumida por indivíduo em uma refeição considerando as variáveis macrorregião, situação de domicílio, gênero, faixa etária e tipo de refeição..... 132

LISTA DE TABELAS

Tabela 1: Estrutura Questionários e Registros da POF	25
Tabela 2: Variáveis e Categorias da Tabela Indivíduos	28
Tabela 3: Quartis 50% e 85% da renda familiar per capita por Unidade Federativa da POF 2017-2018.....	30
Tabela 4: Variáveis e Categorias da Tabela Alimentação	31
Tabela 5: Variáveis e Categorias da Tabela “Preocupação ambiental”	36
Tabela 6: Características atribuídas aos agentes - variáveis estáticas e permanentes em todas rodadas	42
Tabela 7: Resultados da regressão logística não-ajustada para calcular a probabilidade de indivíduos comerem fora de casa.	69
Tabela 8: Resultados da regressão logística ajustada para calcular a probabilidade de indivíduos comerem fora de casa.	70
Tabela 9: Variáveis da Regressão logística – probabilidade do agente i realizar a refeição fora de casa no tempo t	71
Tabela 10: Resultados da regressão logística não-ajustada para calcular a probabilidade de indivíduos consumir carne em uma refeição	72
Tabela 11: Resultados da regressão logística ajustada para calcular a probabilidade de indivíduos consumir carne em uma refeição	75
Tabela 12: Variáveis da regressão logística – probabilidade do agente i consumir de carne bovina no tempo t	76
Tabela 13: Tabela IPCA	123
Tabela 14: Tabela módulo 4 – Parâmetros das distribuições da quantidade de carne bovina consumida por indivíduo em uma refeição considerando as variáveis macrorregião, situação de domicílio, gênero, faixa etária e tipo de refeição.....	133

1 Introdução

O paradigma capitalista embasado no crescimento econômico contínuo como único recurso para se alcançar a prosperidade econômica e social, desencadeou mudanças nas estruturas da sociedade que influenciaram diversas transformações comportamentais e ambientais. Os hábitos alimentares se destacam entre estas mudanças, não só pela sua drástica transformação, mas também pelo seu relevante impacto ao meio ambiente e à saúde humana.

POPKIN (2006) apresenta a transição alimentar da sociedade mostrando a sua relação e interação com as transições demográficas, socioeconômicas e epidemiológicas. À medida que a sociedade começou a desenvolver novos conhecimentos e tecnologias na produção, no armazenamento e no processamento dos alimentos, a população mundial começou a crescer, a incidência de doenças infectocontagiosas a diminuir, e a pirâmide etária a inverter. Paralelamente, a ampla disseminação da tecnologia, o rápido crescimento da renda, das desigualdades sociais, e a dispersão da população urbana, estimularam indivíduos a mudanças de hábitos, como a diminuição de exercícios físicos e aumento do consumo de alimentos pouco saudáveis. Todas essas mudanças levaram não só ao aumento da incidência de Doenças Crônicas Não Transmissíveis (DCNT), mas também a pressionar o ecossistema global, colocando em risco todo o sistema alimentar.

Desde 1961, a produção total de alimentos (cultivo de cereais) aumentou 240%, o uso dos recursos hídricos para irrigação aumentou mais de 100%, e de fertilizantes nitrogenados cerca de 800% (MBOW *et al.*, 2019). Atualmente, o sistema alimentar¹ é responsável por aproximadamente 32% da acidificação terrestre global, 78% da eutrofização (POORE, NEMECEK, 2018) e de 25 a 30% das emissões totais de gases de efeito estufa (GEE) (MBOW *et al.*, 2019). A consequência deste problema recai sobre o próprio sistema alimentar, uma vez que as mudanças climáticas afetam diretamente os quatro pilares da segurança alimentar (disponibilidade, acessibilidade, utilização e estabilidade) através do aumento das temperaturas, mudança nos padrões de precipitação

¹ Sistema alimentar adota uma perspectiva de análise de ciclo de vida e inclui: 1. uso do solo e mudança de uso do solo; 2. produção: produção de produtos alimentares; 3. processamento de alimentos; 4. distribuição de alimentos incluindo embalagem, transporte e varejo; 5. consumo de alimentos incluindo atividades domésticas de preparo de alimentos; e 6. fim de vida dos alimentos, incluindo gestão de resíduos alimentares e gestão de resíduos não alimentares utilizados em fases anteriores do sistema alimentar (CRIPPA *et al.*, 2021).

e maior frequência de eventos extremos (MBOW *et al.*, 2019). Ao mesmo tempo que se faz necessário reduzir as emissões e demais impactos ambientais deste setor, verifica-se a necessidade de aumentar a produção de alimentos cerca de 50% até 2050 para alimentar a crescente população mundial (FAO, 2017). Caso não haja nenhuma alteração nesse cenário, estima-se que as emissões anuais do sistema alimentar possam chegar a 20 Gt CO₂eq, representando até 40% das emissões de GEE globais (MBOW *et al.*, 2019; BRYNGELSSON *et al.*, 2017).

Nesse contexto, o consumo excessivo da carne vermelha ganha grande destaque. Além do seu consumo ter aumentado mais do que dobro desde 1960 (FAO, 2017, 2018), a carne vermelha é um dos alimentos que causam maior impacto ambiental. Em 2000, estima-se que a produção pecuária foi responsável por 14.5% das emissões globais de GEE, pelo consumo de um terço de todos os cereais produzidos, uso de cerca de 33% da terra arável global, e que aproximadamente 10% da água doce utilizada para irrigação é destinada apenas para o gado de corte (FAO, 2018). Além disso, há cada vez mais estudos associando o consumo excessivo da carne vermelha à DCNT como obesidade, doença cardíaca coronária, diabetes tipo II, acidentes vasculares encefálico e diversos cânceres (CLARK, SPRINGMANN, *et al.*, 2019; WCRF 2018; TUFTS UNIVERSITY, 2019).

Em 2020, o agronegócio foi responsável por cerca de 30% do PIB do Brasil sendo mundialmente um dos maiores produtores e consumidores de carne bovina (CNA, 2020). Neste mesmo ano o país se posicionou mundialmente como o maior exportador de carne bovina, o segundo maior produtor, e o terceiro maior consumo per capita (FAOSTAT, 2020). De acordo com o relatório *Global Nutrional Report* de 2020, brasileiros estão comendo mais do que o dobro da quantidade de carne vermelha considerada segura em relação a exposição ao risco de doenças (TUFTS UNIVERSITY, 2019).

Além do Brasil ser o 7º maior emissor de GEE do mundo, cabe destacar que o seu setor de maior emissão está relacionado as atividades agropecuárias e de mudanças no uso do solo (AFOLU - *Agriculture, Forestry and Other Land Use*), diferentemente da maioria dos outros países onde a geração de energia lidera. As emissões de AFOLU no país são responsáveis por 44% das emissões totais (SEEG, 2019), sobretudo devido ao desmatamento na Amazônia e no Cerrado dos quais cerca de 80% está associado direta ou indiretamente a expansão das pastagens para criação bovina (BRINDIS, 2008). Quando somadas as emissões diretas e indiretas do setor agropecuário, este responde por

69% das emissões no Brasil, sendo 77% desta parcela conferido apenas pela pecuária (SEEG, 2019). As emissões do Brasil flutuam, sendo influenciadas pela recessão e pelo desmatamento, o que evidencia que o país ainda não incorporou de forma consistente a redução de emissões à sua economia (SEEG 2019).

A comunidade internacional estabeleceu importantes acordos e metas, designadamente a Agenda 2030 e o Acordo de Paris, com o objetivo de desenvolver proposições de políticas para garantir o desenvolvimento sustentável e a redução das emissões GEE. A Agenda 2030 definiu um plano de ação com 17 Objetivos para o Desenvolvimento Sustentável (ODSs) e 169 metas a serem atingidas até 2030, com a finalidade de melhorar as condições de vida da humanidade e o futuro do planeta, garantindo por exemplo a segurança alimentar, saúde e bem-estar de populações (UN, 2015). O Acordo de Paris determinou metas de contribuições nacionais (NDCs) submetidas a cada cinco anos para mitigação de emissões de carbono com o objetivo de manter o aquecimento global *bem abaixo* de 2°C e idealmente até 1,5°C até 2100 em relação à era pré-industrial (UNFCCC, 2015a). Apesar do empenho na elaboração dessas medidas, os esforços atuais em andamento são insuficientes para atingir tais objetivos. Se as promessas anunciadas para as NDCs forem totalmente cumpridas sem condicionalismos, as emissões globais ainda levariam a um aumento de temperatura próxima a 2,7°C até ao final do século (UNEP, 2021).

Os modelos de avaliação integrados (IAMs – *Integrated Aessment Model*) avaliam as opções de energia de menor custo dada uma restrição de orçamento de carbono afim de estudar formas de mitigação e possíveis cenários diante deste problema (IPCC, 2022). Esses modelos combinam conhecimentos de diversas disciplinas para explorar como o desenvolvimento humano e as escolhas sociais interagem e afetam o mundo natural. Utilizando variáveis físicas, econômicas e sociais, esses modelos simulam processos interativos entre o desenvolvimento econômico e social, assumindo diferentes cenários de desenvolvimento socioeconômico globais projetados até 2100 (RIAHI *et al.*, 2022). Todavia, muitas vezes, eles se apoiam fortemente no progresso técnico, contando com uma grande penetração de tecnologias disruptivas, que apresentam maiores riscos, custos e incertezas de implementação. Além disso, consideram a mitigação à margem das fronteiras do "business-as-usual" (EDENHOFER *et al.*, 2007).

BROWN E VERGRAGT (2015) afirma que embora as melhorias das tecnologias possam ter contribuído para um uso mais eficiente dos recursos, e assim, desacelerado o

crescimento da demanda por matérias primas, elas não acompanharam o crescimento do consumo. Por isso, há um consenso crescente de que soluções puramente tecnológicas, sem reconsiderar os modelos econômicos tradicionais de crescimento contínuo, dificilmente proporcionarão uma transição completa para uma sociedade de baixo carbono (BROWN, VERGRAGT, 2015). Assim, mudanças no estilo de vida e no comportamento do consumidor tem sido cada vez mais apontado como uma estratégia importante para a mitigação de GEE e para alcançar várias metas estabelecidas pelos ODSs (EDENHOFER *et al.*, 2007; CREUTZIG *et al.*, 2022). Entre elas, a mudança para um hábito alimentar mais saudável e equilibrado ganha notoriedade, sendo a redução do consumo de carne bovina um componente chave desta transição.

Embora vários artigos científicos destaquem o potencial de mudança de estilo de vida para redução das emissões de GEE, essas estratégias ainda são na maioria das vezes modeladas em IAMs por meio de parametrização de variáveis implícitas e exógenas através da determinação de diferentes cenários (VAN DEN BERG *et al.*, 2019; IPCC, 2022). Isto se deve à dificuldade de se captar a heterogeneidade dos consumidores e a complexidade do tópico, como compreender as motivações que levam a uma mudança de estilo de vida, e a irracionalidade do consumidor, que faz com que intenções não sejam necessariamente traduzidas em ações. Na revisão bibliográfica feita por VAN DEN BERG *et al.* (2019), os autores apontam algumas soluções promissoras para este problema, entre elas a integração de IAMs com Modelos Baseados em Agentes (ABM na sigla inglesa).

Neste contexto, esta dissertação tem o objetivo de desenvolver uma ferramenta analítica com base na metodologia ABM para simular o consumo carne bovina da população brasileira. Tendo como objetivos específicos: i. Identificar fatores que condicionam o perfil de consumo de carne bovina no Brasil (preço, interação, preocupação ambiental, demográfico); ii. Analisar o consumo de carne bovina pela heterogeneidade dos agentes; iii. Avaliar a efetividade na redução do consumo da carne bovina a partir de uma possível política de precificação de GEE no Brasil.

2 Modelagem baseada em agentes de dietas alimentares

Este capítulo apresenta o estado da arte da modelagem ABM. A primeira seção (2.1) apresenta o contexto histórico do ABM, explicando a origem, seus primeiros modelos e sua evolução na ciência. A seção 2.2 explica os princípios e componentes básicos que compõe um modelo ABM. Por fim, a seção 2.3 apresenta alguns estudos em a que a modelagem ABM foi aplicado no contexto que abordassem políticas no combate das mudanças climáticas ou mudanças de dietas alimentares.

2.1 Contexto histórico

A modelagem baseada em agentes (ABM - *agent-based models*) é uma das várias técnicas de modelagem e simulação. Segundo PEGDEN, SHANNON, *et al.* (1990) a simulação é o processo de projetar um modelo de um sistema real e conduzir experimentos com o propósito de entender seu comportamento e/ou avaliar estratégias para sua operação. O ABM foi desenvolvido a partir de um conjunto de conceitos multidisciplinares, provenientes, sobretudo, da biologia, da física, da matemática e da computação, e principalmente de outros modelos de simulação tradicionais (TAYLOR, 2014).

Enquanto os primeiros modelos de simulação surgiram na década 1950 com o objetivo inicial de investigar sistemas industriais (TAYLOR, 2014) para simular processos de controle e *feedback*, a modelagem ABM começou a evoluir no final da década de 1980, impulsionada pela necessidade de estudar sistemas complexos adaptativos (CAS - *complex adaptive systems*; HOLLAND, 1995; KAUFFMAN, KAUFFMAN, 1993). Sistemas complexos adaptativos são formados por componentes autônomos, capazes de se adaptar, e que ao interagirem entre si podem provocar o surgimento de um novo comportamento no sistema (MACAL, NORTH, 2010). As investigações nesses sistemas buscavam, originalmente, identificar princípios de auto-organização, adaptação e fenômenos emergentes em sistemas biológicos. Porém, como CAS estão presentes em diversas ciências, este modelo apresenta uma grande variedade de aplicações abrangendo áreas desde a ecologia e economia à antropologia, psicologia e muitos outros (MACAL, NORTH, 2010).

HOLLAND (1995) resumiu os sistemas complexos através de quatro propriedades (agregação, não linearidade, fluência, diversidade) e três mecanismos (identificação, modularidade, modelos internos) comuns a todos os CAS, reconhecidos como uma contribuição fundamental para este campo. A agregação, a identificação e a modularidade estão relacionadas as estruturas hierárquicas encontradas nos sistemas complexos. Essas características permitem que componentes semelhantes possam ser agregados ou decompostos em diferentes subgrupos para representarem padrões de comportamentos, de forma que estes componentes podem ser classificados e identificados uns pelos outros. A fluência determina a capacidade dos componentes de interagirem de forma dinâmica uns com outros e com o ambiente, o que possibilita haver a transferência e a transformação de recursos e informações, e, consequentemente, a não linearidade do sistema através da emergência de comportamentos. Os modelos internos são os mecanismos que permitem que agentes tenham a capacidade de perceber e tomar decisões sobre o ambiente que estão inseridos, sendo também entendidos como as regras que regem seus comportamentos. Por fim, a propriedade da diversidade caracteriza estes agentes como heterogêneos, os quais, portanto, não agem da mesma maneira quando estimulados por um mesmo conjunto de condições.

Um dos primeiros modelos usados para estudar sistemas complexos foram os autômatos celulares (*cellular automata* – CA), desenvolvido pelo físico Stanislaw Ulam em resposta a estudos do matemático John von Neumann (MACAL, NORTH, 2005). Neste modelo, células dispostas adjacentes umas outras em um espaço bidimensional são atribuídas com valores que são atualizados a cada período através de um conjunto de regras. Esses novos valores dependem de seus valores atuais e dos valores de seus vizinhos imediatos nas oito células circundantes. Apesar do modelo ser composto por células homogêneas e ser um modelo determinístico, o CA teve um impacto significativo na representação de sistemas complexos. Além do modelo ser constituído por sistemas paralelos, de modo que cada célula toma sua decisão de forma autônoma e simultânea, o conjunto de células consegue criar juntas um comportamento global mesmo com regras extremamente simples (LANGTON, 1989). Depois, a metodologia empregada na CA apresenta uma abordagem *bottom-up*, contrária a abordagem *top-down*, comumente aplicada em modelos lineares na época. Diferentemente da abordagem *top-down*, em que o modelo é construído a partir de subsistemas oriundos da fragmentação de um sistema global, na abordagem *bottom-up*, o modelo é estruturado a partir do comportamento de

vários subsistemas, sendo, portanto, mais adequados a representar sistemas não lineares (TAYLOR, 2014).

O modelo de autômato celular mais famoso que expandiu o interesse no estudo desses modelos foi o “*Game of Life*” (Jogo da Vida) desenvolvido pelo matemático John Conway (GARDNER, 1970). Neste modelo, as células do CA, representadas na época por moedas em um tabuleiro de xadrez, mudavam suas cores entre preto e branco, aplicando-se somente três regras que consideravam apenas informações locais. Após várias atualizações, foi possível observar o surgimento de padrões distintos que, em alguns casos, se sustentavam indefinidamente ao longo da simulação, interpretado como uma imitação da evolução. Usando este jogo, descobriu-se que padrões sustentáveis podem emergir de sistemas descritos por regras simples, além de serem extremamente sensíveis às condições iniciais (GARDNER, 1970).

Muitos outros cientistas depois chegaram as mesmas conclusões, entre os quais pode-se destacar o trabalho de SCHELLING (1978) sobre segregação de moradias. O autor aplicou as técnicas do CA com as mesmas ferramentas matemáticas de Conway, de forma que as moedas representavam indivíduos proprietários de casas, moedas em células circundantes os seus vizinhos, e as interações entre as células representam as percepções dos proprietários sobre seus vizinhos (SCHELLING, 1978). Com este modelo, o autor demonstrou que guetos podem se desenvolver espontaneamente a partir de comportamentos individuais e que, de forma geral, padrões podem emergir mesmo sem estarem implícitos nos objetivos individuais dos agentes (CLARK, FOSSETT, 2008). Este trabalho é reconhecido como o primeiro modelo ABM a considerar seus agentes como indivíduos sociais e por promover maior interesse e direcionamento nos estudos destes modelos (MACAL, NORTH, 2006).

À medida que a tecnologia foi avançando e a ciência da computação progredindo, os modelos foram se desenvolvendo, possibilitando, por exemplo, que agentes fossem autônomos e livres da restrição de suas células, se tornando cada vez mais próximos à realidade (TAYLOR, 2014). Entre os modelos de destaque para o desenvolvimento do campo, pode-se citar o modelo de *Boids* desenvolvido por REYNOLDS (1987), o qual simula o comportamento de um bando de pássaros, e o modelo *Sugarscape*, desenvolvido por EPSTEIN E AXTELL (1996), o qual faz uma representação abstrata de uma sociedade simples. Com computadores mais rápidos, bases de dados maiores, linguagens de programação mais ágeis e mais simples, junto a necessidade crescente de se analisar

sistemas cada vez mais complexos, a metodologia ABM foi sendo cada vez mais difundida e utilizada. A partir de uma pesquisa em bases de dados de artigos científicos, é possível observar que o número de artigos relativos a este modelo tem aumentado constantemente em uma taxa exponencial desde meados da década de 1990 e abrangendo amplamente campos de pesquisa como ecologia, epidemiologia, sociologia e ciência política (HEATH, HILL, CIARALLO, 2009; NIAZI, HUSSAIN, 2011)

2.2 Princípios da modelagem

Modelos ABM podem ser definidos como uma ferramenta para modelar e simular sistemas complexos com base nas decisões, ações e interações de agentes heterogêneos (GRIMM, REVILLA, *et al.*, 2005). A dinâmica do modelo de simulação se dá pela repetição de ciclos de uma série de funções programadas em um determinado software. De acordo com MACAL E NORTH (2010), um ABM típico é composto por três elementos, conforme ilustrado Figura 1. Eles são: 1. Um conjunto de agentes, definidos por seus atributos e métodos que regem seus comportamentos; 2. Uma rede de interações, definidas por um conjunto de métodos e/ou conexões que orientam as interações dos agentes entre si e com o ambiente; e 3. O ambiente em que os agentes estão inseridos.



Figura 1: Componentes de um modelo ABM típico

Fonte: Adaptado de MACAL, NORTH (2010)

O amplo desenvolvimento dos modelos ABM levou a diferentes definições do termo *agente*. MACAL E NORTH (2011) apresentam algumas características essenciais deste elemento, as quais definem, de forma geral, os componentes tomadores de decisão de um sistema, sejam eles pessoas, animais, organizações ou outras entidades. Por serem

componentes de um sistema complexo, um conjunto de agentes é composto por indivíduos heterogêneos, modulares e exclusivamente identificáveis, caracterizados por diversos atributos. Estes podem ser estáticos, não se alterarem ao longo da simulação, como seus nomes e gêneros, ou dinâmicos, como idades e crenças. Dessa forma, os agentes também apresentam características de estado representadas por um conjunto de atributos em um certo momento, os quais condicionam os seus comportamentos.

Os agentes são independentes, autônomos, proativos, e seus comportamentos são regidos por métodos que são definidos de acordo com o objetivo do modelo (MACAL, NORTH, 2011). Eles podem seguir métodos normativos, onde buscam atingir um determinado objetivo, como otimizar e identificar comportamentos ótimos através do uso de funções objetivas, mas também podem seguir métodos descritivos ou heurísticos, que visam modelar o comportamento real ou plausível de um sistema (MACAL, NORTH 2011). Em ABMs que modelam o comportamento social, estes métodos são, frequentemente, embasados em dados empíricos e/ou em teorias comportamentais. Podem utilizar, por exemplo, teorias da ciência econômica sobre o comportamento dos consumidores, como a teoria da ação racional (*theory of reasoned action* – TRA) ou do comportamento planejado (*theory of planned behavior* – TPB), ou teorias da psicologia social, como teoria da difusão da inovação (*innovation diffusion theory*; ROGERS, 1993) e a teoria de controle de afeto (*affect-control theory*; MACKINNON, 1994). Há também a possibilidade se diversas formalizações de estruturas lógicas desenvolvidas para auxiliar modeladores a descrever comportamentos, como as estruturas BDI (*Belief-Desire-Intent*; RAO, GEORGEFF, 1999) e a BOD (*Behavior-Oriented Design*; BRYSON, 2002; MACAL, NORTH, 2005).

Agentes também são caracterizados pelas suas capacidades de se adaptarem, por meio de mecanismos que modifiquem as regras que regem seus comportamentos. A adaptação pode ocorrer tanto a nível individual, como também a nível coletivo, decorrente, por exemplo, do aumento proporcional de determinados indivíduos mais adequados ao ambiente (MACAL, NORTH, 2011). Também podem ser capazes de aprender, caso o método escolhido atribua uma memória que possibilite fazer comparações entre seus objetivos e comportamentos anteriores, ajustando-os em futuras interações e decisões. Nesses casos, é comum a aplicação de algoritmos do campo do *machine learning*, algoritmos genéticos e outras técnicas relacionadas (MACAL, NORTH, 2010). As regras que regem os comportamentos dos agentes podem variar em

níveis de sofisticação dependendo da quantidade de informação considerada nas decisões do agente, na complexidade dos modelos internos para a tomada de decisão e na extensão da memória de eventos passados que os agentes podem reter e usar em suas decisões. No entanto, vale lembrar que comportamentos emergentes complexos e inesperados podem surgir mesmo com a aplicação de regras simples, como mostrado em SCHELLING (1978).

Além disso, os agentes também são caracterizados por serem sociais. Em ABMs, agentes interagem dinamicamente com o meio em que estão inseridos e uns com os outros, o que permite que se possam adquirir e transformar informações que podem influenciar seus comportamentos. Essas interações ocorrem através das redes de interações, o segundo componente principal de um ABM típico. As redes de interações são definidas pela topologia do modelo (Figura 2), que estabelecem como e quais agentes irão interagir. Duas topologias típicas já foram mencionadas na seção 2.1, a grade espacial, presente nos primeiros ABMs de autômatos celulares, e os espaços euclidianos, bidimensionais ou tridimensionais. Há também o sistema de informações geográficas (GIS), em que os agentes se movem sobre uma paisagem geoespacial realista, e o modelo "sopa", em que pares de agentes são selecionados aleatoriamente para interagirem e devolvidos à uma "sopa" de agentes para uma futura seleção (MACAL, NORTH, 2010).

Outra topologia comumente usada é a rede de relacionamentos em que agentes interagem com outros que pertencem a seu espaço social. Em outras palavras, os agentes interagem apenas com aqueles que estão conectados por meio de vínculos, que compõe a sua rede de conexões, ou sua rede social. Esta topologia permite que a vizinhança de um agente seja definida de forma mais geral e flexível, além de descrever com mais precisão os padrões de interação dos agentes sociais relacionadas (MACAL, NORTH, 2010). As redes podem ser estáticas, em que as conexões entre os agentes são preestabelecidas e não mudam ao longo da simulação, ou podem ser dinâmicas, determinadas endogenamente de acordo com os mecanismos programados no modelo (MACAL, NORTH, 2006). Esta topologia é explorada pelo campo de pesquisa da análise de redes sociais (*Social Network Analysis - SNA*), que estuda a caracterização, a estrutura, e as interações sociais por meio da representação de rede (WASSERMAN, FAUST, 1994). Para modelar as redes sociais em um ABM é importante pensar em aspectos como o conjunto de regras que irão estruturar as redes sociais de indivíduos, como e se estas redes irão crescer, a velocidade que as informações podem ser comunicadas, e as distinções entre diferentes tipos de

relacionamentos. A utilização de mais de uma topologia, como por exemplo a composição de espaços 2D e de redes sociais, também são frequentemente usados.

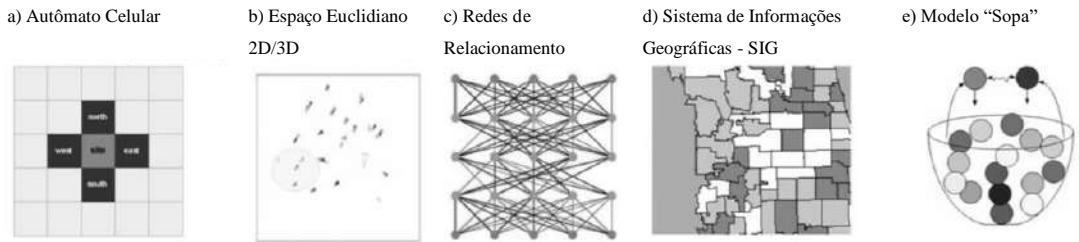


Figura 2: Topologias do ABM

Fonte: MACAL, NORTH (2010)

O terceiro componente fundamental de um modelo típico é o ambiente que os agentes estão inseridos. Assim como os agentes, os ambientes também recebem atributos que podem ser dinâmicos, como a disponibilidade de lojas de alimentos em um município, ou estáticos, como apenas o nome do município. Este componente pode ser usado de forma simples, como fornecer informações a agentes sobre algum atributo local ou sobre a localização espacial de outros agentes, como também de formas complexas, como fornecer um rico conjunto de informações geográficas usado para restringir ações de agentes. Nestes casos, o ambiente pode fornecer, por exemplo, dados específicos de infraestrutura e capacidade de um sistema de transporte, ou da hidrologia e níveis de água subterrânea, poluentes atmosféricos, e outros.

MACAL E NORTH (2006) destacam seis tarefas para construção de um ABM típico: 1. identificar agentes e a teoria que irá embasar seus comportamentos; 2. identificar as relações dos agentes entre si e com o ambiente, e a teoria utilizada para embasar tais interações; 3. escolher uma plataforma ABM e elaborar uma estratégia de implementação do modelo; 4. coletar e processar dados necessários; 5. validar o modelo; 6. executar e avaliar seus resultados.

A primeira e a segunda tarefa consistem na identificação dos três componentes, agentes, ambiente, suas relações e as teorias utilizadas para embasar suas decisões. Ainda que haja uma grande diversidade de teorias na literatura, essa etapa é bastante desafiadora para modeladores. Além da dificuldade de identificar a teoria comportamental mais adequada para um determinado modelo, poucas são formalizadas como teorias computacionais (JAGER, ERNST, 2017). Como a maioria das teorias são baseadas em relações estatísticas, muitas vezes, é preciso traduzi-las para mecanismos causais que,

frequentemente, apresentam lacunas lógicas que são preenchidas por suposições para fazerem a simulação funcionar (JAGER, ERNST, 2017). Além disso, a maioria das teorias descrevem o comportamento humano a partir de motivadores comportamentais - resultados decorrentes de um comportamento que servem como motivadores do comportamento da próxima decisão - gerando *loopins* causais, muitas vezes, difíceis de serem modelados adequadamente. Outro dificultador em usar teorias fundamentadas em relações estatísticas está no desafio de se aplicar teorias baseadas em valores médios em modelos que abordam a heterogeneidade da população. Para maiores informações conferir AN (2012) e JAGER (2017).

A terceira tarefa, que envolve o desenvolvimento da estratégia de implementação, diz respeito a idealização da formalização das teorias comportamentais escolhidas para embasarem a tomada de decisão e a interação dos agentes. A estratégia pode ser apresentada através de um desenho da arquitetura do modelo explicitando as regras que irão reger o processo de decisão, os tipos de equações e análises que precisarão ser desenvolvidas e as bases de dados que serão utilizadas. Uma mesma teoria pode ser implementada diferenciando-se, por exemplo, na arquitetura do modelo, mudando a sequência das regras de decisão, na seleção dos fatores que supostamente influenciam a tomada de decisão, ou na coleta e/ou processamento dos dados empíricos (MUELDER, FILATOVA, 2018).

Os modelos baseados em agentes podem ser desenvolvidos através de softwares comuns, como Microsoft Excel e MATLAB, linguagens de programação, como Python e Java, ou também podem ser feitos utilizando *software* e *kits* de ferramentas projetados especificamente para estes modelos. Estes últimos são divididos em dois grupos, um composto por *softwares* usados para modelos de pequena escala ou prototipagem, como os programas Repast Simphony, NetLogo, StarLogo, e os *softwares* usados para modelos de larga escala, como Repast, Swarm, MASON, AnyLogic (MACAL, NORTH, 2009). A escolha da ferramenta dependerá da complexidade do modelo e dos recursos exigidos por ele, como interfaces gráficas, GIS e acesso à banco de dados, além da familiaridade do modelador com o programa escolhido, da disponibilidade de tempo e de recursos financeiros. Atualmente várias dessas plataformas são disponibilizadas gratuitamente como os *softwares* Repast, Swarm, MASON, NetLogo, entre outros (HEPPENSTALL *et al.*, 2012).

O *Netlogo*, programa criado por WILENSKY (1999), se destaca por ter sido projetado para ser usado tanto para fins educacionais quanto de pesquisas aplicadas. Isso faz com que a plataforma apresente uma interface e uma linguagem bastante intuitiva que permite que alunos e pesquisadores, mesmo que sem muita experiência em programação, sejam capazes de criarem seus próprios modelos. O programa roda em uma máquina virtual Java e usa uma versão modificada da linguagem de programação Logo, inspirada da linguagem Lisp (BANOS, LANG, MARILLEAU, 2015). Essas características fazem com que esta ferramenta seja uma das mais usadas para a modelagem ABM. Apesar de ser uma plataforma mais adequada para modelos de pequena escala e menos complexos, ela possibilita o aumento de suas funcionalidades através de extensões que permitem a interação com outras ferramentas. Essas interações podem envolver simples funções de leitura de arquivo (formato CSV, por exemplo) ou integração de dados representados em forma de vetor (GIS), ou integrações mais complexas diretamente com a funcionalidade de outros programas, como Matlab ou R.

A quarta tarefa, de coleta e processamento dos dados, compreende o desenvolvimento das regras e/ou equações que serão inseridas na modelagem, também conhecidas como os submodelos ou módulos do ABM. Dados empíricos podem ser usados tanto para alimentar um modelo, como também para validá-lo. Esses dados podem ser primários, coletados pelo pesquisador utilizando diferentes estratégias de pesquisas, qualitativos ou quantitativas, ou podem ser secundários, utilizando evidências já disponíveis (Boero e Squazzoni 2005). Devido a dificuldades de acesso a indivíduos ou instituições, restrições de tempo ou de orçamento, o uso de dados secundários ocorre com maior frequência. No entanto, em razão da dificuldade de se encontrar dados tão específicos e detalhados sobre um determinado comportamento, a disponibilidade de dados empíricos para estruturar ou validação os modelos é um dos maiores desafios dos modeladores.

A quinta tarefa, de validação, consiste no processo de garantir que os resultados do modelo correspondem ao mundo real. É muito utilizado em modelos que tem a finalidade de explicar fenômenos empíricos ou analisar políticas públicas. Esse processo compara dados da realidade sobre a macro dinâmica do sistema que está sendo investigada com os resultados da simulação a fim de garantir a confiabilidade no modelo (Boero e Squazzoni 2005). Essa tarefa, frequentemente, envolve a calibração. Este processo consiste em um ajuste fino dos parâmetros do modelo que objetiva selecionar

um único conjunto de parâmetros que validem os resultados o mais próximo aos dados reais.

A sexta tarefa, de executar e avaliar seus resultados, envolve a análise de sensibilidade do modelo. Ela avalia a influência de variáveis de entrada do modelo sobre a variabilidade dos resultados da simulação através de uma investigação sistemática sobre os efeitos de diferentes configurações dos parâmetros (LEE *et al.*, 2015). Além de avaliar a robustez do modelo, esta etapa ajuda a identificar quais parâmetros proporcionam maior impacto sobre os resultados e, assim, compreender as dinâmicas de causalidade do modelo (LIGMANN-ZIELINSKA *et al.*, 2020).

Apesar da validação, da calibração e da análise de sensibilidade serem tarefas distintas, uma está interligada com a outra, uma vez que o processo compreende na definição de parâmetros (CROOKS, CASTLE, BATTY, 2008). Diante desta proximidade, estas três etapas são reconhecidas como as mais desafiadoras da modelagem ABM (AN *et al.*, 2020). Muitos modelos não apresentam uma avaliação completa sobre a calibração e a validação, pois, muitas vezes, o número de parâmetros e suposições dos modelos superam a disponibilidade dos dados. Enquanto modelos ABM adotam estruturas cada vez mais diversificadas e ricas de informações, os dados necessários para testá-los ainda costumam ser escassos ou insuficientes (BATTY, TORRENS, 2005). Além disso, devido à complexidade das estruturas, muitas vezes compostos por diversos parâmetros que podem variar seus valores de inúmeras formas, existe um número infinito de combinações possíveis de serem analisadas.

Outra dificuldade que atravessa essas três tarefas está na enorme quantidade de dados produzidos pelo modelo. Por ser tipicamente um modelo estocástico baseado no método Monte Carlo², cada experimento exige que modelo seja rodado múltiplas vezes a fim de se atingir resultados com a robustez estatística necessária para se testar hipóteses. Isso desafia não só a análise dos resultados, mas também o desenho e a implementação do modelo. Um modelo mal estruturado pode levar a uma produção de dados desnecessariamente maior capaz de chegar às mesmas conclusões, ou a até menos, do que

² A Simulação de Monte Carlo é uma técnica para representar a solução de um problema como um parâmetro de uma população hipotética e, que usa uma sequência aleatória de números para construir uma amostra da população da qual estimativas estatísticas desse parâmetro possam ser obtidas (HALTON, 1970).

se poderia chegar utilizando dados mais enxutos resultantes de um modelo bem projetado. Ainda que haja uma carência de metodologias e orientações específicas sobre a apresentação e análise dos dados que sejam eficazes e capazes de auxiliar modeladores a alcançarem conclusões inovadoras, há estudos que apresentam métodos e estratégicas para auxiliar essas etapas como os de LEE *et al.* (2015), LIGMANN-ZIELINSKA *et al.* (2020) e FAGIOLO, WINDRUM, MONETA (2007).

A comunidade ABM destaca também outros desafios que envolvem a construção do modelo de forma geral como a transparência e a replicação dos modelos (AN, GRIMM, TURNER, 2020). ABMs sem transparência e sem a capacidade de replicabilidade dificultam a reprodução dos resultados, o que impossibilita, muitas vezes, a verificação e a validação de modelos. Isso também implica em maiores dificuldades em comparar ABMs, como identificar diferenças entre populações distintas usando o mesmo modelo, e consequentemente, a generalização de pontos comuns entre eles, reduzindo a utilidade destes modelos em testes de hipóteses e a sua capacidade como instrumento de formulação de teorias (AN *et al.*, 2014; RINDFUSS *et al.*, 2008). Além disso, modelos pouco transparentes prejudicam o avanço do conhecimento dentro deste campo por dificultarem que modelos possam ser estendidos, generalizados e replicados em outras áreas, impossibilitando haver um processo incremental de produção de conhecimento (HAUKE *et al.*, 2020).

Esses dois desafios podem ser auxiliados pela liberação do código e dos dados utilizados e fornecendo uma descrição detalhada do modelo. Atualmente há plataformas onde pesquisadores disponibilizam seus códigos abertamente, e protocolos que ajudam a padronizar a descrição dos modelos a fim de facilitar a compressão e percepção de semelhança e diferenças em relação a outros (AN, GRIMM, TURNER, 2020). O desenvolvimento do protocolo ODD (*Overview, Design concepts, and Details* - Visão Geral, Conceitos de Design e Detalhes), proposto por GRIMM *et al.* (2006; 2010), e o protocolo ODD + D (*Overview, Design concepts, and Detail, with the Decision-making extension*), uma expansão e refinamento do anterior voltado para a tomada de decisão humana elaborada por MÜLLER *et al.* (2013), melhoraram significativamente a transparência, a replicabilidade e a confiança nos resultados do ABM. HAUKE *et al.*, (2020), por exemplo, apresenta em seu estudo como a replicação de um modelo e o desenvolvimento subsequente de uma teoria podem ser promovidos por meio do uso do protocolo ODD.

Ainda que os ABM sejam uma metodologia recente e apresentem muitos desafios, o desenvolvimento desses modelos já se mostrou bastante promissor e necessário para representação de sistemas complexos. A sua capacidade intrínseca de incorporar informações a nível individual, incluindo variáveis espaciais e temporais, permitem a criação de relações distintas entre seus componentes, possibilitam interações não lineares, e a integração de dados e métodos de diversas disciplinas (AN *et al.*, 2005; NATIONAL RESEARCH COUNCIL, 2014). Além de contribuírem para o aumento da utilidade de modelos de simulação, uma vez que podem ser adaptados as necessidades de seus usuários (PARKER *et al.*, 2003), o modelo representa o comportamento humano de forma mais realista ao possibilitar a consideração da racionalidade limitada do indivíduo, a heterogeneidade da população, a habilidade dos indivíduos de aprender e se adaptar, entre outras (AN, 2012; FILATOVA, VERBURG, PARKER, 2013; GROENEVELD *et al.*, 2017).

2.3 Aplicações da modelagem

O ABM como uma ferramenta para auxiliar a formulação de políticas públicas ou na tomada de decisão está sendo cada vez mais utilizado, passando por diversas áreas da ciência, como na economia (DAWID, FAGIOLO, 2008; FREDERICK, 2013; LEBARON, WINKER, 2008), na educação (MAROULIS *et al.*, 2014), no sistema eleitoral (BENDOR *et al.*, 2000; LAVER, 2005), na saúde pública (TRACY, CERDÁ, KEYES, 2018), no setor elétrico (DOS SANTOS, SARAIVA, 2021) e na agricultura (PARKER, MANSON, *et al.*, 2003). Nessa perspectiva, seu uso para avaliar políticas climáticas também vem sendo explorado em diversas esferas. Métodos baseados em ABMs são aplicados, por exemplo, para analisar o impacto de políticas sobre emissões de GEE, como a saída dos EUA do acordo de Paris em 2017 (SPRINZ *et al.*, 2018; SÆLEN *et al.*, 2020), políticas de adaptação às mudanças climáticas, como o tempo para realizar a plantação e a colheita em fazendas agrícolas (AURBACHER *et al.*, 2013; TROOST, BERGER, 2014), além de estratégias de mitigação, como a internalização de custos das emissões de transporte (KICKHÖFER, KERN, 2015), o provimento de subsídios à geração de energia renovável e precificação de carbono (BARAZZA, STRACHAN, 2020), ou o aumento da eficiência na gestão e distribuição de energias renováveis (MOHAMMED, AL-BAZI, 2021).

Entre as políticas de mitigação, o ABM também é usado para abordar estratégias que visam mudanças nos padrões de consumo com o objetivo de diminuir as emissões de GEE pelo lado da demanda. Esses modelos são, frequentemente, usados para estudar mudanças comportamentais relacionadas ao consumo de energia, como na compra de eletrodomésticos mais eficientes (NIAMIR *et al.*, 2020), investimento em painéis solares (PEARCE, SLADE, 2018), ou uso de *smart homes* (WALZBERG *et al.*, 2019). No entanto, há poucos estudos que utilizam o ABM para avaliar o impacto de políticas que visam a mudança de hábitos alimentares.

No entanto, é frequentemente usada na área da saúde pública para estudar intervenções que promovam mudanças de comportamentos reconhecidos como fatores de risco para DCNT (YANG, 2019), entre eles o da alimentação não saudável (LANGELLIER *et al.*, 2019). Este tema é abordado analisando, principalmente, o combate a obesidade por meio de intervenções políticas que podem ser divididas em três categorias (ZHANG *et al.*, 2014): 1. medidas econômicas, como tributações ou subsídio a determinados alimentos ou o aumento da renda da população (BEHESHTI *et al.*, 2017; BLOK *et al.*, 2015; LANGELLIER *et al.*, 2017); 2. ambiente alimentar, por meio de políticas de zoneamento como o incentivo/restrição ao aumento do número de empreendimentos que ofereçam determinado tipo de alimentação (AUCHINCLOSS *et al.*, 2011; LI *et al.*, 2018; ORR, KAPLAN, GALEA, 2016), e; medidas que visam o combate às normas alimentares não saudáveis (ORR, PLAUT, 2014; TROGDON, ALLAIRE, 2014), como campanhas de marketing (LI, ZHANG, PAGÁN, 2016; WIDENER, METCALF, BAR-YAM, 2013), ou incentivos a educação a fim de aumentar a conscientização, seja através da educação formal (BLOK *et al.*, 2015; LANGELLIER *et al.*, 2017) ou em rótulos nutricionais (LEE *et al.*, 2019).

Esses modelos se distinguem nas escolhas dos fatores determinantes sobre a escolha alimentar, o quais podem ser relacionados ao alimento, ao indivíduo, ou a fatores socioculturais (CHEN, ANTONELLI, 2020; RANDALL, SANJUR, 1981; RIET *et al.*, 2011). Além disso, pelas teorias escolhidas para embasar o comportamento e as interações dos agentes como a teoria de multi-nível (KATAPODIS, ZHANG, *et al.*, 2019, ZHANG, GIABBANELLI, *et al.*, 2014), Teoria da Ação Racional - TRA (ORR, PLAUT, 2014) ou Teoria do Comportamento Planejado - TPB, (RICHETIN, SENGUPTA, *et al.*, 2010). E também pelos métodos escolhidos para formalizar estas teorias em teorias computacionais, como através de funções de utilidade (BLOK *et al.*, 2015; BURKE,

HEILAND, 2007) ou regressões (HAMMOND, ORNSTEIN, 2014; LANGELLIER, 2016). Além dessas diferenças, os modelos também podem monitorar e analisar diferentes variáveis, como calorias ingeridas (BLOK *et al.*, 2015), índice de massa corporal (ORR, PLAUT, 2014; ORR, KAPLAN, GALEA, 2016; TROGDON, ALLAIRE, 2014), quantidade de frutas e vegetais (LI, ZHANG, PAGÁN, 2016; LI *et al.*, 2018; WIDENER, METCALF, BAR-YAM, 2013), ou quantidade por grupos de alimentos (BEHESHTI, JONES-SMITH, IGUSA, 2017).

ZHANG *et al.*, 2014, por exemplo, desenvolveram um ABM para entender como a publicidade de alimentos, zoneamento, taxações e subsídios afetam a decisão das pessoas na Califórnia ao escolher entre alimentos saudáveis e não saudáveis. A cada dia, indivíduos interagem com seus amigos para trocarem opiniões sobre suas preferências de sabor e crenças relacionadas a saúde e, então, escolhem entre consumir frutas e vegetais ou alimentos processados (*fast foods*) considerando fatores cognitivos (preferências de sabor, crenças relacionadas a saúde e sensibilidade ao preço), espaciais (o raio de distância das lojas mais próximas), globais (preço dos alimentos) e demográficos (idade, sexo e nível de educação). O comportamento dos agentes é embasado pela teoria multinível e a influência social pela teoria “siga a média” (*follow-the-average*), onde o comportamento do agente é periodicamente ajustado para alinhar com o comportamento médio de sua rede social. A interação dos agentes é formalizada pela atualização das variáveis referentes aos fatores cognitivos e implementado através de uma média ponderada dessas variáveis entre os indivíduos pertencentes a mesma rede de interação. A tomada de decisão é formalizada utilizando uma regressão logística, a qual considera entre as suas variáveis independentes as dos fatores cognitivos. O modelo sugere que intervenções de promoção de normas sociais saudáveis podem ser mais eficazes na mudança de comportamentos alimentares do que políticas de precificação ou de zoneamento. Entretanto, o modelo ressalta incertezas devido as suas limitações quanto à falta de dados empíricos em relação a suscetibilidade das pessoas à influência de amigos e a campanhas de publicidade.

No âmbito das mudanças climáticas, BRAVO *et al.* (2013) desenvolveram um ABM para avaliar o efeito de políticas de precificação de carbono e de conscientização do consumidor na Itália sobre as suas emissões de GEE associadas a três domínios: no consumo de energia, no transporte e na alimentação. Nele, agentes decidem o tipo de consumo que irão optar em cada domínio de acordo com as suas próprias preferências e

com a influência de sua rede social. Os tipos de consumo variam numa escala de quatro níveis de impactos ambientais, com exceção do domínio da alimentação que possui cinco opções de consumo: cenário base (a dieta padrão dos italianos); alto impacto ambiental (dieta com alto consumo de proteína animal); impacto intermediário (dieta mediterrânea); baixo impacto (dieta vegetariana); e mais um nível intermediário referente a uma dieta saudável (orientada pelo guia alimentar da Itália). O modelo mostra que apesar da maior redução de emissão de GEE ter sido decorrente do domínio da alimentação ao aplicar a política econômica de precificação de carbono, a redução no número de agentes optando pela dieta de alto impacto se traduziu principalmente em uma maior adoção das dietas intermediárias, e não em dietas de baixo impacto, como ocorrido nos outros dois domínios. Embora o aumento do preço em itens de alto impacto ambiental, como carne, reduza seu consumo, os autores entendem que a escolha das pessoas de se tornarem totalmente vegetarianas depende também de valores e motivações pessoais.

GIBSON *et al.* (2020) e GIBSON *et al.* (2021) exploram em seu ABM a influência dos hábitos e das interações sociais no processo de tomada de decisão dos ingleses sobre a escolha do consumo de diferentes tipos de leite. O modelo tem o objetivo de reproduzir o consumo de 1974 a 2005 em que se observou as substituições do leite integral pelo desnatado e semidesnatado, a fim de se ter uma melhor compressão sobre os mecanismos na escolha destes produtos, assim como de opções de bebidas vegetais que substituem leite. O modelo testa duas abordagens metodológicas para determinar o processo de escolha, uma baseada em probabilidade e outra que estabelece limites a parâmetros que determinam a tomada de decisão, ambas compostas pela percepção dos impactos ambientais e à saúde.

Em relação ao consumo da carne, SCALCO *et al.* (2019) desenvolveram um ABM para simular o consumo de carne da população britânica e testar a efetividade de políticas de precificação e campanhas de sensibilização relacionadas ao impacto do consumo da carne à saúde, ao meio ambiente e a ética animal. O comportamento dos agentes é embasado pela teoria da ação racional (TRA), e, assim como ZHANG *et al.* (2014), a interação social pela FTA. A cada refeição, agentes trocam com colegas de trabalhos ou familiares as suas percepções quanto ao impacto do consumo da carne à saúde, ao meio ambiente e sobre a ética animal. Depois, eles decidem se vão comer uma refeição com ou sem carne considerando as suas características demográficas, as suas percepções e a variação do preço da carne. A interação social é implementada através de atualizações

das percepções realizada por meio do cálculo da média ponderada das variáveis pertencentes indivíduos que fazem parte das suas redes sociais. Já a tomada de decisão é feita utilizando uma regressão logística. O estudo conclui que o aumento do preço teve o maior efeito na redução do consumo carne, seguido pela campanha de sensibilização relacionada ao impacto à saúde. Entre as limitações do estudo pode-se citar a aleatoriedade embutida na construção das redes de colegas de trabalho e de familiares, a exclusão de pessoas abaixo de 18 anos, além das mesmas embutidos no estudo de ZHANG *et al.* (2014).

Os estudos conduzidos e identificados até o momento destacam o potencial da metodologia ABM em reproduzir comportamentos alimentares e como este instrumento pode ser útil para estudar políticas de mitigação de GEE referentes a mudanças no estilo de vida. Porém, apenas os estudos de GIBSON *et al.* (2020), GIBSON *et al.* (2021), BRAVO *et al.* (2013) e SCALCO *et al.* (2019) abordam a mudanças do comportamento alimentar com o foco na sustentabilidade, sendo apenas o último relativo ao consumo de carne vermelha. Acresce que estes estudos são maioritariamente aplicados ao contexto europeu, evidenciando a lacuna de pesquisas e aplicações para uma realidade do Sul global e economias emergentes, como o Brasil.

3 Metodologia

O modelo deste estudo foi desenvolvido através de uma adaptação do código e da aplicação de premissas e teorias utilizadas pelo modelo de SCALCO *et al.* (2019). Devido a diferença de disponibilidade de dados e do perfil da população objeto de estudo, modificações foram feitas para refletir a realidade brasileira. A metodologia iniciará apresentando a coleta e a tratamento dos dados (seção 3.1), a fim de expor ao leitor os dados disponíveis para o estudo. Em seguida, a seção 3.2 define os componentes e as teorias usadas para fundamentar o ABM. Depois, a seção 3.3 apresentará a estratégia de implementação do modelo, onde será explicitado as regras que irão reger o processo de decisão, os tipos de equações e análises que precisarão ser desenvolvidas. Em seguida, a seção 3.4 irá apresentar a implementação do modelo, onde será detalhado o processamento de dados para construir os módulos, assim como as funções para compor o código do modelo. Por fim, a seção 3.5 apresenta a metodologia seguida para realizar a análise de sensibilidade do modelo.

3.1 Coleta e tratamento das bases de dados

A coleta de dados para o desenvolvimento do ABM buscou construir uma base de dados em nível individual que retratasse o comportamento alimentar do brasileiro em relação ao consumo da carne bovina. Segundo o modelo de SCALCO *et al.* (2019), o estudo buscou dados que relacionassem os hábitos alimentares dos indivíduos com as suas crenças sobre o impacto ao meio ambiente e a variação do preço da carne.

As subseções a seguir apresentam as bases de dados disponíveis identificadas como as mais adequadas para o desenvolvimento do modelo, assim como a limpeza realizada para o desenvolvimento dos módulos e do código do ABM. A manipulação dos dados foi executada com a ferramenta R e interface do RStudio 1.3.1073; *software* gratuito de computação estatística e formulação gráfica baseado em linguagem S (R-PROJECT, 2021). Já o arquivo *shapefile* foi processado com a ferramenta QGIS 3.18.1; *software* gratuito de Sistema de Informação Geográfica - SIG (QGIS, 2021).

3.1.1 Microdados da Pesquisa de Orçamentos Familiares

A Pesquisa de Orçamentos Familiares (POF), realizada pelo IBGE, produz informações sobre a composição orçamentária doméstica segundo as características individuais e dos domicílios, a partir da avaliação de hábitos de consumo, estruturas de gastos, de rendimentos e parte da variação patrimonial das famílias. Além das informações diretamente associadas à estrutura orçamentária, também são investigadas várias características dos domicílios e das famílias, incluindo a autoavaliação subjetiva sobre qualidade de vida (IBGE, 2021a).

A pesquisa tem como objetivo disponibilizar informações sobre a composição orçamentária doméstica e identificar o perfil nutricional e de condições de vida da população brasileira. Seus resultados apresentam um amplo potencial de uso. Contribuem com as informações necessárias para o cálculo dos índices de preços como o Índice Nacional de Preços ao Consumidor Amplo (IPCA), fornecem informações para subsidiar o planejamento de políticas públicas nos campos da nutrição, saúde, moradia, além de servirem como base dados para diversos estudos (IBGE, 2021a).

A POF é uma pesquisa domiciliar de abrangência nacional realizada por amostragem. Sendo assim, apenas alguns domicílios da população são selecionados e investigados, e as conclusões obtidas são expandidas para toda a população. As informações são obtidas diretamente nos domicílios selecionados, por meio de autocompletamento de formulários e entrevistas junto aos moradores. A pesquisa tem uma duração de 12 meses, onde cada domicílio é acompanhado durante um período de nove dias consecutivos, com uma média de quatro visitas por parte do agente de coleta do IBGE. A pesquisa ocorre a cada seis a oito anos, e já publicou seis edições até o momento. Para embasar o modelo optou-se por usar os dados da POF mais recente, lançada em outubro de 2019 e referente ao período de julho 2017 a julho de 2018 (IBGE, 2019).

Para selecionar os domicílios investigados na pesquisa, a POF 2017-2018, adotou um plano amostral denominado como conglomerado em dois estágios. Primeiro, foi selecionado da amostra mestre - uma base comum a várias pesquisas domiciliares do IBGE - as unidades primárias de amostragem (UPAs) que correspondem a um conjunto

de setores censitários³ da base geográfica do Censo Demográfico 2010 (IBGE, 2010). Segundo, foram selecionados por amostragem aleatória simples as unidades secundárias de cada uma das UPAs selecionadas. As unidades secundárias são determinadas como os domicílios particulares permanentes, definido como a habitação de uma ou mais pessoas, ligadas por laços de parentesco, dependência doméstica ou normas de convivência. Para cada UPA de área urbana foram selecionados 13 domicílios, e para as de área rural 17 domicílios. Ao final, foram selecionados no Brasil 5.504 UPA e um total de 57.920 domicílios entrevistados. É importante ressaltar que esta estrutura da amostra propicia a publicação de resultados nos níveis Brasil, Grandes Regiões (Norte, Nordeste, Sudeste, Sul e Centro-Oeste) e por situações urbana e rural.

Os instrumentos de coleta utilizados na POF 2017-2018 são organizados em 7 questionários segundo o tipo de informação pesquisada, conforme apresentado na Tabela 1. O questionário POF 7, referente ao “Bloco de consumo alimentar pessoal”, apresenta alguns requisitos de análise singulares que o difere em alguns aspectos dos demais questionários. Para avaliar o consumo alimentar, foram aplicados dois inquéritos recordatórios de 24 horas em dias não consecutivos em que os participantes eram indagados, em entrevistas pessoais, sobre todos os alimentos e bebidas consumidos no dia anterior em cada uma das duas entrevistas. Por demandar uma quantidade maior de trabalho dos agentes de pesquisa, este questionário foi aplicado em moradores com 10 anos ou mais de idade de uma subamostra de domicílios selecionados aleatoriamente da amostra total da pesquisa. Assim, foi estabelecido que o “Bloco de consumo alimentar pessoal” seria aplicado em cinco dos 13 domicílios selecionados das UPAs de áreas urbanas, e seis dos 17 domicílios das UPAs de áreas rurais. Logo, este questionário foi aplicado em 20.112 domicílios dos 57.920, totalizando em 46.164 indivíduos entrevistados.

Os questionários apresentam perguntas de caráter qualitativo, com opções pré-elaboradas para as respostas, e quantitativo, com unidades de medida para padronização das respostas. Aqueles que dizem a respeito à família ou aos domicílios são aplicados apenas a um membro determinado como referência. Por isso, é dito que as microunidades

³ Setores censitários: “O setor censitário é a unidade territorial estabelecida para fins de controle cadastral, formado por área contínua, situada em um único quadro urbano ou rural, com dimensão e número de domicílios que permitam o levantamento por um recenseador.” (IBGE, 2010)

de análise da POF variam de acordo com o que está sendo analisado no questionário, podendo variar entre indivíduos, famílias e domicílios. O entendimento de famílias na pesquisa é definido pelo termo “unidades de consumos” (UCs). A UC compreende um único morador ou um conjunto de moradores que utilizam um mesmo estoque de alimentos e/ou realizam um conjunto de despesas alimentares comuns. Sendo assim, um domicílio investigado pela pesquisa pode apresentar mais de uma família residente. Os microdados da POF são disponibilizados no site do IBGE no formato de texto corrido (*.txt*) e segmentam os sete questionários em doze registros (IBGE, 2019). A estrutura da POF, em relação aos questionários, registros e microunidades analisadas, é apresentada na Tabela 1.

Tabela 1: Estrutura Questionários e Registros da POF

QUESTIONÁRIO	TEMAS INVESTIGADOS	MICRO-UNIDADE	REGISTRO (MICRODADOS)
POF 1 - Características do domicílio e dos moradores	Características gerais do domicílio, como por exemplo, o material que predomina na construção, número de cômodos etc., e características os moradores, como cor, sexo, escolaridade entre outros.	Domicílio Indivíduo	DOMICÍLIO MORADOR
POF 2 - Aquisição coletiva	Aquisições monetária e não monetária de produtos de uso comum da família cuja aquisição não é frequente como eletrodomésticos, móveis, etc. Também se 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.	Unidade de Consumo (Família)	ALUGUEL ESTIMADO INVENTARIO DESPESA COLETIVA SERVICO_NAO_M ONETARIO_POF2
POF 3 - Caderneta de aquisição coletiva	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.	Unidade de Consumo (Família)	CADERNETA COLETIVA
POF 4 - Aquisição individual	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.	Indivíduo	DESPESA INDIVIDUAL RESTRICAO_PRODUTOS_SERVICOS_SAUDADE SERVICO_NAO_M ONETARIO_POF4
POF 5 - Trabalho e rendimento individual	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.	Indivíduo	RENDIMENTO TRABALHO OUTROS RENDIMENTOS
POF 6 - Avaliação das condições de vida	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.	Unidade de Consumo (Família)	CONDICAO DE VIDA
POF 7 - Bloco de consumo alimentar pessoal	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.	Indivíduo	CARACTERISTICAS DA DIETA CONSUMO ALIMENTAR

Fonte: CRUZ (2021).

O IBGE também fornece, junto aos arquivos texto, documentos complementares que auxiliam no entendimento dos microdados. Dentre eles, se destacam os arquivos “Dicionário de Variáveis” e “Cadastro de Produtos”, “Cadastro de Produtos do Consumo Alimentar”, os arquivos chamados de “Tradutores” e a “Classificação dos grupos de Consumo Alimentar”, todos em *Excel*.

O “Dicionário de Variáveis” apresenta os códigos estabelecidos para as perguntas e suas respostas possíveis, assim como todas as outras informações necessárias para transformar os arquivos textos em tabelas de dados. O “Cadastro de Produtos” apresenta

mais de 13 mil produtos, definidos antes da pesquisa a partir de produtos já citados em POFs anteriores, incluindo variações ou termos regionais para um mesmo produto, além de outros novos no mercado. Este cadastro auxilia tanto no momento da coleta, ajudando os informantes a lembrar de suas respectivas aquisições, como também no momento da leitura e interpretação das respostas através da identificação dos códigos computados nos microdados. O “Cadastro de Produtos do Consumo Alimentar”, composto por 1800 itens, segue a mesma lógica do anterior, porém, este é usado apenas para o questionário “POF 7 - Bloco de consumo alimentar pessoal”.

Os documentos chamados de tradutores descrevem os produtos do “cadastro de produtos” de diferentes formas considerando diferentes níveis de agregação. Os produtos, identificados por números de 7 dígitos, são descritos nos tradutores através dos cinco primeiros dígitos, enquanto os 2 últimos especificam os produtos conforme eles foram citados pelos entrevistados. Por exemplo, o questionário “POF 3 - Caderneta de aquisição coletiva” apresenta entre suas respostas os produtos: “alcatra” (7100301), “alcatra bovina” (7100302), “ponta de alcatra” (7100303), “alcatra com osso” (7100304) e “miolo de alcatra” (7100305). O documento “Tradutor Aquisição Alimentar” identifica todos estes produtos pelos mesmos cinco primeiros dígitos (71003) e os descrevem da mesma forma em 3 níveis diferentes. No nível 1, eles são descritos como “carnes”, no nível 2, como “carne de primeira” e, no nível 3, como “alcatra”. Há dois documentos tradutores na POF referentes a alimentação: o “Tradutor Aquisição Alimentar” e o “Tradutor Alimentação”. O primeiro auxilia apenas na descrição dos produtos citados no registro “Caderneta Coletiva”, e segundo nos produtos dos registros “Despesa Individual” e também na “Caderneta Coletiva”. Já o arquivo “Classificação dos grupos de Consumo Alimentar” agrupa os produtos do “Cadastro de Produtos do Consumo Alimentar” em 116 descrições, porém sem seguirem uma lógica orientada pelos seus códigos.

Após compreender o funcionamento da POF e a disposição de seus microdados, o primeiro passo foi identificar os registros que iriam prover os dados necessários e mais adequados para a construção do ABM. Foi identificado a necessidade de trabalhar com três registros: “consumo alimentar” (questionário POF 7), “morador” (questionário POF 1) e “rendimento_trabalho” (questionário POF 5). O primeiro, responsável por fornecer dados sobre o comportamento alimentar da população, o segundo dados demográficos, e o terceiro apenas para identificar indivíduos que estão empregados ou desempregados. Esses registros foram transformados do formato texto para tabela de dados (“*data tables*”)

a partir do desenvolvimento de rotinas (“scripts” na linguagem de programação estatística), o quais são necessárias para conseguir realizar a leitura e fazer análises estatísticas dessas respostas.

A tabela de dados é uma matriz capaz de conter grande quantidade de informação, cujas colunas representam as perguntas dos questionários (variáveis) e, as linhas, as respostas (observações) de cada microunidade. A tabela do registro “consumo alimentar”, por exemplo, apresenta um total de 1.115.390 observações e 67 variáveis, sendo cada observação um único alimento consumido por um indivíduo, e cada variável uma caracterização sobre o seu consumo, como a refeição, a hora e o local, ou até mesmo se ele foi acompanhado com azeite ou manteiga. Já a tabela do registro “morador”, apresenta um total de 178.431 51 observações e 51 colunas, sendo cada observação um indivíduo, e cada variável características sobre ele, como seu gênero ou idade.

Uma vez que os dados foram coletados, foi realizada a sua limpeza, onde as variáveis desejadas e necessárias foram selecionadas, filtradas, reagrupadas, e os dados desnecessários e imprecisos removidos. Assim, foram desenvolvidas duas tabelas - a Tabela Indivíduos (Tabela 2) e a Tabela Alimentação (Tabela 4) - as quais foram usadas tanto para o desenvolvimento dos módulos, como também como dados de entrada do modelo.

A Tabela Indivíduos (Tabela 2) foi criada com o objetivo de armazenar todas as informações que caracterizam os indivíduos. Nela foram selecionados apenas aqueles que participaram das entrevistas do bloco do consumo alimentar da POF e maiores de 18 anos, totalizando 39.371 indivíduos (observações), e 14 variáveis (colunas). Algumas variáveis foram desenvolvidas a partir da manipulação de um grupo de variáveis, que são resumidas na Tabela 2. Para a melhor compressão do modelo, é importante destacar algumas delas.

Como a POF mantém o sigilo dos entrevistados, foi necessário criar em cada registro as variáveis “id indivíduos” e “id famílias” para que variáveis de diferentes registros fossem reconhecidas como pertencentes a um mesmo indivíduo. Estas foram elaborados a partir da síntese de variáveis que caracterizam os entrevistados de forma anônima dentro da amostra da pesquisa, mas que ao serem unificadas compõe um código que garantem a exclusividade e identificação dos entrevistados e de suas famílias.

Tabela 2: Variáveis e Categorias da Tabela Indivíduos

VARIÁVEIS FINAIS	CATEGORIAS FINAIS	VARIÁVEIS ORIGINAIS (USADAS PARA ELABORAR AS FINAIS)	REGISTROS DAS VARIÁVEIS ORIGINAIS
Id indivíduo	(nº com 12 a 14 dígitos)	Código da unidade primária Número do domicílio Número da UC Código do informante	
Id família	(nº com 11 a 12 dígitos)	Código da unidade primária Número do domicílio Número da UC	
Classe de renda	1 (classe alta - 15% com maior renda da UF); 2 (classe média - 35% com renda intermediária UF); 3 (classe baixa - 50% com menor renda da UF)	Renda Total	CONSUMO_ALIMENTAR
Fator de Expansão da amostra	(1,65585; 107.836,4)	Original	
Dieta	0 (vegetariano) 1 (não vegetariano)	Tipo de alimento Quantidade do alimento	
Macrorregião	1 (Norte); 2 (Nordeste); 3 (Sudeste); 4 (Sul); 5 (Centro-Oeste)	Original	
Unidade federativa	11 (RO);12 (AC); 13 (AM); 14 (RR); 15 (PA); 16 (AP); 17 (TO); 21 (MA); 22 (PI); 23 (CE); 24 (RN); 25 (PB); 26 (PE); 27 (AL); 28 (SE); 29 (BA); 31 (MG); 32 (ES); 33 (RJ); 35 (SP); 41 (PR); 42 (SC); 43 (RS); 50 (MS); 51 (MG); 52 (GO); 53 (DF)	Original	
Situação de domicílio	1 (Urbano); 2 (Rural)	Original	
Posição na família	1 (Chefe da família); 0 (Outros)	Posição na família	
Gênero	1 (Masculino); 2 (Feminino)	Original	
Idade	18 a 98 anos	Original	MORADOR
Grupo de Idade	1 (18 a 39 anos); 2 (40 a 59 anos);3 (60 a 98 anos)	Idade	
Nível de Escolaridade	1 (nível baixo - Sem educação ou ensino fundamental incompleto); 2 (nível médio - ensino fundamental completo ou ensino médio incompleto); 3 (nível alto - ensino médio completo ou superior incompleto ou completo)	Frequenta escola ou creche Curso que frequenta Frequentou escola ou creche Curso mais elevado que frequentou Conclusão do curso mais elevado	
Ocupação	1 (Empregado); 0 (Desempregado)	Código da unidade primária Número do domicílio Número da UC Código do informante	RENDIMENTO_TRABALHO

Fonte: Elaboração própria (2022).

A variável classe de renda foi elaborada a partir da variável “renda total” da POF, estratificando esta em três grupos com o objetivo de compatibilizar estes dados com a elasticidade-preço da carne calculada por PINTOS-PAYERAS (2009), que também foi utilizada pelo modelo conforme será explicado mais a frente. PINTOS-PAYERAS (2009) define a elasticidade-preço da carne bovina a partir de dados da POF de 2002-2003, buscando captar as diferenças no comportamento dos consumidores de classes sociais distintas. Este foi o estudo mais recente encontrado na literatura para determinar a elasticidade-preço do alimento investigado no modelo que considerasse o nível de desagregação desejado sobre as classes. Para classificar a renda da população, o autor prefere não utilizar estratos fixos, uma vez que podem representar proporções da população de diferentes estados de forma muito desigual. Por exemplo, de acordo com os dados de seu trabalho, se o estrato fosse delimitado por uma renda familiar per capita superior a R\$1.190, este valor representaria 95% da população da região metropolitana de Belém e apenas 30 % do Rio de Janeiro. Por isso, o autor calcula a elasticidade-preço para três grupos de renda o quais classificam a renda familiar per capita em quartis calculados por estado, eles são: (1) os 15% com maior renda dentro da UF; (2) os 35% seguintes; e (3) os 50% com menor renda dentro da UF. A Tabela 3 apresenta os limites destes estratos para a POF 2017-2018, sendo, portanto, o grupo 1 composto por indivíduos que apresentam uma renda superior aos 85% da população do seu estado, o grupo 2 por aqueles com renda entre os 85% e 50%, e o grupo 3 abaixo de 50%.

Tabela 3: Quartis 50% e 85% da renda familiar per capita por Unidade Federativa da POF 2017-2018

UF	Renda máxima dos 50% população da UF (quartil 0,5)	Renda máxima dos 85% população da UF (quartil 0,85)
Rondônia	R\$ 845,66	R\$ 1966,37
Acre	R\$ 768,09	R\$ 2238,2
Amazonas	R\$ 604,82	R\$ 1691,83
Roraima	R\$ 736,13	R\$ 2190,44
Pará	R\$ 616,05	R\$ 1472,31
Amapá	R\$ 666,5	R\$ 1666,85
Tocantins	R\$ 660,05	R\$ 1281,74
Maranhão	R\$ 611,02	R\$ 1343,82
Piauí	R\$ 717,38	R\$ 1534,31
Ceará	R\$ 712,79	R\$ 1494,17
Rio Grande do Norte	R\$ 847,21	R\$ 1974,05
Paraíba	R\$ 706,21	R\$ 1719,95
Pernambuco	R\$ 803,04	R\$ 1934,03
Alagoas	R\$ 602,61	R\$ 1433,1
Sergipe	R\$ 1007,66	R\$ 2235,65
Bahia	R\$ 860,52	R\$ 2104,61
Minas Gerais	R\$ 1181,38	R\$ 2534,99
Espírito Santo	R\$ 1190,35	R\$ 2693,02
Rio de Janeiro	R\$ 1161,38	R\$ 3339,35
São Paulo	R\$ 1524,97	R\$ 4039,78
Paraná	R\$ 1453,06	R\$ 3163,05
Santa Catarina	R\$ 1601,58	R\$ 3444,57
Rio Grande do Sul	R\$ 1585,05	R\$ 3600,93
Mato Grosso do Sul	R\$ 1478,21	R\$ 3010,23
Mato Grosso	R\$ 1276,36	R\$ 2817,97
Goiás	R\$ 1343,29	R\$ 2699,47
Distrito Federal	R\$ 1957,65	R\$ 7979,2

Fonte: Elaboração própria (2022).

A variável “fator de expansão”, apesar de não ser uma variável explanatória, também merece destaque. Em função da POF ser uma pesquisa domiciliar realizada por amostragem, cada domicílio da amostra representa um determinado número de domicílios da população de onde a amostra é retirada. Por isso, a pesquisa calcula o fator de expansão para cada domicílio e depois atribui a cada unidade de consumo e pessoa. Assim, é possível calcular estimativas de totais para qualquer variável investigada na pesquisa para qualquer unidade analisada (domicílio, unidade de consumo ou pessoa). Também é importante destacar o desenvolvimento da variável “dieta”, que define se o indivíduo segue ou não uma dieta vegetariana. Porém, para explicar a construção desta variável é preciso explicar antes o processo da elaboração da segunda tabela sobre a alimentação dos indivíduos.

A Tabela Alimentação (Tabela 4) foi criada para conter todos os alimentos consumidos pelos indivíduos, conforme o registro já é apresentado. Sendo assim, não foi necessário buscar dados de outros registros e nem combinar diferentes variáveis para

compor uma, com exceção da variável “id indivíduos”. Neste caso, as variáveis selecionadas tiveram apenas as suas categorias agregadas ou filtradas, conforme apresentado na Tabela 4. Dentre estas cabe destacar as variáveis “Tipo de alimento” e “Código da ocasião de consumo”.

Tabela 4: Variáveis e Categorias da Tabela Alimentação

VARIÁVEIS FINAIS	CATEGORIAS FINAIS ADOTADAS NESTE ESTUDO	VARIÁVEIS ORIGINAIS (USADAS PARA ELABORAR AS FINAIS)
Id indivíduo	(nº com 12 a 14 dígitos)	Código da unidade primária Número do domicílio Número da UC Código do informante
Fator de Expansão	(1,65585; 107.836,4)	Original
Quantidade do alimento	Gramas	Original
VARIÁVEIS FINAIS (ORIGINAIS SELECIONADAS)	CATEGORIAS FINAIS (ORIGINAIS FILTRADAS OU AGRUPADAS)	CATEGORIAS ORIGINAIS
Tipo de alimento	Descrição nova (combinação das descrições do nível 1 e 2 do tradutor “aquisição alimentar domiciliar”)	códigos do “cadastro de produtos”
Código da Ocasão de consumo	- 1 (Almoço) - 2 (Jantar) - - - 1 (Em casa ou levado de casa)	1 (Café da manhã) 2 (Almoço) 3 (Lanche) 4 (Jantar) 5 (Ceia) 6 (Outra ocasião) 9 (Não determinado) 1 (Em casa ou levado de casa) 2 (Merenda escolar) 3 (Restaurante à quilo) 4 (Cantina, bar, lanchonete) 5 (Restaurante - outros) 6 (Vendedores ambulantes) 7 (Fora de casa - outros) 9 (Não determinado)
Código do Local de refeição	2 (Fora de casa)	Segunda-Feira Terça-Feira Quarta-Feira Quinta-Feira Sexta-Feira Sábado Domingo
Dia da semana do Consumo do alimento	0 (Dia de semana) 1 (Fim de semana)	

Fonte: Elaboração própria (2022).

A variável “Tipo de alimento” foi elaborada para descrever os códigos que identificam o alimento consumido com o objetivo de identificar o consumo da carne bovina. Esta descrição foi elaborada a partir da combinação das descrições dos níveis 1 e 2 do tradutor “aquisição alimentar domiciliar”, originalmente oferecido para descrever os produtos do registro “caderneta_coletiva”. Optou-se por não utilizar o documento

“Classificação dos grupos de Consumo Alimentar”, fornecido como um tradutor para o respectivo registro, devido a melhor descrição do outro documento referente às proteínas animais. O tradutor escolhido descreve estes produtos a um maior nível de desagregação, e portanto, possibilita maior liberdade para reagrupa-los da forma mais interessante para o modelo. Além disso, também oferece um maior nível de agregação em relação aos outros alimentos, o que permite maior simplificação dos dados que não são do interesse da análise.

Nesta perspectiva, os níveis 1 e 2 de descrição do tradutor “aquisição alimentar” foram simplificados em uma única tradução com objetivo de descrever as proteínas animais com maior nível de detalhamento. De forma geral, optou-se por descrever os alimentos conforme o apresentado no nível 1, exceto para as descrições das “carnes”, “Víceras” e “Aves e ovos”. Estas três foram substituídas por outras cinco (“Carne bovina”, “Carne suína”, “Carnes de outros animais”, “Aves” e “Ovos”) criadas partir do reagrupamento de suas descrições no nível 2, como ilustrado na Figura 3. O problema de não se utilizar o respectivo tradutor do registro, é que alguns produtos listados no registro não são traduzidos em outros tradutores que não o seu próprio. Por isso, 284 produtos não encontrados foram descritos manualmente conforme a nova descrição.

DESCRIÇÃO - NÍVEL 1	DESCRIÇÃO - NÍVEL 1	DESCRIÇÃO - NÍVEL 2	DESCRIÇÃO NOVA ADOTADA NESTE ESTUDO	DESCRIÇÃO NOVA ADOTADA NESTE ESTUDO
Cereais e leguminosas	Carnes	Carnes bovinas de primeira		Cereais e leguminosas
Hortaliças	Carnes	Carnes bovinas de segunda	Carne Bovina	Hortaliças
Frutas	Carnes	Carnes bovinas outras		Frutas
Cocos, castanhas e nozes	Vísceras	Vísceras bovinas		Cocos, castanhas e nozes
Farinhas, féculas e massas	Carnes	Carnes suínas com e sem osso	Carne Suína	Farinhas, féculas e massas
Panificados	Carnes	Carnes suínas outras		Panificados
Laticínios	Vísceras	Vísceras suínas		Laticínios
Açúcares, doces e produtos de conf.	Carnes	Carnes de outros animais	Carnes de outros animais	Açúcares, doces e produtos de conf.
Sais e condimentos	Vísceras	Outras vísceras		Sais e condimentos
Óleos e Gorduras	Aves e ovos	Aves	Aves	Óleos e Gorduras
Bebidas e infusões	Aves e ovos	Ovos	Ovos	Bebidas e infusões
Alimentos preparados e misturas industriais				Alimentos preparados e misturas industriais
Outros produtos				Outros produtos
Pescados				Pescados
Carnes			Carne Bovina	
Vísceras			Carne Suína	
Aves e ovos			Carnes de outros animais	
			Aves	
			Ovos	

Figura 3: Descritores do tradutor “aquisição alimentar” e seu reagrupamento em uma nova descrição

Fonte: Elaboração própria (2022).

Diante dessa nova descrição dos alimentos, foi observado que 96,78% de toda a carne bovina consumida pelos participantes da pesquisa encontrava-se nas refeições de almoço e jantar. Por isso optou-se por simplificar as categorias da variável “Código da ocasião de consumo” filtrando estas duas refeições, removendo as observações das outras.

A variável “dieta” presente na tabela “Perfil dos Indivíduos” (Tabela 2) também foi criada a partir da descrição dos alimentos. Apesar do nível de detalhamento fornecido pela POF em relação consumo alimentar, não há uma pergunta que defina se os participantes seguem uma determinada dieta que restrinja algum tipo de alimento específico. O registro “características da dieta” chega a abordar o tema, porém, apenas no que tange necessidades médicas como dietas para pressão alta, para controle colesterol, por conta de diabetes ou outra necessidade, além de dietas para emagrecimento. No entanto, a POF não questiona se a pessoa segue uma dieta vegana, vegetariana, pescetariana, flexetariana ou outras neste sentido.

Não há nenhuma pesquisa oficial no Brasil que estime o número de vegetarianos. A pesquisa mais recente sobre o assunto, conduzida pelo IBOPE Inteligência em abril de

2018, publicou que 14% da população brasileira se declara vegetariana. Este número foi estimado a partir da afirmação “sou vegetariano” em que, dos 2002 entrevistados, 8% responderam que “concordam totalmente” e 6% que “concordam parcialmente”. Apesar da pesquisa ser usada como a maior referência, até então, para a estimativa da população vegetariana, a pergunta usada para definir a dieta pode ser entendida de diferentes formas por parte dos entrevistados.

O vegetarianismo apresenta um conceito bastante amplo. A Sociedade Vegetariana Brasileira (SVB, 2020) o define como um regime alimentar que exclui todos os produtos de origem animal. No entanto, devido ao dinamismo da linguagem, ela reconhece variações de interpretação do termo, como o ovolactovegetarianismo (utiliza ovos, leite e laticínios), o lactovegetarianismo (utiliza leite e laticínios), o ovovegetarianismo (utiliza ovos) e o vegetarianismo estrito ou veganismo (não utiliza nenhum produto de origem animal). De acordo com o senso comum, o termo é frequentemente utilizado para se referir a uma dieta isenta de carnes, entendendo-se muitas vezes, erroneamente, que a palavra carne inclui apenas carnes vermelhas, ou só exclui peixes e frutos do mar. Além disso, há também pessoas que se consideram vegetarianas por comerem carne raramente.

Diante deste contexto, optou-se por considerar vegetariano neste estudo todos os indivíduos que não consumiram nos dois dias investigados pela pesquisa alimentos descritos como “carne bovina”, “carne suína”, “aves” e “carnes de outros animais”. Desta forma, foi estimado cerca de 9,52% da população brasileira como vegetariana, sendo 7,04% sem incluir a descriptor “pescados”. Um número razoável ao se comparar com o resultado do IBOPE que incluem aqueles que “concordam totalmente” com a pergunta da pesquisa.

3.1.2 Mudanças Climáticas na Percepção dos Brasileiros

A pesquisa Mudanças Climáticas na Percepção dos Brasileiros, do Instituto de Tecnologia e Sociedade (ITS, 2021) em parceria com *Yale Program on Climate Change Communication*, tem o objetivo de compreender o que a população brasileira pensa a respeito de questões relativas ao clima e ao meio ambiente. A pesquisa faz um levantamento nacional de dados inédito que abordam questões como nível de preocupação relacionado ao meio ambiente, o entendimento sobre as causas das

mudanças climáticas, quem poderia contribuir na busca de resoluções destes problemas, e muitas outras.

A pesquisa é representativa para população brasileira com mais de 18 anos, e também é feita por amostragem, sendo esta formada por 2.600 indivíduos selecionados aleatoriamente. Os fatores de expansão da amostra do estudo foram calculados pelo IBOPE Inteligência, com base em dados da Pesquisa Nacional por Amostra de Domicílio (PNAD) do IBGE. A coleta dos dados foi feita através de entrevistas telefônicas utilizando o sistema C.A.T.I. (*Computer Assisted Telephone Interviewing*) com uma duração média de 19 minutos, realizadas entre os dias 24 de setembro a 16 de outubro de 2020. O questionário pode ser dividido em 3 partes:

1. Características Demográficas dos participantes: essas informações incluem sexo, idade, UF, escolaridade, raça, religião, disponibilidade de internet, e perguntas referente a classificação econômica segundo Critério de Classificação Econômica Brasil (CCEB) de 2015.
2. Percepções quanto ao Aquecimento global: 14 questões relativas ao nível de preocupação em relação ao meio ambiente, ao aquecimento global e as mudanças climáticas, assim como os seus conhecimentos sobre assunto, causas, impactos sociais e ambientais, e os maiores protagonista na resolução do problema.
3. Percepções quanto as Queimadas na Amazônia: 7 questões relativas as queimadas na Amazônia, como o conhecimento sobre o problema, suas causas, maiores responsáveis, seus impactos, e os maiores protagonista na resolução do problema.

Os dados da pesquisa são disponibilizados pelo ITS, mediante solicitação, em um único arquivo gerado pelo software SPSS, na extensão “.sav”. Estes dados foram primeiramente convertidos para o formato de tabela de dados do software R com um total de 2600 observações e 77 variáveis que foram tratadas em seguida. As variáveis relativas as características dos indivíduos foram selecionadas e tratadas conforme o realizado na base da POF, com exceção da variável classe de renda que não foi adaptada. Já as variáveis referentes as percepções dos brasileiros às mudanças climáticas, selecionou-se apenas a variável relativa à pergunta “O quanto você considera que está preocupado(a) com o meio ambiente atualmente?”, em que foi excluída apenas duas observações em que os entrevistados deixaram em branco ou responderam que não sabem. A Tabela 5 apresenta as variáveis selecionadas e adaptadas.

Tabela 5: Variáveis e Categorias da Tabela “Preocupação ambiental”

VARIÁVEIS	CATEGORIAS
Macrorregião	1 (Norte); 2 (Nordeste); 3 (Sudeste); 4 (Sul); 5 (Centro-Oeste)
Unidade federativa	11 (RO); 12 (AC); 13 (AM); 14 (RR); 15 (PA); 16 (AP); 17 (TO); 21 (MA); 22 (PI); 23 (CE); 24 (RN); 25 (PB); 26 (PE); 27 (AL); 28 (SE); 29 (BA); 31 (MG); 32 (ES); 33 (RJ); 35 (SP); 41 (PR); 42 (SC); 43 (RS); 50 (MS); 51 (MG); 52 (GO); 53 (DF)
Área dos domicílios	1 (Urbano); 2 (Rural)
Gênero	1 (Masculino); 2 (Feminino)
Idade	18 a 98 anos
Grupos de Idade	1 (18 a 39 anos); 2 (40 a 59 anos); 3 (60 a 98 anos)
Nível de Escolaridade	1 (Sem educação ou ensino fundamental incompleto); 2 (ensino fundamental completo ou ensino médio incompleto); 3 (ensino médio completo ou superior incompleto ou completo)
Classe de renda	1 (A, B1 e B2); 2 (C1 e C2); 3 (D e E)
Preocupação ambiental (O quanto você considera que está preocupada com o meio ambiente atualmente?)	1 (Nada preocupada); 2 (Um pouco preocupada); 3 (Preocupada); 4 (Muito preocupada);

Fonte: Elaboração própria (2022).

3.1.3 Índice de Preços ao Consumidor Amplo

O Sistema Nacional de Índices de Preços ao Consumidor (SNIPC), desenvolvido pelo IBGE, acompanha continuamente e sistematicamente a variação de preços de um conjunto de produtos e serviços mais consumidos pelas famílias de determinadas faixas de renda, a fim de produzir índices de preços ao consumidor, que servem para atualizar os valores monetários.

O Índice de Preços ao Consumidor Amplo (IPCA), um dos índices medidos pelo SNIPC, tem o objetivo de medir a inflação de um conjunto de produtos e serviços comercializados no varejo. Sua coleta de preços se dá do dia 1º ao dia 30, e sua população objetivo abrange as famílias com rendimentos de 1 a 40 salários mínimos e residentes nas áreas urbanas de regiões metropolitanas do país. A pesquisa é realizada no Rio de Janeiro, Porto Alegre, Belo Horizonte, Recife, São Paulo, Belém, Fortaleza, Salvador, Curitiba e Vitória, Goiânia, Campo Grande e do Distrito Federal.

A divulgação do IPCA é mensal, e seus resultados são divulgados como índices gerais, por grupos de produtos, subgrupos, itens e subitens, para as regiões pesquisadas, além do agregado Brasil (Índice Nacional de Preço ao Consumidor - INPC). Para a construção do índice de cada região são utilizadas informações das Pesquisa de Locais de

Compras (PLC), Pesquisa de Especificação de Produtos e Serviços (PEPS), e da POF, que fornece as estruturas de ponderações das populações objetivo.

A POF atualiza os hábitos de consumo das famílias, apontando os produtos que ganham importância e os produtos que caem em desuso à medida que o tempo avança. Os resultados da pesquisa são então usados para atualizar os pesos dos componentes do IPCA, sendo estes segmentados em 9 grupos: alimentação e bebidas, habitação, artigos de residência, vestuário, transportes, saúde e cuidados pessoais, despesas pessoais, educação e comunicação. Seguidamente, os pesos de cada região metropolitana que compõem o índice também são atualizados usando o rendimento familiar medido pela POF em cada uma das regiões pesquisadas. As atualizações da POF feitas em 1974-1975; 2002-2003, 2008-2009 e 2017-2018 atualizaram o IPCA em 1980, 2006, 2012 e 2020.

A fim de incorporar a variação do preço da carne no modelo, foram coletados os dados do IPCA do subgrupo da carne e rearrumados em uma tabela. Cada linha da tabela contém a variação do índice deste produto no mês, de janeiro de 2017 a dezembro de 2020, e cada coluna determina um estado. Os índices de cada uma das 13 áreas investigadas SNIPC foram utilizados para a respectiva unidade federativa. Para as unidades não cobertas pelo IPCA, adotou-se a mesma metodologia usada pela POF para os procedimentos de deflacionamento dos dados da pesquisa. Os estados da Região Norte não contemplados (Rondônia, Amazonas, Roraima, Amapá, Tocantins e Acre de 2017 à abril de 2018) se utilizou as variações observadas para a Região Metropolitana de Belém. No caso dos demais estados (Piauí, Rio Grande do Norte, Paraíba, Alagoas, Santa Catarina, Mato Grosso, e Maranhão e Sergipe de 2017 à abril de 2018), foi utilizada a média ponderada das variações da região a qual pertencem, considerando a participação dos estados no SNIPC. Ao final, esses dados foram adequados a uma tabela para ser inserida no modelo, de modo que as linhas representavam os índices de cada mês, e as colunas os respectivos estados do índice. Esta tabela será referida ao longo do texto como tabela IPCA (ANEXO II).

3.1.4 Base Territorial - Setores Censitários do Censo Demográfico de 2010

A base territorial do censo demográfico, elaborada pelo IBGE (2010), consiste na integração de um sistema de mapas, cadastros e banco de dados, feita com o objetivo de contribuir com a organização e manutenção de atividades de planejamento, coleta e

análise dos dados, além da divulgação dos resultados. A unidade territorial de controle cadastral de sua coleta é o setor censitário, o mesmo que constitui as UPAs que compõe a amostra da POF 2017-2018. A fim de se ter uma representação dos indivíduos no espaço o mais fiel as suas localizações disponibilidades na POF, estado e situação de domicílio (urbano/rural), optou-se por utilizar o mapa do Brasil derivado dos dados de setores censitários estabelecidos no Censo de 2010 disponibilizado pelo IBGE no formato *shapefile*.

O “*shape*” é um tipo de arquivo digital que representa elementos gráficos, como pontos, linhas ou polígonos, referenciados no espaço através de coordenadas geográficas (ARCGIS, 2020). Este arquivo é formado por um conjunto de arquivos, dos quais três são obrigatórios para conseguir visualizar o *shapefile*. O primeiro arquivo com a extensão “*.shp*”, é responsável por armazenar a geometria que compõe o mapa que visualizamos. O segundo, em extensão “*.dbf*”, armazena a tabela de atributos que caracteriza as geometrias. O terceiro, e o último, com a extensão “*.shx*”, é responsável por criar o vínculo entre o arquivo “*.shp*” e “*.shx*”. Além destes essenciais, também é comum arquivo em “*.prj*”, o qual armazena as informações cartográficas. Os arquivos “*shape*” podem ser criados e manipulados por uma variedade de programas, entre os mais conhecidos pode-se destacar o AutoCAD MAP, ArcGIS, QGIS, dentre outros.

Os arquivos usados no modelo foram desenvolvidos a partir da simplificação dos *shapefiles* dos setores censitários dos Censo 2010 com o auxílio da ferramenta QGIS. O arquivo disponibilizado pelo IBGE é composto por 4 arquivos nas extensões citadas anteriormente, e apresenta níveis de detalhamento altíssimo, com uma tabela de atributos contendo 16 variáveis e 328.801 observações referentes a cada setor censitário do mapa. Uma vez que menor unidade territorial disponível dos indivíduos da POF compatível com este arquivo é o estado e a situação do domicílio do indivíduo, as variáveis da tabela foram reduzidas para apenas três colunas: macrorregião, unidade federativa e o tipo de área, todas codificadas pelas mesmas categorias identificadas pela POF. Com a tabela de atributos simplificada foi possível então dissolver as geometrias do mapa de forma que a menor divisão territorial fosse a área rural ou urbana de um determinado estado. Dessa forma a tabela de atributos terminou com apenas três variáveis e 53 observações, pelo distrito federal não apresentar área rural de acordo com a base de dado.

Para que o mapa do Brasil representado no modelo fosse capaz de identificar através de diferentes cores as divisões das macrorregiões das divisões dos estados e das

áreas urbanas e rurais, foi preciso criar outros dois arquivos *shapefile*. Seguindo o mesmo processo de dissolver geometrias do arquivo através da simplificação das tabelas de atributos, criou-se um em que a menor divisão territorial fossem os estados, e outro das macrorregiões. Ao final do processo, foram gerados três arquivos *shapefiles* para serem inseridos no modelo, sendo cada um deste compostos por quatro arquivos.

3.1.5 Disponibilidade Interna de Carne no Brasil

Os dados de disponibilidade interna da carne bovina do Brasil foram utilizados somente na etapa de validação modelo, abordada na seção 4.5. Para isso, foram coletados os dados da disponibilidade interna mensal de carne bovina do Brasil para o período de janeiro de 2017 a dezembro de 2020. Os dados foram adquiridos mediante solicitação a Companhia Nacional de Abastecimento (CONAB⁴), visto que a Companhia estava disponibilizando no site até o momento apenas o dado agregado por ano.

A CONAB é uma empresa pública vinculada ao Ministério da Agricultura, Pecuária e Abastecimento (MAPA) com a missão de fornecer ao Governo Federal informações detalhadas e atualizadas sobre a produção agropecuária nacional com o objetivo de embasar tomadas de decisão quanto à elaboração de políticas voltadas à agricultura. Para tal, a companhia realiza diversos levantamentos como de previsão de safras, de custos de produção e armazenagem, de posicionamento dos estoques e outros, os quais são disponíveis no site da instituição. Entre estes, há o levantamento mensal sobre a disponibilidade interna da carne no Brasil, o qual é estimado através de um cálculo a partir de três bases de dados:

1. A Pesquisa Trimestral de Abates (PTA) do IBGE, que investiga informações sobre a quantidade de animais abatidos e o peso total das carcaças, por espécie, tendo como unidade de coleta o estabelecimento que efetua o abate sob fiscalização sanitária federal, estadual ou municipal (IBGE, 2021b);
2. A Pesquisa Trimestral do Couro (PTC), do IBGE, a qual investiga informações sobre a quantidade de couro cru de bovino adquirida e curtida, tendo como unidade de coleta o estabelecimento que se dedica a essa atividade (curtume) e

⁴ Comunicação pessoal via e-mail no dia 16 de março de 2021.

- que adquire, anualmente, 5.000 ou mais unidades inteiras de couro cru bovino (IBGE, 2021c), e;
3. Os dados das exportações e importações de carne bovina fornecidas pela Secretaria de Comércio Exterior (SECEX) do Ministério da Economia, adquiridas através do Comex-Stat, sistema de divulgação estatística de comércio exterior do Brasil (COMEXSTAT, 2021).

A disponibilidade interna é resultado da soma da produção nacional com o total importado subtraído o total exportado. Tendo isso em vista, a metodologia seguida pela CONAB pode ser resumida em quatro passos.

Primeiro, a companhia estima a quantidade total de animais abatidos. Um dos desafios de se dimensionar este número deve-se a falta de informação sobre os abates informais no país. Os dados do PTC são os que melhor se aproximam da realidade. Por essa pesquisa aferir a quantidade de couro bovino produzido a partir de curtumes, a pesquisa capta não só o abate formal, mas também uma parte do informal, diferentemente da PTA. Esta, por sua vez, representa apenas o universo do abate formal pois investiga somente estabelecimentos legalizados, uma vez que é previsto pela lei a necessidade desta atividade ser fiscalizada. Desta forma, a quantidade total de animais abatidos é estimada a partir dos dados fornecidos pelo PTC acrescido ainda de 5% de seu valor, como uma tentativa de se aproximar ainda mais ao número real desconhecido pelo abate informal. Depois, eles calculam o peso total da carcaça desta quantidade estimada de animais abatidos multiplicando a quantidade total pelo peso médio da carcaça fornecido pela PTA.

Em seguida, realiza-se o cálculo do total de carne bovina importada e exportada. Os dados dos produtos comercializados são extraídos do sistema Comex-Stat. Como o comércio de produtos da bovinocultura inclui uma variedade de itens, incluindo a carne desossada, a carne com osso, e até mesmo animais vivos, é necessário converter os produtos a uma mesma unidade, conhecida por tonelada equivalente de carcaça (tec). A conversão para essa unidade, amplamente usada em análises relacionadas à produção de carne bovina, é realizada usando coeficientes específicos para cada item. De forma geral, utiliza-se o fator 1,0 para toneladas de carne in natura com osso, 1,3 para toneladas de carne in natura sem osso e o fator de 2,5 para tonelada de carne industrializada. Com as três parcelas da equação nas mesmas unidades de medida, a CONAB realiza a soma da produção nacional com o total importado menos o total exportado.

Como o volume de carne fornecido pela CONAB considera o peso da carcaça, e o modelo utiliza dados de entrada que refletem a quantidade de carne bovina ingerida autorreferida pelos consumidores, foi preciso adequar os dados da validação as mesmas unidades adotadas no modelo. Embora o peso da carcaça varie com a raça, idade, sexo e estado corporal do animal, a quantidade média de rendimento de carne comestível de uma carcaça é cerca de 50% (MOREIRA *et al.*, 2014; VINCENZI *et al.*, 2017). Sendo assim, os resultados do modelo foram comparados aos dados da disponibilidade interna mensal de carne bovina do Brasil reduzidos em 50%.

3.2 Componentes e base teórica da modelagem baseada em agentes

Os agentes representam consumidores brasileiros adultos, maiores de 18 anos, reproduzidos dentro modelo pelos 39.371 indivíduos respondentes do bloco alimentar da POF, selecionados no processamento de dados explicado na seção 3.1.1 (Tabela 2). Estes são caracterizados pelos atributos descritos na Tabela 6, que incluem além das diversas características demográficas e do tipo de dieta, provenientes do processamento de dados da POF, a elasticidade-preço da carne bovina derivada do estudo de PINTOS-PAYERAS (2009), e o nível de preocupação com o ambiente adquirido da Pesquisa de Mudanças Climáticas (ITS, 2021). Além disso, aos agentes também são atribuídos valores referentes as suas suscetibilidades às influências de familiares e colegas de trabalho embasados nos trabalhos de BELL, PLINER, 2003 e aplicados no modelo SCALCO *et al.*, 2019. Estas suscetibilidades são determinadas por um processo estocástico, detalhados na seção 3.4.5.2, e limitadas por valores de máximo e mínimo entre 0,30 e 0 para familiares, e entre 0,12 e 0 para colegas de trabalho (BELL, PLINER, 2003 apud SCALCO *et al.*, 2019). Todos os atributos dos agentes são estáticos, com exceção da preocupação com o meio ambiente que se altera ao longo da simulação através da interação dos agentes.

As redes de interação seguem a topologia das redes de relacionamento e são segmentadas em duas: uma relativa a membros da família e outra a colegas de trabalho. Ambas são estáticas e unidirecionais. Em outras palavras, além das redes não se alterarem ao longo da simulação, dois agentes diferentes de uma mesma rede (família/colegas) possuem o mesmo poder de influência sobre o outro. No entanto, é estabelecido que relações familiares apresentam maior poder de influência do que a de colegas, conforme demonstrado por CASTRO (1994). Todos os agentes fazem parte de uma rede de

familiares, porém apenas os identificados como empregados fazem parte da rede de colegas de trabalho.

O terceiro componente do modelo, o ambiente, foi definido em um espaço 2D, ilustrado pelo mapa georreferenciado do Brasil. O ambiente é utilizado de forma simples, sendo apenas ilustrativo. Ele orienta o posicionamento dos agentes no ambiente, alocando-os próximos a seus familiares e em seus devidos estados e áreas (urbano/rural), e ilustra a intensidade do consumo carne em cada região do país. Assim, este componente apresenta apenas três atributos estáticos: a unidade federativa, a área e a macrorregião do país. Como o modelo de SCALCO *et al.* (2019) o comportamento dos agentes é embasado pela teoria da ação racional (TRA - *theory of reasoned action*), e a interação dos agentes pela teoria “siga a média” (FTA - *follow-the-average*), descritas no ANEXO I

Tabela 6: Características atribuídas aos agentes - variáveis estáticas e permanentes em todas rodadas

VARIÁVEL	VALORES	FONTE
Macrorregião	1 (Norte); 2 (Nordeste); 3 (Sudeste); 4 (Sul); 5 (Centro-Oeste)	
Unidade federativa (UF)	11 – 53 (27 UFs)	
Situação de domicílio	1 (Urbano); 2 (Rural)	
Posição na família	1 (Chefe da família); 0 (Outros)	
Gênero	1 (Masculino); 2 (Feminino)	
Idade	18 a 98 anos	
Grupo de Idade	1 (18 a 39 anos); 2 (40 a 59 anos); 3 (60 a 98 anos)	
Escolaridade	1 (Nível baixo - Sem educação ou ensino fundamental incompleto); 2 (Nível médio - ensino fundamental completo ou ensino médio incompleto); 3 (Nível alto - ensino médio completo ou superior incompleto/completo)	(IBGE, 2020)
Ocupação	1 (Empregado); 0 (Desempregado)	
Classe de renda	1 (Classe alta - 15% mais ricos da UF); 2 (Classe média - 35% seguintes da UF); 3 (Classe baixa - 50% mais pobres da UF)	
Dieta	0 (vegetariano); 1 (não vegetariano)	
Preocupação ambiental	1 (Nada preocupada); 2 (Um pouco preocupada); 3 (Preocupada); 4 (Muito preocupada)	(ITS, 2021)
Elasticidade-preço	0,76 (15% mais ricos da UF); 0,89 (35% seguintes da UF); 0,93 (50% mais pobres da UF)	(PINTOS-PAYERAS, 2009)
Suscetibilidade à influência de familiares	[0; 0,30]	(BELL, PLINER, 2003 apud SCALCO <i>et al.</i> , 2019)
Suscetibilidade à influência de colegas	[0; 0,30]	

Fonte: Elaboração própria (2022).

3.3 Estratégia de implementação do modelo

A estratégia de implementação do modelo é apresentada no desenho ilustrado na Figura 4. Este é estruturado a partir de três funções principais compostas por regras, equações e módulos que regem o processo de decisão dos agentes. Os módulos indicam as equações e análises estatísticas desenvolvidas para alimentar o ABM.

A primeira função “configuração inicial” é responsável por introduzir bases de dados de arquivos externos, criar os componentes do ABM e definir variáveis estáticas do modelo. Como pode ser observado na etapa 1 da Figura 4, o Módulo 1: Provável preocupação é utilizado para compor a base de dados que será carregada pelo modelo na função “configurar”. Este módulo é encarregado por caracterizar a preocupação com o meio ambiente dos 39.371 indivíduos respondentes do bloco alimentar da POF, selecionados no processamento de dados explicado na seção 3.1.1.

A segunda função (2 na Figura 4) é responsável por definir as variáveis dinâmicas e outras estáticas determinadas por processos estocásticos ao reiniciar a simulação. As duas primeiras funções foram separadas a fim de otimizar o tempo de configuração do modelo para uma nova rodada. Sendo assim, a primeira é executada apenas ao abrir o arquivo, e a segunda, antes de iniciar uma nova rodada do modelo.

A terceira função principal é responsável por iniciar a simulação do consumo de carne bovina da população brasileira. Cada ciclo da simulação representa uma única refeição. Portanto, dois ciclos correspondem a 1 dia, iniciando pelo almoço e seguindo pelo jantar. Com base na TAR, a atitude pessoal e a influência social que determinam a intenção do indivíduo são implementadas criando uma ponte entre estas duas dimensões, de modo que ao longo da simulação os processos de influência social ocorrem a cada refeição e afetam as atitudes individuais sobre o consumo da carne.

As duas primeiras etapas dessa função (3.1 e 3.2 na Figura 4) determinam o grupo de agentes que os indivíduos poderão interagir e serem influenciados e/ou influenciarem. Na primeira, o modelo determina se os agentes devem fazer a refeição junto a colegas no trabalho ou junto a seus familiares em casa. Na segunda etapa, os agentes decidem entre comer no ambiente designado pelo modelo (casa/trabalho) ou fora dele. Esta decisão é feita utilizando a regressão logística desenvolvida no Módulo 2: Probabilidade de realizar uma refeição fora de casa que calcula as probabilidades de comer fora. A terceira etapa (3.3 na Figura 4) retrata a influência social. Nela os agentes interagem com aqueles

pertencentes a sua rede social e que estão realizando a refeição no mesmo lugar e trocam de “opiniões” sobre suas preocupações ambientais. A interação é implementada através das equações propostas por ZHANG *et al.* (2014), a qual atualiza as preocupações ambientais dos agentes considerando as influências de suas companhias.

A quarta etapa (3.4 na Figura 4) descreve a intenção dos indivíduos de comerem carne bovina. A intenção é representada pela probabilidade desse evento ocorrer, a qual é calculada a partir de uma regressão logística desenvolvida no Módulo 3: Probabilidade de consumir carne. Caso os agentes decidam por comer carne bovina, eles seguem para a quinta etapa (3.5 na Figura 4) para decidir a quantidade que irão consumir na refeição. Essa quantidade é definida retirando um número aleatório de uma curva de distribuição normal com uma determinada média e desvio padrão, calculada pelo Módulo 4: . Por fim, esta quantidade é ajustada aplicando-se a equação proposta do SCALCO *et al.* (2019) que modela o efeito da variação do preço da carne sobre a quantidade, reduzindo ou aumentando o consumo (3.6 na Figura 4).

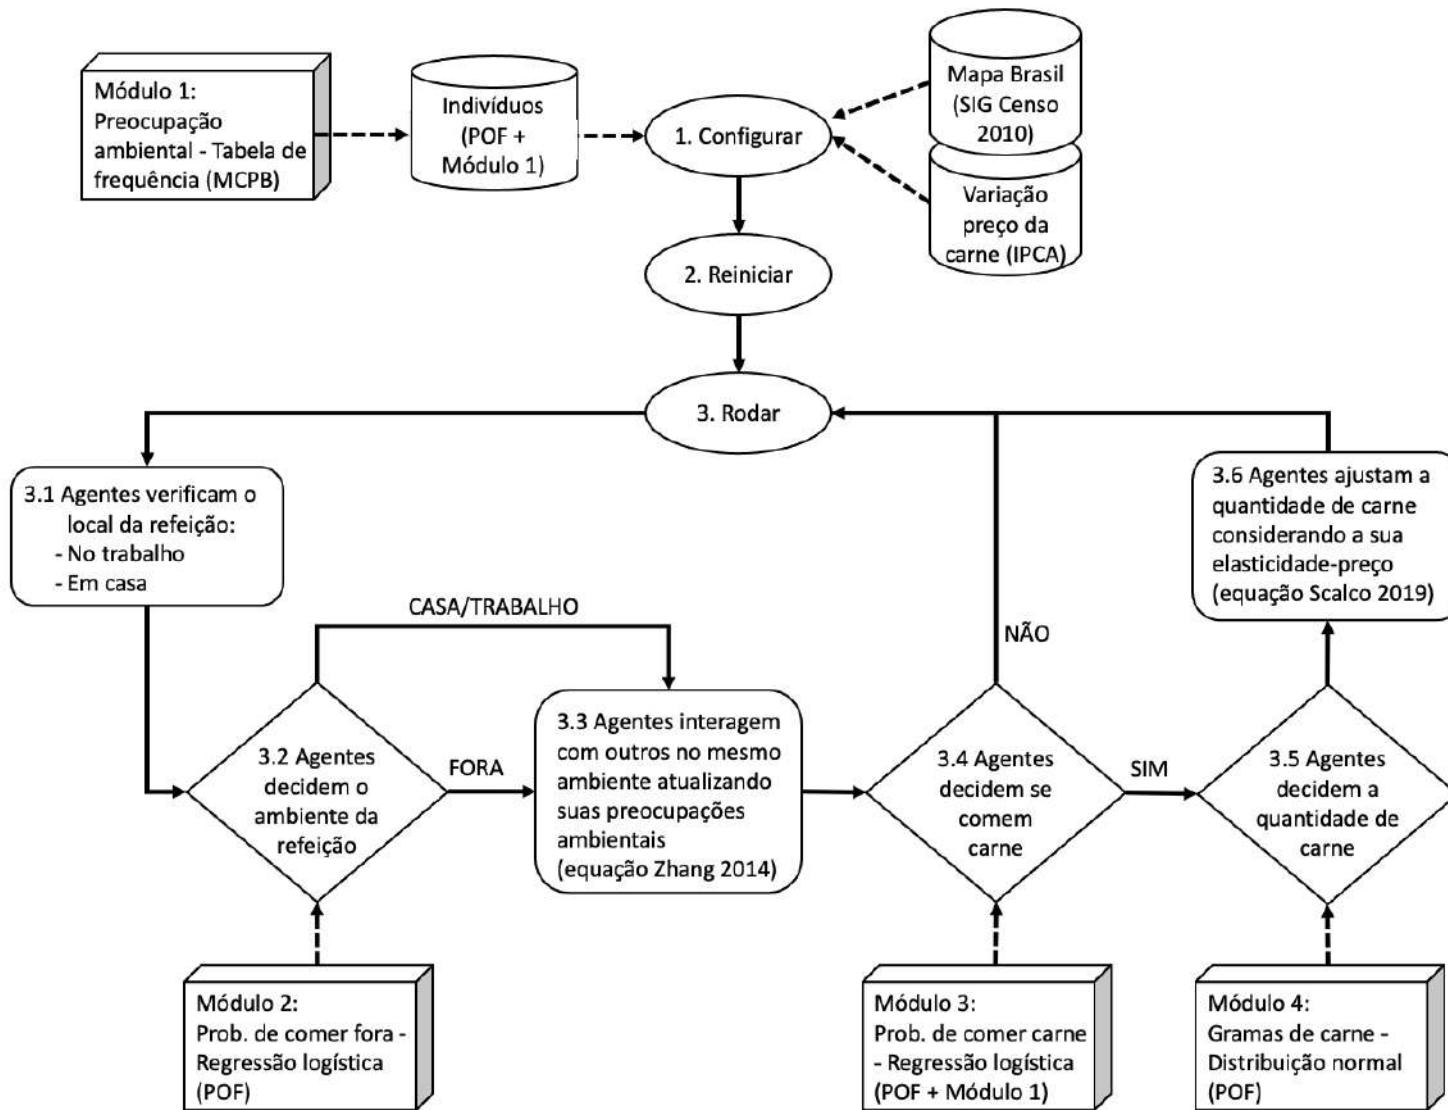


Figura 4: Estrutura do modelo ABM

Fonte: Elaboração própria (2022)

3.4 Implementação do modelo baseado em agentes

O ABM foi implementado no *Netlogo* 6.1.1 explorando os recursos disponíveis no programa de forma a facilitar a compreensão, adaptação, replicação e análise do modelo (NETLOGO, 2021). A interface do programa contém três guias: Informações, Código e Interface. A primeira é usada para documentar o modelo, a segunda para escrever o código, e a terceira, denominada como guia da interface (GUI), contém a interface gráfica do simulador. A GUI é projetada para controlar as funções básicas do modelo, permitindo alterar variáveis de entrada e, simultaneamente, observar dados de saída do modelo por meio de gráficos. Os elementos de controle podem ser botões, que açãoam funções descritas no código; chaves de ativação/desativação (“*switches*”), as quais permitem ou impedem a execução de diferentes linhas de código; controles deslizantes (“*sliders*”) e selecionadores (“*choosers*”), que definem variáveis de entrada; monitores e gráficos, os quais apresentam os resultados simultaneamente a simulação.

A guia “Informação” foi preenchida com a descrição do modelo seguindo o protocolo ODD (*Overview, Design concepts, and Details* - Visão Geral, Conceitos de Design e Detalhes). A guia do código foi desenvolvida buscando escrever de forma simplificada e organizada funções capazes de se adaptarem a diferentes bases de dados. A guia “interface” foi elaborada utilizando diversos recursos como botões e monitores com o objetivo de possibilitar diferentes formas de exploração dos dados de entrada e de visualização dos dados saída. Essa guia, exibida na Figura 5, apresenta três botões no topo, os quais açãoam as três principais funções - configurar (“*setup-model*”); reiniciar (“*reset-model*”), e; rodar (“*start*”) – e vários outros elementos de controle identificados pelas iniciais “iv_”, do inglês *interface variables* (variáveis da interface), para facilitar a identificação destas variáveis dentro código.

Esta seção irá primeiro detalhar o desenvolvimento dos quatro módulos, citados na seção 3.3, desenvolvidos para alimentar o modelo com equações e parâmetros estatísticos. O Módulo 1: Provável preocupação apresenta a metodologia usada para atribuir o nível de preocupação com o meio ambiente dos participantes da POF. O Módulo 2: Probabilidade de realizar uma refeição fora de casa e o Módulo 3: Probabilidade de consumir carne exibem as duas regressões logísticas desenvolvidas, a primeira para calcular a probabilidade de os agentes comerem fora de casa, e a segunda para calcular a probabilidade de os agentes comerem carne bovina em uma refeição. E o Módulo 4: apresenta a metodologia para o desenvolvimento das curvas de distribuição da quantidade

de carne bovina, as quais alimentam o modelo com as média e desvio padrão das curvas para determinar no modelo a quantidade de carne bovina ingerida pelos agentes. Por fim, será detalhado a sequência de eventos implementados no código nas três principais funções relacionando-os com os principais componentes da interface.

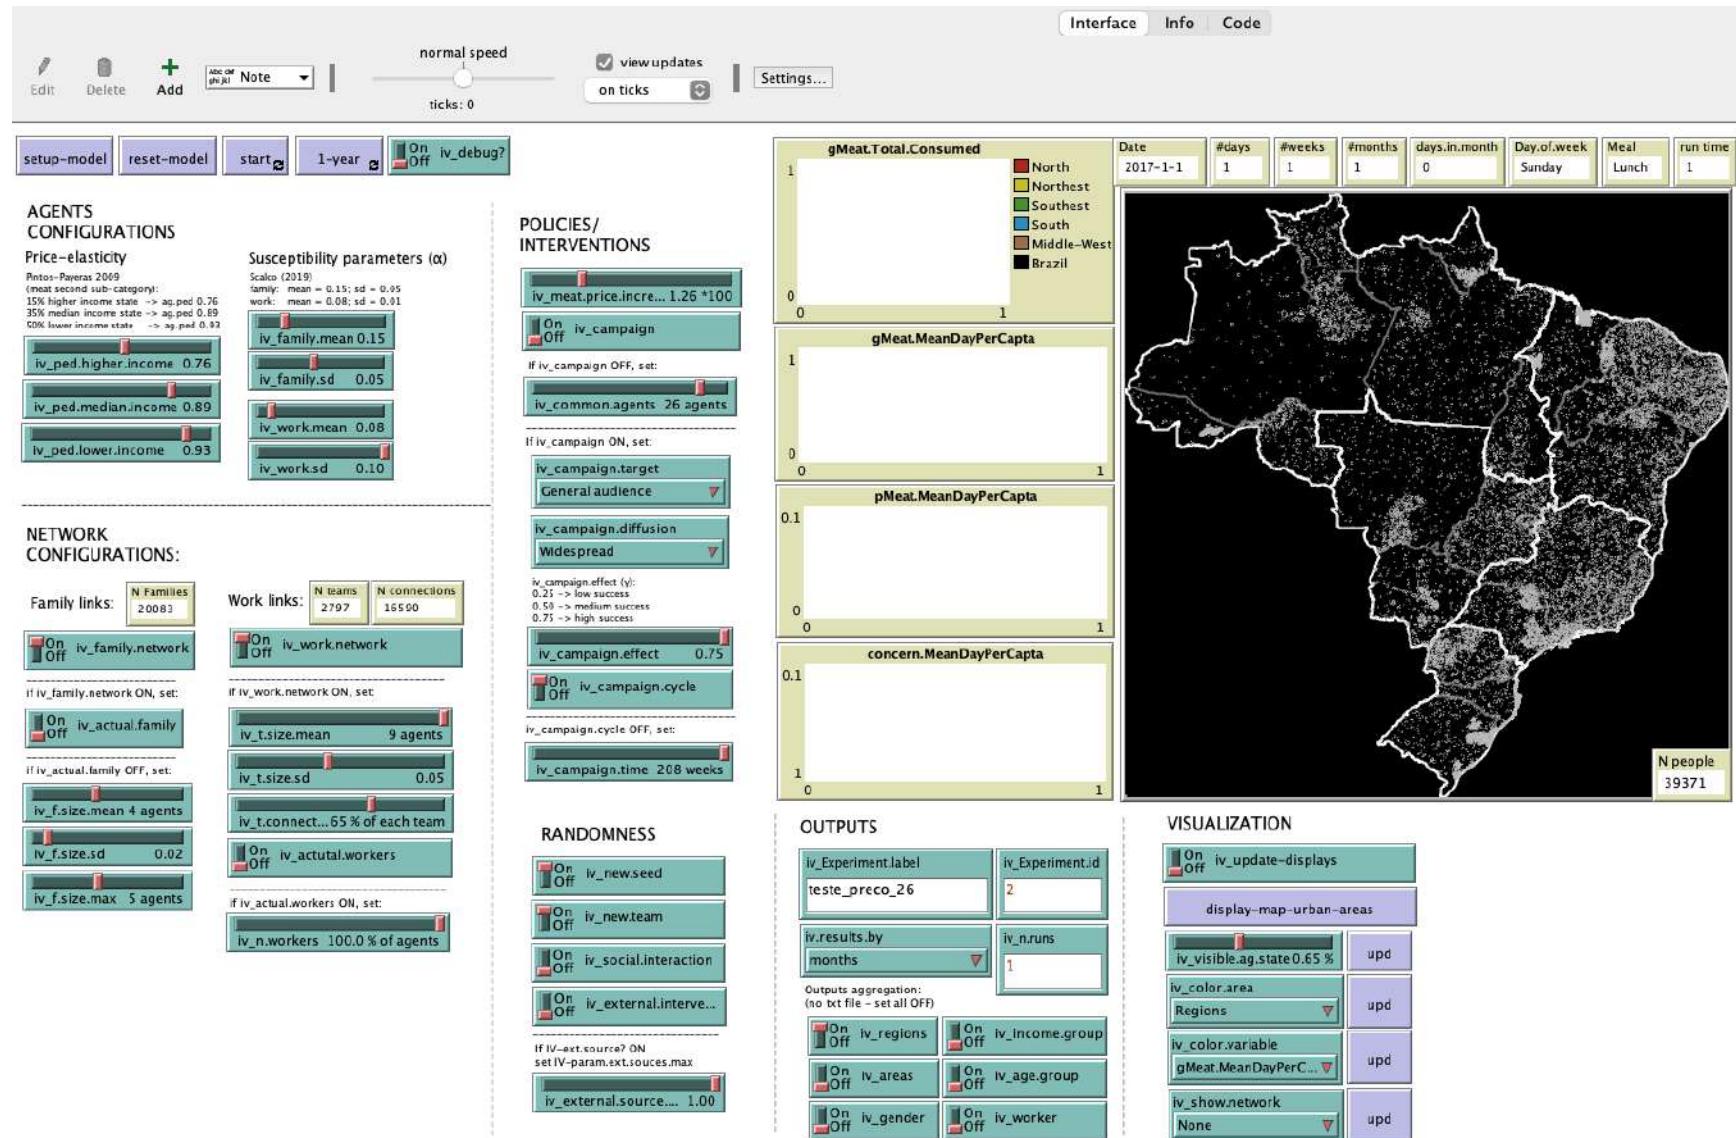


Figura 5: Guia da Interface do modelo desenvolvido no *Netlogo*.

Fonte: Elaboração própria (2022)

3.4.1 Módulo 1: Provável preocupação com o meio ambiente

O Módulo 1: foi desenvolvido a partir do processamento de dados da seção 3.1.2 (Tabela 5) com o objetivo de atribuir aos participantes da POF o nível de preocupação com o meio ambiente mais provável de acordo com as suas variáveis demográficas. Para isso, foi preciso primeiro selecionar um conjunto de variáveis que melhor expressasse a heterogeneidade da população sobre as suas preocupações com o meio ambiente que resultassem em um número mínimo de 30 respostas (observações) para a pergunta selecionada da pesquisa do ITS (“O quanto você considera que está preocupado(a) com o meio ambiente atualmente?”).

A partir da seleção deste grupo de variáveis criou-se uma tabela de frequência das possíveis respostas (1. Nada preocupado; 2. Pouco preocupado; 3. Preocupado; 4. Muito preocupado). Em seguida, foi atribuído aos 39.371 indivíduos respondentes do bloco alimentar da POF (Tabela 2), os quais representam os agentes dentro do modelo, uma resposta aleatória sobre as suas preocupações ambientais, de forma que ao final as respostas tivessem as mesmas proporções apresentadas na tabela de frequências, permitindo uma margem de diferença de até 5%.

Em outras palavras, caso fosse averiguado nos dados da pesquisa de mudanças climáticas (ITS, 2021) que características de gênero, idade e escolaridade são determinantes relevantes sobre o nível de preocupação com o meio ambiente, a tabela de frequências apresentaria, por exemplo, que entre mulheres com idade de 18 a 39 anos e com nível de escolaridade médio a proporção das respostas é: 10% Nada preocupada; 20% Pouco preocupada; 30% Preocupada; e 40 % Muito preocupada. Assim, seria atribuído aos indivíduos da POF um nível de preocupação ambiental aleatório, de forma que ao final a população da POF de mulheres com idade de 18 a 39 anos e com nível de escolaridade médio apresentassem as mesmas proporções de respostas.

3.4.2 Módulo 2: Probabilidade de realizar uma refeição fora de casa

O Módulo 2 consiste em uma regressão logística desenvolvida a partir do processamento de dados da seção 3.1.1 (Tabela 2 e Tabela 4), com o objetivo de se obter a probabilidade dos indivíduos de realizarem uma refeição fora de casa. Para desenvolver a regressão foi preciso preparar a tabela de dados agregando todas as observações de uma mesma refeição, de modo que fosse possível identificar a refeição feita em casa, indicada

pelo valor 0, e a fora de casa, indicada pelo valor 1. A amostra final apresenta o total de 136.412 observações (refeições), de modo que cada indivíduo apresenta o mínimo de uma e o máximo de quatro observações, uma vez que foram selecionadas duas refeições (almoço e jantar) para os dois dias da entrevista da POF.

O desenvolvimento da regressão logística foi realizado em dois estágios, conforme ALLISON (1999). No primeiro, foi feita uma avaliação univariada para estimar o efeito de cada variável sobre a decisão de realizar uma refeição fora de casa. Nessa análise, denominada não-ajustada, todas as variáveis significativas ao nível de 25% (valor $p \leq 0,25$) são selecionadas. No segundo estágio, o modelo ajustado é implementado e as variáveis estatisticamente significativas ao nível de 5% são interpretadas. A seleção das variáveis foi feita por meio dos testes de Wald e da Razão de verossimilhança, e o ajuste do modelo foi avaliado pela estatística $\Delta\beta$ que mede a variação nos coeficientes dos parâmetros quando uma observação específica é excluída. Com o objetivo de simplificar a análise, foram selecionadas apenas variáveis que mostraram $\Delta\beta$ menor do que 20%. Portanto não foi avaliado nesta análise a interação de variáveis selecionadas ou que apresentaram $\Delta\beta$ maior do que 20%.

A probabilidade do agente i realizar uma refeição fora de casa no tempo t segue a Equação 1, onde os coeficientes (β) estimados das variáveis selecionadas são apresentados na seção 4.2.

Equação 1: Probabilidade de realizar uma refeição fora de casa (genérica)

$$p_i(\text{cons. carne}) = \frac{e^{-y_i}}{(1+e^{-y_i})} , \text{ onde:}$$

$$y_i = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p$$

O pacote "glmmTMB" do *software R* usado para desenvolver a regressão logística utiliza o método para codificar variáveis de *design* da equação conhecido como codificação de célula de referência, ou “codificação 0-1”. Este é um dos métodos mais utilizados sendo o padrão em muitos pacotes de software estatístico. Nele, considera-se que se uma variável em escala nominal tem k valores possíveis, então são necessárias na equação $k - 1$ variáveis. A razão para se usar uma a menos deve-se a consideração de um termo constante (β_0). Para ilustrar a notação usada para variáveis neste texto, suponha que a j^{a} variável independente seja macrorregião, a qual apresenta 5 níveis – Norte (N), Nordeste (NE), Sudeste (SE), Sul (S), Centro-Oeste (CO). As variáveis de *design* $k_j - 1$ serão x_{ne} , x_{se} , x_s , x_{co} , e os coeficientes para essas variáveis de projeto serão denotados

como β_{ne} , β_{se} , β_s , β_{co} . A célula de referência neste caso será a macrorregião Norte. Logo, se o indivíduo for da região sudeste, a variável referente a esta região será atribuída com o valor um e restante zero ($x_{ne} = 0$, $x_{se} = 1$, $x_s = 0$, $x_{co} = 0$). No caso, do indivíduo ser da região norte (célula de referencia), todas variáveis referente a macrorregião serão nulas ($x_{ne} = 0$, $x_{se} = 0$, $x_s = 0$, $x_{co} = 0$), sendo considerado apenas o termo constante da equação (β_0).

3.4.3 Módulo 3: Probabilidade de consumir carne bovina em uma refeição

O Módulo 3 consiste em uma regressão logística desenvolvida a partir do processamento de dados da seção 3.1.1 (Tabela 2 e Tabela 4), com o objetivo de se obter a probabilidade dos indivíduos de consumirem carne bovina em uma refeição. Para desenvolver a regressão foi preciso preparar a tabela de dados agregando todas as observações de uma mesma refeição e dicotomizar a variável resposta que identificasse se o indivíduo comeu carne bovina na refeição. Criou-se a variável “consumo.carne” a qual atribuiu-se o valor 0 para as refeições que não incluíam alimentos identificados pelo tradutor “carne bovina” e o valor 1 para os que incluíam. A amostra final apresenta o total de 136.412 observações (refeições), de modo que cada indivíduo apresenta o mínimo de uma observação e o máximo de quatro, uma vez que foram selecionadas duas refeições (almoço e jantar) para os dois dias da entrevista da POF. A regressão logística foi desenvolvida seguindo a mesma metodologia explicada no Módulo 2: Probabilidade de realizar uma refeição fora de casa.

A probabilidade do agente i consumir carne bovina no tempo t segue a Equação 2, onde os coeficientes (β) estimados das variáveis selecionadas são apresentados no capítulo 4.3.

Equação 2: Probabilidade de consumir de carne bovina na refeição (genérica)

$$p_{i,t}(\text{cons. carne}) = \frac{e^{-y_{i,t}}}{(1+e^{-y_{i,t}})} * \text{vegi} \quad , \text{ onde:}$$

$$y_{i,t} = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k$$

É importante ressaltar que as variáveis “classe de renda” e “preocupação com o meio ambiente” foram necessariamente incluídas nesta regressão por serem responsáveis por diferenciar a probabilidade de os agentes consumirem carne bovina ao longo da simulação. A variável “classe de renda”, a qual determina os grupos referente a

elasticidade-preço da carne bovina calculada por PINTOS-PAYERAS (2009), foi incluída como *proxy* para a sensibilidade dos consumidores à variação do preço da carne bovina, o qual é atualizado mensalmente. Já a “preocupação com o meio ambiente” é atualizada pela interação dos agentes antes de realizarem uma refeição. A variável “veg”, a qual determina se a pessoa segue uma dieta vegetariana ou não, também foi introduzida na equação com o objetivo de zerar a probabilidade daqueles que não consomem carne.

3.4.4 Módulo 4: Probabilidade da quantidade de carne bovina a ser consumida

O Módulo 4: foi desenvolvido a partir dos dados processados exibidos na seção 3.1.1 (Tabela 2 e Tabela 4) com o objetivo de se obter curvas de distribuição da quantidade de carne bovina consumida em uma refeição para que os agentes do modelo definissem a quantidade que iriam ingerir através da retirada de um número aleatório desta amostra. Para isso, primeiro foi preciso filtrar os alimentos identificados pelo tradutor “carne bovina” e somar a quantidade consumida em uma mesma refeição (almoço/jantar), visto que cada observação da tabela representa a quantidade de um alimento específico consumido por um indivíduo em uma determinada refeição. Ao final, cada indivíduo da tabela apresenta o mínimo de uma observação e o máximo de quatro, uma vez que foram selecionadas duas refeições de dois dias entrevistados pela pesquisa. Outra manipulação necessária foi a transformação logarítmica dos dados de quantidade de carne bovina, visto que a distribuição da variável em questão apresentou uma das extremidades elevadas e uma cauda longa. Por isso, aplicou-se a transformação utilizando o logaritmo neperiano a fim de adequá-los a distribuição normal e reduzir o efeito do viés, como pode ser observada na Figura 6.

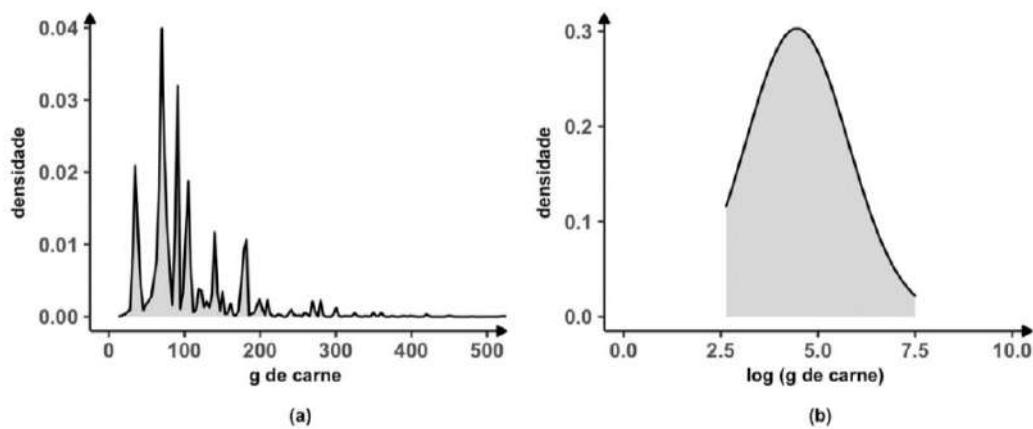


Figura 6: Distribuição normal da quantidade de carne bovina consumida por refeição por individuo

Fonte: Elaboração própria (2022)

Assim, foi analisado o comportamento das curvas considerando variáveis demográficas, socioeconômicas e relativas ao contexto das refeições para encontrar um conjunto de variáveis relevantes para determinação da quantidade de carne bovina consumida em uma refeição, atendendo ao número mínimo de 30 observações. A partir da seleção deste grupo de variáveis, criou-se uma tabela com a média e desvio padrão das curvas para cada um destes grupos. Isto é, caso fosse constatado que características de gênero, idade e escolaridade são determinantes relevantes sobre a quantidade de carne bovina consumida, seria feita uma tabela que conteria por exemplo, 18 observações (três gêneros x três grupos de idade x três níveis de escolaridade = 18 linhas), com três colunas, uma que identificasse ao grupo de variáveis, e as outras duas com a média e o desvio padrão. Nesse contexto, uma das linhas desta tabela apresentaria a média e o desvio padrão para o grupo referente a mulheres com idade de 18 a 39 anos e com nível de escolaridade médio.

3.4.5 Implementação do código

A seguir será apresentado de forma detalhada a implementação do código das três funções principais resumidas na seção 3.3: Função Configurar; Função Reiniciar; Função Rodar.

3.4.5.1 Função Configurar

A função configurar é composta por uma sequência de funções, as quais podem ser discriminadas em cinco eventos principais. A primeira função é responsável por carregar todas as informações externas e armazená-las em variáveis adequadas para que possam ser acessadas nas funções seguintes. A segunda cria os agentes e o ambiente do ABM, a terceira configura as variáveis globais, a quarta configura os atributos estáticos dos agentes que não se alteram ao reiniciar uma nova rodada modelo, e a quinta cria as redes de interação. Esta função foi criada com o objetivo de facilitar a manipulação do código para replicação de outros modelos, de modo a concentrar em uma única função todas as informações que precisem ser alteradas por outros pesquisadores, como por exemplo, nome de arquivos e data de início e fim da simulação. Para isso, o modelo usa algumas extensões do *NetLogo* que serão citadas a seguir.

O ambiente é construído através da leitura dos arquivos *shapefiles* da Base Territorial, carregados na primeira função com ajuda da extensão “*GIS*”. Esta função ilustra na interface do programa o mapa do Brasil e define seus atributos (macrorregião, estados, e situação de domicílio). Os agentes são criados através da leitura da base de dados Tabela Indivíduos (Tabela 2), carregadas na primeira função com o auxílio da extensão “*csv*”. Dessa forma, os agentes do modelo representam exatamente os 39.371 respondentes selecionados da pesquisa do bloco alimentar da POF, com a diferença de que estes agora também são caracterizados por um nível de preocupação com o meio ambiente, atribuído pelo Módulo 1: .

Em relação as variáveis globais, o modelo configura os coeficientes das duas regressões logística, referentes a probabilidade do agente comer fora de casa (Módulo 2: Probabilidade de realizar uma refeição fora de casa) e a probabilidade de comer carne bovina em uma refeição (Módulo 3: Probabilidade de consumir carne). Além dessas, o modelo também configura a matriz que contém a variação preço da carne bovina, em que cada linha indica o mês, e cada coluna o estado do Brasil. Esses dados também foram carregados na primeira função, a partir da leitura do arquivo Tabela IPCA carne (ANEXO II) auxiliada pela extensão “*csv*”, e armazenadas na matriz com auxílio da extensão “*matrix*”, para facilitar o acesso a estas variáveis ao rodar modelo.

Na função que configura os atributos estáticos dos agentes, o modelo atribui a cada agente o número da coluna da matriz IPCA, que corresponde ao seu respectivo estado, o qual permite que os agentes possam acessar a variação do preço local da carne bovina ao longo dos meses. Esta função também configura as médias e desvio padrão das curvas de distribuição que servirão para determinar a quantidade de carne consumida em uma refeição. Assim como os dados da variação do preço da carne, estes parâmetros também são carregados na primeira função, através da leitura da tabela gerada no Módulo 4: Probabilidade da quantidade de carne bovina a ser consumida no formato *csv*, e armazenada em uma matriz. Nela cada linha contém a média e desvio padrão da distribuição da quantidade de carne bovina consumida em uma refeição para um determinado grupo de variáveis (ex: macrorregião, gênero, idade, etc.) definidas no desenvolvimento do Módulo 4: Probabilidade da quantidade de carne bovina a ser consumida. Desta forma, esta função atribui aos agentes o número da linha desta matriz, o qual permite ao agente acessar a média e o desvio padrão da sua respectiva distribuição de acordo com as suas variáveis. Além dessas variáveis, o modelo também cria uma

variável matriz que auxilia na coleta dos resultados do modelo, que será explicada mais adiante na função “rodar” (seção 3.4.5.3).

Em relação à configuração das redes de interação, o modelo permite algumas possibilidades. Ele inicia pela rede de familiares, a qual pode ser configurada de duas maneiras dependendo do interruptor “iv_actual.family”. Caso esteja desativado, no caso do uso de base de dados que não apresentem esta informação, o modelo segue com o código desenvolvido por SCALCO *et al.* (2019), configurando a rede seguindo o princípio da homofilia⁵, porém, associando indivíduos não só pela proximidade de suas probabilidades de consumir carne bovina, mas também considerando seus estados e situação de domicílio. Conforme desenvolvido pelo autor, o número de membros da família é escolhido retirando-se um número de uma curva gamma⁶, em que os parâmetros de média e desvio padrão desta curva de distribuição são definidos na interface, assim como o máximo de integrantes. Como este estudo utilizou uma base de dados que identificava indivíduos de mesmas famílias, adicionou-se ao modelo a possibilidade de configurar esta rede conforme os dados empíricos. Sendo assim, caso este interruptor esteja ativado, o modelo configura a rede de acordo com a variável “id família”.

A rede de colegas de trabalhos também pode ser configurada de duas formas, conforme o desenvolvido por SCALCO *et al.* (2019). Caso o interruptor “iv_actual.workers”, esteja ativado, o modelo considera os dados empíricos que identificam os indivíduos empregados e desempregados. Caso contrário, o modelo define parte da população como empregada, selecionando de forma aleatória a proporção da população definida pelo controle da interface “iv_n.workers”. Independentemente da forma, as pessoas identificadas como empregadas são agrupadas em equipes, sendo selecionadas de forma aleatória com a condição de serem do mesmo estado e mesma situação de domicílio. A quantidade de agentes por equipe é definida retirando um número aleatório de uma curva de distribuição normal, em que a média e o desvio padrão também são determinados pela interface. Neste estudo, considerou-se a média e o desvio padrão respectivamente em 4 e 0,5, seguindo o estudo de BELL E PLINER (2003) o qual

⁵ A homofilia é o princípio de que o contato entre pessoas semelhantes ocorre em uma taxa maior do que entre pessoas diferentes (MCPHERSON, SMITH-LOVIN, COOK, 2001).

⁶ A curva gamma é um tipo de função de densidade de probabilidade. Outros tipos comuns são a curva normal, lognormal e exponencial.

relata a variação do número de pessoas em um almoço na cantina do local de trabalho entre um a oito, assim como o assumido por SCALCO *et al.* (2019).

Todos os agentes empregados possuem conexões com todos os integrantes de suas equipes, porém alguns ainda possuem uma conexão a mais com outro agente integrante de outra equipe diferente da sua. A escolha desses agentes que fazem ponte com outras equipes é também feita de forma aleatória com a restrição de serem apenas do mesmo estado. A quantidade de pessoas que terão conexão com uma segunda equipe é definida pelo controle “*iv_teams.interconnect.*” na interface, o qual define a porcentagem dos indivíduos dentro de uma equipe que irá criar esta relação adicional. Por fim, a função “configurar” aciona a função de “reiniciar” o modelo.

3.4.5.2 Função Reiniciar

A função principal “reiniciar” é composta por uma sequência de funções que pode ser resumida em três eventos. Primeiro, são reiniciadas as variáveis globais, que incluem a matriz usada para armazenar os resultados sobre o consumo da população, as variáveis marcadoras do tempo (como o número de dias, de semanas) e o número da linha da matriz IPCA, o qual é atualizado durante a simulação a cada primeiro dia do mês. Em seguida, reinicia-se os atributos dos agentes dinâmicos, os atributos estáticos definidos por processos estocásticos e definidos por controles na interface.

A preocupação ambiental, por ser dinâmica, é redefinida aos valores iniciais fornecidos pela base de dados. A elasticidade preço da demanda, apesar de ser estática, pode ser redefinida por botões na interface, caso seja realizada uma análise de sensibilidade sobre o parâmetro. As suscetibilidades, também estáticas, são reiniciadas por serem definidas retirando-se um número aleatório de uma distribuição normal com média e desvio padrão definidos na interface. Uma vez que não há conhecimento de dados específicos sobre os parâmetros desta distribuição, foram utilizados os mesmos valores empregados por SCALCO *et al.* (2019), embasados pelo estudo de BELL E PLINER (2003). A distribuição normal referente a suscetibilidade aos familiares apresenta uma média de 0,15 e um desvio padrão de 0,05, e limita seus valores de máximo e mínimo entre 0,30 e 0. Já a distribuição normal referente a suscetibilidade dos colegas de trabalho apresenta uma média de 0,08 e um desvio padrão de 0,01, e limita seus valores de máximo e mínimo entre 0,12 e 0.

As redes de interação quando não utilizam dados empíricos, também são definidas através de um processo estocástico. Por isso, elas também podem ser reconfiguradas caso os interruptores “*iv_new.team*” e “*iv_new.family*” sejam ativados. Por fim, a função reinicia todas as configurações relativas a visualização gráfica na GUI. Ao final da função o modelo está pronto para rodar.

3.4.5.3 *Função Rodar*

O modelo contabiliza o ciclo da simulação utilizando a extensão “*time*” do *Netlogo*. Ao definir a data de início da simulação e a unidade de tempo que cada ciclo representa, o modelo conta automaticamente o passar dos dias, meses e ano. Como cada ciclo da simulação é equivalente a uma refeição, e dois ciclos a um dia, foi estabelecido que a unidade de tempo de um ciclo equivale a 12 horas. Assim, o almoço é representado às 11 horas e o jantar às 23 horas. O modelo inicia no dia 01 de janeiro de 2017 às 11 horas e termina no dia 31 de dezembro de 2020 às 23 horas.

Na primeira etapa dessa função (3.1 na Figura 4), o modelo determina se os agentes devem fazer a refeição junto a colegas de trabalho ou junto a seus familiares. A refeição é feita com colegas em ciclos referentes a almoços em dias de semana caso o indivíduo seja empregado. Caso seja desempregado, ou o ciclo seja referente a jantares ou a qualquer refeição em finais de semana, os agentes realizam as refeições com familiares. Na segunda etapa (3.2 na Figura 4) os agentes decidem entre comer no ambiente designado pelo modelo (casa/trabalho) ou fora dele. Esta decisão é feita comparando as suas respectivas probabilidades de comer fora, calculadas a partir da regressão logística desenvolvida no Módulo 2. Caso o último seja menor do que o primeiro, o agente terá sua refeição fora do ambiente junto aos outros da sua rede que também tiveram a mesma escolha.

Em outras palavras, se entre quatro colegas da mesma equipe, dois decidam comer no ambiente do trabalho e dois fora, todos terão a companhia de um colega. Caso apenas um decida comer fora, este irá fazer a refeição sozinho. O mesmo vale para as refeições em casa com membros de família. Vale ressaltar que se um indivíduo decide comer fora do trabalho ao mesmo tempo que um membro de sua família decide comer fora de casa, o modelo não considera que eles terão a refeição juntos. Diferente do modelo tido como referência deste estudo em que há dados disponíveis que questionam se os indivíduos

tiveram refeições sozinhos ou acompanhados, nem a POF e nenhuma outra pesquisa sobre hábitos alimentares no Brasil aborda esta questão. Por isso, optou-se por adicionar a probabilidade de comer fora como uma forma de reduzir as interações dos agentes nas refeições, de modo a refletir estes casos em que os agentes não interagem com outros.

Na terceira etapa (3.3 na Figura 4) os indivíduos atualizam a variável de preocupação ambiental a partir de uma ponderação entre as opiniões próprias dos agentes e as opiniões das outras pessoas pertencentes as suas redes (ZHANG *et al.*, 2014). O quanto a pessoa será influenciada pela opinião dos outros é determinado pela sua suscetibilidade, onde quanto maiores os valores, maior a sensibilidade à influência de outros agentes. Este atributo varia entre os indivíduos e entre as suas redes sociais, de modo que alguns agentes serão mais facilmente influenciados em comparação a outros e cada um terá dois tipos de suscetibilidades, uma referente à influência de familiares e outra a colegas de trabalho, ambas configuradas na função “reiniciar” do modelo.

Na ausência de qualquer estratégia de marketing para promover a preocupação ambiental, definido pelo desligamento do interruptor “*iv_campaign*” no NetLogo, todos os agentes pertencentes a mesma rede de interação de um indivíduo têm o mesmo poder de influência sobre ele. Assim, conforme apresentado na Equação 3, a atualização da preocupação ambiental do indivíduo i no tempo t , denotado por $C_{i,t}$, é representada pela ponderação, estabelecida pela suscetibilidade α_i , da sua própria preocupação ambiental, e da média de seus familiares/colegas no tempo $t-1$.

Equação 3: Interação social sem campanha de marketing

$$C_{i,t} = (1 - \alpha_i)C_{i,t-1} + \alpha_i \frac{\sum_{j \in \text{rede}(i)} C_{j,t-1}}{\sum_{j \in \text{rede}(i)} 1}$$

Ao se aplicar a estratégia de marketing para promover a preocupação ambiental, agentes da mesma rede de interação não possuem o mesmo poder de influência sobre um indivíduo. As estratégias de marketing aumentam a visibilidade de colegas/familiares que possuem uma preocupação com o ambiente maior, dando a eles um maior poder de influência. O tamanho deste poder varia de acordo com o nível de sucesso da campanha aplicada, o qual escalona os efeitos das campanhas. Ou seja, campanhas de grande sucesso aumentam a visibilidade destes agentes em um grau maior do que as campanhas de baixo sucesso. Consequentemente, a parcela da equação que expressa a influência dos agentes da rede de interação é representada na Equação 4 por uma média ponderada pelo fator $\gamma \in (0,1)$, definido na GUI pelo controle “*iv_campaign.effect*”. Esta traduz o grau de

sucesso da estratégia de sensibilização, aumentando o poder de influência daqueles com maior preocupação e diminuindo o poder dos outros com menor. Nota-se que ao zerar o grau de sucesso da campanha ($\gamma = 0$), a Equação 4 torna-se igual a Equação 3 e, portanto, desconsidera a aplicação de campanhas e as diferenças sobre o poder de influência.

Equação 4: Interação social com campanha de marketing

$$C_{i,t} = (1 - \alpha_i)C_{i,t-1} + \alpha_i \frac{\sum_{\substack{j \in rede(i) \\ C_{j,t-1} > C_{i,t-1}}} (1 + \gamma_t)C_{j,t-1} + \sum_{\substack{j \in rede(i) \\ C_{j,t-1} \leq C_{i,t-1}}} (1 - \gamma_t)C_{j,t-1}}{\sum_{\substack{j \in rede(i) \\ C_{j,t-1} > C_{i,t-1}}} (1 + \gamma_t) + \sum_{\substack{j \in rede(i) \\ C_{j,t-1} \leq C_{i,t-1}}} (1 - \gamma_t)}$$

O modelo ainda possibilita a consideração de um efeito de dissipação da atenção dada às mensagens de campanhas de sensibilização (CIALDINI, RENO, KALLGREN, 1990). Conforme utilizado por SCALCO *et al.* (2019), o grau de sucesso (γ_t) pode sofrer um decaimento no tempo t dado pelo fator exponencial equivalente a -0,0125 de seu efeito inicial (γ_0), conforme demonstrado na Equação 5. O fator de -0,0125 baseou-se na literatura sobre a persistência dos efeitos de campanhas de marketing social (ALLCOTT, 2011; ALLCOTT, ROGERS, 2012; FERRARO *et al.*, 2011; NOLAN *et al.*, 2008; ROBINSON *et al.*, 2014). Este efeito entra em ação quando ativado o interruptor “*iv_campaign.cycle*”, o qual considera que a campanha se renova em ciclos de um determinado espaço de tempo, definido pelo controle da interface “*iv_campaign.time*”, que ao chegar ao fim do ciclo redefine o γ_t ao valor inicial γ_0 .

Equação 5: Decaimento do efeito da campanha de sensibilidade

$$\gamma_t = \gamma_{t0} * e^{-0,0125 t}$$

A atualização da preocupação ambiental não é realizada por todos os agentes em todas as refeições, apenas por uma parcela da população. Caso não esteja sendo aplicada a campanha de sensibilização, o modelo seleciona um determinado número de agentes aleatoriamente de forma que todos têm a mesma chance de serem selecionados. O número de agentes é definido através da divisão da população total por um divisor estabelecido pelo controle controle “*iv_common.agents*” na GUI. Optou-se por não calcular esta parcela através de uma simples porcentagem da população, devido à limitação do intervalo do controle, que acabaria possibilitando uma variação pouco abrangente. Ao se aplicar a estratégia de sensibilização, os agentes selecionados serão todos aqueles definidos como público-alvo e que fazem parte do meio escolhido para difundir a campanha, determinados pelos seletores “*iv_campaign.target*” e “*iv_campaign.diffusion*”, respectivamente.

Na quarta etapa dessa função (3.4 na Figura 4), os agentes calculam a suas probabilidades de comerem carne bovina utilizando a regressão logística, desenvolvida no Módulo 3: Probabilidade de consumir carne. Assim, os agentes decidem se irão comer carne bovina ou não comparando esta probabilidade com um número aleatório entre 0 e 1. Se o último for menor do que o primeiro, o agente consome carne bovina. Na quinta etapa (3.5 na Figura 4), os agentes que optaram por consumir carne bovina na refeição, decidem a quantidade retirando um número aleatório de uma curva de distribuição normal com a média e desvio padrão definidos no Módulo 4: . Cabe ressaltar que a transformação logarítmica das curvas de distribuição é aplicada apenas para retirar o valor aleatório. Sendo assim, a quantidade de carne bovina consumida é convertida de volta a escala original dentro do *Netlogo*.

Por fim, a etapa 6 (3.6 na Figura 4) ajusta o consumo de carne bovina utilizando a Equação 6 (SCALCO *et al.*, 2019). A equação corrige as quantidades de carne bovina consumida em gramas pelo fator ω , o qual considera a variação do preço do alimento provido pelos dados do IPCA (*IPCA.carne*) e pela elasticidade-preço da demanda (*epd*) estimada por PINTOS-PAYERAS (2009).

Equação 6: Ajuste da quantidade da carne ingerida

$$gCarne = gCarne * \omega, \text{ onde:}$$

$$\omega = 1 - \left(epd \left(\frac{100 + IPCA.carne}{100} - 1 \right) \right)$$

Conforme proposto por SCALCO *et al.* (2019), no final do dia, após o jantar, algumas oscilações aleatórias podem ser aplicadas para simular mudanças nas preocupações ambientais dos agentes devido a outras fontes de influência que não são explicitamente modeladas. Entre as possíveis outras fontes de influência sobre a preocupação ambiental pode-se citar, por exemplo, a influência de desastres naturais, ondas de calor, ou de mídias sociais como redes sociais ou documentários. Quando o interruptor “*iv_external.intervention*” é ativado, os agentes escolhem um número aleatório flutuante entre 0 e 1 e, caso seja menor do que 0,33, eles atualizam as suas preocupações ambientais. A atualização considera o valor definido no controle na interface “*iv_external.source.max*”, o qual define um intervalo máximo de variação da variável. Assim, eles subtraem de suas preocupações ambientais o valor deste controle e somam a um número aleatório que pode ir de 0 ao dobro do controle.

Ao final desses eventos, o modelo realiza a soma das quantidades consumidas pela população. Primeiro, os agentes multiplicam a quantidade de carne consumida pelos seus respectivos fatores de expansão para que o modelo possa apresentar resultados capazes de representar a população brasileira. Além da quantidade consumida, o modelo também coleta dos agentes dados da preocupação com o meio ambiente, da probabilidade de comer carne bovina, e a quantidade de vezes em que os agentes optaram por consumir e não consumir carne bovina. Essas observações são exibidas em gráficos na interface e registradas em um arquivo texto que pode ser interpretado ao final da simulação utilizando um software estatístico.

A coleta de dados pode ser feita mensalmente, semanalmente, diariamente ou até mesmo por refeição, a depender da escolha no controle seletor “iv.results.by” e da análise que se deseja fazer. O arquivo texto registra as observações de forma agregada devido a grande quantidade de agentes e de rodadas necessárias para atingir resultados com a robustez estatística necessária. Eles podem ser agregados por região, situação de domicílio, gênero, grupos de idade, classe de renda ou status empregatício, o que também depende da análise desejada e do conjunto de botões ativados na GUI (“iv_regions”, “iv_area”, “iv_gender”, “iv_age.group”, “iv_income.group”, “iv_worker”). Por exemplo, caso os controles “iv_regions” e “iv_gender” sejam ativados, os resultados são registrados em estratos que combinam as duas variáveis. Neste caso, o modelo iria coletar as observações estratificando os resultados em 10 grupos (cinco macrorregiões x dois gêneros = 10 grupos), entre eles por exemplo, o de mulheres da região Norte, de homens da região Norte e de mulheres da região Nordeste. Dessa forma, a cada ciclo da simulação, o modelo realiza a soma das variáveis de acordo com o configurado na GUI para estratificar os resultados e armazena estes valores na matriz dos resultados.

A matriz resultados, criada na função “configurar”, é elaborada de forma que as linhas representam os grupos de estratificação dos resultados configurado na GUI e as colunas os tipos de observações coletadas (quantidades de carne consumida, probabilidade, preocupação ambiental e outras). Além destas observações, a matriz também contém o número total da população destes grupos, vegetariana e não vegetariana, a qual foi somada na função “configurar”. Essa matriz, por ser criada de acordo com os agentes inseridos no ABM e com a configuração dos grupos de estratificação que se deseja analisar os resultados, possibilita, além de um maior nível de

desagregação dos resultados, uma maior adaptação do código a outros estudos com diferentes bases de dados.

As atualizações dos gráficos e do mapa do Brasil apresentam os resultados agregados em macrorregiões e consolidados para o país. Os gráficos mostram o consumo total da população, o consumo, a probabilidade e a preocupação com o meio ambiente médio per capita. Caso o modelo seja rodado com o objetivo final apenas para analisar arquivo texto, é possível desativar estas atualizações na interface e acelerar o processamento da simulação.

3.5 Análise de sensibilidade

A análise de sensibilidade foi desenvolvida considerando dois fatores que condicionam as escolhas dos agentes em consumir carne vermelha: influência da interação entre agentes e aumento do preço da carne através de um mecanismo de precificação de GEE. A primeira, compara os resultados do modelo sem aplicar nenhuma intervenção (modelo base) com o modelo sem permitir a interação dos agentes. O objetivo dessa análise é avaliar como a interação dos agentes, e consequentemente, a atualização da preocupação com o meio ambiente, impacta os resultados da simulação. A segunda avalia a sensibilidade do modelo quanto ao aumento do preço da carne bovina. Para isso, foram comparados os resultados da simulação sem aplicar nenhuma intervenção (modelo base), e aplicando o aumento do preço em 5%, 30% e 60%. Esses valores foram determinados a partir de três estimativas realizadas utilizando os preços de varejo da carne bovina de 2017 a 2020, disponibilizados pela CONAB (CONAB, 2022), baseando-se na ideia de três cenários.

O aumento do preço em 5% está relacionado a variação de preço usual da carne, o qual foi estimada verificando a variação da média do preço mensal para o período de 2017 a 2019. O aumento de 30% está relacionado a uma variação no preço decorrente de um evento extraordinário, como o ocorrido recentemente com a pandemia do Coronavírus (COVID-19), iniciada no decorrer deste estudo, a qual causou um choque na oferta e na demanda fazendo com que os preços fugissem da serie histórica. Este aumento foi estimado a partir da diferença entre a média do preço do período de 2017 a 2019 e a média de junho a dezembro de 2020, quando a pandemia agravou no Brasil e os preços da carne dispararam. Por fim, o aumento de 60% foi estimado ao se considerar uma precificação de carbono sobre a carne bovina. Para chegar a este valor, considerou-se a pegada de

carbono da carne bovina de 78 kg CO_{2e}/kg Carne (INSTITUTO ESCOLHAS, 2020), a taxa de emissão de CO₂ de U\$42,00, referente a média de preço do mercado de carbono europeu em abril de 2021 (TAX FOUNDATION, 2021), o preço da carne bovina sem especificação de carbono de R\$18,80, referente a média do preço do período de 2017 a 2019, e Taxa Cambial de 3,60 (BCB, 2022), referente a média da taxa para o mesmo período.

4 Resultados

Este capítulo apresenta os resultados dividindo-os em seis partes. As seções 4.1, 4.2, 4.3, 4.4 apresentam os resultados dos módulos inseridos no modelo. A seção 4.5 apresenta os resultados produzidos pela simulação do módulo, e a seção 4.6 os resultados obtidos pelas análises de sensibilidade executadas.

4.1 Módulo 1: Provável preocupação com o meio ambiente

A Figura 7 revela a frequência das respostas à pergunta “O quanto você considera que está preocupado(a) com o meio ambiente atualmente?” da pesquisa Mudanças Climáticas na Percepção dos Brasileiros (ITS, 2021), considerando diferentes fatores demográficos da população. Apesar do Figura 7.A demostrar que a maioria da população brasileira se considera preocupada com o meio ambiente, com 86% das respostas positivas (“Muito Preocupada” e “Preocupada”) e apenas 14% negativas (“Pouco Preocupada” e “Nada Preocupada”), estas respostas apresentam diferentes proporções ao serem analisada considerando a demografia da população, conforme demonstrado pelos outros painéis desta figura. A estratificação respectiva a gênero (Figura 7.D) destaca-se entre todas as analisadas com a maior discrepância entre as suas categorias. Enquanto, entre os homens, 6% responderam estar nada preocupados e 14% pouco preocupados, entre as mulheres estas mesmas respostas tiveram quase um terço e metade destas porcentagens, respectivamente. Assim, as mulheres apresentam 8% de suas respostas sendo negativas e os homens 20%, o que se reflete em uma diferença de mais de 15 pontos percentuais relativas à resposta “Muito preocupada”.

A Figura 7.B, a qual mostra a diferença entre as macrorregiões, aponta a região norte como a menos preocupada, com 19% das respostas negativas (81% positivas) e com o índice da resposta “pouco preocupada” se destacando sobre as outras regiões em pelo menos 5 pontos. Esta é seguida da região centro-oeste com 15% negativas (85% positivas). A região sudeste aparece como a mais preocupada, com 87% das respostas positivas (13% negativas), sendo a única com sua porcentagem sobre as respostas “muito preocupada” (64%) acima da média da população (62%). Esta é seguida pela região Nordeste com 87% respostas positivas (13% negativas). A estratificação relativa as áreas urbanas e rurais (Figura 7.C) não apresentaram diferenças relevantes.

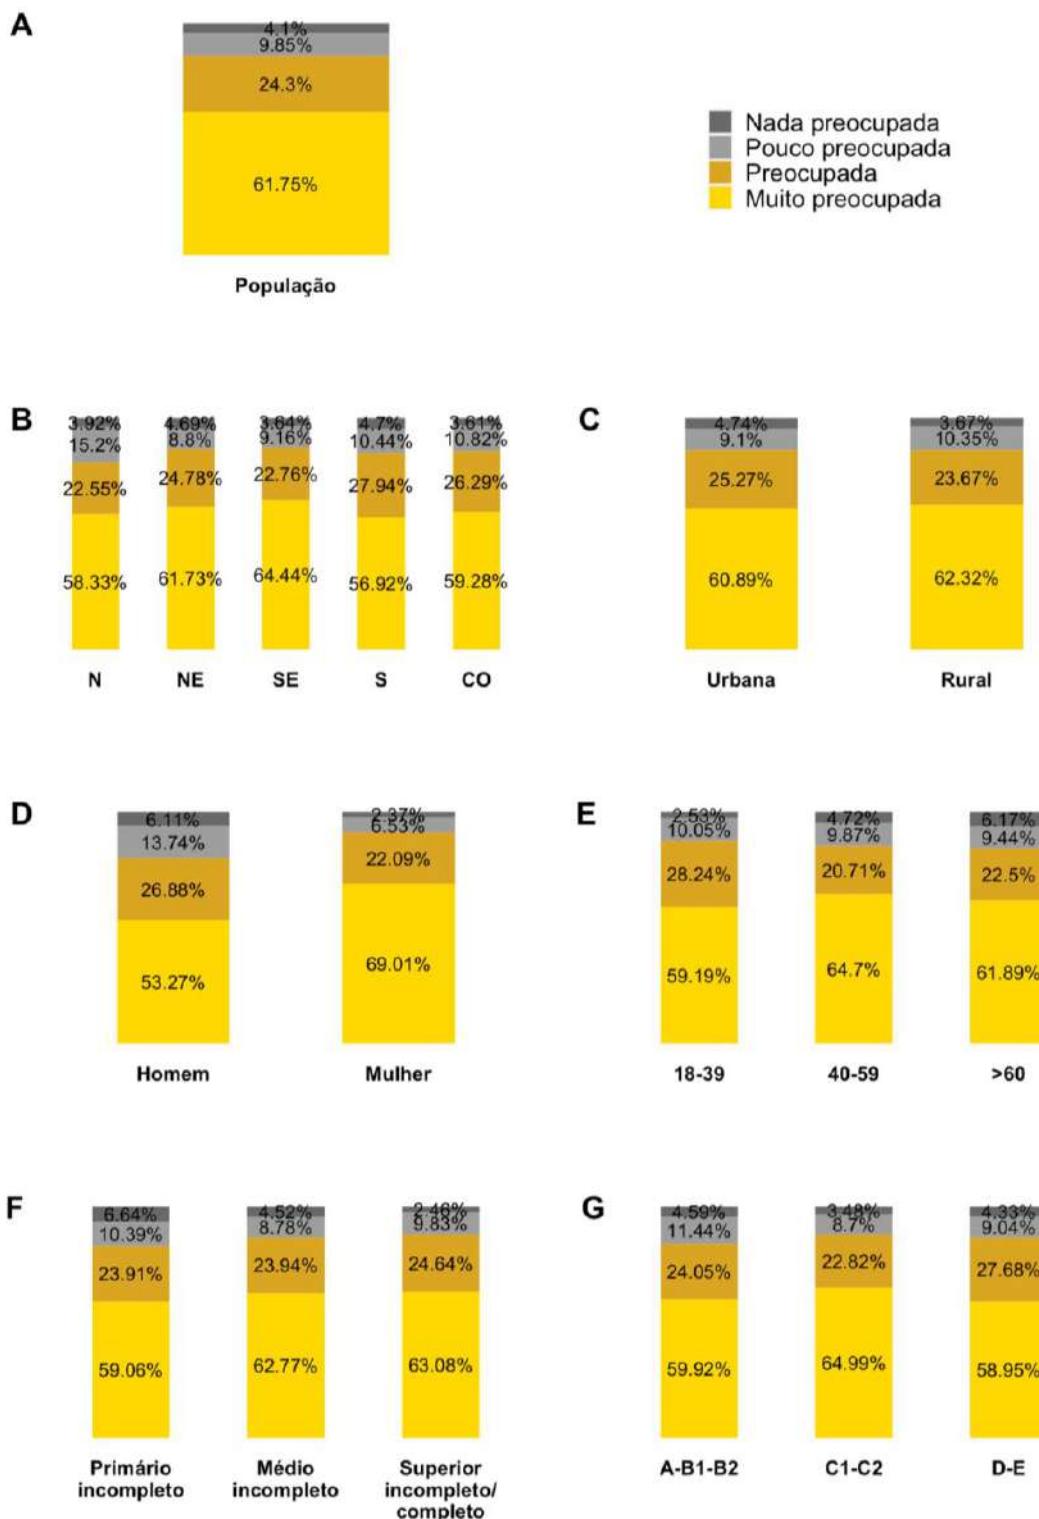


Figura 7: Frequência das respostas à pergunta “O quanto você considera que está preocupado(a) com o meio ambiente atualmente?” considerando: A) população geral B) macrorregião; C) situação de domicílio; D) gênero; E) faixa etária; F) nível de escolaridade; G) Classe de renda

Fonte: Elaboração própria (2022)

A Figura 7.E apresenta a diferença entre 3 grupos de idades, indicando uma tendência de que quanto mais velho, menor a preocupação com o meio ambiente. Apesar do grupo de 18 a 39 anos ter tido o maior percentual total positivo de 88%, com a resposta “preocupada” se destacando sobre os outros grupos e sobre a média brasileira, o grupo de 40 a 59 anos, com o total de 85% de respostas positivas, se destaca entre os grupos e a média pela resposta de maior preocupação.

Em relação a escolaridade da população, a Figura 7.F, confirma a tendência intuitiva de que quanto maior o nível de escolaridade maior a preocupação ambiental. O grupo referente a pessoas sem educação ou com primário incompleto apresentam 83% das respostas sendo positivas - “Muito Preocupada” e “Preocupada” - sendo as duas respostas abaixo da média brasileira. O grupo que contempla pessoas com o primário completo e o ensino médio incompleto apresenta 87% das respostas sendo positivas (13% negativas), com apenas a resposta “preocupada” abaixo da média. Já o grupo respectivo as pessoas com o ensino médio completo e superior incompleto/completo apresenta 87% das respostas sendo positivas (13% negativas), com estas duas respostas acima da média.

Contradicitoriamente a estes dados, a Figura 7.G referente a classe econômica, indica classe mais alta (A, B1 e B2) como aquela com a menor preocupação com o meio ambiente com 84% das respostas sendo positivas (16% negativas). Embora as diferenças entre as proporções das respostas sejam pequenas, os dados indicam a classe média (C1 e C2) como a mais preocupada, com 88% das respostas positivas (12% negativas) e com o índice da resposta “muito preocupada” se destacando sobre as outras classes e da média da população. Esta é seguida pela classe mais baixa (D e E) com 87% positivas (13% negativas).

Diante deste contexto, optou-se por caracterizar a população em relação a sua percepção sobre a sua preocupação com o meio ambiente considerando a macrorregião, o gênero e a escolaridade. Apesar das classes econômicas e idade apresentarem diferenças entre as suas categorias tão destoantes quanto as da escolaridade, optou-se por essa variável devido a sua linearidade, de que quanto maior o nível de escolaridade maior a preocupação ambiental, e ao fato das categorias da escolaridade serem as mesmas da POF, diferentemente da classificação econômica.

A Figura 8 apresenta as distribuições de respostas ao se considerar essas três variáveis da população. Nela pode-se notar, por exemplo, como a diferença entre homens e mulheres varia entre regiões e escolaridade. Ao comprar homens e mulheres é possível

notar uma discrepância maior entre respostas positivas e negativas nas regiões Norte e Centro-oeste, do que o Sul e o Sudeste. A escolaridade, por sua vez, perde seu caráter linear. Enquanto as mulheres e os homens do sudeste apresentam uma tendência crescente da preocupação com o meio ambiente em relação ao grau de escolaridade, as mulheres e os homens do norte e do centro-oeste apresentam uma tendência decrescente.

Os valores de preocupações ambientais foram atribuídos aos indivíduos da POF aleatoriamente considerando as suas respectivas probabilidades de respostas e assegurando que ao final as proporções das respostas de cada grupo fosse o mesmo apresentado na Figura 8, permitindo um erro de até 5 pontos percentuais.

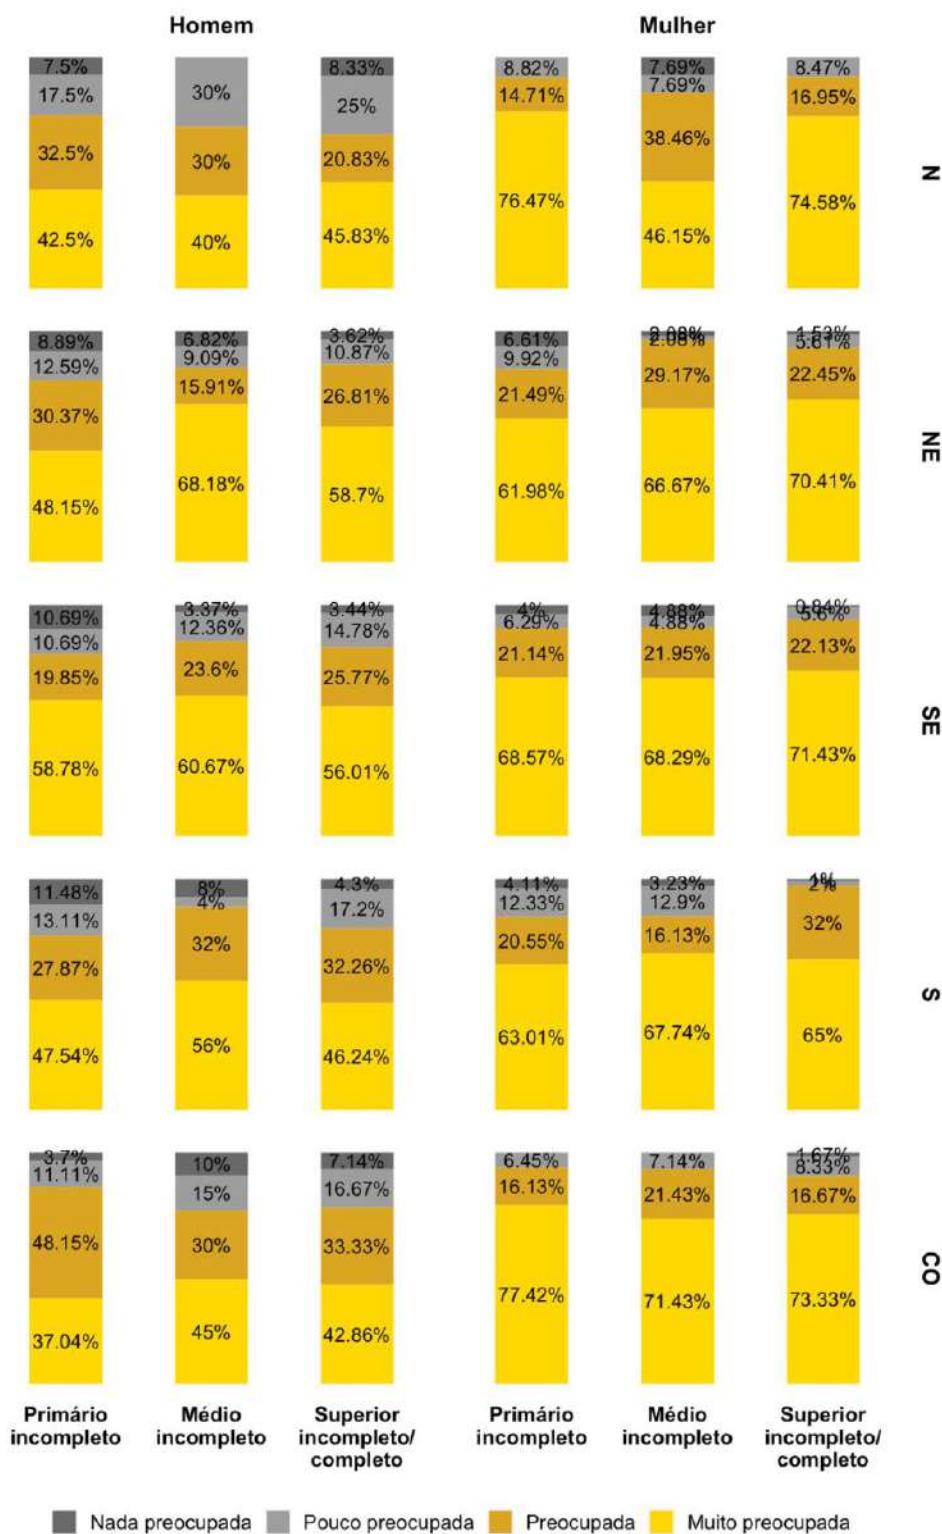


Figura 8: Frequência das respostas à pergunta “O quanto você considera que está preocupado(a) com o meio ambiente atualmente?” considerando a combinação das variáveis macrorregião, gênero e nível de escolaridade.

Fonte: Elaboração própria (2022).

4.2 Módulo 2: Probabilidade de realizar uma refeição fora de casa

Os resultados do módulo 2 são apresentados a seguir através da razão de chances - RC (*odds ratio* na língua inglesa - OR) a fim de facilitar uma interpretação correta e comparações pertinentes. A RC é amplamente usada como medida de associação, uma vez que estima o quanto mais provável ou improvável é de um determinado evento ocorrer ao comparar diferentes valores para uma variável. Esta medida é a razão entre as chances de um determinado evento ocorrer quando $x = 1$ e as chances de quando $x = 0$, dado pela Equação 7. No caso de covariáveis dicotômicas (como urbano e rural) e covariáveis policotômicas (norte, nordeste, sudeste, sul e centro-oeste) não envolvidas em nenhuma interação, e que utilizem o método de codificação de célula de referência, a RC e o intervalo de confiança das variáveis pode ser simplificado ao exponencial de seus respectivos coeficientes e intervalos de confiança. Vale ressaltar que quando RC é igual 1, significa que a chance de algo ocorrer sobre a chance de algo não acontecer é a mesma.

Equação 7 - Razão de chances

$$RC = \frac{\frac{p(1)}{[1 - p(1)]}}{\frac{p(0)}{[1 - p(0)]}}$$

Na Tabela 7 são apresentados a razão de chance (RC), o intervalo de confiança (IC) e o nível de significância (valor p) das variáveis avaliadas como possíveis fatores associados a comer fora de casa, obtidas a partir dos modelos de regressão logística não-ajustada (univariada). Todas as variáveis nestes modelos foram estatisticamente significativas avaliadas ao nível de 1%.

Entre as variáveis demográficas destaca-se a macrorregião e situação de domicílio. Em relação a primeira, pode-se observar que a chance de uma pessoa residente na região Centro-Oeste e Sul decidir por comer fora de casa foi, respectivamente, 48% maior ($RC = 1,48$; IC95%: 1,39-1,59) e 28% maior ($RC = 1,28$; IC95%: 1,20-1,37) em relação a região Norte (célula de referência). As regiões Sudeste e Nordeste também apresentaram chances maiores do que a região Norte, de 13% ($RC = 1,13$; IC95%: 1,07-1,20) e 9% ($RC = 1,09$; IC95%: 1,03-1,15), respectivamente. No entanto, ambas com intervalos de confiança com valores muito próximos. Quanto a situação de domicílio, as pessoas que residiam no meio rural apresentaram chances de comer fora de casa 38% menor ($RC = 0,62$; IC95%: 0,59 - 0,65) quando comparada a residentes no meio urbano. Em relação ao gênero, mulheres apresentaram 17% menos chances de comerem fora de

casa do que os homens ($RC = 0,83$; IC95%: 0,80 - 0,86). E em relação a idade, resultados mostram que a cada ano acrescido a chance do indivíduo comer fora de casa diminui 2% ($RC = 0,98$; IC95%: 0,981 - 0,983).

Tabela 7: Resultados da regressão logística não-ajustada para calcular a probabilidade de indivíduos comerem fora de casa.

Variáveis	Coeficientes (β)	Desvio padrão	Valor p	Razão de chances	IC (95%)
Macrorregião					
Norte (referência)				1,000	
Nordeste	0,085	0,029	0,0036 *	1,089	1,028 - 1,154
Sudeste	0,124	0,031	0,0001 ***	1,132	1,065 - 1,203
Sul	0,247	0,034	0,0000 ***	1,281	1,197 - 1,370
Centro-Oeste	0,393	0,034	0,0000 ***	1,482	1,385 - 1,585
Área					
Urbano (referência)				1,000	
Rural	-0,481	0,024	0,0000 ***	0,618	0,590 - 0,648
Gênero					
Homem (referência)				1,000	
Mulher	-0,183	0,018	0,0000 ***	0,833	0,804 - 0,862
Idade					
	-0,018	0,001	0,0000 ***	0,982	0,981 - 0,983
Grupo de renda					
Classe alta (referência)				1,000	
Classe média	-0,540	0,023	0,0000 ***	0,583	0,557 - 0,610
Classe baixa	-0,918	0,024	0,0000 ***	0,399	0,381 - 0,418
Status Empregatício					
Desempregado (referência)				1,000	
Empregado	1,040	0,023	0,0000 ***	2,828	2,705 - 2,957
Educação					
Sem educação/Primário incomp. (referência)				1,000	
Primário comp./Médio incomp.	0,573	0,021	0,0000 ***	1,773	1,701 - 1,849
Médio comp./Superior incomp./comp.	0,988	0,024	0,0000 ***	2,685	2,561 - 2,816
Tipo de refeição					
Almoço (referência)				1,000	
Jantar	-0,770	0,019	0,0000 ***	0,463	0,446 - 0,481
Dia da refeição					
Dia de semana (referência)				1,000	
Fim de semana	0,148	0,020	0,0000 ***	1,159	1,113 - 1,207

*** valor $p < 0,0001$; ** valor $p < 0,001$; * valor $p < 0,01$; . valor $p < 0,05$

Fonte: Elaboração própria (2022)

As variáveis socioeconômicas apresentaram maiores efeitos e discrepâncias entre as categorias de suas variáveis. Como o esperado, resultados mostram que quanto menor a renda, e menor o nível educacional, menor as chances de comer fora de casa. A classe média apresentou chances 42% menor ($RC = 0,58$; IC95%: 0,56 - 0,61), e a classe mais baixa 60% menor ($RC = 0,40$; IC95%: 0,38 - 0,42), quando comparadas a classe mais alta. Em relação ao nível educacional, pessoas que fazem parte do grupo que tiveram o primário completo ou o ensino médio incompleto e do grupo que completaram o ensino médio ou tiveram o ensino superior incompleto/completo apresentam, respectivamente, chances 77% maiores ($RC = 1,77$; IC95%: 1,70 - 1,85) e 169% maiores ($RC = 2,69$;

IC95%: 2,56 - 2,82) quando comparado a pessoas que não tiveram educação ou o primário incompleto. Quanto aos status empregatício, as diferenças foram ainda mais discrepantes, sendo a chances de um indivíduo empregado ser 183% maior (RC = 2,83; IC95%: 2,71 - 2,96) do que um indivíduo desempregado.

Entre as variáveis relacionadas a refeição, a chance de uma pessoa comer fora no jantar é 54% menor do que no almoço (RC = 0,46; IC95%: 0,45 - 0,48), e 16% maior no fim de semana comparativamente a dias da semana (RC = 1,16; IC95%: 1,11 - 1,21).

Na Tabela 8 são apresentados a razão de chance, o intervalo de confiança, o nível de significância (valor p) e os coeficientes das variáveis selecionadas, obtidas a partir dos modelos de regressão logística ajustada. Para construir o modelo ajustado foram selecionadas primeiramente todas as variáveis do modelo não-ajustado, com exceção da variável gênero. Apesar de todas as variáveis terem apresentado p-valor significante nos testes de Wald e da Razão de verossimilhança, as variáveis de macrorregião, situação de domicílio, gênero, status empregatício e educação apresentaram uma variação dos coeficientes ($\Delta\beta\%$) acima de 20%. Removendo uma variável por vez e avaliando as variações dos coeficientes chegou-se ao modelo ajustado final, apresentado na Tabela 8.

Tabela 8: Resultados da regressão logística ajustada para calcular a probabilidade de indivíduos comerem fora de casa.

Variáveis	Coefici- entes (β)	Desvio padrão	Valor p	$\Delta\beta\%$	Razão de chances	IC (95%)
Macrorregião						
Norte (referência)					1,000	
Nordeste (β_1)	0,092	0,030	0,0023 *	7%	1,096	1,033 - 1,163
Sudeste (β_2)	0,106	0,032	0,0008 **	-17%	1,112	1,045 - 1,184
Sul (β_3)	0,262	0,035	0,0000 ***	6%	1,299	1,213 - 1,392
Centro-Oeste (β_4)	0,420	0,035	0,0000 ***	6%	1,522	1,421 - 1,631
Área						
Urbano (referência)					1,000	
Rural (β_5)	-0,383	0,025	0,0000 ***	-26%	0,682	0,650 - 0,716
Grupo de renda						
Classe alta (referência)					1,000	
Classe média (β_6)	-0,489	0,024	0,0000 ***	-10%	0,613	0,585 - 0,643
Classe baixa (β_7)	-0,814	0,024	0,0000 ***	-13%	0,443	0,422 - 0,465
Status Empregatício						
Desempregado (referência)					1,000	
Empregado (β_8)	1,006	0,023	0,0000 ***	-3%	2,735	2,615 - 2,860
Tipo de refeição						
Almoço (referência)					1,000	
Jantar (β_9)	-0,785	0,020	0,0000 ***	2%	0,456	0,439 - 0,474
Dia da refeição						
Dia de semana (referência)					1,000	
Fim de semana (β_{10})	0,163	0,021	0,0000 ***	9%	1,177	1,129 - 1,226
Constante da equação (β_0)	-2,173	0,037	0,0000 ***			

*** valor $p < 0,0001$; ** valor $p < 0,001$; * valor $p < 0,01$; . valor $p < 0,05$

Fonte: Elaboração própria (2022)

No modelo ajustado final pode-se observar que a magnitude e a orientação dos sinais dos coeficientes, assim como a significância estatística dos parâmetros são semelhantes às observadas no modelo de regressão logístico não-ajustado. Apenas a variável situação de domicílio teve uma variação de coeficiente acima dos 20%, mas por ter sido próxima ao limite estabelecido pela metodologia e apresentar alta significância estatística, optou-se por manter a variável. A Tabela 9 apresenta os coeficientes da equação da regressão logística, e a Equação 8 exibe a equação introduzida no modelo.

Equação 8: Regressão logística – probabilidade do agente i realizar a refeição fora de casa no tempo t .

$$p_{i,t}(\text{cons. carne}) = \frac{e^{-y_{i,t}}}{(1+e^{-y_{i,t}})} \text{, onde:}$$

$$y_{i,t} = \beta_0 + \beta_1 (Xne_i) + \beta_2 (Xse_i) + \beta_3 (Xs_i) + \beta_4 (Xco_i) + \beta_5 (Xrural_i) + \beta_6 (Xrenda2_i) + \beta_7 (Xrenda3_i) + \beta_8 (Xemprego_i) + \beta_9 (Xjantar_t) + \beta_{10} (Xfds_t)$$

Tabela 9: Variáveis da Regressão logística – probabilidade do agente i realizar a refeição fora de casa no tempo t .

Parâmetro	Valores	Descrição
Xne_i	{0; 1}	Macrorregião do agente i : nordeste = 1; outros = 0
Xse_i	{0; 1}	Macrorregião do agente i : sudeste = 1; outros = 0
Xs_i	{0; 1}	Macrorregião do agente i : sul = 1; outros = 0
Xco_i	{0; 1}	Macrorregião do agente i : centro-oeste = 1; outros = 0
$Xrural_i$	{0; 1}	Área do agente i : rural = 1; urbano = 0
$Xrenda2_i$	{0; 1}	Grupo de renda do agente i : 35% renda intermediária = 1; outros = 0
$Xrenda3_i$	{0; 1}	Grupo de renda do agente i : 50% menor renda = 1; outros = 0
$Xemprego_i$	{0; 1}	Status empregatício do agente i : empregado = 1; desempregado = 0
$Xjantar_t$	{0; 1}	Tipo de refeição no tempo t : jantar = 1; almoço = 0
$Xfds_t$	{0; 1}	Dia de refeição no tempo t : fim de semana = 1; dia de semana = 0
β_0	-2,1731	Constante da equação
β_1	0,0916	Coeficiente da macrorregião nordeste
β_2	0,1062	Coeficiente da macrorregião sudeste
β_3	0,2620	Coeficiente da macrorregião sul
β_4	0,4203	Coeficiente da macrorregião centro-oeste
β_5	-0,3826	Coeficiente de situação de domicílio rural
β_6	-0,4891	Coeficiente do grupo de renda classe média
β_7	-0,8141	Coeficiente do grupo de renda classe baixa
β_8	1,0060	Coeficiente do status empregatício empregado
β_9	-0,7847	Coeficiente do tipo de refeição jantar
β_{10}	0,1628	Coeficiente do dia de refeição fim de semana

Fonte: Elaboração própria (2022)

4.3 Módulo 3: Probabilidade de consumir carne bovina em uma refeição

Os resultados do módulo 3 são apresentados a seguir seguindo o mesmo modelo dos resultados do módulo 2. Na Tabela 10 são apresentadas as razões de chance, os intervalos de confiança (IC) e os níveis de significância (valor p) das variáveis avaliadas como possíveis fatores associados a comer carne em uma refeição, obtidas a partir dos modelos de regressão logística não-ajustada (univariada). Todas as variáveis avaliadas nestes modelos foram estatisticamente significativas avaliadas ao nível de 1%, com exceção da situação de domicílio, nível de preocupação com o meio ambiente e o parâmetro da classe média.

Tabela 10: Resultados da regressão logística não-ajustada para calcular a probabilidade de indivíduos consumir carne em uma refeição

Variáveis	Coefici- entes (β)	Desvio padrão	Valor p	Razão de chances	IC (95%)
Macrorregião					
Norte (referência)				1,000	
Nordeste	-0,1404	0,0186	0,00000 ***	0,869	0,838 - 0,901
Sudeste	-0,0748	0,0197	0,00015 **	0,928	0,893 - 0,965
Sul	-0,1377	0,0227	0,00000 ***	0,871	0,833 - 0,911
Centro-Oeste	0,4070	0,0224	0,00000 ***	1,502	1,438 - 1,570
Área					
Urbano (referência)				1,000	
Rural	-0,0040	0,0140	0,77541	0,996	0,969 - 1,024
Gênero					
Homem (referência)				1,000	
Mulher	-0,2009	0,0119	0,00000 ***	0,818	0,799 - 0,837
Idade					
	-0,0012	0,0003	0,00039 **	0,999	0,998 - 0,999
Grupo de renda					
Classe alta (referência)				1,000	
Classe média	0,0240	0,0180	0,18302	1,024	0,989 - 1,061
Classe baixa	-0,0882	0,0175	0,00000 ***	0,916	0,885 - 0,947
Educação					
Sem educação/Primário incompleto (referência)				1,000	
Primário completo/Médio incompleto	0,0860	0,0131	0,00000 ***	1,090	1,062 - 1,118
Médio completo/Superior incompleto/completo	0,0508	0,0171	0,00300 *	1,052	1,017 - 1,088
Preocupação com o meio ambiente					
	-0,0119	0,0070	0,08616	0,988	0,975 - 1,002
Tipo de refeição					
Almoço (referência)				1,000	
Jantar	-0,7311	0,0123	0,00000 ***	0,481	0,470 - 0,493
Dia da refeição					
Dia de semana (referência)				1,000	
Fim de semana	-0,1095	0,0142	0,00000 ***	0,896	0,872 - 0,922
Local da refeição					
Em casa (referência)				1,000	
Fora de casa	0,1362	0,0193	0,00000 ***	1,146	1,103 - 1,190

*** valor $p < 0,0001$; ** valor $p < 0,001$; * valor $p < 0,01$; . valor $p < 0,05$

Fonte: Elaboração própria (2022)

Entre as variáveis demográficas destaca-se a da macrorregião e de gênero. Em relação a primeira, observou-se elevada propensão a comer carne bovina em uma refeição entre indivíduos residentes na região Centro-Oeste. A chance de uma pessoa residente desta região foi 50% maior ($RC = 1,50$; IC95%: 1,44 - 1,57) do que a região Norte. As regiões Sudeste, Sul e Nordeste, apresentaram chances menores do que a região Norte, respectivamente de, -7% ($RC = 0,93$; IC95%: 0,89 - 0,96), -13% ($RC = 0,87$; IC95%: 0,83 - 0,91), e -13% ($RC = 0,87$; IC95%: 0,84 - 0,90). Apesar das três regiões apresentarem resultados estatisticamente significativos, seus intervalos de confiança apresentam um grande intervalo de interseção. Isto é, enquanto a região Sudeste pode apresentar chances de até 11% menor ou de apenas 4% menor do que a região Norte, a região Sul pode apresentar chances de até 17% menor ou de apenas 9% menor do que a região Norte. Podendo haver, portanto, uma certa imprecisão ao comparar estas regiões entre si.

Em relação ao gênero, mulheres apresentaram 18% menos chances de comerem carne em uma refeição do que os homens ($RC = 0,82$; IC95%: 0,80 - 0,84). A variável situação de domicílio não apresentou associações estatisticamente significativas (meio rural: $RC = 1,00$; IC95%: 0,97 - 1,02). Já os resultados da variável de idade, estatisticamente significativas ao nível de 1%, mostram que a cada ano acrescido, a chance do indivíduo comer carne bovina em uma refeição diminui apenas 0,1% ($RC = 0,999$; IC95%: 0,998 - 0,999).

No que tange as variáveis socioeconômicas, resultados apresentaram de forma geral efeitos brandos sobre a chance de comer carne bovina em uma refeição. A variável relativa ao nível educação, apesar de ter mostrado significância ao nível de 1%, suas categorias apresentaram diferenças pequenas e de baixa magnitude. Pessoas que fazem parte do grupo que tiveram o primário completo ou o ensino médio incompleto e do grupo que tiveram o ensino médio completo ou ensino superior incompleto/completo apresentaram, respectivamente, chances 9% maiores ($RC = 1,09$; IC95%: 1,06 - 1,12) e 5% maiores ($RC = 1,05$; IC95%: 1,02 - 1,09) quando comparado a pessoas que não tiveram educação ou o primário incompleto. Quanto as variáveis de renda, observou-se que a classe média apresenta chances 2% maior ($RC = 1,02$; IC95%: 0,99 - 1,06), e a classe mais baixa 8% menor ($RC = 0,92$; IC95%: 0,88 - 0,95) em relação a classe mais alta. Como o valor p do teste Wald para a classe média é de 0,183, não é surpreendente que o valor nulo de 1 esteja contido no intervalo de confiança. Ainda que a classe alta e

classe média possam vir a apresentar a mesma influência sobre as chances de consumir carne em uma refeição, a classe baixa ainda apresenta diferenças significantes sobre a classe alta.

Já as variáveis status empregatício, a chance de um indivíduo empregado comer carne em uma refeição foi 12% maior ($RC = 1,12$; IC95%: 1,10 - 1,15) do que um indivíduo desempregado. O resultado sobre nível de preocupação com o meio ambiente apontou que o acréscimo de 1 unidade sobre esta variável diminui a chance do indivíduo comer carne bovina em uma refeição em 1% ($RC = 0,99$; IC95%: 0,97 - 1,00), tendo uma significância ao nível de 10%.

Entre as variáveis relacionadas ao contexto da refeição, destaca-se a variável relativa à ocasião, em que a chance de uma pessoa comer carne no jantar foi 52% menor do que no almoço ($RC = 0,48$; IC95%: 0,47 - 0,49). As variáveis de dia e local apresentaram efeito menor sobre o consumo da carne, sendo apenas 10% menor no fim de semana comparativamente a dias da semana ($RC = 0,89$; IC95%: 0,87 - 0,92), e 15% maior fora de casa relativamente ao consumo em casa ($RC = 1,15$; IC95%: 1,10 - 1,19).

Na Tabela 11 são apresentados a razão de chance (RC), o intervalo de confiança (IC), o nível de significância (valor p) e os coeficientes das variáveis selecionadas, obtidas a partir dos modelos de regressão logística ajustada. Para construir o modelo ajustado foram selecionadas primeiramente todas as variáveis do modelo não-ajustado, com exceção da variável situação de domicílio. As variáveis de grupo de renda, educação, preocupação com o meio ambiente e local da refeição apresentaram uma variação dos coeficientes ($\Delta\beta\%$) acima de 70%. Removendo uma variável por vez e avaliando as variações dos coeficientes, realizando testes de Wald e da Razão de verossimilhança, chegou-se ao modelo ajustado final apresentado na Tabela 11 .

No modelo ajustado final, pode-se observar que a magnitude e a orientação dos sinais dos coeficientes, assim como a significância estatística dos parâmetros são semelhantes às observadas no modelo de regressão logístico não-ajustado, com exceção da região sudeste e da preocupação com o meio ambiente. No caso da região sudeste, optou-se por manter a macrorregião não só por ter tido uma variação de β próxima ao limite estabelecido pela metodologia, mas também por ser significativos nos dois testes propostos.

Tabela 11: Resultados da regressão logística ajustada para calcular a probabilidade de indivíduos consumir carne em uma refeição

Variáveis	Coeficientes (β)	Desvio padrão	Valor p	$\Delta\beta\%$	Razão de chances	IC (95%)
Macrorregião						
Norte (referência)					1,00	
Nordeste (β_1)	-0,1380	0,0189	0,00000 ***	-2%	0,87	0,839 - 0,904
Sudeste (β_2)	-0,0979	0,0201	0,00000 ***	24%	0,91	0,872 - 0,943
Sul (β_3)	-0,1476	0,0231	0,00000 ***	7%	0,86	0,825 - 0,903
Centro-Oeste (β_4)	0,4067	0,0228	0,00000 ***	0%	1,50	1,436 - 1,570
Gênero						
Homem (referência)					1,00	
Mulher (β_5)	-0,2104	0,0123	0,00000 ***	5%	0,81	0,791 - 0,830
Grupo de renda						
Classe alta (referência)					1,00	
Classe média (β_6)	0,0266	0,0184	0,14739	10%	1,03	0,991 - 1,065
Classe baixa (β_7)	-0,0856	0,0178	0,00000 ***	-3%	0,92	0,886 - 0,951
Preocupação com o meio ambiente (β_8)	0,0096	0,0072	0,18671	225%	1,01	0,995 - 1,024
Tipo de refeição						
Almoço (referência)					1,00	
Jantar (β_9)	-0,7378	0,0124	0,00000 ***	1%	0,48	0,467 - 0,490
Dia da refeição						
Dia de semana (referência)						
Fim de semana (β_{10})	-0,1161	0,0144	0,00000 ***	6%	0,89	0,866 - 0,916
Constante da equação (β_0)	-0,3871	0,03253	0,00000 ***			

*** valor p < 0,0001 ; ** valor p < 0,001 ; * valor p < 0,01 ; . valor p < 0,05

Fonte: Elaboração própria (2022)

Já a preocupação com o meio ambiente, a variável mostrou uma variação bastante elevada e inversão do sentido observado no modelo não ajustado, sugerindo que quanto maior a preocupação, maior a chance de se comer carne bovina em uma refeição. Além disso, a variável não passou no teste de Wald, apresentando significância ao nível de 20%, e consequentemente, também não passou no teste da verossimilhança, o que sugere que sua presença na equação não faz diferença. Apesar destes indicadores apontarem a retirada da variável, ela foi mantida pelos motivos explicados na metodologia do módulo 3 (3.4.3). A Tabela 12 apresenta os coeficientes da equação da regressão logística, e a Equação 8, exibe a equação introduzida no modelo.

Equação 9: Regressão logística – probabilidade do agente i consumir de carne bovina no tempo t .

$$p_{i,t}(\text{cons. carne}) = \frac{e^{-y_{i,t}}}{(1+e^{-y_{i,t}})} * \text{veg}_i, \text{ onde:}$$

$$y_{i,t} = \beta_0 + \beta_1(Xne_i) + \beta_2(Xse_i) + \beta_3(Xs_i) + \beta_4(Xco_i) + \beta_5(Xmulher_i) + \beta_6(Xrenda2_i)(preco_{i,t}) + \beta_7(Xrenda3_i)(preco_{i,t}) + \beta_8(Xpreoc_{i,t}) + \beta_9(Xjantar_t) + \beta_{10}(Xfds_t)$$

Tabela 12: Variáveis da regressão logística – probabilidade do agente i consumir de carne bovina no tempo t .

Parâmetro	Valores	Descrição
veg_i	{0; 1}	Dieta seguida pelo agente i : vegetariana = 0; não vegetariana = 1
Xne_i	{0; 1}	Macrorregião do agente i : nordeste = 1; outros = 0
Xse_i	{0; 1}	Macrorregião do agente i : sudeste = 1; outros = 0
Xs_i	{0; 1}	Macrorregião do agente i : sul = 1; outros = 0
Xco_i	{0; 1}	Macrorregião do agente i : centro-oeste = 1; outros = 0
$Xmulher_i$	{0; 1}	Gênero do agente i : homem = 0; mulher = 1
$Xrenda2_i$	{0; 1}	Grupo de renda do agente i : 35% renda intermediária = 1; Outros = 0
$Xrenda3_i$	{0; 1}	Grupo de renda do agente i : 50% menor renda = 1; Outros = 0
$preço_{i,t}$	[1,2]	Variação do preço da carne do estado do agente i no tempo t
$Xpreoc_{it}$	[1,4]	Preocupação com o meio ambiente do agente i no tempo t
$Xjantar_t$	{0; 1}	Tipo de refeição no tempo t : jantar = 1; almoço = 0
$Xfds_t$	{0; 1}	Dia de refeição no tempo t : fim de semana = 1; dia de semana = 0
β_0	-0,3871	Constante da equação
β_1	-0,1380	Coeficiente da macrorregião nordeste
β_2	-0,0979	Coeficiente da macrorregião sudeste
β_3	-0,1476	Coeficiente da macrorregião sul
β_4	0,4067	Coeficiente da macrorregião centro-oeste
β_5	-0,2104	Coeficiente do gênero mulher
β_6	0,0266	Coeficiente do grupo de renda classe média
β_7	-0,0856	Coeficiente do grupo de renda classe baixa
β_8	0,0096	Coeficiente da preocupação com o meio ambiente
β_9	-0,7378	Coeficiente do tipo de refeição jantar
β_{10}	-0,1161	Coeficiente do dia de refeição fim de semana

Fonte: Elaboração própria (2022)

4.4 Módulo 4: Probabilidade da quantidade de carne bovina a ser consumida

Os resultados do módulo 4 são apresentados através de gráficos violinos sobre a quantidade de carne bovina ingerida em uma refeição. O gráfico violino é a combinação do *boxplot* e a linha de densidade no mesmo diagrama. O primeiro identifica informações de centralidade (mediana), de dispersão (quartis, limites e valores extremos), de assimetria (distribuição entre as hastes) e *outliers*. Já o segundo evidencia a distribuição dos dados, indicando através dos picos e vales onde há incidências de concentração de dados. Além disso, foi adicionado aos gráficos os valores das médias representado através de um triângulo.

A Figura 9 apresenta as curvas de distribuição para todas as variáveis analisadas. Nela constata-se que as curvas não seguem uma distribuição normal. De forma geral, as curvas apresentam formatos bastante semelhantes, com médias medianas e moda notavelmente distintas, com a distribuição afastada em torno da média, com a cauda da distribuição declinando para direita, além de apresentar muitos outliers.

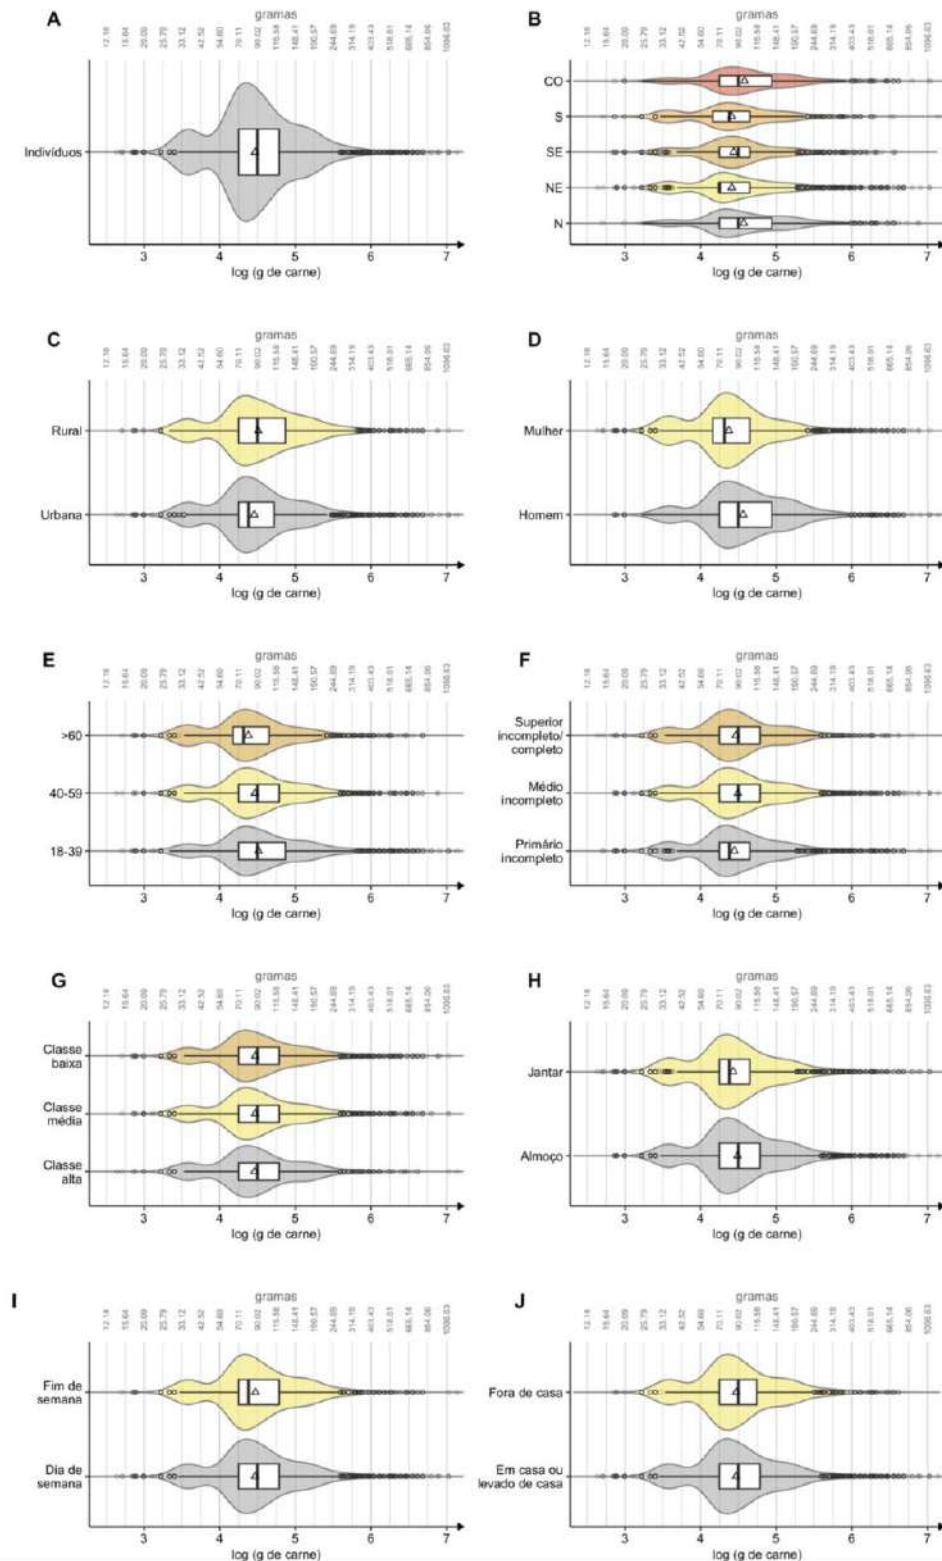


Figura 9: Distribuição da quantidade de carne bovina consumida por indivíduo em uma refeição considerando: A) média global no Brasil B) macrorregião; C) situação de domicílio; D) gênero; E) faixa etária; F) nível de escolaridade; G) Classe de renda; H) Tipo de refeição; I) Dia da refeição; J) Lugar da refeição. Os triângulos marcam as médias e as áreas coloridas a distribuição da quantidade de carne consumida em uma refeição.

Fonte: Elaboração própria (2022)

A Figura 9.B revela as diferenças entre as macrorregiões do Brasil em relação a quantidade de carne bovina consumida em uma refeição. As regiões Centro-Oeste e Norte apresentam distribuições muito semelhantes. Ambas as curvas seguem a mesma forma, com uma distribuição dispersa, intervalos interquartis extensos (1º quartil = 70 gramas, 3º quartil = 135 gramas) e limites inferiores e superiores extremos (mín. = 25 gramas, máx. = 396 gramas). As duas exibem médias de magnitudes elevadas quando comparadas as outras regiões, sendo a do Centro-Oeste equivalente a 98 gramas e a do Norte a 97 gramas, e defasadas da mediana, estimada de 90 gramas.

Já a curva do Sudeste e do Nordeste, ainda que apresentem intervalos interquartis e limites superiores e inferiores semelhantes, suas curvas apresentam muitas diferenças. A curva do Sudeste exibe uma forma mais simétrica, com uma distribuição mais uniforme, contendo a terceira maior média, equivalente a 84 gramas, e mediana de 90 gramas. A região Nordeste, por outro lado, exibe uma curva bastante assimétrica, com a cauda declinando fortemente para esquerda, com a mediana igual ao valor de seu 1º quartil, de 70 gramas, muito abaixo de sua média de 82 gramas. A região Sul, surpreendentemente, apresentou a menor média entre as cinco regiões, equivalente a 82 gramas, e o menor valor para o 1º quartil, equivalente a 64 gramas. No entanto, exibe valores para 3º quartil e limites superiores maiores do que as regiões sudeste e nordeste, e apresenta a curva que mais se aproxima de uma normal, com distribuição simétrica e mediana muito próxima a média.

A Figura 9.C, sobre as situações de domicílio mostra curvas muito diferentes para as áreas rurais e urbanas. A primeira, ainda que apresente valores iguais de média e mediana (equivalente a 90 gramas), ambas estão deslocadas a esquerda do centro da caixa do *boxplot*, indicando uma assimetria com alongamento da cauda a esquerda. Além disso apresenta uma distribuição dispersa, com limites inferiores e superiores mais extremos do que a curva da área urbana. Esta, por sua vez, exibe dados mais concentrados no entorno da média, e maior quantidade de outliers no limite superior que deslocam a média (86 gramas) de sua mediana (de 80 gramas), ambos menores do que os valores da outra curva.

As curvas de distribuição de homens e mulheres no painel D se destacam na Figura 9 como sendo uma das curvas mais discrepantes uma da outra. A curva referente a mulheres apresenta médias e mediana, respectivamente de 79 g e 75 g, bastante abaixo das curvas dos homens, de 96 g e 90 g. Também exibe uma distribuição mais simétrica e

concentrada no entorno de sua média, e uma quantidade de outliers muito superior a curva dos homens. Esta, por sua vez, apresenta uma curva mais dispersa e mais assimétrica com uma cauda declinando fortemente a direita, com valores nos limites inferiores e superiores mais extremos ao comparar com a curva de mulheres.

Na Figura 9.E, referente as diferenças de consumo relativo a faixas etárias, é possível notar que as três curvas possuem formatos bastante semelhantes e que quanto mais velha a faixa de idade, menor as médias, menor o intervalo interquartil, e menos extremos são os valores dos limites superiores e inferiores. A faixa referente a pessoas maiores de 60 anos se destoa das demais, por apresentar média e mediana, respectivamente de 79 g e 75 g, bem abaixo das outras duas faixas (18-39 anos: média 91 g e mediana 90 g; 40-59 anos: média 87 g e mediana 90 g). Estas, apesar de apresentarem estes dois parâmetros muito próximos uma a outra, se diferenciam no desvio padrão, proporcionando uma diferença em relação ao terceiro quartil (18-39 anos: 130 g; 40-59 anos: 120 g), e a seus limites superiores (18-39 anos: 329 g; 40-59 anos: 269 g).

Em relação a Figura 9.F, referente ao nível de educação, destaca-se o grupo que inclui pessoas que não tiveram educação ou o primário incompleto. Esta curva apresenta uma distribuição mais concentrada no entorno da média e com a cauda da distribuição declinando para direita. Sua média (85 g) e mediana (80 g), defasadas uma da outra, apresentam valores inferiores aos outros níveis de escolaridade, os quais exibem curvas mais simétricas com esses parâmetros alinhados em 90g. Além disso, apresenta valores mínimos notavelmente maiores e valores máximos menores do que outras curvas. A Figura 9.G referente as diferenças entre os grupos de renda relativas a quantidade de carne bovina consumida em uma refeição, não apresentou nenhuma diferença entre suas categorias.

Entre os painéis H, I e J, os quais mostram as curvas de distribuição relacionando a diferentes contextos, respectivamente, ocasião, dia e lugar da refeição, destacam-se os dois primeiros como sendo mais relevantes sobre a quantidade de carne bovina consumida em uma refeição. Ao comparar o consumo do almoço e do jantar, o primeiro apresenta uma curva mais simétrica e mais dispersa, com média e mediana iguais a 90 g, notavelmente superior a curva relativa ao jantar (média 84 g; mediana 80 g). Esta apresenta uma assimetria positiva, e limites superiores, equivalente a 193 g, bem abaixo da curva do almoço, de 270 g. Em relação as curvas do dia da refeição, a distribuição referente ao dia semana apresenta um formato mais simétrico e mais disperso e com a

mediana, estimada de 90 gramas, superior a curva do fim de semana, de 80 gramas. Apesar da discrepância entre este parâmetro, suas médias não apresentam diferenças, sendo ambas equivalentes a 87 gramas. A Figura 9.J relativa as diferenças entre o consumo da carne bovina em casa/levado de cada e uma refeição feita fora de casa não apresentou nenhuma diferença entre suas categorias.

Diante deste contexto, foram selecionadas as variáveis que apresentassem maior discrepância entre suas curvas para determinar a heterogeneidade dos indivíduos quanto a quantidade de carne bovina consumida em uma refeição. Assim, a partir das variáveis macrorregião, área, gênero, idade e tipo de refeição, foram elaboradas 120 distribuições (ANEXO III), das quais criou-se uma tabela com as médias e desvios padrão que determinam as curvas de distribuição normal do modelo das quais os agentes retiram um número aleatório para definir a quantidade de carne bovina a ser consumida em uma refeição (ANEXO IV).

De acordo com as médias destas distribuições, o perfil de indivíduo que consome mais carne seriam homens de 18 a 39 anos residentes em áreas rurais da região Centro-Oeste. Já o perfil de menor consumo seriam mulheres com mais de 40 anos da zona rural da região Sul.

4.5 Resultados dos Modelo

O padrão de consumo de carne bovina resultante da simulação foi validado comparando-o aos dados a disponibilidade mensal carcaças bovinas produzidas no Brasil para o período de janeiro de 2017 a dezembro de 2020, de acordo com o inventário da CONAB⁷ reduzidos em 50% devido ao peso da carcaça, tal como detalhado na seção 3.1.5. A simulação foi executada 100 vezes sem aplicar nenhuma intervenção. No final de cada execução, foi realizado no software R (versão 1.3.1073) a soma do consumo mensal dos indivíduos fornecido pelo modelo, o qual considera os fatores de expansão, explicados na seção 3.1.1. O consumo total de carne bovina da população é apresentado na Figura 10.A em toneladas por mês. Estes mesmos dados também foram avaliados na unidade mês per capita, exibido na Figura 10.B. Neste caso, o total consumido pela população foi dividido pelo total de indivíduos considerando os fatores de expansão, e comparados com os dados da CONAB divididos pela projeção da população brasileira com 20 anos ou mais, calculados pelo IBGE para os anos de 2017, 2018, 2019 e 2020 (IBGE, 2018). Cabe ressaltar que não foi considerada a população de 18 anos ou mais, como o considerado pelo modelo, pois o IBGE informa os dados por idade agrupando-os em faixas, que incluem entre elas as faixas de 15-19 anos e 20-24.

A Figura 10 apresenta nos painéis A e B os resultados da simulação em amarelo, denominados de modelo base, juntamente com os intervalos de confiança de 95% em cinza, e os dados de validação em preto. Os resultados do modelo mostraram ao longo dos anos um padrão semelhante ao reportado pela CONAB, tanto em relação a quantidade de carne bovina estimada pela Companhia, como também em relação as tendências da curva, a qual pode ser explicada principalmente pela variação do preço da carne ao longo dos anos, exibida na Figura 10 no painel C. No entanto, é possível observar que a diferença entre a quantidade de carne bovina das duas curvas varia ao longo dos meses, indicando que a simulação não reproduziu as amplitudes das variações do consumo, produzindo aumentos e reduções menores do que o fornecido pelos dados da validação. Além disso, os resultados das 100 execuções da simulação apresentam variações muito pequenas, como pode ser observado através dos intervalos de confiança de 95% em cinza,

⁷Comunicação pessoal via e-mail no dia 16 de março de 2021.

praticamente imperceptíveis. Isto indica que mesmo com todos os fatores estocásticos o modelo apresentou resultados robustos.

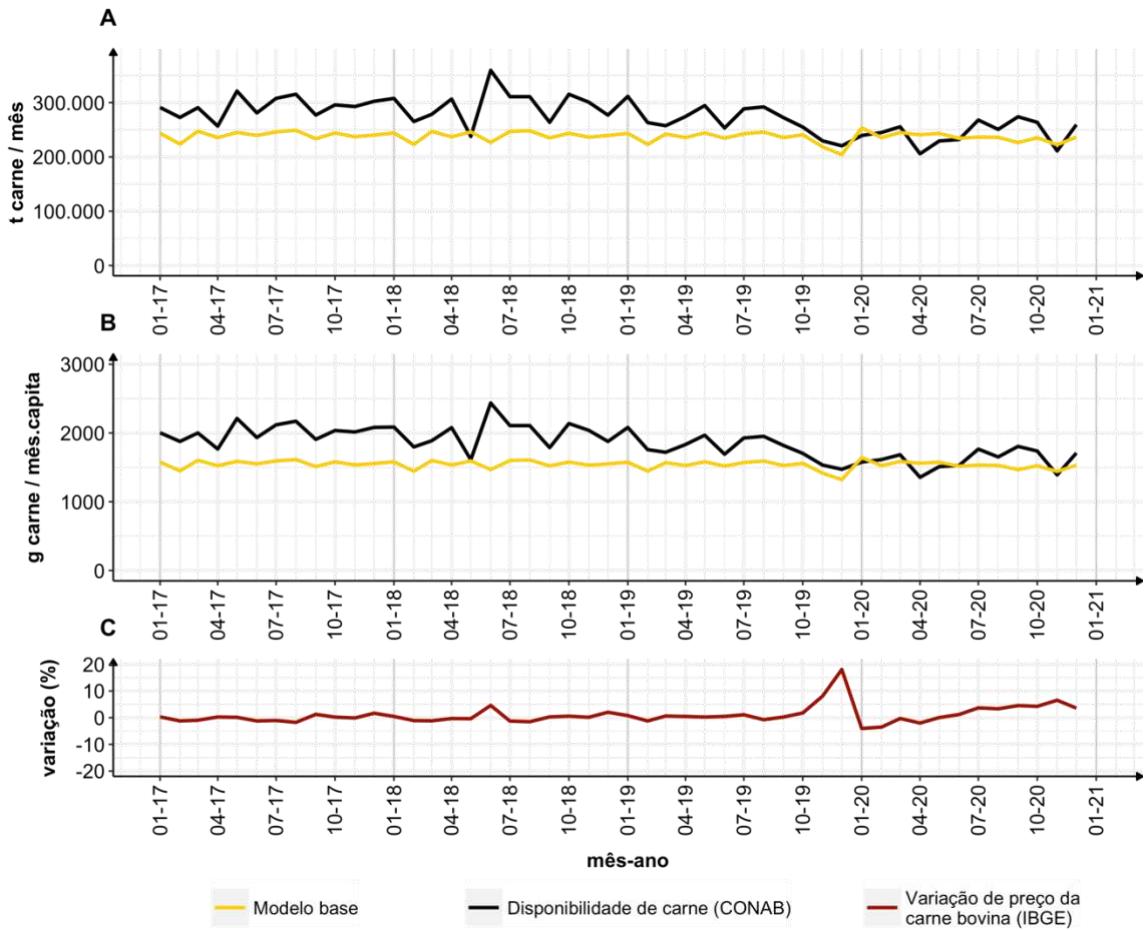


Figura 10: Validação dos resultados do modelo

Fonte: Elaboração própria (2022)

4.6 Análise de Sensibilidade

As Figura 11 e Figura 12 exibem os resultados das duas análises de sensibilidade: a primeira relativa a interação entre os agentes, e segunda, relativa ao aumento do preço da carne bovina. Na Figura 11 é possível observar que ao impedir a interação dos agentes, a média da preocupação com o meio ambiente da população fica constante, próxima a pontuação de 3,4, e ao permitir a interação (modelo base), este valor vai diminuindo ao longo da simulação até chegar a 3,15. O decaimento desta variável faz com que as probabilidades dos indivíduos comerem carne e a quantidade final consumida fique ligeiramente acima dos resultados da simulação em que a variável permanece no valor inicial. Ainda que o impacto desta variação seja sutil, os resultados do modelo mostram que ao permitir a socialização dos agentes, estes influenciam uns aos outros de forma a

diminuir suas preocupações com o meio ambiente, e contraditoriamente, causa uma redução do consumo da carne bovina.

Ao comparar estes resultados com os apresentados na Figura 12 fica evidente que, tal como esperado, a variação do preço da carne é o fator mais influente sobre a mudança de comportamento dentro deste modelo. Observa-se que as curvas que consideram o aumento no preço aparecem deslocadas abaixo da curva do modelo base, apontando que quanto maior o aumento do preço, menor a probabilidade de se consumir carne bovina em uma refeição e menor o consumo por mês per capita.

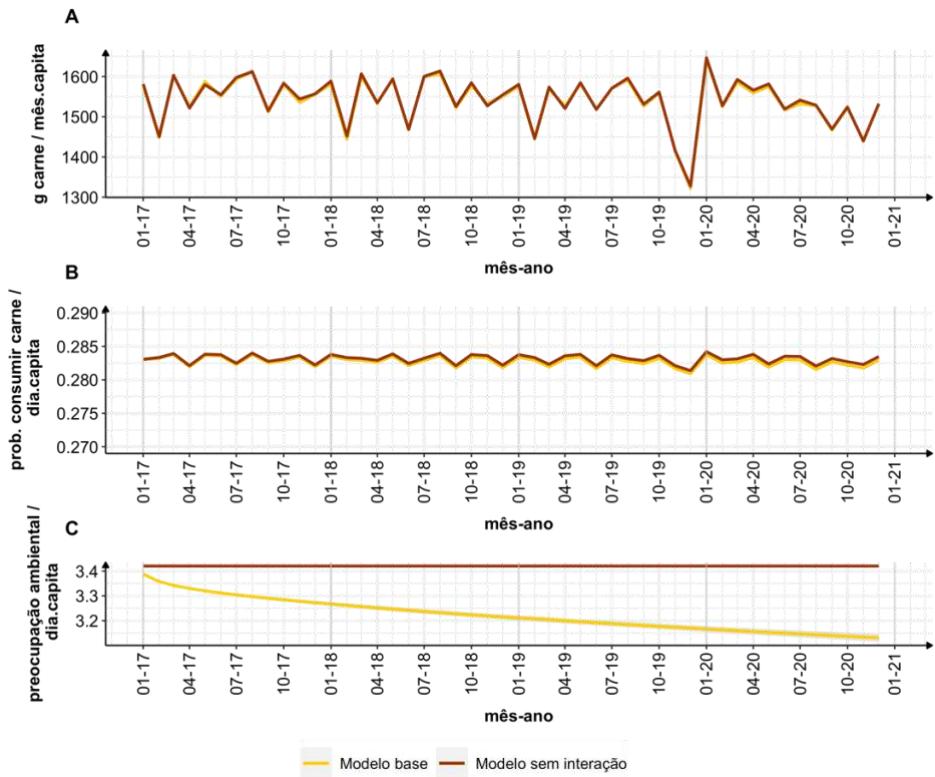


Figura 11: Análise de sensibilidade sobre a preocupação com o meio ambiente.

Fonte: Elaboração própria (2022)

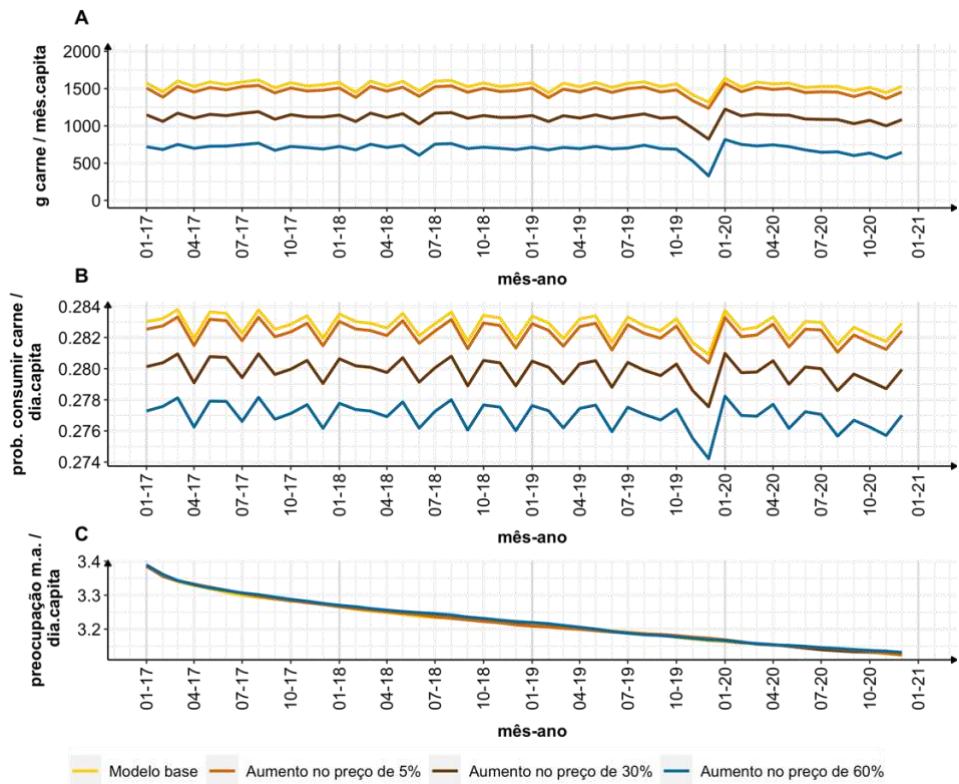


Figura 12: Análise de sensibilidade do preço da carne bovina.

Fonte: Elaboração própria (2022)

A Figura 13 e Figura 14 expõem os mesmos resultados da Figura 12, porém de formas diferentes. O primeiro apresenta a média dos quatro anos simulados da quantidade de carne consumida por dia per capita, estratificando-os em diferentes classes. Já o segundo, exibe a diferença percentual destas médias ao comparar o modelo sem aplicar nenhuma intervenção (modelo base) com os modelos aplicando os aumentos dos preços citados.

No painel A da Figura 13 é possível observar os impactos dos aumentos dos preços sobre o consumo de carne bovina no âmbito nacional. Resultados mostram que os aumentos no preço de 5%, 30% e 60% proporcionam reduções expressivas no consumo médio anual do país, de respectivamente 133.382 t, 794.209 t e 1.571.441 t por ano. Os demais painéis da figura evidenciam este efeito sobre diferentes grupos, mostrando a reprodução do modelo sobre a heterogeneidade da população brasileira em relação a este consumo. Ao comparar o painel B com os subsequentes, é possível notar como o consumo médio diário per capita se diferencia ao analisar o dado em diferentes grupos, como se destaca o painel C sobre as macrorregiões, o painel E relativo aos gêneros, o painel F de faixas etárias e H relativo a ocupação. Além disso, também é possível observar em todos os painéis como os aumentos crescentes no preço da carne provocam reduções expressivas no consumo da carne bovina. No entanto, ao fazer uma análise percentual sobre as reduções do consumo, nota-se que as variações entre as classes foram praticamente as mesmas.

A Figura 14 mostra que os aumentos de preços de 5%, 30% e 60% provocaram reduções no consumo da carne de aproximadamente 5%, 28% e 55% em todas as categorias analisadas quando comparado ao modelo sem aplicar nenhuma intervenção, com exceção da classe de renda (Figura 14.E). Esta variável, apesar de não ter se destacado na Figura 13, apresentou variações notáveis entre as três categorias. Quando foi aplicado o aumento de 5% no preço da carne, a classe alta reduziu seu consumo em 4%, a classe média em 5% e a classe baixa em 5%. No caso do aumento do preço de 30%, a redução foi de respectivamente 23%, 28% e 30%. Quanto foi aplicado o aumento de 60% no preço da carne, as diferenças percentuais foram ainda mais desequilibradas, de 46%, 55% e 58%. Comparando as variações do consumo entre as classes, pode-se dizer que à medida que o preço aumentou a classe média teve seu consumo reduzido em torno de 15% a mais do que a classe alta, a classe baixa 21% a mais do que a classe alta, e classe baixa 7% a mais do que a classe média.

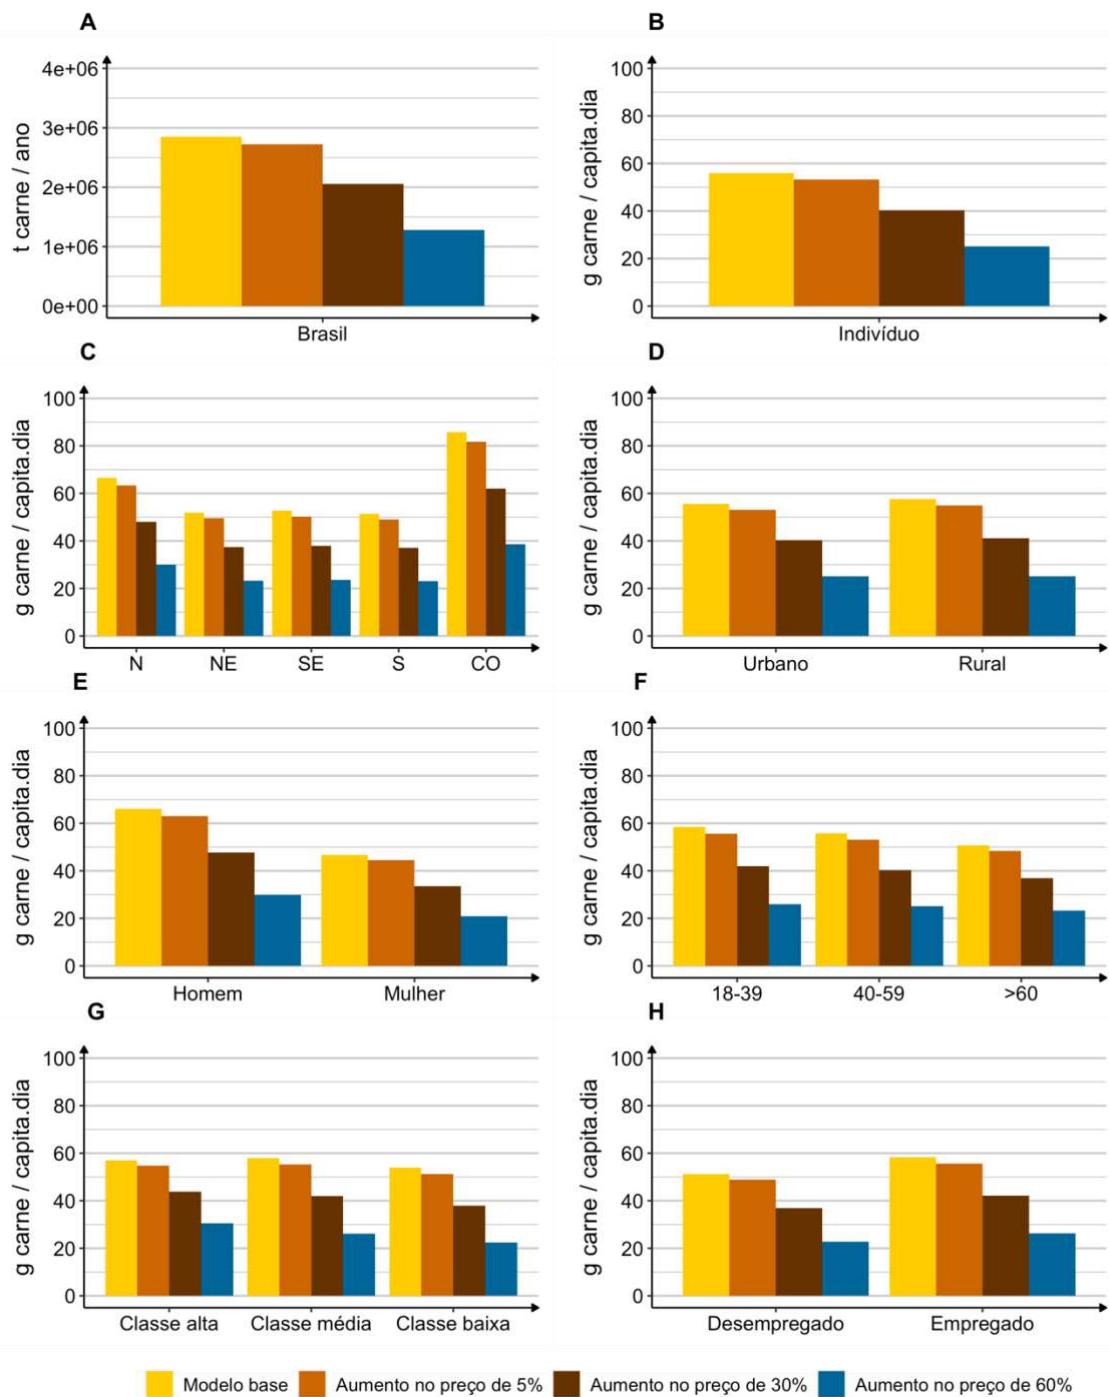


Figura 13: Análise de sensibilidade do preço da carne bovina: média de gramas de carne bovina consumida por dia por pessoa de 2017 a 2020 por grupos considerando: A) macrorregião; B) situação de domicílio; C) gênero; D) classe renda; E) faixa etária; F) ocupação.

Fonte: Elaboração própria (2022)

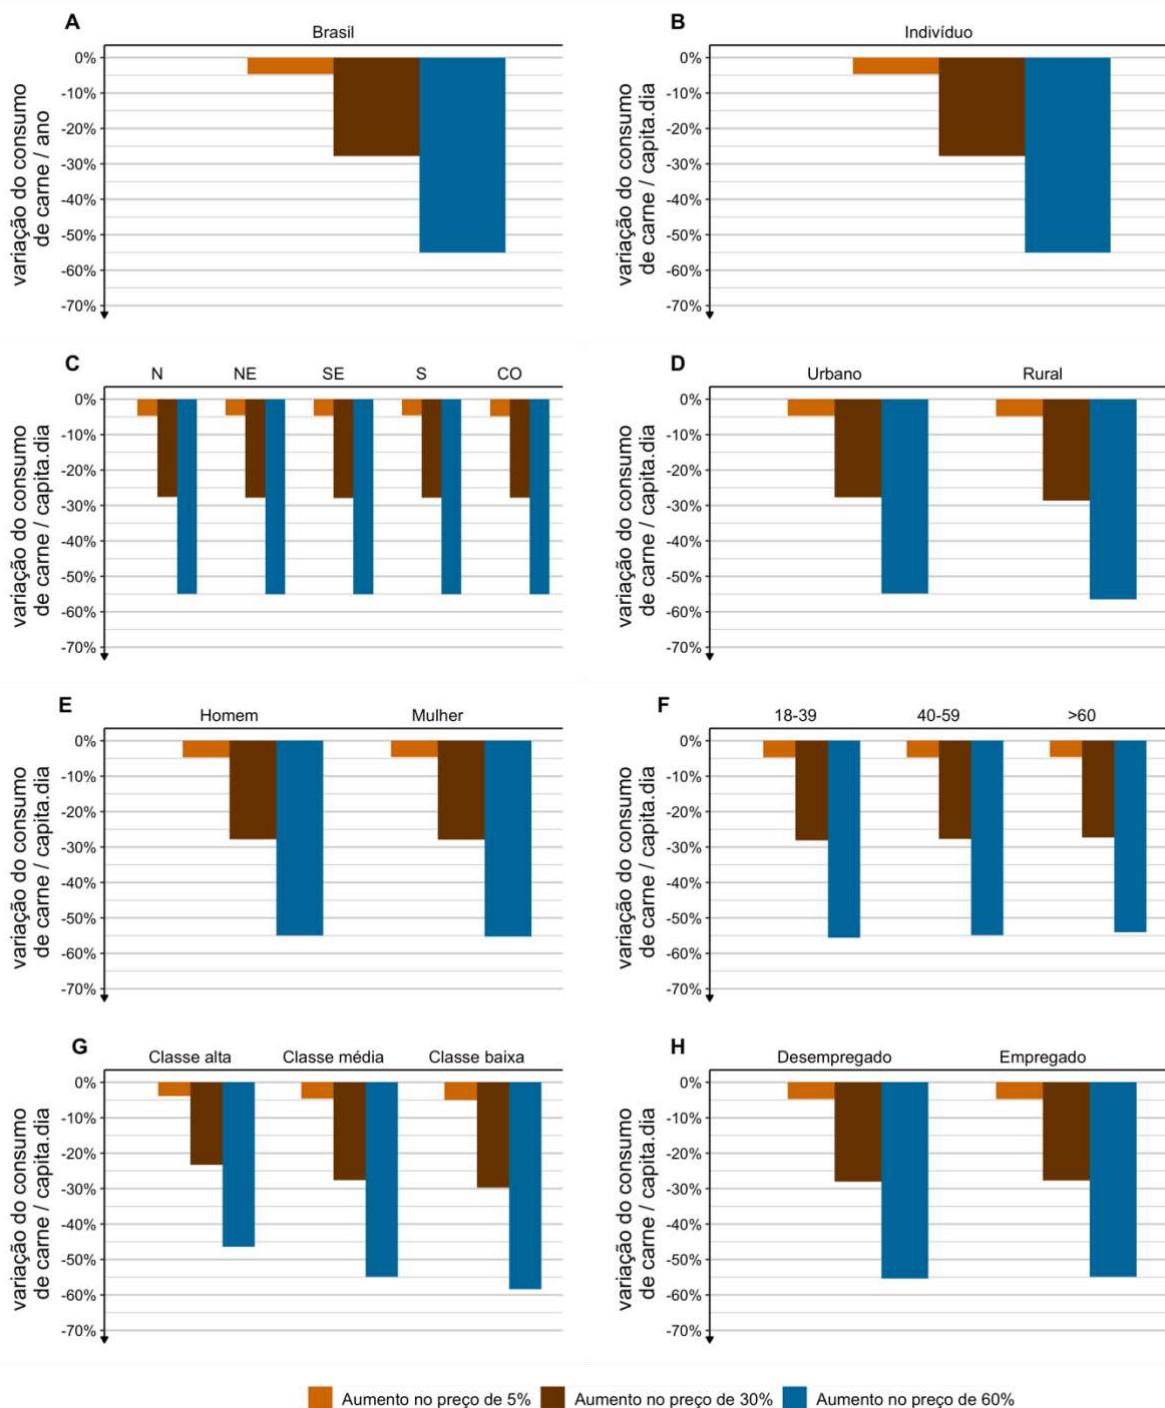


Figura 14: Análise de sensibilidade do preço da carne bovina: variação percentual da média de gramas de carne bovina consumida por dia por pessoa de 2017 a 2020 por grupos considerando: A) macrorregião; B) situação de domicílio; C) gênero; D) classe renda; E) faixa etária; F) ocupação

Fonte: Elaboração própria (2022)

5 Discussão dos resultados

Utilizando dados empíricos da POF 2017-2018 foi possível construir um modelo de simulação baseado em agentes capaz de reproduzir o padrão de consumo de carne bovina dos brasileiros para os anos de 2017-2020. Os módulos desenvolvidos a partir desta base de dados foram capazes de mostrar como perfis diferenciados de indivíduos podem apresentar diferenças sobre o consumo de carne bovina, e como este comportamento é atravessado não só por fatores culturais, mas também por fatores socioeconômicos.

A elevada prevalência do consumo de carne bovina nas regiões Centro-Oeste e Norte, exibida nos módulos 3 e 4 através de uma maior probabilidade de consumo e em maior quantidade por refeição, podem ser decorrentes da maior disponibilidade deste alimento nestas duas regiões (SOUZA *et al.*, 2013). O Norte e o Centro-Oeste se destacam na produção de carne bovina do país, tendo a maior concentração do rebanho brasileiro em suas áreas rurais (FGV, s.d.). A diferença entre o consumo das áreas urbanas e rurais é retratado no módulo 4, o qual aponta maior consumo a esta última. Porém, esta diferença não é refletida sobre a probabilidade de consumir carne em uma refeição, uma vez que o módulo 3 indica que esta associação não foi estatisticamente significativa.

De forma geral, a decisão de consumir carne em uma refeição (módulo 3) apresentou diferenças em relação a quantidade a ser ingerida (módulo 4). Isto pode ser observado por exemplo no caso da região Centro-Oeste e Norte. Embora a primeira tenha apresentado chances 50% maiores do que a segunda, suas curvas de distribuição sobre a quantidade de carne ingerida em uma refeição foram extremamente semelhantes. No entanto, é importante considerar que características culturais e relativas a disponibilidade do alimento das áreas rurais e urbanas podem variar entre as regiões do Brasil. Em outras palavras, áreas rurais podem apresentar maiores chances de comer carne em uma refeição nas regiões Centro-Oeste e Norte, porém é possível que áreas urbanas possam apresentar maiores chances de comer carne nas regiões Sudeste e Nordeste. Essas diferenças podem ser a razão da situação de domicílio não apresentar uma associação estatisticamente significativa, porém curvas de distribuição discrepantes. Para se ter tal avaliação seria preciso analisar a interação entre as variáveis, uma vez a interação implica que o efeito de cada variável não é constante sobre os níveis da outra variável.

Outro destaque sobre as macrorregiões está na assimetria destoante da curva de distribuição da carne do Nordeste. Este traço possivelmente é reflexo da enorme desigualdade social presente na região, a qual é evidenciada pelo seu maior valor para o índice de Gini (IBGE, 2020), parâmetro usado para medir a desigualdade social. Neste mesmo sentido, o fato de a região Sul apresentar a curva de distribuição com baixa dispersão e mais simétrica entre as cinco regiões pode ser explicado por este apresentar o menor valor para este índice.

O Sul também surpreendeu por apresentar os menores valores para a média e primeiro quartil, visto que o churrasco gaúcho é considerado uma grande tradição da região. Isto pode ser consequência do escopo deste estudo se limitar a analisar somente o consumo de carne bovina e excluir outros tipos de carne. Vale ressaltar que a categoria analisada inclui de forma indiferenciada tanto as carnes bovinas de primeira e de segunda, como também vísceras bovinas e outras carnes bovinas, que incluem por exemplo carne de sol e mocotó. Esse fator também deve explicar o porquê das curvas de distribuição do consumo de carne e as probabilidades de consumir o alimento relativa as classes de renda não apresentarem diferenças relevantes entre suas categorias. De fato, o modelo desenvolvido avalia de forma agregada os diferentes tipos de carne bovina, ao passo que evidências empíricas revelam que agentes de classes econômicas altas tendem a consumir carnes mais nobres e agentes de classes baixas carnes de segunda e derivados. Os resultados obtidos são consistentes com os trabalhos de SCALCO *et al.* (2019) e WELLESLEY, HAPPER E FROGGATT (2015) que também não relataram nenhuma evidência que sustente uma correlação entre a renda familiar e a probabilidade de consumir carne.

O resultado sobre o perfil com maior consumo de carne bovina mostrou estar em concordância com os estudos de TRAVASSOS, CUNHA E COELHO (2020) e GARZILLO *et al.* (2021) em que estimam a pegada de carbono da dieta brasileira em estratos sociodemográficos a partir de dados da POF 2008-2009. Tendo em vista que ambos destacam o consumo de carne bovina responsável pela maior fatia das emissões, os estudos concluem que homens entre 20 a 45 anos residentes de áreas rurais das regiões Centro-Oeste e Norte são associados ao maior impacto ambiental, assim como demonstrado pelas médias das distribuições desenvolvidas pelo módulo 4.

O módulo 2, sobre a probabilidade de comer fora, também evidenciou a influência sobre os fatores socioeconômicos, destacando as diferenças de renda, nível educacional,

e o status empregatício. Os resultados desta última variável junto ao tipo de refeição, revelaram que as premissas assumidas por este modelo, assim como definido por SCALCO *et al.* (2019), de que agentes empregados saem para almoçar uns com os outros nos dias de semana, mostraram estar consistentes com a estrutura do modelo. Por outro lado, os resultados sobre o dia da refeição constataram que a probabilidade de comer fora nos fins de semana é sutilmente maior do que dos dias de semana. Esta diferença também poderia ser melhor aferida avaliando a interação destas variáveis. É possível que tal análise mostrasse que as chances de um indivíduo empregado comer fora de casa fossem maiores em dias de semana, mas que de alguém desempregado fosse maior em dias de semana. Apesar da relevância deste módulo para determinação dos grupos de agentes que irão interagir para trocar sobre suas preocupações com o meio ambiente, o local da refeição não se mostrou ser relevante em relação a probabilidade do indivíduo comer carne em uma refeição e nem sobre quantidade dela. Entre as variáveis relacionadas a refeição, destacou-se o tipo, em que o almoço apresentou não só uma chance maior de se optar pelo consumo da carne bovina, como também em uma maior quantidade média.

Em relação ao padrão de consumo de carne bovina emergente da simulação, os resultados do modelo mostraram um padrão semelhante ao reportado pela CONAB, porém, apresentaram uma defasagem em relação a quantidade total de carne e per capita. Tal discrepância pode ser explicada pela exclusão dos consumidores menores de 18 anos da simulação ou por uma superestimativa do número de vegetarianos. Além disso, os dados da CONAB estimam os dados da disponibilidade da carne, que podem trazer incertezas sobre a quantidade que de fato foi consumida. A disponibilidade da carne não diferencia os setores industriais aos quais o produto é destinado, o que inclui, por exemplo, insumos para produção de ração animal, e também não contabiliza o desperdício de alimentos.

O desperdício pode acontecer desde as perdas no campo, passando pelo transporte, processamento, venda no varejo e no âmbito alimentar relativo ao consumidor (compra, estocagem, manuseio, consumo, descarte e pós-consumo). O estudo de PORPINO *et al.* (2018), o qual buscou mapear como o consumidor brasileiro interage com o desperdício alimentar, concluiu que o grupo da carne, composto por carne bovina, aves, peixes e outros, teve a segunda maior quantidade do total de alimentos desperdiçados (20%), com a quantidade média de 113,2 g / dia / domicílio.

Outro fator não contabilizado é a perda de peso da carne pela cocção. De acordo com PURSLOW *et al.* (2016) a redução do volume da carne pode variar de 15 a 30% do seu volume inicial, dependendo da temperatura e do tempo de cozimento. Apesar destas diferenças, ao comparar o resultado médio per capita do modelo com o consumo alimentar fornecido pela POF 2017-2018 para a carne bovina, eles apresentam uma diferença de apenas 11%, sendo o primeiro igual a 55,9 g/dia e segundo de 50,2 g/dia. Esta diferença pode ser decorrente da POF incluir nesta estimativa crianças maiores de 10 anos.

Os testes de sensibilidade do modelo revelaram que a influência social sobre a preocupação com o meio ambiente não apresentou impactos relevantes sobre o consumo da carne bovina, além de exibir uma relação inversamente proporcional entre esta variável e o consumo de carne. Sendo assim, este modelo sugere que políticas de precificação podem ser mais efetivas em reduzir o consumo da carne bovina da população brasileira do que estratégias que promovam a conscientização ambiental. Apesar deste resultado ser contrário ao encontrado por ZHANG *et al.* (2014), o qual sugere que a influência da rede social pode ser mais eficaz no aumento do comportamento alimentar saudável, ele está de acordo com o encontrado por SCALCO *et al.* (2019) e BRAVO *et al.* (2013), que modelaram melhorias na educação ambiental e não notaram mudanças relevantes nos padrões de consumo.

A relação inversamente proporcional entre esta variável e o consumo de carne pode ser decorrente da equação escolhida para representar a interação (Equação 4), onde os indivíduos atualizam a variável de preocupação ambiental a partir de uma ponderação entre as opiniões próprias dos agentes e as opiniões das outras pessoas pertencentes as suas redes (ZHANG *et al.*, 2014). Outras teorias de interação social e outras formas de implementação podem fazer com que haja um comportamento emergente da população diferente deste aplicado no modelo. Como seria o caso se a atualização das preocupações ambientais considerasse que pessoas com alta preocupação ambiental apresentassem uma menor suscetibilidade à pessoas com menor preocupação, e portanto apresentassem uma maior convicção de suas crenças e maior dificuldade de diminuir seus níveis de preocupação.

Outra possibilidade é esta relação ser decorrente do fenômeno conhecido como *green gap*. Este termo define a inconsistência entre o que os consumidores declaram e o que eles realmente fazem em termos de comportamento sustentável (ELHAFFAR,

DURIF, DUBÉ, 2020). Se compararmos os resultados do módulo 1 com o módulo 3, pode-se verificar que de fato pode haver uma contradição entre as percepções e os comportamentos dos indivíduos. No módulo 1, pode-se verificar que quanto maior o nível educacional, maior o nível de preocupação com o meio ambiente. No entanto, isto não se reflete sobre o módulo 3 e 4, em que quanto maior nível educacional, maior a probabilidade de se consumir carne e maior a quantidade em uma refeição. GARZILLO *et al* (2021) notam a mesma contradição em seu estudo, apontando que a pegada de carbono da dieta é crescente com o nível da escolaridade, assim como a preocupação com os riscos climáticos.

SANCHEZ-SABATE E SABATÉ (2019) concluíram em sua revisão sistemática sobre atitudes e comportamentos do consumidor em relação a carne uma falta de disposição da população de países ocidentais a deixar de comer carne por razões ambientais. Mesmo para veganos/vegetarianos, as preocupações ecológicas são apenas mais um motivo para justificar seus padrões alimentares, sendo comumente motivado originalmente pelo bem-estar animal e saúde pessoal. Dentro dessa minoria de pessoas conscientes, dispostas a mudar ou que já mudaram seus comportamentos, mulheres são uma clara maioria, assim como observado nos resultados do módulo 1.

RAIMUNDO, PACHOUD e BATALHA (2017) também encontraram em seu estudo que brasileiros dão maior importância a aparência, a data de validade e o teor de gordura da carne ao comprar este produto. Já o local de origem e selos de bem-estar animal ou produção sustentável mostraram importância reduzida, indicando pouco interesse do brasileiro por tais questões. VIEGAS, SANTOS e FONTES (2015) também investigaram se a segurança sanitária dos alimentos, o bem estar animal e o meio ambiente apresentam relevância nas preocupações dos consumidores portugueses. Seus resultados mostraram maior importância à questão sensorial, relativa a qualidade intrínseca da carne, indicando uma baixa influencia pelos três atributos investigados.

Apesar do resultado estar coerente com outros estudos, é importante ressaltar que os dados utilizados para caracterizar a preocupação com o meio ambiente dos indivíduos são provenientes de uma outra pesquisa que não relaciona esta percepção com o consumo da carne bovina. Isto pode ter refletido sobre o módulo 3, em que o coeficiente da regressão logística desta variável apresenta o menor valor, com magnitude discrepante dos demais, e nenhuma relevância estatística, sendo, portanto, o fator menos influente sobre a probabilidade de comer carne no modelo. Por outro lado, outros estudos que

tentaram compreender os fatores que influenciam as escolhas alimentares dos brasileiros não abordaram questões ambientais e nem os relacionaram diretamente ao consumo da carne bovina.

SOUZA *et al.* (2020), por exemplo, buscaram identificar os determinantes da escolha alimentar entre trabalhadores de indústrias no Brasil utilizando o questionário da escolha alimentar (*Food Choice Questionnaire - FCQ*), desenvolvido por STEPTOE, POLLARD E WARDLE (1995). O FCQ é um instrumento extensamente utilizado, traduzido e validado para o português (HEITOR *et al* 2015; HEITOR *et al* 2019), que avalia a partir de 36 itens a importância atribuída por indivíduos a nove dimensões relacionados às escolhas alimentares. Surpreendentemente, os resultados do estudo apontaram o grupo da carne vermelha altamente associado a dimensão conveniência, exaltando entre os itens da dimensão a importância da disponibilidade para aquisição do alimento e desvalorizando o tempo de preparo. Ainda que este questionário inclua entre as suas dimensões uma denominada “preocupação ética”, esta aborda apenas questões relacionadas ao país de origem do alimento e sobre o malefício da embalagem ao meio ambiente. Além disso, o estudo também não relaciona os itens investigados a uma quantidade de alimentos ou número de vezes que este é ingerido.

SPROESSER *et al* (2019) e MORAES *et al* (2020) utilizaram a pesquisa de motivação alimentar (*The Eating Motivation Survey - TEMS*) para avaliar quais os fatores individuais do comportamento alimentar, o primeiro no estado de São Paulo, e o segundo em dois municípios do Brasil com realidades socioeconômicas diferentes. O TEMS foi desenvolvido por RENNER *et al.* (2012), traduzido e validado por MORAES E ALVARENGA (2017), visando captar de forma ainda mais extensa as motivações alimentares propostas no FCQ, e contém 45 itens que envolvem 15 dimensões. Os resultados do primeiro estudo indicam maior relação a necessidade e fome, normas sociais, saúde e controle de peso. Já o do segundo, apresentam 3 fatores comuns aos dois municípios como melhores preditores: prazer, tradição e socialização. Apesar do TEMS ser uma extensão FCQ, este não apresenta nenhuma dimensão próxima a questões éticas ou ambientais, e nem mesmo relaciona as motivações a grupos de alimentos específicos.

Em relação a análise de sensibilidade relativa ao aumento de preço, os resultados do estudo mostram estar alinhados com a mesma análise feita por SCALCO *et al.* (2019). As reduções do consumo de carne para o aumento de 5% dos dois modelos foram equivalentes, sendo a redução do autor de 6%, e a do presente estudo de 5%. Além disso,

vale ressaltar que as reduções do consumo consequentes aos aumentos de preços de 5%, 30% e 60%, de respectivas 5%, 28% e 55%, são equivalentes a 133.382 t, 794.209 t e 1.571.441 t de carne bovina em média por ano. Considerando a emissão da carne bovina de 78 kg CO₂e/kg Carne (INSTITUTO ESCOLHAS, 2020), os resultados estimam que os aumentos de preços poderiam reduzir por ano 10.404 ktCO₂e, 61.948 ktCO₂e e 122.572 ktCO₂e. Essas emissões equivalem a respectivamente cerca de 3%, 16% e 31% da média das emissões de 2017 a 2020 do setor pecuário, considerando a emissão pela fermentação entérica e o manejo de dejetos animais (SEEG, 2022).

Apesar das políticas de precificação terem mostrado ser bastante efetivas na redução do consumo da carne bovina, e consequentemente, na redução da emissão de GEE, quando analisado por classe de renda verificou-se um impacto desproporcional entre as classes. Há uma queda muito maior no consumo dos agentes de classe média e baixa. Ao mesmo tempo que esta política contribuiria com os ODS 12 (consumo e produção sustentável) e 13 (ação contra mudança global do clima), elas também podem contribuir para maior insegurança alimentar e desigualdade social, entrando em conflito com outros ODS's como o 2 (Fome zero) e o 4 (Redução da desigualdade) (HASEGAWA *et al.*, 2021, FUJIMORI *et al.*, 2022). A pandemia da covid-19, iniciada no Brasil em março de 2020, acarretou restrições ao acesso à alimentação através dos aumentos dos preços decorrentes por diversos fatores, entre eles a inflação global de alimentos, que evidenciaram esta questão. O aumento do preço das carnes levou o consumo de carne bovina a uma queda de quase 14% de 2019 a 2021, chegando ao menor nível desde 1996, início da série histórica da CONAB. O problema é que nem sempre brasileiros conseguem fazer a substituição necessária do alimento.

Segundo NERI (2022), o avanço da fome no período de análise deste estudo, foi particularmente expressivo no contexto pós-pandémico. Enquanto em 2019 30% da população encontrava-se em insegurança alimentar, em 2021 este número subiu para 36%. Ao analisar estes números por renda verifica-se uma discrepância enorme entre as classes. Ao mesmo tempo que a parcela 20% mais pobres do Brasil teve este quadro agravado durante a pandemia, indo de 53% em 2019 para 75% em 2021, os 20% mais ricos, experimentaram queda de insegurança alimentar de três pontos percentuais (indo de 10% para 7%). Comparando com outros 122 países avaliados nesta pesquisa para o ano 2021, estes números aproximam a insegurança alimentar do Brasil a Serra Leoa (77%), que está entre 10 países com maior nível de insegurança alimentar, e a Suécia

(5%), com o menor nível. O retrato destoante de maior assimetria alimentar brasileira se repete na escala educacional e de gênero.

De forma geral, entre 2019 e 2021, a insegurança alimentar na média dos mesmos 120 países aumentou 1,5 pontos percentuais contra 6 no Brasil. Ou seja, a piora brasileira no período de pandemia foi quatro vezes superior à média desses países. Tudo isso revela como a profunda desigualdade na sociedade brasileira provoca uma maior dificuldade relativa do país em endereçar o problema da insegurança alimentar e seus impactos sobre grupos mais vulneráveis, tal como foi observado no presente estudo em relação ao consumo da carne bovina de classes mais baixas. MEDINA *et al* (2019), por exemplo, mediram a magnitude das desigualdades sociais no perfil da qualidade alimentar da população brasileira. Seus resultados revelaram o melhor perfil de consumo alimentar nos indivíduos de cor da pele branca, nos grupos sociais de maior renda e maior escolaridade.

Quando comparado os resultados da análise sensibilidade do aumento do preço de 30%, estimado como alusão ao período pandêmico, com o aumento de 60%, estimado como o aumento decorrente da precificação de carbono, é possível verificar que o segundo teria seu consumo reduzido em 40% em relação ao primeiro. Tendo em vista as consequências causadas pela pandemia sobre a segurança alimentar e a vulnerabilidade da população brasileira, é preciso ser crítico aos números. Ainda que o modelo aponte uma redução do consumo da carne substancial consequente a tal política, ele não avalia como esse alimento seria substituído. Segundo HARGREAVES *et al* (2020), nem mesmo parte da população brasileira vegetariana não atinge a ingestão diária de frutas e hortaliças recomendado pela Organização Mundial da Saúde. Sendo assim, caso fosse implementada a política de precificação de carbono sobre a carne bovina no Brasil, seria importante associá-la a outras políticas de incentivos fiscais a alimentos substitutos, a fim de assegurar a ingestão necessária de calorias e nutrientes de toda a população.

6 Considerações Finais

Esta dissertação teve como objetivo desenvolver um modelo ABM capaz de simular o consumo carne bovina da população brasileira, com o intuito de ampliar a pesquisa de ferramentas capazes de auxiliar a formulação de políticas públicas que visam diminuir as emissões de GEE pelo lado da demanda. Tendo em vista a notoriedade do debate sobre a mudança de hábitos alimentares neste contexto, o destaque a redução do consumo de carne bovina, e o protagonismo do Brasil na produção, no consumo e na emissão de GEE relativa a este alimento, o estudo também se propôs a: analisar a heterogeneidade da população brasileira em relação ao consumo da carne bovina; identificar fatores que condicionam este consumo, e; avaliar a efetividade na redução deste consumo de uma política de precificação de carbono.

O presente modelo foi desenvolvido a partir de uma adaptação da metodologia e premissas utilizadas pelo ABM de SCALCO *et al.* (2018), sendo ampliado e modificado para atender à realidade brasileira. O modelo simula o comportamento de brasileiros maiores de 18 anos em relação ao consumo da carne bovina no almoço e no jantar considerando a variação do preço do alimento e as suas próprias percepções sobre as suas preocupações com o meio ambiente. Este atributo dos agentes é atualizado ao longo da simulação pela influência exercida por colegas de trabalho ou familiares que pertencem as suas redes sociais e que estão realizando a refeição no mesmo local. O comportamento dos agentes do modelo é simulado de 2017 à 2020.

A partir disso, o modelo foi validado e foi realizada uma análise de sensibilidade quanto à influência dos agentes relativo às suas preocupações com o meio ambiente sobre o consumo de carne bovina, e também em relação ao aumento do preço da carne. A primeira, compara os resultados do modelo sem aplicar nenhuma intervenção com o modelo impedindo a interação dos agentes. A segunda compara os resultados do modelo base com outros aplicando o aumento do preço em 5%, 30% e 60%, valores determinados baseando-se na ideia dos respectivos cenários: a variação de preço usual da carne, a uma variação no preço decorrente de um evento extraordinário, como a pandemia do Coronavírus, e a precificação de carbono sobre a carne bovina.

Os resultados indicam que o modelo ABM foi capaz de reproduzir o padrão de consumo de carne bovina dos brasileiros entre 2017 e 2020, mostrando resultados robustos, com ordem de grandeza e tendências de curva semelhantes aos dados da

validação. Os testes de sensibilidade do modelo revelaram que a influência social sobre a preocupação com o meio ambiente apresentou impactos insignificantes sobre o consumo da carne bovina, além de exibir uma relação inversamente proporcional entre esta variável e o consumo de carne. Isto é, ao permitir a socialização dos agentes, estes influenciam uns aos outros de forma a diminuir suas preocupações com o meio ambiente, e contraditoriamente, aumentam o consumo da carne bovina. Por outro lado, os aumentos no preço de 5%, 30% e 60% proporcionaram reduções expressivas no consumo médio anual do país, de respectivamente a 5%, 28% e 55%, que é equivalente a 133.382 t, 794.209 t e 1.571.441 t de carne bovina por ano.

Em relação a heterogeneidade dos agentes, o modelo apontou diferenças sobre o consumo, indicando os perfis que mais consumiram carne bovina em cada variável analisada homens, indivíduos de 18 a 39 anos, residentes de áreas rurais, e da região Centro-Oeste, enquanto os perfis de menor consumo foram mulheres, indivíduos com mais de 40 anos, residentes da zona rural, e da região Sul. Além disso, entre as variáveis relacionadas ao contexto da refeição, a ocasião se destacou indicando maior consumo de carne bovina no almoço, e a variável local refeição evidenciou uma indiferença sobre este consumo ocorrer em casa ou fora de casa. Ao aplicar o aumento do preço da carne bovina, agentes do modelo de diferentes classes sociais também apresentaram reduções percentuais distintas sobre o consumo, refletindo como políticas podem impactar a população de diferentes formas ao considerar a heterogeneidade dos indivíduos. Comparando as variações do consumo entre as classes ao considerar o aumento do preço, as classes média e baixa tiveram maior impacto na redução do consumo do que a classe alta.

Diante destes resultados, é possível concluir que o modelo sugere que políticas de precificação podem ser mais efetivas em reduzir o consumo da carne bovina da população brasileira do que estratégias que promovam a conscientização ambiental. Porém, ainda que os aumentos de preços analisados de 5%, 30% e 60% tenham sugerido a possível redução anual de emissão de carbono equivalente de respectivamente 10.404 ktCO₂e, 61.948 ktCO₂e e 122.572 ktCO₂e, é preciso considerar que a discrepância do impacto destas políticas sobre as diferentes classes sociais pode contribuir para maior insegurança alimentar e desigualdade social do país. A pandemia da covid-19, acarretou restrições ao acesso à alimentação através dos aumentos dos preços, escancarando como a profunda desigualdade na sociedade brasileira provoca uma maior dificuldade relativa do país em

endereçar o problema da insegurança alimentar e seus impactos sobre grupos mais vulneráveis. Tendo em vista estas consequências, caso fosse implementada a política de precificação de carbono sobre a carne bovina no Brasil, seria importante associá-la a outras políticas de incentivos fiscais a alimentos substitutos, a fim de assegurar a ingestão necessária de calorias e nutrientes de toda a população. Estudos futuros poderiam incluir no modelo o preço e o consumo de outros alimentos para simular o comportamento e as consequências relativas à substituição da carne bovina, assim como as possíveis redução de emissões de GEE.

Embora a simulação tenha reproduzido o padrão de consumo do brasileiro e apresentado resultados robustos, é preciso destacar que este estudo apresenta algumas limitações que impactam a interpretação dos resultados obtidos. Tal como elencando na seção 2.2, a necessidade de usar dados secundários por conta da restrições de tempo e orçamento, evidenciou a dificuldade em relação a disponibilidade de dados empíricos específicos e detalhados para estruturar um determinado comportamento e validá-lo. Apesar da crescente disponibilidade de dados e aprimoramento no processamento com a finalidade de prever um padrão sobre um comportamento humano, como é possível observar nos atuais algoritmos de plataformas de mídias sociais e aplicativos, há poucas fontes que exploram os fatores que condicionam as escolhas alimentares. Principalmente no que diz respeito a dados que abordam o consumo da carne bovina da população brasileira, apontando a frequência ou a quantidade, e os relacionem com as percepções dos indivíduos sobre as razões que os fazem optar ou rejeitar o seu consumo.

Por isso, a variável preocupação com o meio ambiente foi adquirida de uma outra pesquisa, a qual não relaciona esta percepção com o consumo da carne bovina, e foi agregada aos dados da POF 2017-2018, a fim de ser usada como *proxy* para a sensibilidade dos consumidores às suas crenças e as normas subjetivas referentes influências sociais. É possível que, de fato, haja uma inconsistência entre o que os consumidores declararam e o que eles realmente fazem em termos de comportamento relacionados a sustentabilidade. No entanto, seria preciso ter dados que relacionassem as percepções e o consumo para se ter uma avaliação precisa. Também não foi possível encontrar nenhuma pesquisa oficial no Brasil que verifique o número de vegetarianos, sendo necessário portanto estimar através de suposições feitas a partir do consumo registrado nos dois dias investigados pela POF 2017-2018. Estudos futuros poderiam avaliar outras formas de estimar este número, como considerando também as informações

do questionário POF 3 - Caderneta de aquisição coletiva, que poderia indicar se houve a compra da carne bovina para a residência ou não.

Ademais, as elasticidades-preço da carne bovina das três classes sociais analisadas no modelo também foram adquiridas de outra pesquisa calculada a partir de dados da POF de 2002-2003. Consequentemente, esta pesquisa também é responsável pela classe de renda dos agentes, uma vez que estas foram determinadas de forma a compatibilizar com a estratificação feita para as elasticidades-preço. Também devido a escassez de dados, as classes de renda determinadas pelas elasticidades-preço foram incluídas como proxy para a sensibilidade dos consumidores à variação do preço da carne bovina. Estudos futuros poderiam incluir o refinamento deste dado, calculando a elasticidade-preço para os dados da POF 2017-2018, e também poderiam introduzir um efeito de decaimento marginal do aumento de preços, o qual exigiria a adição de outros fatores como mudanças no poder de compra dos consumidores.

Outra limitação deste estudo relacionada a esta questão está na insuficiência dos dados para realizar a validação do modelo. A disponibilidade interna de carne bovina do Brasil, estimada pela CONAB, foram os dados disponíveis com maior nível de desagregação encontrado. Embora eles sejam capazes de mostrar a quantidade mensal disponível deste alimento exclusivo, eles não permitem fazer uma validação mais detalhada sobre o consumo, como por exemplo, uma validação regional e/ou por situação de domicílio, e não são equivalentes a quantidade que chega ao consumidor final. A fim de explorar a levea discrepancia sobre as diferenças quantitativas entre o resultado da simulação e os dados da validação, estudos futuros também poderiam incluir comportamento relativo ao desperdício do alimento.

Em relação ao processo de influência, os dados utilizados sobre a alimentação não abordam a questão relativa aos hábitos sociais envolvidos na refeição, se as pessoas comeram acompanhados ou sozinhas. Ademais, os dados sobre as suscetibilidades das pessoas às influências de seus colegas e familiares não dizem respeito ao contexto brasileiro. Além disso, o modelo não considerou uma estrutura hierárquica nas redes de colegas de trabalho e familiares, o que poderia refletir diferenças em termos de poder de influência. Esta questão também poderia ser explorada em pesquisas futuras. O modelo também não inclui pessoas menores de 18 anos, uma vez que o entendimento sobre o grau de autonomia que crianças possuem sobre as escolhas envolvidas em suas refeições ou em relação as suas preocupações com o consumo, adiciona um grau de complexidade

maior ao modelo. Pesquisas futuras poderiam explorar esta questão, uma vez que há evidências mostrando que alguns adultos com filhos fazem escolhas alimentares diferentes para acomodá-los, e que crianças podem ser influenciadas por seus próprios pares. Outra análise interessante seria explorar os impactos de outras formas de implementar a interação dos agentes, diferentes do conceito usado do “*follow the average*”.

Estudos futuros poderiam incluir refinamentos adicionais nos dados de entrada, como por exemplo nas equações de regressão logística, as quais poderiam ser feitas análises das interações das variáveis e a consideração dos fatores de expansão da pesquisa. Em relação as curvas de distribuição, estas poderiam ser melhor ajustadas para uma distribuição que reflita melhor o comportamento dos dados. Também seria interessante realizar mais análises de sensibilidade, explorando políticas já disponibilizadas no modelo, como campanhas de sensibilização para o meio ambiente, e também os efeitos de outros parâmetros explorando melhor o processo de calibração para se chegar um único conjunto de parâmetros que aproximem mais o resultado aos dados reais. Outra possibilidade seria avaliar o consumo da carne bovina desagregando as carnes de primeira e de segunda.

Estudos futuros também podem explorar o efeito de outras políticas sobre o consumo da carne bovina. Por exemplo, poderiam ser exploradas os efeitos sobre políticas de zoneamento, visto a importância da disponibilidade para aquisição deste alimento para o consumidor brasileiro. Outra possibilidade seria investigar os comportamento e políticas que incentivem a substituição da carne bovina pela carne sintética ou fermentada, dado que o prazer também já foi associado entre os preditores das escolhas alimentares. Além dessas, os impactos de políticas que provam a conscientização em relação a saúde também poderiam investigado, posto que a questões relacionadas a saúde e controle de peso também foram levantadas entre importantes preditores em outros estudos sobre o contexto brasileiro.

Ademais, o modelo desenvolvido no presente estudo estendeu o modelo de SCALCO *et al.* de forma transparente e detalhada facilitando a sua replicabilidade e capacidade de ser estendido em outros estudos. O modelo acrescentou a possibilidade de criar a rede de familiares de acordo com dados empíricos, e adaptou o código para que este fosse capaz de usar dados de pesquisas representativas considerando os efeitos dos fatores de expansão sobre os resultados dos agentes da simulação. Além disso, a estrutura

do código foi executada agrupando em uma única função as variáveis que devem ser modificadas para replicar o modelo com outros bases de dados, e usando variáveis matrizes para armazenar e acessar dados que alimentam o modelo, tornando o código mais eficiente e de fácil adaptação. Desta forma, a adaptação do modelo para outros contextos dependeria apenas do processamento dos dados novos para gerar novas tabelas para serem imputadas.

Ainda que o modelo ABM desenvolvido neste estudo apresente uma série de limitações, esta metodologia mostrou potencial para investigar políticas de mitigação de emissão de GEE relativas a mudanças de estilo vida, como a mudança de hábitos alimentares. Além disso, é importante destacar que este estudo é pioneiro em utilizar o modelo ABM para abordar o comportamento do consumidor brasileiro em relação ao consumo da carne no contexto do combate as mudanças climáticas. Trabalhos futuros podem se concentrar em estabelecer *links* com modelos top-down e IAMs, a fim de auxiliar estas ferramentas com relação à dificuldade de captar a heterogeneidade e irracionalidade dos consumidores ao modelar mudanças pelo lado da demanda.

7 Referências Bibliográficas

AJZEN, I., FISHBEIN, M., **Understanding attitudes and predicting social behavior**, Englewood Cliffs, NJ, Prentice-Hall, 1980.

ALLCOTT, H., "Social norms and energy conservation", **Journal of Public Economics**, 95(9-10), 1082–1095, 2011.

ALLCOTT, H., ROGERS, T, "How long do treatment effects last? Persistence and durability of a descriptive norms intervention's effect on energy conservation", HKS Faculty Research Working Paper Series RWP12-045, Harvard University, Boston, MA, 2012.

ALLISON PD., **Logistic regression using the SAS System: theory and application**, Cary, NC: SAS Institute Inc, 1999.

AN, L. "Modeling human decisions in coupled human and natural systems: Review of agent-based models", **Ecological Modelling**, v. 229, p. 25–36, 2012. DOI: 10.1016/j.ecolmodel.2011.07.010.

AN, L., GRIMM, V., TURNER, B. L. "Editorial: Meeting grand challenges in agent-based models", **Jasss**, v. 23, n. 1, 2020. DOI: 10.18564/jasss.4012.

AN, L., LINDERMAN, M., QI, J., *et al.* "Exploring Complexity in a Human-Environment System: An Agent-Based Spatial Model for Multidisciplinary and Multiscale Integration", **Annals of the Association of American Geographers**, v. 95, p. 54–79, 28 fev. 2005. DOI: 10.1111/j.1467-8306.2005.00450.x.

AN, L., ZVOLEFF, A., LIU, J., *et al.* "Agent-Based Modeling in Coupled Human and Natural Systems (CHANS): Lessons from a Comparative Analysis", **Annals of the Association of American Geographers**, v. 104, 2 jun. 2014. DOI: 10.1080/00045608.2014.910085.

ARCGIS, 2020. Portal for ArcGIS: Shapefiles. Disponível em: < <https://enterprise.arcgis.com/pt-br/portal/latest/use/shapefiles.htm> > (acesso: 04/02/2021).

AUCHINCLOSS, A. H., RIOLO, R. L., BROWN, D. G., *et al.* "An agent-based model of income inequalities in diet in the context of residential segregation",

American Journal of Preventive Medicine, v. 40, n. 3, p. 303–311, 2011. DOI: 10.1016/j.amepre.2010.10.033.

AURBACHER, J., PARKER, P. S., CALBERTO SÁNCHEZ, G. A., *et al.* "Influence of climate change on short term management of field crops - A modelling approach", **Agricultural Systems**, v. 119, p. 44–57, 2013. DOI: 10.1016/j.agsy.2013.04.005. Disponível em: <http://dx.doi.org/10.1016/j.agsy.2013.04.005>.

BANOS, A., LANG, C., MARILLEAU, N. **Agent-Based Spatial Simulation with NetLogo 1: Introduction and Bases**. [S.l: s.n.], 2015. v. 2.

BARAZZA, E., STRACHAN, N. "The co-evolution of climate policy and investments in electricity markets: Simulating agent dynamics in UK, German and Italian electricity sectors", **Energy Research & Social Science**, v. 65, p. 101458, 2020. DOI: <https://doi.org/10.1016/j.erss.2020.101458>. Disponível em: <http://www.sciencedirect.com/science/article/pii/S2214629620300359>.

BATTY, M., TORRENS, P. M. "Modelling and prediction in a complex world", **Futures**, v. 37, n. 7 SPEC.ISS., p. 745–766, 2005. DOI: 10.1016/j.futures.2004.11.003.

BCB, 2022, Banco Central do Brasil: Cotações e boletins. Disponível em : < <https://www.bcb.gov.br/estabilidadefinanceira/historicocotacoes> > (acesso 10/04/2022)

BEHESHTI, R., JALALPOUR, M., GLASS, T. A. "Comparing methods of targeting obesity interventions in populations: An agent-based simulation", **SSM - Population Health**, v. 3, n. June 2016, p. 211–218, 2017. DOI: 10.1016/j.ssmph.2017.01.006. Disponível em: <https://doi.org/10.1016/j.ssmph.2017.01.006>.

BEHESHTI, R., JONES-SMITH, J. C., IGUSA, T. "Taking dietary habits into account: A Computational method for modeling food choices that goes beyond price", **PLoS ONE**, v. 12, n. 5, p. 1–13, 2017. DOI: 10.1371/journal.pone.0178348.

BELL, R., PLINER, P. L. "Time to eat: The relationship between the number of people eating and meal duration in three lunch settings", **Appetite**, v. 41, n. 2, p. 215–218, 2003. DOI: 10.1016/S0195-6663(03)00109-0.

BENDOR, J., DIERMEIER, D., TING, M. "A Behavioral Model of Turnout", **American Political Science Review**, v. 97, 1 abr. 2000. DOI: 10.1017/S0003055403000662.

BIASINI, B., ROSI, A., GIOPP, F., *et al.* "Understanding, promoting and predicting sustainable diets: A systematic review", **Trends in Food Science and Technology**, v. 111, n. February, p. 191–207, 2021. DOI: 10.1016/j.tifs.2021.02.062. Disponível em: <https://doi.org/10.1016/j.tifs.2021.02.062>.

BLOK, D. J., DE VLAS, S. J., BAKKER, R., *et al.* "Reducing income inequalities in food consumption: Explorations with an agent-based model", **American Journal of Preventive Medicine**, v. 49, n. 4, p. 605–613, 2015. DOI: 10.1016/j.amepre.2015.03.042. Disponível em: <http://dx.doi.org/10.1016/j.amepre.2015.03.042>.

BRAVO, G., VALLINO, E., CERUTTI, A. K., *et al.* "Alternative scenarios of green consumption in Italy: An empirically grounded model", **Environmental Modelling and Software**, v. 47, n. 256, p. 225–234, 2013. DOI: 10.1016/j.envsoft.2013.05.015.

BRINDIS, D., **Slaughtering the Amazon**, Amsterdam, Netherlands, Greenpeace International, 2008

BROWN, H., VERGRAGT, P. "From Consumerism to Wellbeing: Toward a Cultural Transition?", **Journal of Cleaner Production**, v. 132, 1 maio 2015. DOI: 10.1016/j.jclepro.2015.04.107.

BRYNGELSSON, D., HEDENUS, F., JOHANSSON, D. J. A., *et al.* **How Do Dietary Choices Influence the Energy-System Cost of Stabilizing the Climate?** *Energies* . [S.l: s.n.], 2017

BRYSON, J. **The Behavior-Oriented Design of Modular Agent Intelligence.** [S.l: s.n.], 2002.

BURKE, M. A., HEILAND, F. "Social dynamics of obesity", **Economic Inquiry**, v. 45, n. 3, p. 571–591, 2007. DOI: 10.1111/j.1465-7295.2007.00025.x.

CAIRNS, G., ANGUS, K. & HASTINGS, G., "The extent, nature and effects of food promotion to children: A review of the evidence to 2008", **World Health**

Organization, Geneva, Switzerland, 2009. Disponível em:
http://www.who.int/dietphysicalactivity/Evidence_Update_2009.pdf

CHEN, P., ANTONELLI, M. "Conceptual Models of Food Choice : Influential Factors Related to Foods", **Foods**, v. 9, n. 1898, p. 1–21, 2020.

CIALDINI, R.B., RENO, R.R. AND KALLGREN, C.A., "A Focus Theory of Normative Conduct: Recycling the Concept of Norms to Reduce Littering in Public Places", **Journal of Personality and Social Psychology**, 58, 1015-1026, 1990, DOI: 10.1037/0022-3514.58.6.1015

CLARK, M. A., SPRINGMANN, M., HILL, J., *et al. Supplementary Information for Multiple health and environmental impacts of foods*. 2019. 2019. DOI: 10.1073/pnas.1906908116.

CLARK, W. A. V., FOSSETT, M. "Understanding the social context of the Schelling segregation model", **Proceedings of the National Academy of Sciences of the United States of America**, v. 105, n. 11, p. 4109–4114, 2008. DOI: 10.1073/pnas.0708155105.

CNA. 2021. PIB do agronegócio. Confederação da Agricultura e Pecuária do Brasil. Disponível em: <<https://www.cnabrasil.org.br/publicacoes/pib-do-agronegocio-avanca-no-trimestre-e-acumula-alta-de-9-81-no-primeiro-semestre-de-2021>> (Acesso em 20/04/2021).

COMEXSTAT, 2021, Exportação e Importação Geral. Disponível em : <<http://comexstat.mdic.gov.br/pt/geral>> (acesso 18/07/2021)

CONAB, 2022, Preços Agropecuários. Disponível em : <<https://www.conab.gov.br/info-agro/precos>> (acesso 10/04/2022)

CREUTZIG, F., J. ROY, P. DEVINE-WRIGHT, J. DÍAZ-JOSÉ, F.W. GEELS, A. GRUBLER, N. MAÏZI, E. MASANET, Y. MULUGETTA, C.D. ONYIGE, P.E. PERKINS, A. SANCHES-PEREIRA, E.U. WEBER, 2022: Demand, services and social aspects of mitigation. In IPCC, 2022: Climate Change 2022: Mitigation of Climate Change. Contribution of Working Group III to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change [P.R. Shukla, J. Skea, R. Slade, A. Al Khourdajie, R. van Diemen, D. McCollum, M. Pathak, S. Some, P. Vyas, R. Fradera, M. Belkacemi, A. Hasija, G. Lisboa, S. Luz, J. Malley, (eds.)]. Cambridge University Press,

Cambridge, UK and New York, NY, USA. doi: 10.1017/9781009157926.007

CRIPPA, M., SOLAZZO, E., GUIZZARDI, D., *et al.* "Food systems are responsible for a third of global anthropogenic GHG emissions", **Nature Food**, v. 2, n. 3, p. 198–209, 2021. DOI: 10.1038/s43016-021-00225-9. Disponível em: <http://dx.doi.org/10.1038/s43016-021-00225-9>.

CROOKS, A., CASTLE, C., BATTY, M. "Key challenges in agent-based modelling for geo-spatial simulation", **Computers, Environment and Urban Systems**, v. 32, n. 6, p. 417–430, 2008. DOI: 10.1016/j.compenvurbsys.2008.09.004. Disponível em: <http://dx.doi.org/10.1016/j.compenvurbsys.2008.09.004>.

CRUZ, TALITA BORGES, **Modelagem microeconómétrica para avaliar impactos da desigualdade socioeconômica e da mudança do clima na demanda de eletricidade do setor residencial brasileiro**, 2021, Tese de D. Sc. Programa de Planejamento Energético, COPPE/UFRJ, Rio de Janeiro, Brasil, 2015. Disponível em: <http://www.ppe.ufrj.br/>.

DAWID, H., FAGIOLO, G. "Agent-based models for economic policy design: Introduction to the special issue", **Journal of Economic Behavior & Organization - J ECON BEHAV ORGAN**, v. 67, p. 351–354, 1 ago. 2008. DOI: 10.1016/j.jebo.2007.06.009.

DE CASTRO, J. M. "Family and friends produce greater social facilitation of food intake than other companions", **Physiology and Behavior**, v. 56, n. 3, p. 445–455, 1994. DOI: 10.1016/0031-9384(94)90286-0.

DOS SANTOS, A. F., SARAIVA, J. T. "Agent-based models in power systems-a literature review", **U.Porto Journal of Engineering**, v. 7, n. 3, p. 101–113, 2021. DOI: 10.24840/2183-6493_007.003_0009.

EDENHOFER, O. *et al.*, "Climate Change 2014: Mitigation of Climate Change", **Working Group III Contribution to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change**. 1454 pp, 2007.

ELHAFFAR, G., DURIF, F., DUBÉ, L. "Towards closing the attitude-intention-behavior gap in green consumption: A narrative review of the literature and an overview of future research directions", **Journal of Cleaner Production**, v. 275, p. 122556, 1 jun. 2020. DOI: 10.1016/j.jclepro.2020.122556.

EPSTEIN, J. M., AXTELL, R. **Growing artificial societies: Social science from the bottom up. Growing artificial societies: Social science from the bottom up.**, Complex adaptive systems. Cambridge, MA, US, The MIT Press. , 1996

FAGIOLO, G., WINDRUM, P., MONETA, A. "Empirical Validation of Agent-Based Models: Alternatives and Prospects", **Journal of Artificial Societies and Social Simulation**, v. 10, 1 maio 2007.

FAO, FAOSTAT, 2019, Disponível em: <<http://www.fao.org/faostat/en/#data>>

FAO. **The future of food and agriculture: trends and challenges. The future of food and agriculture: trends and challenges.** Rome, [s.n.], 2017. Disponível em: http://www.fao.org/3/a-16583e.pdf%0Ahttp://siteresources.worldbank.org/INTARD/825826-1111044795683/20424536/Ag_ed_Africa.pdf%0Awww.fao.org/cfs%0Ahttp://www.jstor.org/stable/4356839%0Ahttps://ediss.uni-goettingen.de/bitstream/handle/11858/00-1735-0000-0022.

FAO. **World Livestock: Transforming the livestock sector through the Sustainable Development Goals.** [S.l: s.n.], 2018. Disponível em: <http://www.fao.org/3/CA1201EN/ca1201en.pdf>.

FERRARO, P. J., MIRANDA, J. J., PRICE, M. K., "The persistence of treatment effects with norm-based policy instruments: Evidence from a randomized environmental policy experiment" **American Economic Review**, 101(3), 318–22, 2011.

FERREIRA DOS SANTOS, ANTÓNIO AND JOÃO TOMÉ SARAIVA. "Agent Based Models in Power Systems.", 2021.

FGV, sd, O Setor de Carnes no Brasil e suas Interações com o Comércio Internacional. Disponível em: https://gvagro.fgv.br/sites/gvagro.fgv.br/files/u115/03_Setor_Carnes_Brasil_PT.pdf (acesso 10/04/2022)

FILATOVA, T., VERBURG, P. H., PARKER, D. C., *et al.* "Spatial agent-based models for socio-ecological systems: Challenges and prospects", **Environmental Modelling & Software**, v. 45, p. 1–7, 2013. DOI: <https://doi.org/10.1016/j.envsoft.2013.03.017>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1364815213000807>>.

FREDERICK, R. "Agents of influence", **Proceedings of the National Academy of Sciences of the United States of America**, v. 110, n. 10, p. 3703–3705, 5 mar. 2013. DOI: 10.1073/pnas.1302005110. Disponível em: <<https://pubmed.ncbi.nlm.nih.gov/23471958>>

FUJIMORI, S., WU, W., DOELMAN, J. *et al.*, "Land-based climate change mitigation measures can affect agricultural markets and food security, **Nat Food** 3, 110–121, 2022. Disponível em: <<https://doi.org/10.1038/s43016-022-00464-4>>

GARDNER, M. "Mathematical Games", **Scientific American**, v. 223, n. 4, p. 120–123, 12 jul. 1970. Disponível em: <<http://www.jstor.org/stable/24927642>>

GARZILLO, JOSEFA MARIA FELLEGGER *et al*, "Pegada de carbono da dieta no Brasil", **Rev. Saúde Pública**, São Paulo, v. 55, 90, 2021. Disponível em:

GIBSON, M., SLADE, R., PORTUGAL-PEREIRA, J., *et al.* "Comparing Mechanisms of Food Choice in an Agent-Based Model of Milk Consumption and Substitution in the UK", **An Agent-Based Model to Simulate Meat Consumption Behaviour of Consumers in Britain**, v. 24, n. 3, p. 9, 2020. DOI: 10.18564/jasss.4637. Disponível em: <http://jasss.soc.surrey.ac.uk/24/3/9.html>.

GRIMM, V., BERGER, U., BASTIANSEN, F., *et al.* "A standard protocol for describing individual-based and agent-based models", **Ecological Modelling**, v. 198, n. 1–2, p. 115–126, 2006. DOI: 10.1016/j.ecolmodel.2006.04.023.

GRIMM, V., BERGER, U., DEANGELIS, D. L., *et al.* "The ODD protocol: A review and first update", **Ecological Modelling**, v. 221, n. 23, p. 2760–2768, 2010. DOI: 10.1016/j.ecolmodel.2010.08.019.

GRIMM, V., REVILLA, E., BERGER, U., *et al.* "Pattern-oriented modeling of agent-based complex systems: Lessons from ecology", **Science**, v. 310, n. 5750, p. 987–991, 2005. DOI: 10.1126/science.1116681.

GROENEVELD, J., MÜLLER, B., BUCHMANN, C. M., *et al.* "Theoretical foundations of human decision-making in agent-based land use models – A review", **Environmental Modelling & Software**, v. 87, p. 39–48, 2017. DOI: <https://doi.org/10.1016/j.envsoft.2016.10.008>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1364815216308684>.

HALTON, JOHN H. "A Retrospective and Prospective Survey of the Monte Carlo Method." *SIAM Review* 12, no. 1 (1970): 1–63.
<http://www.jstor.org/stable/2029039>.

HAMMOND, R. A., ORNSTEIN, J. T. "A model of social influence on body mass index", **Annals of the New York Academy of Sciences**, v. 23, n. 1, p. 34–42, 2014. DOI: 10.1111/nyas.12344.A. Disponível em:
<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3624763/pdf/nihms412728.pdf>.

HARGREAVES, S. M., ARAÚJO, W. M. C., NAKANO, E. Y., *et al.* "Brazilian vegetarians diet quality markers and comparison with the general population: A nationwide cross-sectional study", **PLoS ONE**, v. 15, n. 5, p. 1–21, 2020. DOI: 10.1371/journal.pone.0232954.

HASEGAWA, T., FUJIMORI, S., FRANK, S. *et al.*, "Land-based implications of early climate actions without global net-negative emissions", *Nat Sustain* 4, 1052–1059, 2021. <https://doi.org/10.1038/s41893-021-00772-w>

HAUKE, J., ACHTER, S., MEYER, M. "Theory development via replicated simulations and the added value of standards", **Jasss**, v. 23, n. 1, 2020. DOI: 10.18564/jasss.4219.

HEATH, B., HILL, R., CIARALLO, F. "A Survey of Agent-Based Modeling Practices", **Journal of Artificial Societies and Social Simulation**, v. 12, n. 4 (9), p. 1–46, 2009.

HEITOR, S. F. D., ESTIMA, C. C. P., DAS NEVES, F. J., *et al.* "Translation and cultural adaptation of the questionnaire on the reason for food choices (Food choice Questionnaire - FCQ) into Portuguese", **Ciencia e Saude Coletiva**, v. 20, n. 8, p. 2339–2346, 2015. DOI: 10.1590/1413-81232015208.15842014.

HEITOR, S. F. D., REICHENHEIM, M. E., FERREIRA, J. E. de S., *et al.* "Validity of the factorial structure of the brazilian version scale of the food choice questionnaire", **Ciencia e Saude Coletiva**, v. 24, n. 9, p. 3551–3561, 2019. DOI: 10.1590/1413-81232018249.26482017.

HOLLAND, J. H. "Studying Complex Adaptive Systems", **Journal of Systems Science and Complexity**, v. 19, n. 1, p. 1–8, 1995. DOI: 10.1007/s11424-006-0001-z.
Disponível em: <https://doi.org/10.1007/s11424-006-0001-z>.

<https://doi.org/10.11606/s1518-8787.2021055003614> >. Acessado 10 janeiro de 2020.

IBGE, 2010, Guia do censos 2010. Disponível em : < <https://censo2010.ibge.gov.br/materiais/guia-do-censo/operacao-censitaria.html#:~:text=O%20que%20%C3%A9%20%22setor%20censit%C3%A1rio,o%20levantamento%20por%20um%20recenseador.> > (acesso 21/06/2021)

IBGE, 2018, Projeções da População. Disponível em : < <https://www.ibge.gov.br/estatisticas/sociais/populacao/9109-projecao-da-populacao.html?=&t=resultados> > (acesso 10/04/2022)

IBGE, 2019, Pesquisa de Orçamentos Familiares 2017-2018: Primeiros Resultados, Rio Janeiro. <http://scholar.google.com/scholar?hl=en&btnG=Search&q=intitle:Pesquisa+de+Or%3Famentos+Familiares#0>.

IBGE, 2020, Censo Agro 2017. Disponível em : < <https://censoagro2017.ibge.gov.br/2012-agencia-de-noticias/noticias/27596-nordeste-e-unico-regiao-com-aumento-na-concentracao-de-renda-em-2019.html> > (acesso/10/04/2022)

IBGE, 2021a, Pesquisa de Orçamentos Familiares - POF: O que é. Disponível em : < <https://www.ibge.gov.br/estatisticas/sociais/protecao-social/9050-pesquisa-de-orcamentos-familiares.html?=&t=o-que-e> > (accessed February 4, 2021).

IBGE, 2021b, Pesquisa Trimestral do Abate de Animais. Disponível em : < <https://www.ibge.gov.br/estatisticas/economicas/agricultura-e-pecuaria/9203-pesquisas-trimestrais-do-abate-de-animal.html?=&t=o-que-e> > (acesso 18/07/2021)

IBGE, 2021c, Pesquisa Trimestral do Couro. Disponível em : < <https://www.ibge.gov.br/estatisticas/economicas/agricultura-e-pecuaria/9214-pesquisa-trimestral-do-couro.html?=&t=o-que-e> > (acesso 18/07/2021)

IBGE, 2021d, Pesquisa de Orçamentos Familiares - POF: Microdados.

INSTITUTO ESCOLHAS, Do Pasto ao Prato: Subsídios e Pegada Ambiental da Carne Bovina, São Paulo, janeiro, 2020. Disponível em : < <https://www.escolhas.org/wp-content/uploads/2020/01/Do-pasto-ao-prato-subsidios-e-pegada-ambiental-da-cadeia-da-carne-SUM%C3%81RIO-EXECUTIVO.pdf> > (acesso 10/04/2022)

IPCC, 2022: Annex III: Scenarios and modelling methods [Guivarch, C., E.

Kriegler, J. Portugal-Pereira, V. Bosetti, J. Edmonds, M. Fischedick, P. Havlík, P. Jaramillo, V. Krey, F. Lecocq, A. Lucena, M. Meinshausen, S. Mirasgedis, B. O'Neill, G.P. Peters, J. Rogelj, S. Rose, Y. Saheb, G. Strbac, A. Hammer Strømman, D.P. van Vuuren, N. Zhou (eds)]. In IPCC, 2022: Climate Change 2022: Mitigation of Climate Change. Contribution of Working Group III to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change [P.R. Shukla, J. Skea, R. Slade, A. Al Khourdajie, R. van Diemen, D. McCollum, M. Pathak, S. Some, P. Vyas, R. Fradera, M. Belkacemi, A. Hasija, G. Lisboa, S. Luz, J. Malley, (eds.)]. Cambridge University Press, Cambridge, UK and New York, NY, USA. doi: 10.1017/9781009157926.022

ITS, 2021. Mudanças Climáticas na Percepção dos Brasileiros. Disponível em: <www.percepcaoclimatica.com.br/edicao-2020> (acesso: 04/02/2021).

JAGER, W. "Enhancing the realism of simulation (EROS): On implementing and developing psychological theory in social simulation", **Jasss**, v. 20, n. 3, 2017. DOI: 10.18564/jasss.3522.

JAGER, W., ERNST, A. "Introduction of the special issue “Social simulation in environmental psychology”", **Journal of Environmental Psychology**, v. 52, p. 114–118, 2017. DOI: 10.1016/j.jenvp.2017.07.002.

KAUFFMAN, S. A., KAUFFMAN, M. S. F. I. P. B. S. A. **The Origins of Order: Self-organization and Selection in Evolution**. [S.l.], Oxford University Press, 1993. Disponível em: <https://books.google.com.br/books?id=lZcSpRJz0dgC>.

KICKHÖFER, B., KERN, J. "Pricing local emission exposure of road traffic: An agent-based approach", **Transportation Research Part D: Transport and Environment**, v. 37, p. 14–28, 2015. DOI: 10.1016/j.trd.2015.04.019.

LANGELLIER, B. A. "An agent-based simulation of persistent inequalities in health behavior: Understanding the interdependent roles of segregation, clustering, and social influence", **SSM - Population Health**, v. 2, p. 757–769, 2016. DOI: 10.1016/j.ssmph.2016.10.006. Disponível em: <http://dx.doi.org/10.1016/j.ssmph.2016.10.006>.

LANGELLIER, B. A., BILAL, U., MONTES, F., *et al.* "Complex Systems Approaches to Diet: A Systematic Review", **American Journal of Preventive Medicine**, v. 57, n. 2, p. 273–281, 2019. DOI: 10.1016/j.amepre.2019.03.017. Disponível em: <https://doi.org/10.1016/j.amepre.2019.03.017>.

LANGELLIER, B. A., LÊ-SCHERBAN, F., PURTLE, J. "Funding quality pre-kindergarten slots with Philadelphia's new "sugary drink tax": Simulating effects of using an excise tax to address a social determinant of health", **Public Health Nutrition**, v. 20, n. 13, p. 2450–2458, 2017. DOI: 10.1017/S1368980017001756.

LANGTON, C. G. **Artificial Life: Proceedings of an Interdisciplinary Workshop on the Synthesis and Simulation of Living Systems**. USA, Addison-Wesley Longman Publishing Co., Inc., 1989.

LAVER, M. "Policy and the dynamics of political competition", **American Political Science Review**, v. 99, p. 263–281, 1 maio 2005.

LEBARON, B., WINKER, P. "Introduction to the Special Issue on Agent-Based Models for Economic Policy Advice", **Journal of Economics and Statistics (Jahrbuecher fuer Nationaloekonomie und Statistik)**, v. 228, p. 141–148, 1 jun. 2008. DOI: 10.1515/jbnst-2008-2-302.

LEE, B. Y., FERGUSON, M. C., HERTENSTEIN, D. L., *et al.* "Labels in Three Cities", **American Journal of Preventive Medicine**, v. 54, n. 2, p. 197–204, 2019. DOI: 10.1016/j.amepre.2017.11.003.

LEE, J. S., FILATOVA, T., LIGMANN-ZIELINSKA, A., *et al.* "The complexities of agent-based modeling output analysis", **Jasss**, v. 18, n. 4, p. 1–26, 2015. DOI: 10.18564/jasss.2897.

LI, Y., ZHANG, D., PAGÁN, J. A. "Social Norms and the Consumption of Fruits and Vegetables across New York City Neighborhoods", **Journal of Urban Health**, v. 93, n. 2, p. 244–255, 2016. DOI: 10.1007/s11524-016-0028-y.

LI, Y., ZHANG, D., THAPA, J. R., *et al.* "Assessing the role of access and price on the consumption of fruits and vegetables across New York City using agent-based modeling", **Preventive Medicine**, v. 106, n. September 2017, p. 73–78, 2018. DOI: 10.1016/j.ypmed.2017.10.014.

LIGMANN-ZIELINSKA, A., SIEBERS, P. O., MAGLIOCCIA, N., *et al.* "'One size does not fit all': A roadmap of purpose-driven mixed-method pathways for sensitivity analysis of agent-based models", **Jasss**, v. 23, n. 1, 2020. DOI: 10.18564/jasss.4201.

MACAL, C. M., NORTH, M. J. "Agent-based modelling and simulation". 2009. **Anais** [...] [S.l: s.n.], 2009. p. 86–98. DOI: 10.1109/WSC.2009.5429318.

MACAL, C. M., NORTH, M. J. "Introductory Tutorial: Agent-Based Modeling And Simulation". 2011. **Anais** [...] [S.l: s.n.], 2011. p. 1456–1469. DOI: 10.1109/WSC.2014.7019874.

MACAL, C. M., NORTH, M. J. "Proceedings of the 2005 Winter Simulation Conference. Tutorial on Agent-Based Modeling and Simulation", **Simulation**, p. 1643–1649, 2005. Disponível em: <http://www.mendeley.com/research/proceedings-2005-winter-simulation-conference-m-e-kuhl-n-m-steiger-f-b-armstrong-j-joines-eds-65/>.

MACAL, C. M., NORTH, M. J. "Tutorial On Agent-Based Modeling And Simulation Part 2: How To Model With Agents". 2006. **Anais** [...] [S.l: s.n.], 2006. p. 73–83. DOI: 10.1109/WSC.2006.323040.

MACAL, C. M., NORTH, M. J. "Tutorial on agent-based modelling and simulation", **Journal of Simulation**, v. 4, n. 3, p. 151–162, 2010. DOI: 10.1057/jos.2010.3.

MACKINNON, N. J. **Symbolic interactionism as affect control**. Albany, NY, US, State University of New York Press, 1994. (SUNY series in the sociology of emotions.).

MAROULIS, S., BAKSHY, E., GOMEZ, L., *et al.* "Modeling the Transition to Public School Choice", **JASSS**, v. 17, 31 mar. 2014. DOI: 10.18564/jasss.2402.

MATTHEW GIBSON, JOANA PORTUGAL PEREIRA, RAPHAEL SLADE, JOERI ROGELJ, 2022, "Agent-Based Modelling of Future Dairy and Plant-Based Milk Consumption for UK Climate Targets," **Journal of Artificial Societies and Social Simulation**, vol. 25(2), pages 1-3.

MBOW, C., C. ROSENZWEIG, L.G. BARIONI, T.G. BENTON, M. HERRERO, M. KRISHNAPILLAI, E. LIWENGA, P. PRADHAN, M.G. RIVERA-FERRE, T. SAPKOTA, F.N. TUBIELLO, Y. XU, 2019: Food Security. In: Climate Change and Land: an IPCC special report on climate change, desertification, land degradation, sustainable land management, food security, and greenhouse gas fluxes in terrestrial ecosystems [P.R. Shukla, J. Skea, E. Calvo Buendia, V. Masson-Delmotte, H.-O. Pörtner, D.C. Roberts, P. Zhai, R. Slade, S. Connors, R. van Diemen, M. Ferrat, E. Haughey, S.

Luz, S. Neogi, M. Pathak, J. Petzold, J. Portugal Pereira, P. Vyas, E. Huntley, K. Kissick, M. Belkacemi, J. Malley, (eds.)]. In press.

MCPHERSON, M., SMITH-LOVIN, L., COOK, J. M. "Birds of a Feather: Homophily in Social Networks", **Annual Review of Sociology**, v. 27, n. 1, p. 415–444, 1 ago. 2001. DOI: 10.1146/annurev.soc.27.1.415. Disponível em: <https://doi.org/10.1146/annurev.soc.27.1.415>.

MEDINA, L. de P. B., BARROS, M. B. de A., SOUSA, N. F. da S., *et al.* "Social inequalities in the food consumption profile of the Brazilian population: National health survey, 2013", **Revista Brasileira de Epidemiologia**, v. 22, n. Suppl 2, p. 1–15, 2019. DOI: 10.1590/1980-549720190011.supl.2.

MOHAMMED, N. A., AL-BAZI, A. "Management of renewable energy production and distribution planning using agent-based modelling", **Renewable Energy**, v. 164, p. 509–520, 2021. DOI: 10.1016/j.renene.2020.08.159. Disponível em: <https://doi.org/10.1016/j.renene.2020.08.159>.

MORAES, J. M. M., ALVARENGA, M. dos S. "Adaptação transcultural e validade aparente e de conteúdo da versão reduzida da The Eating Motivation Survey (TEMS) para o Português do Brasil", **Cadernos de Saude Publica**, v. 33, n. 10, 2017. DOI: 10.1590/0102-311X00010317.

MORAES, J. M. M., MORAES, C. H. de C., SOUZA, A. A. L. de, *et al.* "Food choice motives among two disparate socioeconomic groups in Brazil", **Appetite**, v. 155, n. June, 2020. DOI: 10.1016/j.appet.2020.104790.

MOREIRA, L. C., EIFERT, E. C., MAGNABOSCO, C. U., JORDÃO, ROSA, A. M., FRAGOSO, R. R., SOUZA F. M., LOPES, B. F., SAINZ R. D., "PESOS E RENDIMENTOS DA CARCAÇA DE BOVINOS NELORE MOCHO SELECCIONADOS PARA MACIEZ". XXIV Congresso brasileiro de zootecnia, Universidade Federal do Espírito Santo, Vitória, ES, 12-14 Maio 2014

MUELDER, H., FILATOVA, T. "One theory-many formalizations: Testing different code implementations of the theory of planned behaviour in energy agent-based models", **Jasss**, v. 21, n. 4, 2018. DOI: 10.18564/jasss.3855.

MÜLLER, B., BOHN, F., DRESSLER, G., *et al.* "Describing human decisions in agent-based models - ODD+D, an extension of the ODD protocol", **Environmental Modelling and Software**, v. 48, p. 37–48, 2013. DOI: 10.1016/j.envsoft.2013.06.003.

NATIONAL RESEARCH COUNCIL, **Advancing land change modeling: Opportunities and research requirements**, Washington, DC: The National Academies Press, 2014.

NERI, MARCELO C., "Insegurança Alimentar no Brasil: Pandemia, Tendências e Comparações Internacionais", 29 pags., Rio de Janeiro, RJ, Maio/2022, FGV Social. Disponível em: <<https://cps.fgv.br/FomeNaPandemia>>

NETLOGO, 2022, What is NetLogo? . Disponível em : <<https://ccl.northwestern.edu/netlogo/docs/>> (acesso 10/05/2021)

NIAMIR, L., KIESEWETTER, G., WAGNER, F., *et al.* "Assessing the macroeconomic impacts of individual behavioral changes on carbon emissions", **Climatic Change**, v. 158, n. 2, p. 141–160, 2020. DOI: 10.1007/s10584-019-02566-8.

NIAZI, M., HUSSAIN, A. "Agent-based computing from multi-agent systems to agent-based models: A visual survey", **Scientometrics**, v. 89, n. 2, p. 479–499, 2011. DOI: 10.1007/s11192-011-0468-9.

NOLAN, J. M., SCHULTZ, P. W., CIALDINI, R. B., GOLDSTEIN, N. J. & GRISKEVICIUS, V., "Normative social influence is underdetected", **Personality and Social Psychology Bulletin**, 34(7), 913–923, 2008.

ORR, M. G., KAPLAN, G. A., GALEA, S. "Neighbourhood food, physical activity, and educational environments and black/white disparities in obesity: A complex systems simulation analysis", **Journal of Epidemiology and Community Health**, v. 70, n. 9, p. 862–867, 2016. DOI: 10.1136/jech-2015-205621.

ORR, M. G., PLAUT, D. C. "Complex systems and health behavior change: Insights from cognitive science", **American Journal of Health Behavior**, v. 38, n. 3, p. 404–413, 2014. DOI: 10.5993/AJHB.38.3.9.

PARKER, D. C., MANSON, S. M., JANSSEN, M. A., *et al.* "Multi-agent systems for the simulation of land-use and land-cover change: A review", **Annals of the Association of American Geographers**, v. 93, n. 2, p. 314–337, 2003. DOI: 10.1111/1467-8306.9302004.

PEARCE, P., SLADE, R. "Feed-in tariffs for solar microgeneration: Policy evaluation and capacity projections using a realistic agent-based model", **Energy Policy**, v. 116, n. January, p. 95–111, 2018. DOI: 10.1016/j.enpol.2018.01.060. Disponível em: <https://doi.org/10.1016/j.enpol.2018.01.060>.

PEGDEN, C. D., SHANNON, R. E., SADOWSKI, R. P. **Introduction to simulation using SIMAN**. [S.l.], New York (N.Y.) : McGraw-Hill, 1990. Disponível em: <http://lib.ugent.be/catalog/rug01:000256128>.

PINTOS-PAYERAS, J. A. "Estimação Do Sistema Quase Ideal de Demanda para uma Cesta Apliada de Produtos Empregando dados da POF de 2002-2003", **Economia Aplicada**, v. 13, n. 2, p. 231–255, 2009.

POORE, J., NEMECEK, T. "Reducing food's environmental impacts through producers and consumers", **Science**, v. 360, n. 6392, p. 987–992, 2018. DOI: 10.1126/science.aaq0216.

POPKIN, B. M. "Global nutrition dynamics: The world is shifting rapidly toward a diet linked with noncommunicable diseases", **American Journal of Clinical Nutrition**, v. 84, n. 2, p. 289–298, 2006. DOI: 10.1093/ajcn/84.2.289.

PORPINO, G.; LOURENÇO, C. E.; ARAÚJO, C.M.; BASTOS, A. (2018). Intercâmbio Brasil – União Europeia sobre desperdício de alimentos. Relatório final de pesquisa. Brasília: Diálogos Setoriais União Europeia – Brasil. Disponível em: < <http://www.sectordialogues.org/publicacao>

PURSLOW, P. P., OISETH, S., HUGHES, J., *et al.* "The structural basis of cooking loss in beef: Variations with temperature and ageing", **Food Research International**, v. 89, p. 739–748, 2016. DOI: 10.1016/j.foodres.2016.09.010. Disponível em: <http://dx.doi.org/10.1016/j.foodres.2016.09.010>.

QSIG, 2021. Open Source Geographic Information System. Versão 3.18.1. Disponível em: <https://qgis.org/> (acesso 10/06/2020)

R-PROJECT, What is R? Introduction to R, (2021). <https://www.r-project.org/about.html> (acesso 10/06/2020).

RANDALL, E., SANJUR, D. "Food preferences—Their conceptualization and relationship to consumption", **Ecology of Food and Nutrition**, v. 11, n. 3, p. 151–161, 1981. DOI: 10.1080/03670244.1981.9990671.

RAO, A. S. AND M. P. GEORGEFF. 1999. "Modeling agents within a BDI-architecture", In **Proc. International Conference on Principles of Knowledge Representation and Reasoning (KR)**, Eds., R. Fikes and E. Sandewall, Cambridge, MA: Morgan Kaufmann. Repast.

RENNER B., SPROESSER G., STROHBACH S., SCHUPP H.T., "Why we eat what we eat: The Eating Motivation Survey (TEMS)", **Appetite**, 2012; 59: 117-28.

REYNOLDS, C. W. "Flocks, herds, and schools: A distributed behavioral model", **Proceedings of the 14th Annual Conference on Computer Graphics and Interactive Techniques, SIGGRAPH 1987**, v. 21, n. 4, p. 25–34, 1987. DOI: 10.1145/37401.37406.

RIAHI, K., R. SCHAEFFER, J. ARANGO, K. CALVIN, C. GUIVARCH, T. HASEGAWA, K. JIANG, E. KRIEGLER, R. MATTHEWS, G.P. PETERS, A. RAO, S. ROBERTSON, A.M. SEBBIT, J. STEINBERGER, M. TAVONI, D.P. VAN VUUREN, 2022: Mitigation pathways compatible with long-term goals. In IPCC, 2022: Climate Change 2022: Mitigation of Climate Change. Contribution of Working Group III to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change [P.R. Shukla, J. Skea, R. Slade, A. Al Khourdajie, R. van Diemen, D. McCollum, M. Pathak, S. Some, P. Vyas, R. Fradera, M. Belkacemi, A. Hasija, G. Lisboa, S. Luz, J. Malley, (eds.)]. Cambridge University Press, Cambridge, UK and New York, NY, USA. doi: 10.1017/9781009157926.00Riahi, K., R. Schaeffer, J. Arango, K. Calvin, C. Guivarch, T. Hasegawa, K. Jiang, E. Kriegler, R. Matthews, G.P. Peters, A. Rao, S. Robertson, A.M. Sebbit, J. Steinberger, M. Tavoni, D.P. van Vuuren, 2022: Mitigation pathways compatible with long-term goals. In IPCC, 2022: Climate Change 2022: Mitigation of Climate Change. Contribution of Working Group III to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change [P.R. Shukla, J. Skea, R. Slade, A. Al Khourdajie, R. van Diemen, D. McCollum, M. Pathak, S. Some, P. Vyas, R. Fradera, M. Belkacemi, A. Hasija, G. Lisboa, S. Luz, J. Malley, (eds.)]. Cambridge University Press, Cambridge, UK and New York, NY, USA. doi: 10.1017/9781009157926.005

RIET, J. van't, SIJTSEMA, S. J., DAGEVOS, H., *et al.* "The importance of habits in eating behaviour . An overview and recommendations for future research", **Appetite**, v. 57, p. 585–596, 2011. DOI: 10.1016/j.appet.2011.07.010.

RINDFUSS, R., ENTWISLE, B., WALSH, S., *et al.* "Land use change: Complexity and comparisons", **Journal of Land Use Science**, v. 3, p. 1–10, 17 jan. 2008. DOI: 10.1080/17474230802047955.

ROBINSON, E., FLEMING, A. & HIGGS, S., "Prompting healthier eating: Testing the use of health and social norm based messages", **Health Psychology**, 33(9), 1057, 2014.

ROGERS, E. M., Diffusion of Innovations, 4th ed. New York, NY: The Free Press Salzarulo, 1993.

SÆLEN, H., HOVI, J., SPRINZ, D., *et al.* "How US withdrawal might influence cooperation under the Paris climate agreement", **Environmental Science and Policy**, v. 108, n. April, p. 121–132, 2020. DOI: 10.1016/j.envsci.2020.03.011. Disponível em: <https://doi.org/10.1016/j.envsci.2020.03.011>.

SANCHEZ-SABATE, R., SABATÉ, J. "Consumer attitudes towards environmental concerns of meat consumption: A systematic review", **International Journal of Environmental Research and Public Health**, v. 16, n. 7, 2019. DOI: 10.3390/ijerph16071220.

SCALCO, A., MACDIARMID, J. I., CRAIG, T., *et al.* "An Agent-Based Model to Simulate Meat Consumption Behaviour of Consumers in Britain", **Journal of Artificial Societies and Social Simulation**, 2019.

SCHELLING, T.C., Micromotives and Macrobbehavior. Norton, New York, 1978.

SEEG (Sistema de Estimativa de Emissões de Gases de Efeito Estufa). Análise das emissões brasileiras de Gases de Efeito Estufa e suas implicações para as metas do Brasil (1970- 2018), **Observatório do Clima**, São Paulo, 2019. Disponível em: < www.observatoriodoclima.eco.br/wp-content/uploads/2019/11/OC_SEEG_Relatorio_2019pdf.pdf > Acesso em: 10 mar. 2020.

SEEG (Sistema de Estimativa de Emissões de Gases de Efeito Estufa). Análise das emissões brasileiras de Gases de Efeito Estufa e suas implicações para as metas do Brasil (1970- 2018), Observatório do Clima, São Paulo, 2019. Disponível em: <<https://plataforma.seeg.eco.br/sectors/agropecuaria>> Acesso em: 17 mar. 2022.

SOUZA, A. de M., PEREIRA, R. A., YOKOO, E. M., *et al.* "Most consumed foods in Brazil: National dietary survey 2008-2009", **Revista de Saude Publica**, v. 47, n. SUPPL.1, p. 190–199, 2013.

SOUZA, A. M., BEZERRA, I. W. L., PEREIRA, G. S., *et al.* "Relationships between motivations for food choices and consumption of food groups: A prospective cross-sectional survey in manufacturing workers in brazil", **Nutrients**, v. 12, n. 5, 2020. DOI: 10.3390/nu12051490.

SPRINZ, D. F., SÆLEN, H., UNDERDAL, A., *et al.* "The effectiveness of climate clubs under Donald Trump", **Climate Policy**, v. 18, n. 7, p. 828–838, 2018. DOI: 10.1080/14693062.2017.1410090.

SPROESSER, G., MORAES, J. M. M., RENNER, B., *et al.* "The Eating Motivation Survey in Brazil: Results From a Sample of the General Adult Population", **Frontiers in Psychology**, v. 10, n. October, p. 1–9, 2019. DOI: 10.3389/fpsyg.2019.02334.

STEPTOE A., POLLARD T.M., WARDLE J., "Development of a measure of the motives underlying the selection of food: the food choice questionnaire", **Appetite**, 1995 Dec;25(3):267-84. doi: 10.1006/appc.1995.0061. PMID: 8746966.

SVB, 2020. Vegetarianimo. Disponível em: <<https://www.svb.org.br/vegetarianismo1/o-que-e>> (acesso: 02/08/2020).

TAX FOUNDATION, 2022, Carbon Taxes in Europe. Disponível em : <<https://taxfoundation.org/carbon-taxes-in-europe-2021/>> (acesso 10/04/2022)

TAYLOR, S. (Org.). **Agent-Based Modeling and Simulation**. 1. ed. [S.l.], Palgrave Macmillan UK, 2014. v. 53.

TRACY, M., CERDÁ, M., KEYES, K. M. "Agent-Based Modeling in Public Health: Current Applications and Future Directions", **Annual Review of Public Health**, v. 39, n. 1, p. 77–94, 2018. DOI: 10.1146/annurev-publhealth-040617-014317.

TRAVASSOS, G. F., ANTÔNIO DA CUNHA, D., COELHO, A. B. "The environmental impact of Brazilian adults' diet", **Journal of Cleaner Production**, v. 272, 2020. DOI: 10.1016/j.jclepro.2020.122622.

TROGDON, J. G., ALLAIRE, B. T. "The effect of friend selection on social influences in obesity", **Economics and Human Biology**, v. 15, p. 153–164, 2014. DOI: 10.1016/j.ehb.2014.08.004. Disponível em: <http://dx.doi.org/10.1016/j.ehb.2014.08.004>.

TROOST, C., BERGER, T. "Dealing with uncertainty in agent-based simulation: Farm-level modeling of adaptation to climate change in southwest Germany", **American Journal of Agricultural Economics**, v. 97, n. 3, p. 833–854, 2014. DOI: 10.1093/ajae/aau076.

TUFTS UNIVERSITY, Global Dietary Database, 2019, Disponível em: <https://www.globaldietarydatabase.org/data-download>. Acessado 6 Setembro de 2021.

UN, 2015, Transforming our World: The 2030 Agenda for Sustainable Development. Disponível em: < <https://sdgs.un.org/publications/transforming-our-world-2030-agenda-sustainable-development-17981> > (acesso: 30/03/2020).

VAN DEN BERG, N. J., VAN SOEST, H. L., HOF, A. F., *et al.* "Implications of various effort-sharing approaches for national carbon budgets and emission pathways", **Climatic Change**, v. 162, n. 4, p. 1805–1822, 2020. DOI: 10.1007/s10584-019-02368-y. Disponível em: <https://doi.org/10.1007/s10584-019-02368-y>.

VINCENZI, R., FILHO, P. M., SAKAMOTO, L. S., ANDRADE, L. L., BERNDT, A., TULLIO R. R., MARCONDES, C. R., "Peso e rendimento de carcaça de novilhos Canchim de diferentes linhagens terminados em confinamento". XII Simpósio Brasileiro de Melhoramento Animal, Ribeirão Preto, SP, 12-13 Junho 2017.

WALZBERG, J., DANDRES, T., MERVEILLE, N., *et al.* "Assessing behavioural change with agent-based life cycle assessment: Application to smart homes", **Renewable and Sustainable Energy Reviews**, v. 111, n. August 2018, p. 365–376, 2019. DOI: 10.1016/j.rser.2019.05.038. Disponível em: <https://doi.org/10.1016/j.rser.2019.05.038>.

WASSERMAN, S., FAUST, K. **Social network analysis: Methods and applications**. New York, NY, US, Cambridge University Press, 1994. (Structural analysis in the social sciences.).

WCRF. Diet, Nutrition, Physical Activity and Cancer: a Global Perspective. Continuous Update Project Expert Report 2018. [S.l: s.n.], 2018.

WELLESLEY, L., HAPPER, C. & FROGGATT, A., "Changing climate, changing diets pathways to lower meat consumption", **Chatham House Report**, 2015, Disponível em: <<https://www.chathamhouse.org>>

WIDENER, M. J., METCALF, S. S., BAR-YAM, Y. "Agent-based modeling of policies to improve urban food access for low-income populations", **Applied Geography**, v. 40, p. 1–10, 2013. DOI: 10.1016/j.apgeog.2013.01.003. Disponível em: <http://dx.doi.org/10.1016/j.apgeog.2013.01.003>.

WILENSKY, URI, NetLogo (and NetLogo User Manual), **Center for Connected Learning and Computer-Based Modeling**, Northwestern University. <http://ccl.northwestern.edu/netlogo/>

YANG, Y. "A narrative review of the use of agent-based modeling in health behavior and behavior intervention", **Translational Behavioral Medicine**, v. 9, n. 6, p. 1065–1075, 2019. DOI: 10.1093/tbm/iby132.

ZHANG, D., GIABBANELLI, P. J., ARAH, O. A., *et al.* "Impact of different policies on unhealthy dietary behaviors in an urban adult population: An agent-based simulation model", **American Journal of Public Health**, v. 104, n. 7, p. 1217–1222, 2014. DOI: 10.2105/AJPH.2014.301934.

RAIMUNDO, L., BATALHA, M., PACHOUD, C., 2017. "CARNE DA AMAZÔNIA: A PERCEPÇÃO DO CONSUMIDOR", 2017. Disponível em: <https://www.researchgate.net/publication/313876936_CARNE_DA_AMAZONIA_A_PERCEPCAO_DO_CONSUMIDOR> Acessado: 01/05/2022

VIEGAS, I., SANTOS, J. M. L., FONTES, M. A., " Percepção dos Consumidores Relativamente à Carne de Bovino: cenários de escolha a partir de grupos de discussão." **Revista de Economia e Sociologia Rural** [online]. 2015, v. 53, n. Suppl 1 [Acessado 30 Junho 2022] , pp. 49-62. Disponível em: <<https://doi.org/10.1590/1234-56781806-94790053s01004>>. ISSN 0103-2003. <https://doi.org/10.1590/1234-56781806-94790053s01004>.

ANEXOS

ANEXO I

Teorias de embasamento do modelo:

A TRA foi inicialmente desenvolvida por AJZEN E FISHBEIN (1980) no campo da psicologia social, porém foi aplicada em uma ampla variedade de estudos, incluindo a ciência econômica para estudar o comportamento do consumidor. Apesar de não ter sido desenvolvida especificamente para avaliar o comportamento relativo à escolha alimentar, a teoria tem sido amplamente utilizada para esse fim BIASINI *et al.* (2021) realizaram uma revisão sistemática de trabalhos que aplicam a teoria para identificar os principais fatores que influenciam a mudança comportamental em direção a dietas sustentáveis. A teoria se baseia na premissa de que o melhor preditor do comportamento de um indivíduo é a sua intenção em praticá-lo.

A intenção apresenta dois determinantes: as atitudes do indivíduo e as normas subjetivas. As atitudes dizem respeito ao aspecto pessoal. Elas consideram a força das crenças e valores que o indivíduo possui e a sua avaliação (positiva ou negativa) sobre as consequências deste comportamento. Já as normas subjetivas, se referem a influências sociais. Estas são determinadas pelas crenças do meio social do indivíduo e pela sua motivação em aceitar a pressão exercida pelos seus pares. As normas subjetivas também consideram estudos de De Castro (1994), Feunekes *et al.* (1998), e Pachucki, Jacques, and Christakis (2011), os quais mostram a relevância da influência social na escolha alimentar, destacando as influências da família e de colegas, e diferenciando as suscetibilidades dos indivíduos em relação as influências desses dois grupos.

ANEXO II

Tabela 13: Tabela IPCA

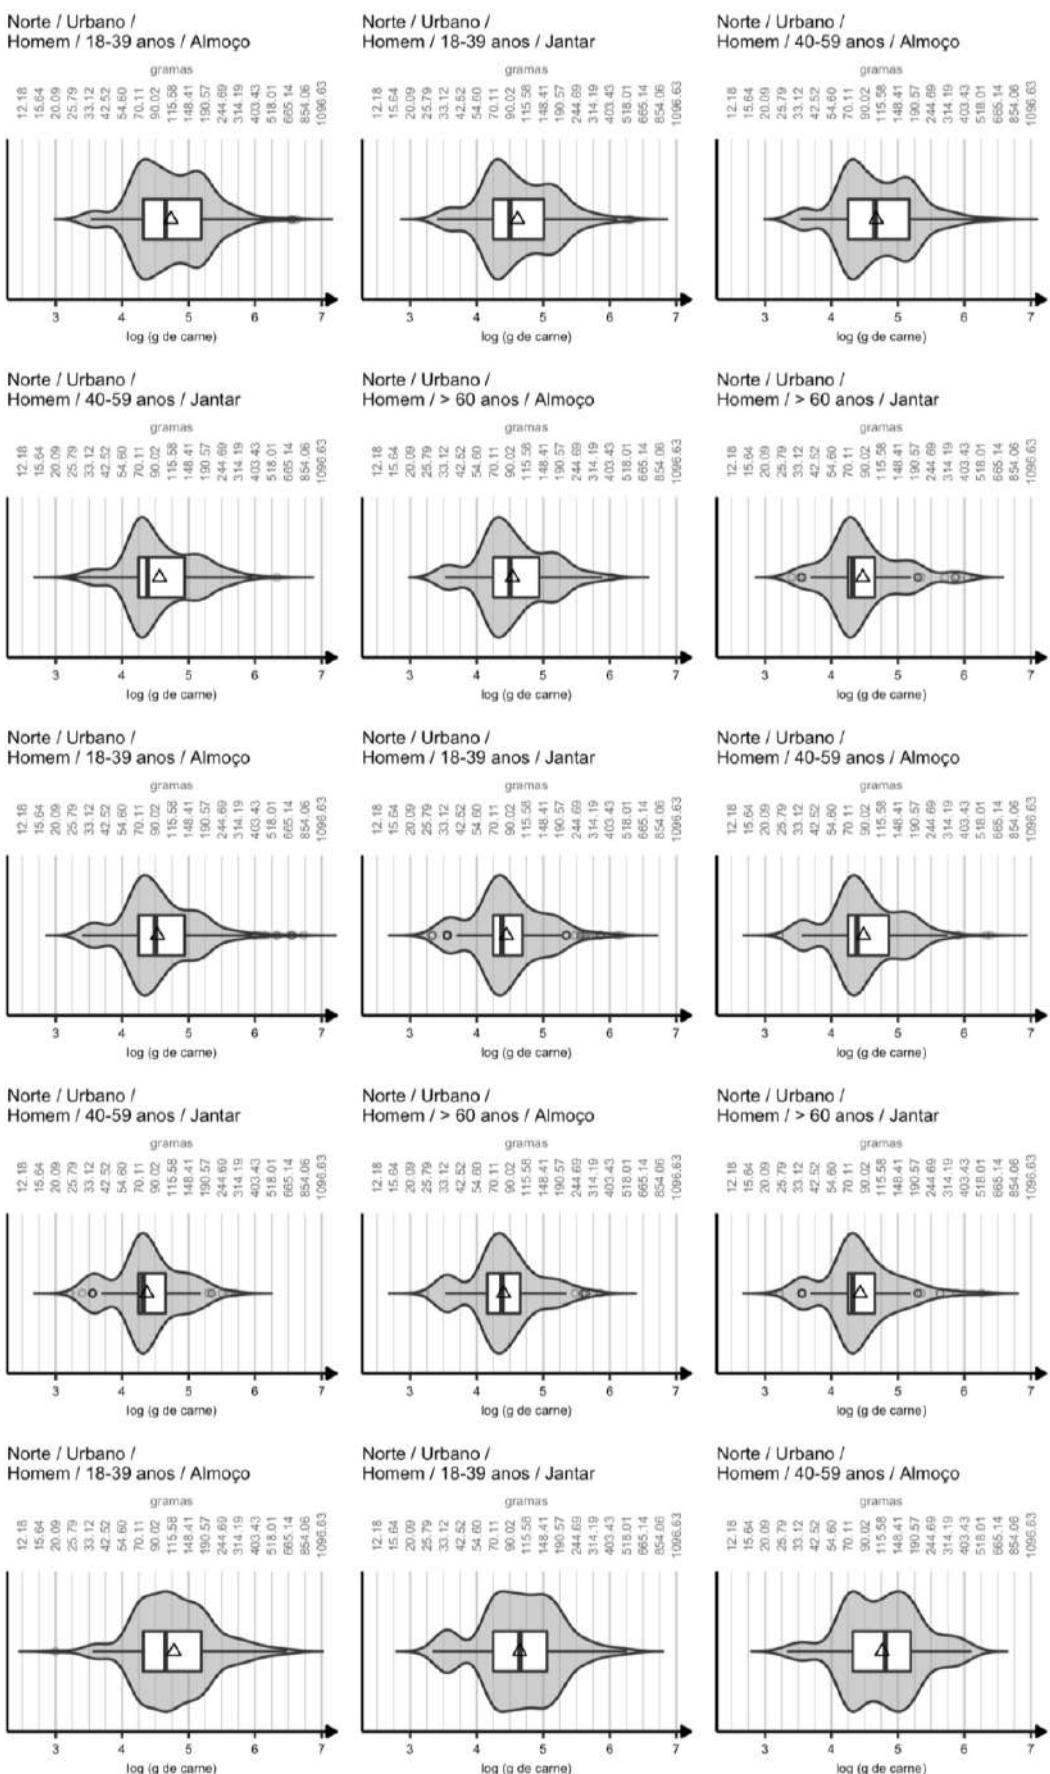
11	12	13	14	15	16	17	21	22	23	24	25	26	27	28	29	31	32	33	35	41	42	43	50	51	52	53
1,80	1,80	1,80	1,80	1,80	1,80	1,80	0,66	0,66	2,81	0,66	0,66	0,18	0,66	0,66	-1,13	0,47	1,76	1,11	-0,35	-0,05	0,48	0,95	-0,81	-0,70	-0,43	-0,98
-0,93	-0,93	-0,93	-0,93	-0,93	-0,93	-0,93	-1,39	-1,39	-2,64	-1,39	-1,39	0,10	-1,39	-1,39	-1,23	-0,81	-1,27	-3,32	-0,16	-3,05	-1,63	-0,38	-1,45	-1,88	-2,85	-0,96
-0,49	-0,49	-0,49	-0,49	-0,49	-0,49	-0,49	-0,71	-0,71	-0,67	-0,71	-0,71	-0,94	-0,71	-0,71	-0,57	-2,09	-3,73	-2,04	-0,71	-1,88	-0,26	1,12	0,55	-0,96	-1,88	-2,43
1,82	1,82	1,82	1,82	1,82	1,82	1,82	-0,12	-0,12	1,14	-0,12	-0,12	0,87	-0,12	-0,12	-2,19	-1,07	0,15	-2,72	2,60	-0,32	-0,02	0,23	-1,02	-1,21	-1,24	-1,55
-2,16	-2,16	-2,16	-2,16	-2,16	-2,16	-2,16	-0,43	-0,43	-1,97	-0,43	-0,43	-0,25	-0,43	-0,43	1,05	0,25	-0,97	1,42	0,35	1,30	0,65	0,11	-0,11	0,19	-0,03	1,29
-1,28	-1,28	-1,28	-1,28	-1,28	-1,28	-1,28	-0,94	-0,94	-1,30	-0,94	-0,94	-1,44	-0,94	-0,94	-0,16	-0,60	-0,86	2,17	-2,56	-2,47	-1,92	-1,46	-1,94	-1,12	-0,81	0,07
-0,63	-0,63	-0,63	-0,63	-0,63	-0,63	-0,63	0,33	0,33	1,49	0,33	0,33	-0,04	0,33	0,33	-0,56	-0,61	-2,48	-3,29	-1,11	-2,00	-0,98	-0,13	-2,02	-1,97	-2,79	-0,32
-3,56	-3,56	-3,56	-3,56	-3,56	-3,56	-3,56	-1,58	-1,58	-2,07	-1,58	-1,58	-1,68	-1,58	-1,58	-0,99	-1,64	-2,01	-2,62	-1,18	-1,64	-1,75	-1,84	-2,79	-1,69	-0,61	-1,30
3,06	3,06	3,06	3,06	3,06	3,06	3,06	1,34	1,34	0,55	1,34	1,34	3,23	1,34	1,34	0,67	-0,65	1,12	2,94	1,16	0,60	0,24	-0,05	4,55	2,71	2,41	-0,62
-1,07	-1,07	-1,07	-1,07	-1,07	-1,07	-1,07	-0,04	-0,04	0,46	-0,04	-0,04	-1,50	-0,04	-0,04	0,63	0,05	0,91	0,61	0,96	0,86	0,04	-0,62	-0,48	-0,14	0,04	0,28
0,53	0,53	0,53	0,53	0,53	0,53	0,53	-0,73	-0,73	0,30	-0,73	-0,73	-0,61	-0,73	-0,73	-1,90	-1,04	-0,39	1,33	0,29	-1,27	-0,68	-0,20	-0,86	0,41	1,66	0,83
-0,51	-0,51	-0,51	-0,51	-0,51	-0,51	-0,51	0,71	0,71	0,30	0,71	0,71	0,72	0,71	0,71	1,13	2,88	2,07	3,29	1,31	4,31	2,63	1,26	2,56	2,00	2,02	0,76
1,56	1,56	1,56	1,56	1,56	1,56	1,56	0,17	0,17	0,52	0,17	0,17	-0,85	0,17	0,17	0,61	0,66	2,39	0,41	0,51	-0,33	0,28	0,79	-1,19	-0,53	-0,89	1,63
-0,81	-0,81	-0,81	-0,81	-0,81	-0,81	-0,81	-0,47	-0,47	-0,84	-0,47	-0,47	-1,14	-0,47	-0,47	0,45	-0,03	-1,46	-2,91	-1,56	-0,94	-0,60	-0,31	-3,70	-2,47	-1,14	-2,29
-0,22	-0,22	-0,22	-0,22	-0,22	-0,22	-0,22	-1,04	-1,04	-0,90	-1,04	-1,04	0,00	-1,04	-1,04	-1,98	-0,31	-0,74	-2,92	-1,11	-2,28	-1,33	-0,54	-2,06	-1,54	-1,73	-0,10
0,19	0,19	0,19	0,19	0,19	0,19	0,19	0,61	0,61	0,66	0,61	0,61	0,12	0,61	0,61	0,95	-1,31	-1,42	-1,10	-0,79	-0,99	-0,05	0,71	0,86	0,29	-0,57	0,68
-1,08	0,92	-1,08	-1,08	-1,08	-1,08	-1,08	0,14	-0,50	-1,24	-0,50	-0,50	-0,57	-0,50	-0,55	-0,43	-1,73	-0,89	-0,32	-0,40	1,43	0,89	0,46	1,84	0,11	-0,76	-1,88
2,05	1,10	2,05	2,05	2,05	2,05	2,05	1,34	3,42	4,07	3,42	3,42	3,99	3,42	3,97	4,21	4,12	3,81	9,65	6,75	3,77	2,79	1,99	1,95	2,55	2,19	4,50
-0,45	1,01	-0,45	-0,45	-0,45	-0,45	-0,45	0,47	-1,23	-0,17	-1,23	-1,23	-1,41	-1,23	-3,57	-1,39	-0,24	0,38	-4,14	-1,89	-0,43	-0,81	-1,12	0,42	-0,13	0,00	-1,50
-1,35	-1,28	-1,35	-1,35	-1,35	-1,35	-1,35	-1,37	-0,77	-1,99	-0,77	-0,77	-1,51	-0,77	1,90	-1,35	-0,39	-0,59	-2,25	-2,46	-2,16	-1,25	-0,50	-1,14	-0,86	-0,46	-1,02
0,12	0,99	0,12	0,12	0,12	0,12	0,12	-2,34	-0,50	1,75	-0,50	-0,50	-0,67	-0,50	-1,10	0,30	0,35	1,02	0,22	0,98	0,00	-0,52	-0,94	2,78	1,36	0,76	-0,56
0,83	1,24	0,83	0,83	0,83	0,83	0,83	1,01	1,01	0,39	1,01	1,01	1,19	1,01	1,63	0,78	0,97	0,80	-0,63	-0,23	1,92	1,13	0,48	2,24	1,77	0,93	2,30
-1,49	0,56	-1,49	-1,49	-1,49	-1,49	-1,49	1,10	0,49	1,14	0,49	0,49	1,96	0,49	-0,79	-0,52	0,29	-0,99	0,88	0,22	0,92	0,02	-0,73	0,04	0,20	1,04	-0,98
1,71	1,48	1,71	1,71	1,71	1,71	1,71	1,83	1,91	0,06	1,91	1,91	-0,14	1,91	1,94	5,57	0,22	2,28	3,98	2,80	1,19	1,53	1,82	1,00	0,42	0,18	-0,41
-1,17	1,99	-1,17	-1,17	-1,17	-1,17	-1,17	0,60	0,87	-0,13	0,87	0,87	0,50	0,87	1,81	1,36	1,16	-0,03	1,89	0,20	1,55	1,73	1,88	-0,19	0,64	0,05	3,63
1,66	-1,28	1,66	1,66	1,66	1,66	1,66	-1,54	-0,94	-1,65	-0,94	-0,94	0,51	-0,94	0,05	-1,76	-1,18	-1,19	-2,55	-1,43	-1,22	-2,01	-2,68	0,35	-0,42	-0,60	-1,75
0,30	-0,20	0,30	0,30	0,30	0,30	0,30	2,78	0,87	1,58	0,87	0,87	-1,18	0,87	0,56	-0,16	0,42	1,29	-0,29	1,24	-0,32	0,67	1,52	-0,06	0,43	0,37	1,62
3,87	0,23	3,87	3,87	3,87	3,87	3,87	0,83	1,11	1,59	1,11	1,11	0,69	1,11	1,00	1,39	-0,01	0,66	0,32	-0,39	-0,82	-0,21	0,31	-0,08	0,01	0,80	-1,22
-1,54	1,51	-1,54	-1,54	-1,54	-1,54	-1,54	0,31	0,57	1,57	0,57	0,57	1,86	0,57	0,40	-0,89	0,40	0,06	-1,06	1,77	0,02	-0,81	-1,50	0,66	0,57	0,41	0,65
0,91	-0,44	0,91	0,91	0,91	0,91	0,91	-1,89	-0,13	0,71	-0,13	-0,13	0,65	-0,13	0,67	-0,42	2,29	1,09	1,21	-0,04	-0,50	0,46	1,29	-0,13	-0,05	0,00	0,04

-0,44	-0,46	-0,44	-0,44	-0,44	-0,44	-0,44	1,58	0,86	0,29	0,86	0,86	0,86	0,53	1,02	1,48	1,75	1,26	0,53	1,70	2,19	2,60	1,40	1,81	1,18	3,87	
0,24	0,17	0,24	0,24	0,24	0,24	0,24	0,46	-0,27	-1,12	-0,27	-0,27	0,33	-0,27	-1,12	0,30	-1,77	-1,51	-1,44	-1,07	0,97	-0,77	-2,21	-0,47	-0,36	0,68	-2,00
-1,47	0,89	-1,47	-1,47	-1,47	-1,47	-1,47	0,72	0,45	0,93	0,45	0,45	-0,61	0,45	0,48	0,44	-0,09	0,14	1,07	0,45	-0,33	0,55	1,31	-1,89	-0,49	0,96	-0,13
4,42	1,31	4,42	4,42	4,42	4,42	4,42	2,45	1,28	1,05	1,28	1,28	1,83	1,28	0,53	0,57	1,56	2,13	3,64	1,38	1,52	0,79	0,17	4,47	2,67	1,28	1,41
9,80	4,90	9,80	9,80	9,80	9,80	9,80	6,82	5,15	6,56	5,15	5,15	5,57	5,15	3,55	3,20	10,03	6,31	7,28	10,01	7,98	5,66	3,67	10,34	11,78	14,13	10,55
15,23	7,67	15,23	15,23	15,23	15,23	15,23	21,54	17,46	16,58	17,46	17,46	17,65	17,46	13,97	17,28	18,52	18,05	22,49	17,32	19,55	19,42	19,30	18,52	17,32	16,34	16,58
-3,49	0,51	-3,49	-3,49	-3,49	-3,49	-3,49	-2,55	-1,81	-3,59	-1,81	-1,81	-2,51	-1,81	0,61	-0,73	-5,63	-3,45	-8,48	-4,80	-5,01	-3,04	-1,05	-3,01	-3,11	-3,41	-2,68
-3,80	-0,48	-3,80	-3,80	-3,80	-3,80	-3,80	-2,56	-2,07	-1,52	-2,07	-2,07	-2,28	-2,07	-2,01	-1,75	-2,80	-3,41	-8,39	-4,41	-3,43	-1,82	-0,27	-2,58	-3,60	-3,75	-6,05
-1,60	1,24	-1,60	-1,60	-1,60	-1,60	-1,60	1,35	0,51	-0,32	0,51	0,51	0,40	0,51	2,70	-2,17	-1,04	-1,04	0,25	0,34	1,82	-0,43	-2,54	1,71	0,37	-2,20	2,76
-2,32	-1,28	-2,32	-2,32	-2,32	-2,32	-2,32	-2,11	-0,97	0,16	-0,97	-0,97	0,99	-0,97	-2,34	-0,21	-1,64	0,53	-3,58	-1,80	-4,83	-3,65	-2,49	-1,56	-1,88	-2,22	-1,97
-0,79	-0,05	-0,79	-0,79	-0,79	-0,79	-0,79	-3,69	0,29	3,13	0,29	0,29	0,47	0,29	1,91	2,06	-0,77	0,51	3,26	-0,14	-2,28	-1,47	-0,69	0,10	0,18	1,03	-1,56
1,28	0,80	1,28	1,28	1,28	1,28	1,28	0,05	1,21	-0,48	1,21	1,21	2,24	1,21	2,76	2,34	2,23	-0,19	1,17	1,30	2,34	1,19	0,10	0,69	0,13	-1,08	1,42
4,86	4,11	4,86	4,86	4,86	4,86	4,86	3,16	3,90	0,24	3,90	3,90	1,66	3,90	6,39	7,73	5,26	0,74	-0,81	3,85	4,75	3,82	2,92	3,71	3,62	3,72	3,11
4,57	3,62	4,57	4,57	4,57	4,57	4,57	1,66	2,50	1,97	2,50	2,50	3,04	2,50	3,06	3,25	5,44	3,52	3,30	2,37	3,54	2,45	1,38	6,28	5,63	5,32	4,54
5,25	7,09	5,25	5,25	5,25	5,25	5,25	7,95	6,29	4,05	6,29	6,29	5,53	6,29	5,17	7,72	5,14	6,52	5,38	3,90	1,41	1,94	2,47	6,63	5,22	5,49	0,55
3,80	9,24	3,80	3,80	3,80	3,80	3,80	5,88	3,31	3,01	3,31	3,31	2,18	3,31	2,13	1,92	5,73	4,04	4,26	5,44	4,14	4,16	4,17	3,22	2,80	2,08	3,31
5,83	6,97	5,83	5,83	5,83	5,83	5,83	2,83	4,05	4,45	4,05	4,05	4,46	4,05	5,29	3,96	7,43	5,41	5,54	7,76	7,53	6,84	6,15	4,92	7,05	9,11	8,48
4,29	1,49	4,29	4,29	4,29	4,29	4,29	11,30	5,08	3,90	5,08	5,08	3,38	5,08	3,20	0,28	1,66	5,19	5,93	2,40	6,24	5,61	4,99	3,31	3,22	3,29	2,79

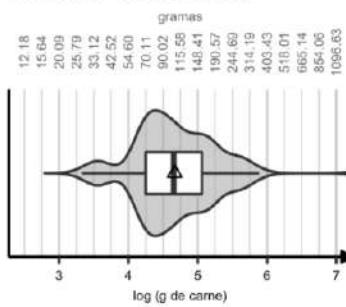
Nota: Equivalências dos números do cabeçalho das colunas: 11 (RO); 12 (AC); 13 (AM); 14 (RR); 15 (PA); 16 (AP); 17 (TO); 21 (MA); 22 (PI); 23 (CE); 24 (RN); 25 (PB); 26 (PE); 27 (AL); 28 (SE); 29 (BA); 31 (MG); 32 (ES); 33 (RJ); 35 (SP); 41 (PR); 42 (SC); 43 (RS); 50 (MS); 51 (MG); 52 (GO); 53 (DF)

Fonte: Elaboração própria (2022)

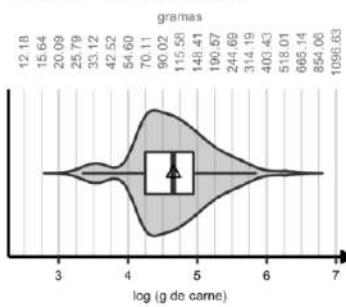
ANEXO III



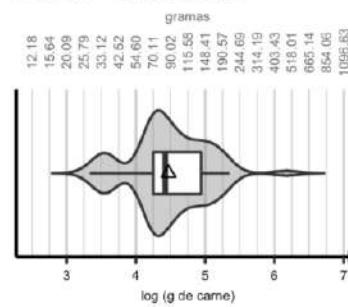
Norte / Urbano /
Homem / 40-59 anos / Jantar



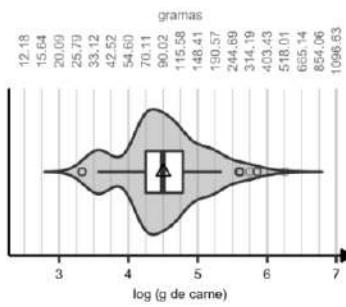
Norte / Urbano /
Homem / > 60 anos / Jantar



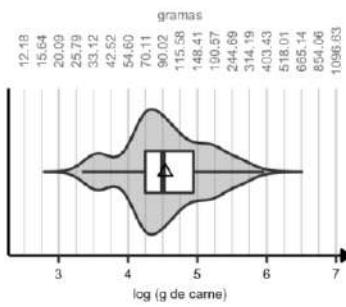
Norte / Urbano /
Homem / > 60 anos / Jantar



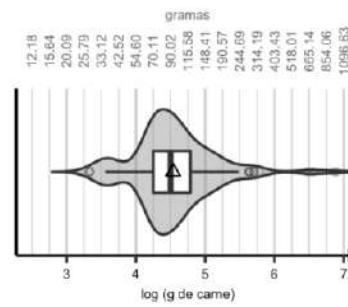
Norte / Rural /
Mulher / 18-39 anos / Almoço



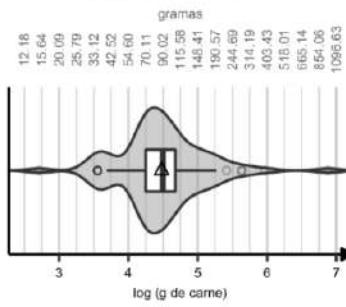
Norte / Rural /
Mulher / 18-39 anos / Jantar



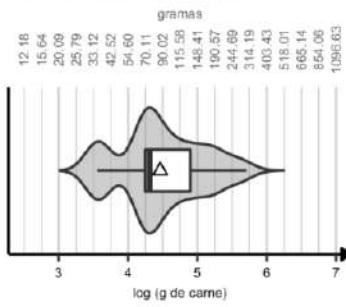
Norte / Rural /
Mulher / 40-59 anos / Almoço



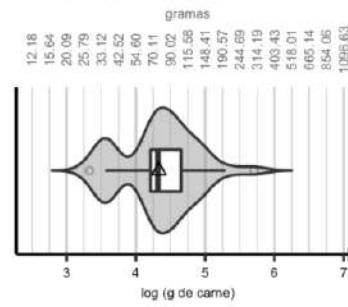
Norte / Rural /
Mulher / 40-59 anos / Jantar



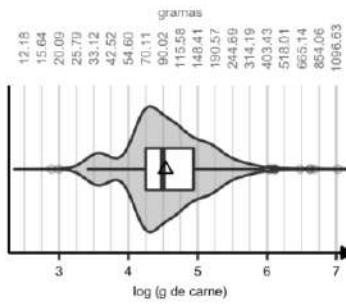
Norte / Rural /
Mulher / > 60 anos / Almoço



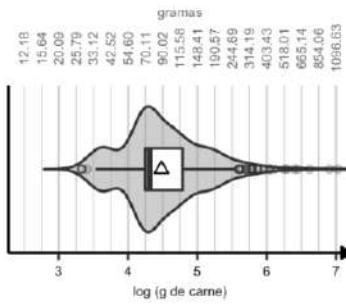
Norte / Rural /
Mulher / > 60 anos / Jantar



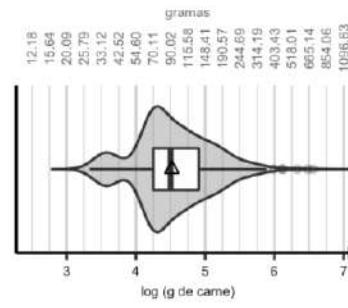
Nordeste / Urbano /
Homem / 18-39 anos / Almoço



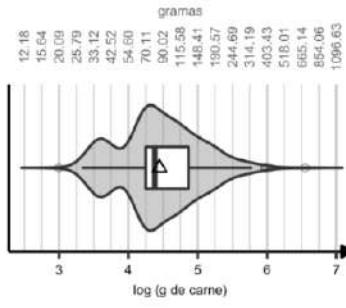
Nordeste / Urbano /
Homem / 18-39 anos / Jantar



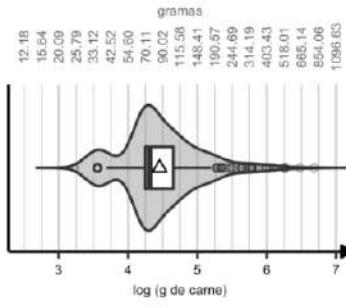
Nordeste / Urbano /
Homem / 40-59 anos / Almoço



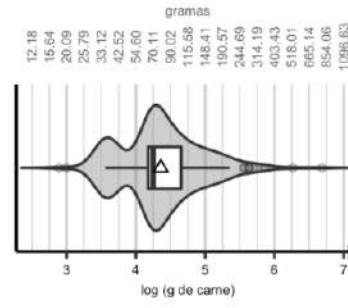
Nordeste / Urbano /
Homem / 40-59 anos / Jantar

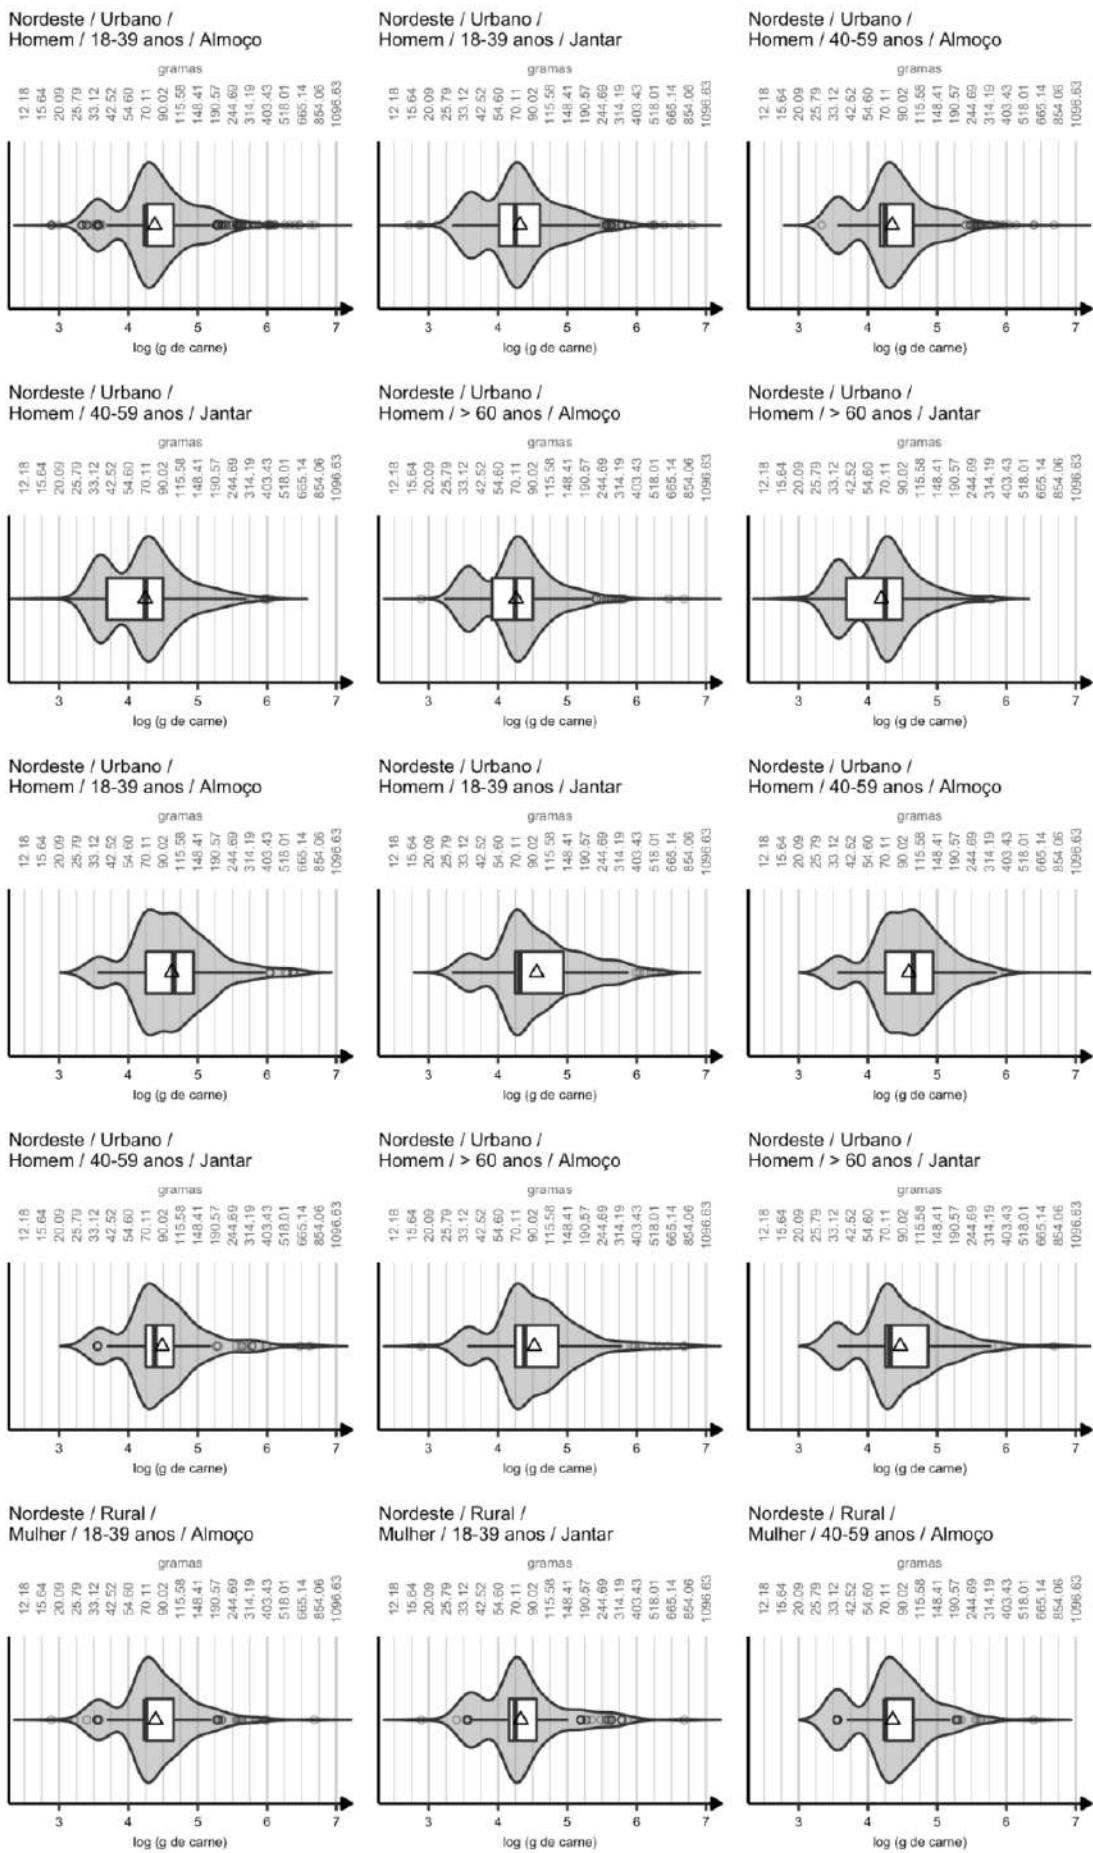


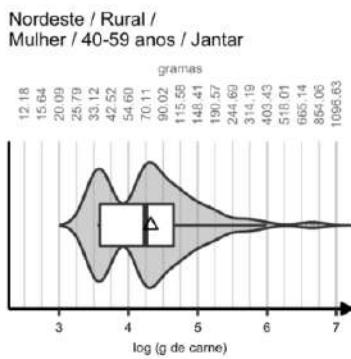
Nordeste / Urbano /
Homem / > 60 anos / Almoço



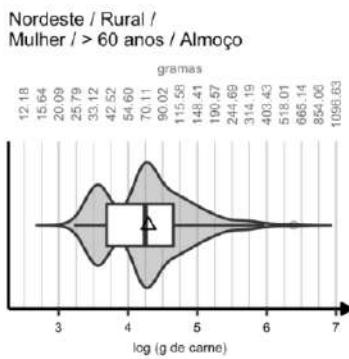
Nordeste / Urbano /
Homem / > 60 anos / Jantar



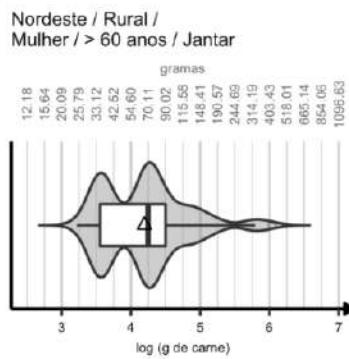




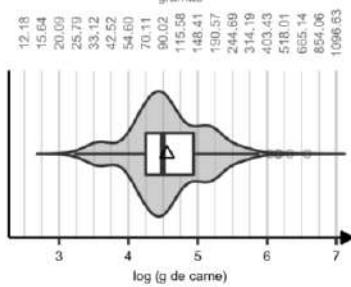
Sudeste / Urbano /
Homem / 18-39 anos / Almoço



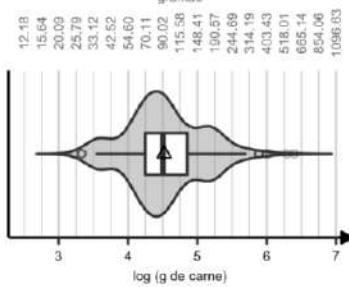
Sudeste / Urbano /
Homem / 18-39 anos / Jantar



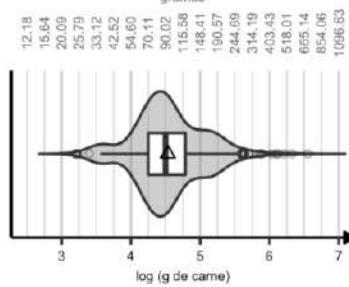
Sudeste / Urbano /
Homem / 40-59 anos / Almoço



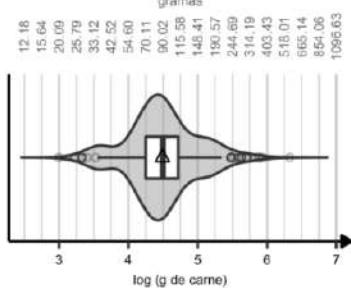
Sudeste / Urbano /
Homem / 40-59 anos / Jantar



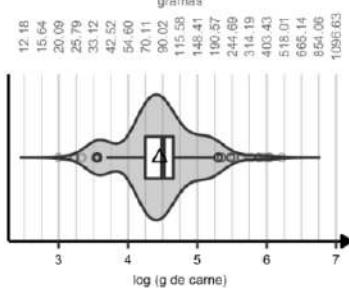
Sudeste / Urbano /
Homem / > 60 anos / Almoço



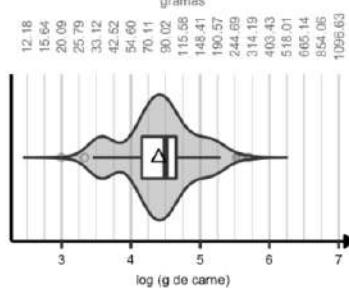
Sudeste / Urbano /
Homem / > 60 anos / Jantar



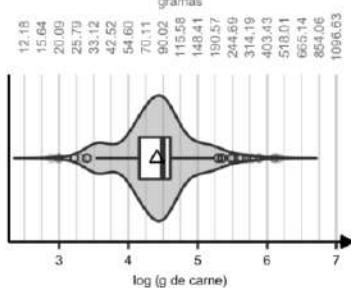
Sudeste / Urbano /
Homem / 18-39 anos / Almoço



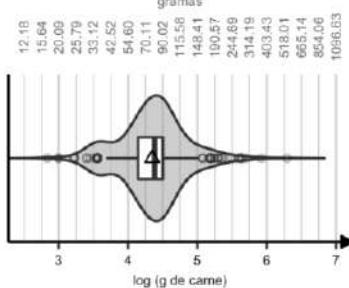
Sudeste / Urbano /
Homem / 18-39 anos / Jantar



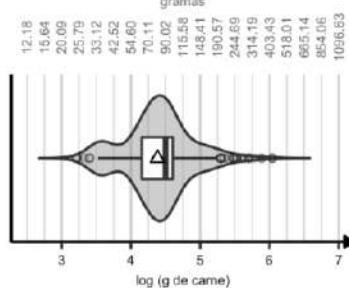
Sudeste / Urbano /
Homem / 40-59 anos / Almoço



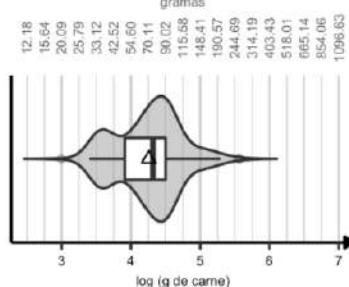
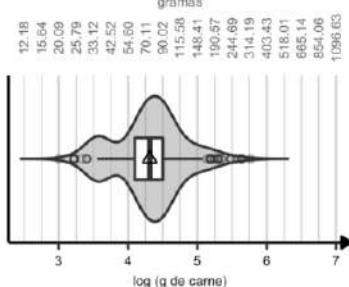
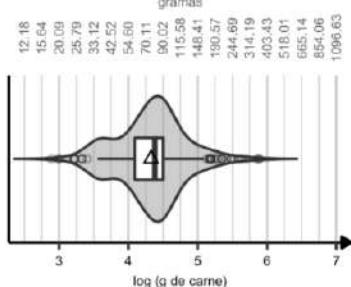
Sudeste / Urbano /
Homem / 40-59 anos / Jantar

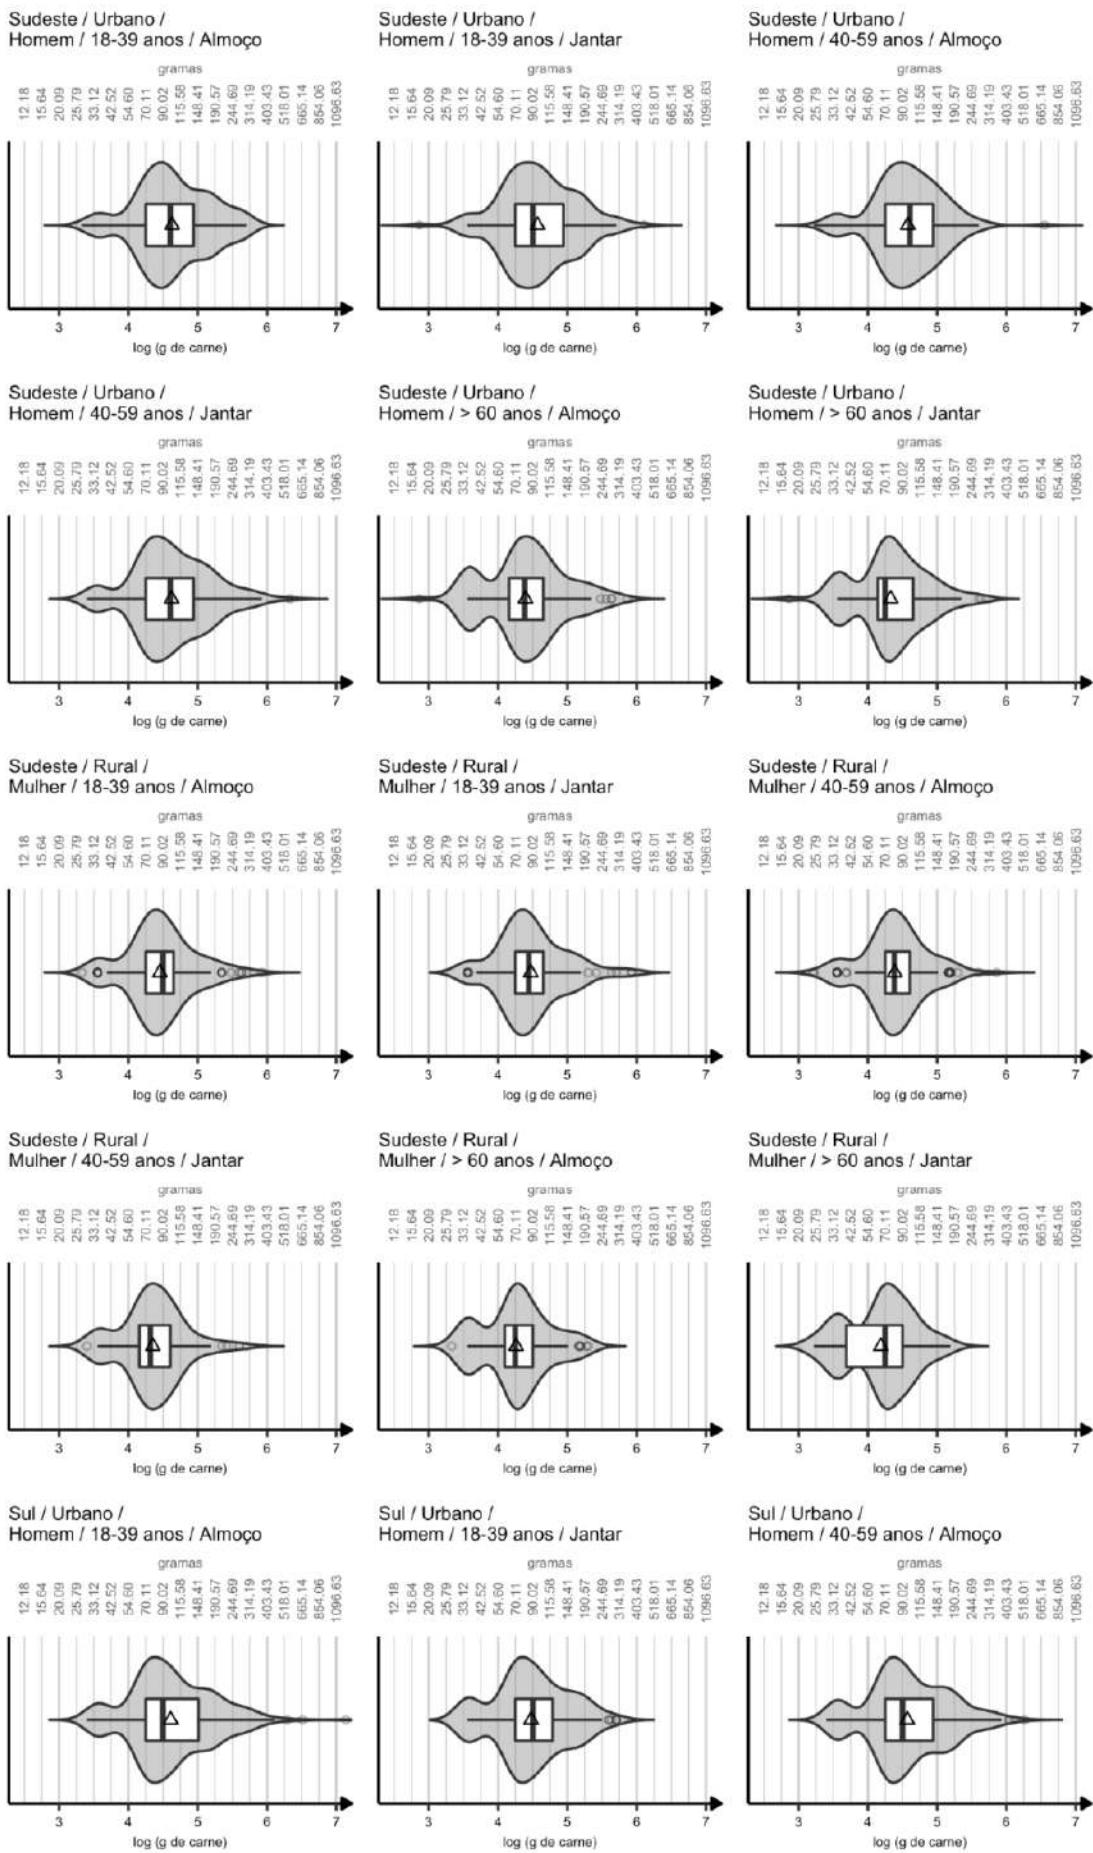


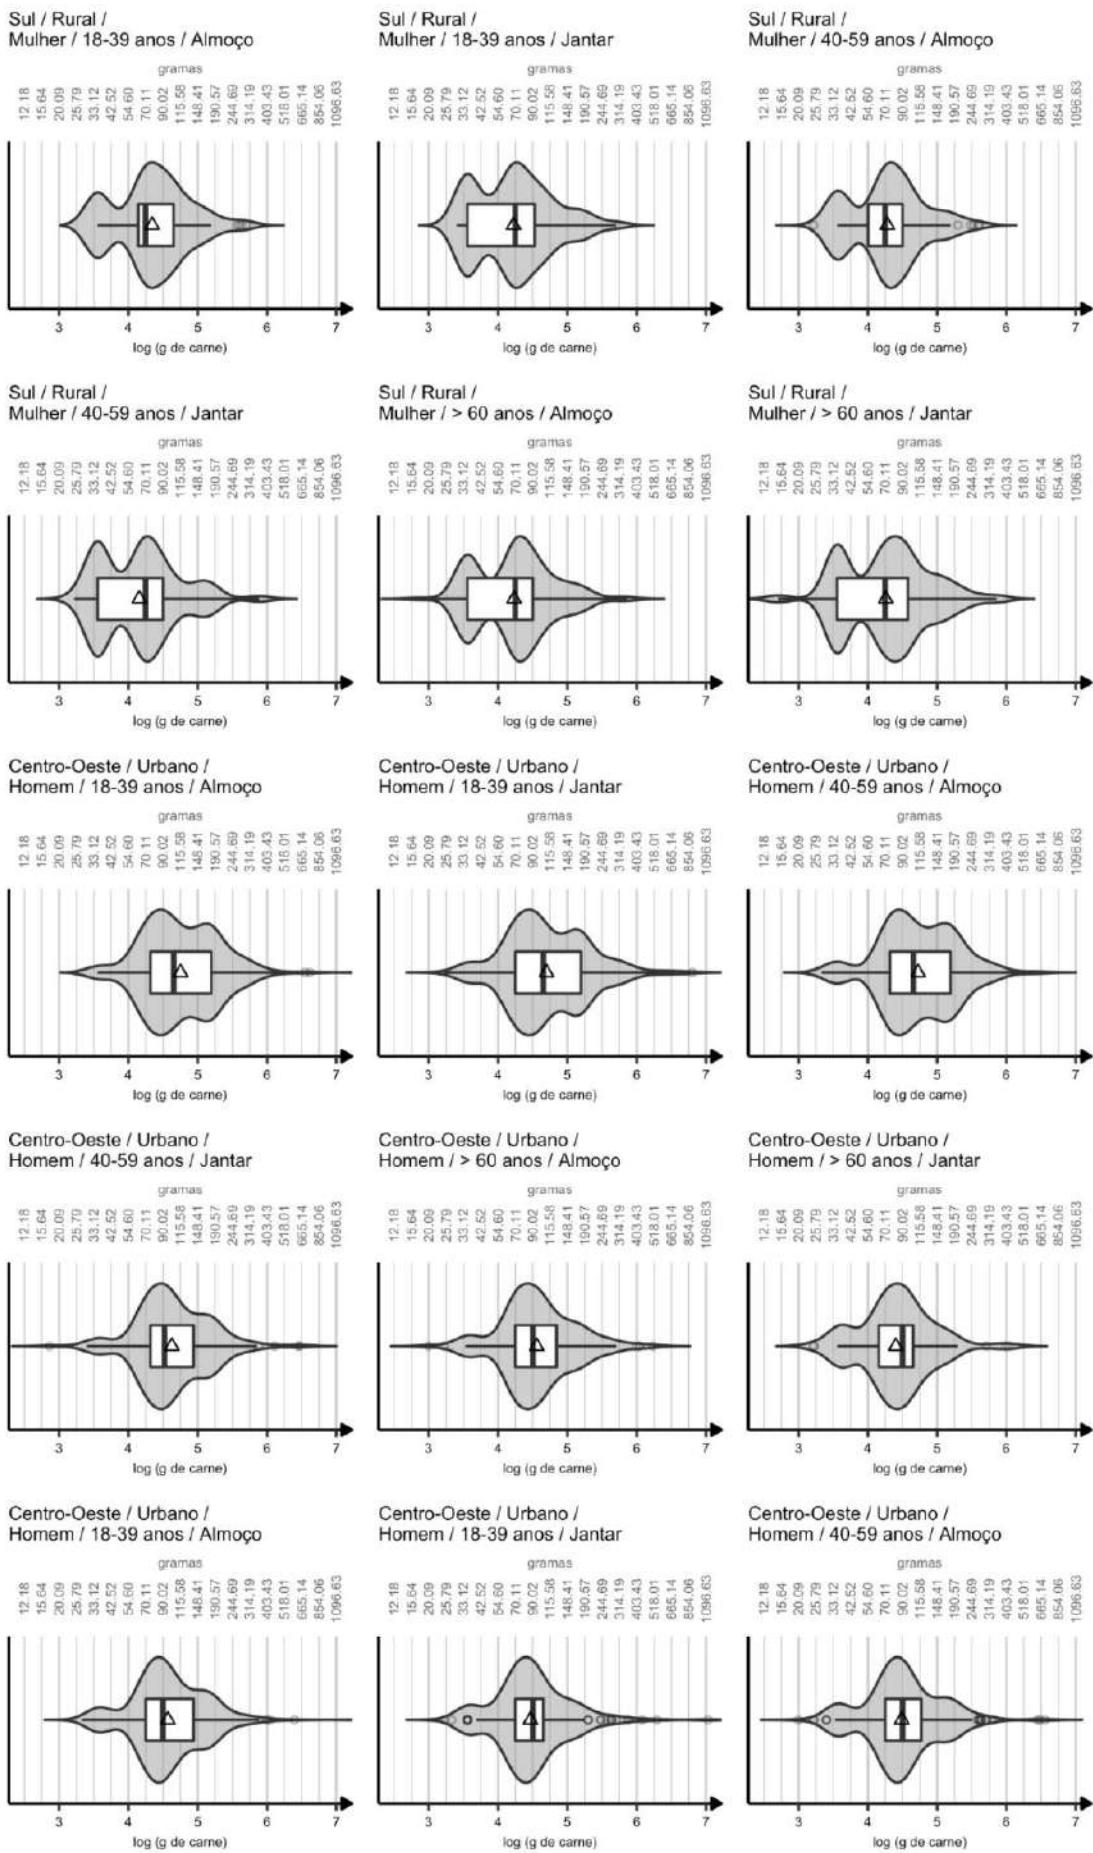
Sudeste / Urbano /
Homem / > 60 anos / Almoço

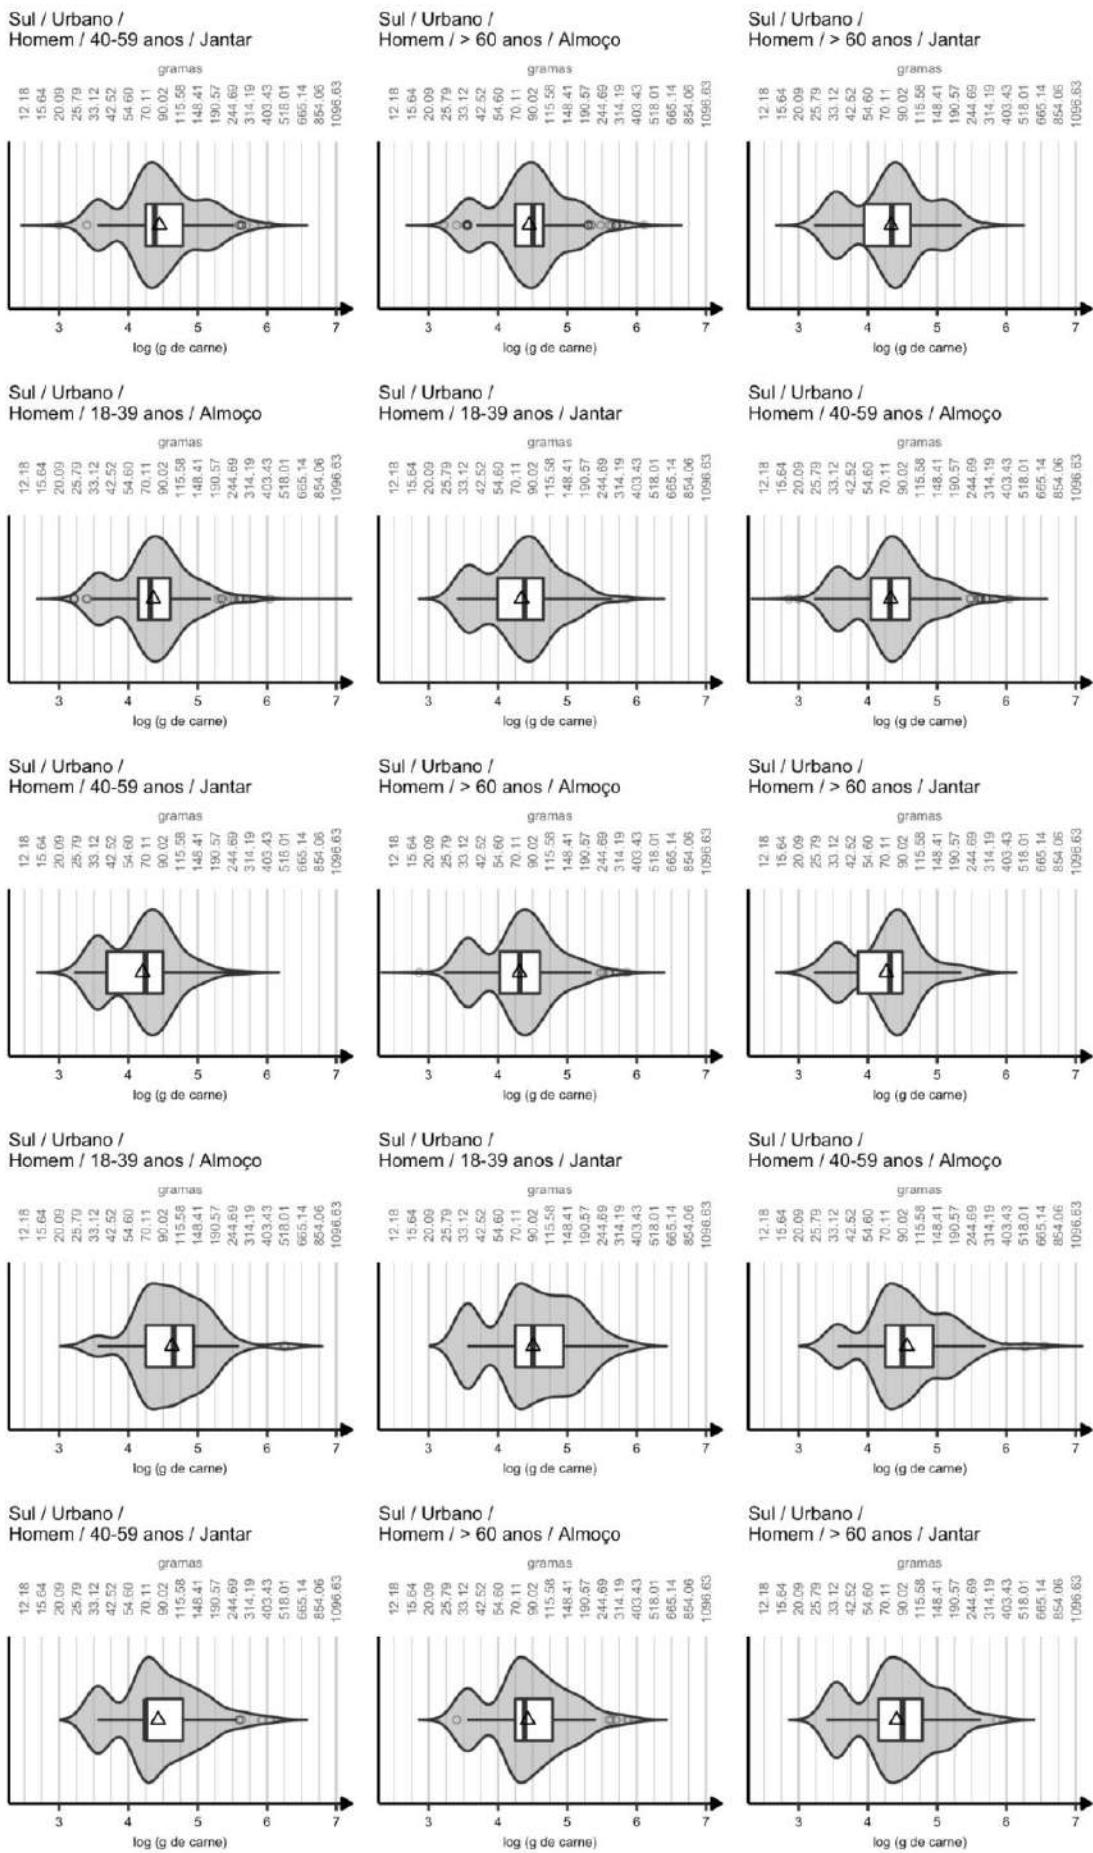


Sudeste / Urbano /
Homem / > 60 anos / Jantar









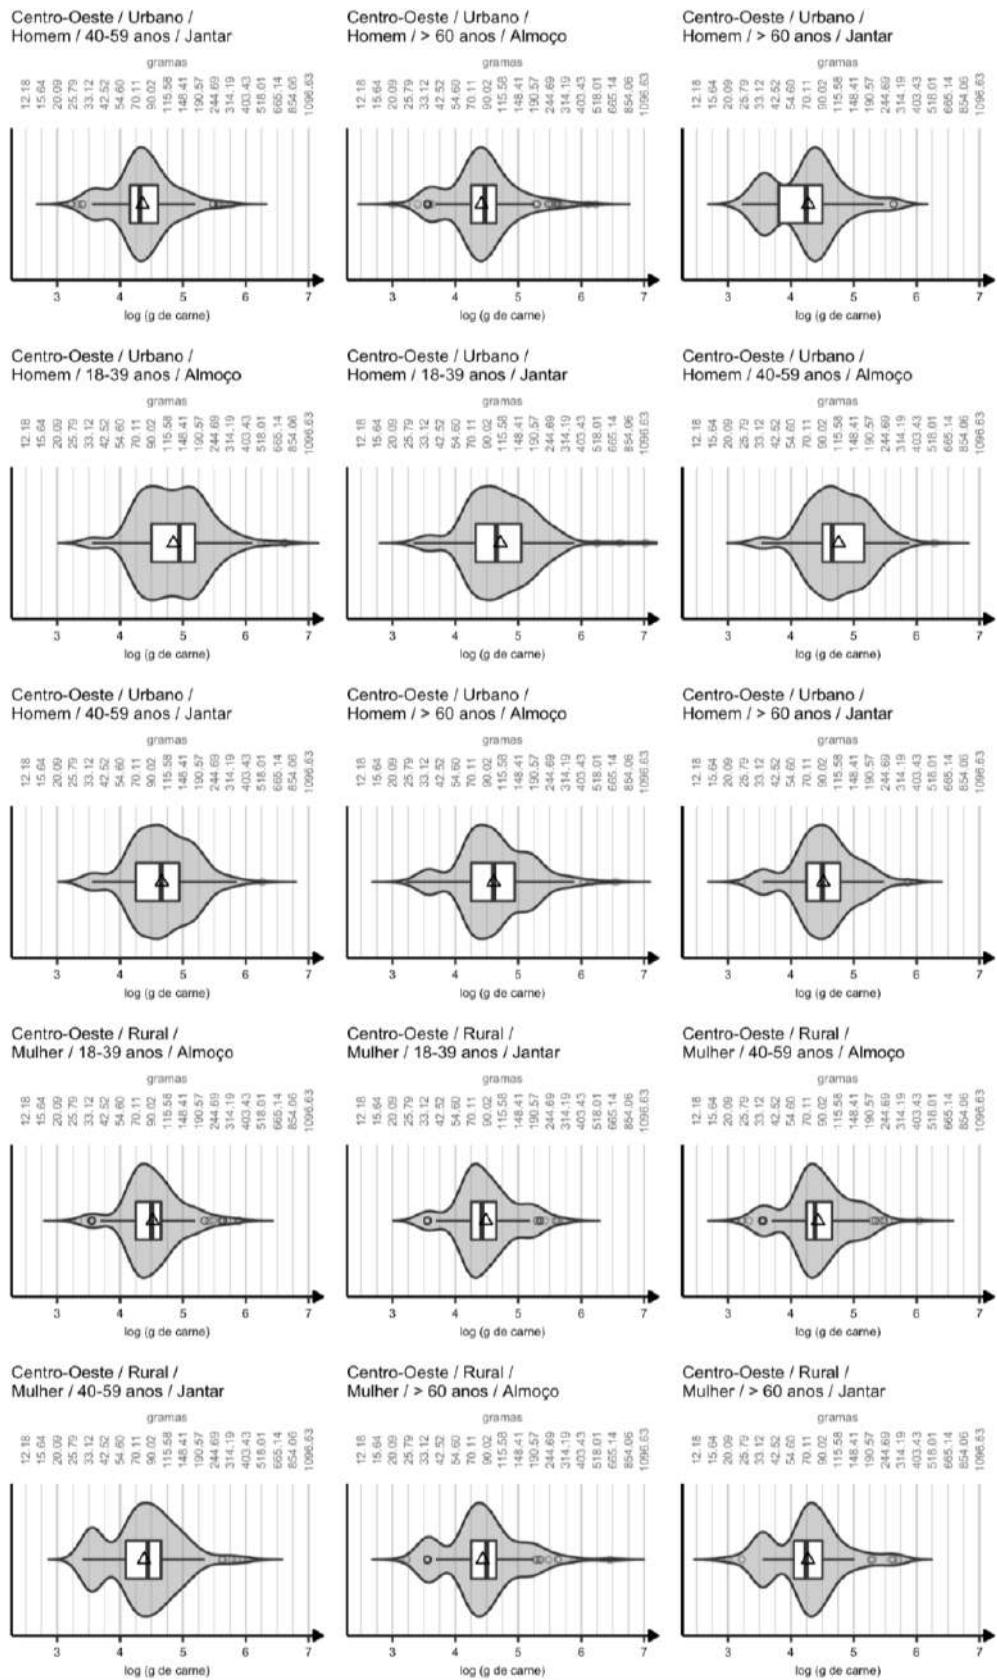


Figura 15: Distribuição da quantidade de carne bovina consumida por indivíduo em uma refeição considerando as variáveis macrorregião, situação de domicílio, gênero, faixa etária e tipo de refeição.

Fonte: Elaboração própria (2022)

ANEXO IV

Tabela 14: Tabela módulo 4 – Parâmetros das distribuições da quantidade de carne bovina consumida por indivíduo em uma refeição considerando as variáveis macrorregião, situação de domicílio, gênero, faixa etária e tipo de refeição

Perfil id	Média	Desvio Padrão	Média	Desvio Padrão
1111	4,736	0,541	4,613	0,550
1112	4,672	0,564	4,562	0,521
1113	4,537	0,522	4,470	0,546
1121	4,535	0,532	4,448	0,526
1122	4,484	0,524	4,372	0,496
1123	4,404	0,508	4,433	0,540
1211	4,780	0,566	4,648	0,586
1212	4,763	0,575	4,669	0,594
1213	4,656	0,529	4,471	0,545
1221	4,506	0,577	4,536	0,569
1222	4,539	0,575	4,479	0,615
1223	4,463	0,591	4,332	0,530
2111	4,537	0,540	4,480	0,578
2112	4,520	0,529	4,450	0,567
2113	4,454	0,549	4,360	0,576
2121	4,381	0,559	4,317	0,577
2122	4,351	0,532	4,244	0,551
2123	4,260	0,515	4,194	0,511
2211	4,626	0,575	4,556	0,626
2212	4,590	0,538	4,489	0,570
2213	4,524	0,608	4,469	0,590
2221	4,393	0,525	4,327	0,580
2222	4,359	0,542	4,322	0,665
2223	4,292	0,584	4,196	0,598
3111	4,559	0,518	4,520	0,540
3112	4,535	0,490	4,491	0,498
3113	4,455	0,513	4,404	0,490
3121	4,411	0,489	4,348	0,463
3122	4,385	0,471	4,327	0,479
3123	4,310	0,479	4,258	0,456
3211	4,631	0,527	4,569	0,532
3212	4,577	0,483	4,623	0,553
3213	4,395	0,570	4,330	0,520
3221	4,455	0,483	4,470	0,485
3222	4,388	0,445	4,352	0,443
3223	4,259	0,473	4,187	0,481
4111	4,611	0,590	4,475	0,528
4112	4,569	0,577	4,450	0,575

4113	4,448	0,549	4,335	0,558
4121	4,360	0,529	4,339	0,526
4122	4,329	0,546	4,203	0,478
4123	4,306	0,524	4,265	0,516
4211	4,629	0,499	4,503	0,621
4212	4,564	0,592	4,430	0,596
4213	4,427	0,568	4,417	0,586
4221	4,343	0,525	4,222	0,555
4222	4,281	0,516	4,157	0,570
4223	4,230	0,547	4,258	0,622
5111	4,753	0,536	4,699	0,580
5112	4,725	0,544	4,628	0,513
5113	4,557	0,519	4,403	0,515
5121	4,570	0,513	4,466	0,519
5122	4,487	0,531	4,357	0,468
5123	4,413	0,519	4,276	0,553
5211	4,848	0,534	4,717	0,541
5212	4,762	0,474	4,665	0,492
5213	4,607	0,557	4,516	0,489
5221	4,520	0,439	4,486	0,464
5222	4,430	0,499	4,384	0,556
5223	4,432	0,582	4,273	0,558

Nota: Perfil id identifica as variáveis dos agentes:

1º dígito = Macrorregião: 1 (Norte); 2 (Nordeste); 3 (Sudeste); 4 (Sul); 5 (Centro-Oeste)

2º dígito = Situação de domicílio: 1 (Urbano); 2 (Rural)

3º dígito = Gênero: 1 (Homem); 2 (Mulher)

4º dígito = Grupo de idade: 1 (18 a 39 anos); 2 (40 a 59 anos); 3 (60 a 98 anos)

Fonte: Elaboração própria (2022)