

UNIVERSIDADE FEDERAL DE SANTA CATARINA  
CENTRO SOCIOECONÔMICO  
DEPARTAMENTO DE ECONOMIA E RELAÇÕES INTERNACIONAIS  
CURSO DE CIÊNCIAS ECONÔMICAS

Natalia Mayumi Von Zuccalmaglio

**O impacto das mudanças climáticas na mortalidade infantil:**

Uma análise do Brasil entre 1997 e 2022

Florianópolis

2024



Natalia Mayumi Von Zuccalmaglio

**O impacto das mudanças climáticas na mortalidade infantil:**

Uma análise do Brasil entre 1997 e 2022

Trabalho Conclusão do Curso de Graduação em Ciências Econômicas do Centro Socioeconômico da Universidade Federal de Santa Catarina como requisito parcial para a obtenção do título de Bacharela em Ciências Econômicas

Orientador: Prof. Dr. Guilherme de Oliveira.

Florianópolis

2024

## Ficha de identificação da obra

Von Zuccalmaglio, Natalia Mayumi

O impacto das mudanças climáticas na mortalidade infantil: Uma análise do Brasil entre 1997 e 2022 / Natalia Mayumi Von Zuccalmaglio ; orientador, Guilherme de Oliveira, 2024.

68 p.

Trabalho de Conclusão de Curso (graduação) - Universidade Federal de Santa Catarina, Centro Socioeconômico, Graduação em Ciências Econômicas, Florianópolis, 2024.

Inclui referências.

1. Ciências Econômicas. 2. Meio ambiente .3. Economia Ambiental. 4. Mudança Climática. 5. Mortalidade Infantil. I. Oliveira, Guilherme de. II. Universidade Federal de Santa Catarina. Graduação em Ciências Econômicas. III. Título.

Natalia Mayumi Von Zuccalmaglio

**O impacto das mudanças climáticas na mortalidade infantil: Uma análise do Brasil  
entre 1997 e 2022**

O presente Trabalho de Conclusão de Curso foi avaliado e aprovado pela banca  
examinadora composta pelos seguintes membros:

Prof. Guilherme Valle Moura, Dr.  
Instituição UFSC

Profª. Liana Bohn, Dra.  
Instituição UFSC

Certifico que esta é a **versão original e final** do Trabalho de Conclusão de Curso  
que foi julgado adequado para obtenção do título de Bacharel em Economia por mim e  
pelos demais membros da banca examinadora.

---

Prof. Guilherme De Oliveira, Dr.  
Orientador

Florianópolis, 2024.

## AGRADECIMENTOS

Em uma noite que eu estava caminhando pela faculdade na chuva, eu encontrei com uma pessoa que me disse as seguintes palavras “A gente só sente saudades do que valeu a pena”. É o tipo de frase clichê que sempre é bom ser revivido naqueles momentos que tudo que se pensa é o que se foi e não o que ficou. Por isso, quero agradecer em primeiro lugar a minha universidade, que me formou acima de tudo como pessoa e que hoje é uma parte do que eu sou.

Meus sinceros agradecimentos aos meus pais, Geraldo Von Zuccalmaglio e Norma Megumi Arata, que em todos os seus erros nunca foram menos do que os melhores pais que eu algum dia poderia querer.

Agradeço aos professores que me ensinaram a se importar, são eles: Guilherme Valle Moura; Guilherme de Oliveira; Dominik Hartmann; Fábio Pádua dos Santos e Nildo Ouriques.

As minhas amigas, não posso expressar o valor que dou a vocês, quero mencionar as seguintes: Ane Macedo; Gi Aguirre; Lê Alves; Lê Beck e Sabrina. Aos meus amigos: Matheus Schulz; Nicholas Martins; Davy Balen e Gabriel Volpi, eu tenho um imenso carinho por vocês.

Aos economistas/chefes/mentores e grandes inspirações, saibam que eu nunca poderia esperar ser tão bem acolhida como eu fui e sou ao poder ter a chance de aprender com vocês, meu especial abraço para: Camila Moraes; Marcelo Masera de Alburquerque; João Luiz Toogood Pitta e Tainara Venâncio.

Obrigada por tudo,

Natalia Mayumi Von Zuccalmaglio

*“Suffering and tragedy and folly will not disappear in a purified world. They are part of humanity. That is why even in a world of suffering there can also be joy and shining light”.* (NAUSICÄÄ of The Valley of Whe Wind, Direção: Hayao Miyazaki, 1984)



## RESUMO

Esta monografia tem como objetivo geral avaliar o impacto das mudanças climáticas na mortalidade infantil brasileira entre os anos de 1997 e 2022. As mudanças climáticas geram diversas externalidades negativas sendo um desafio a ser enfrentado. Essas consequências são especialmente prejudiciais sobre as crianças e refletem no desenvolvimento econômico pela perda de capital humano. A amostra do estudo vem dos registros de óbitos infantis do Sistema de Saúde Único brasileiro, ao qual foram realizados tratamentos baseados na literatura econométrica e de economia ambiental em busca de construir um experimento quase-aleatório robusto e representativo do país. É feita uma revisão de literatura para entender o estado da arte nessa área recente da economia e situar o trabalho das diferentes camadas que formam o ramo. Para efetivamente estimar o impacto das mudanças climáticas, a escolha foi o uso do índice SPEI e do estimador Logit, regressão logística, por conta que a amostra do SUS é desagregada ao nível do indivíduo. Ademais, foi definido um modelo onde a variável dependente é a mortalidade infantil medida semanalmente, ou seja, valores em 0 nas semanas que a criança permanece viva e valores em 1 na semana de óbito e estimado para o Brasil e Grandes Regiões. Os resultados da identificação dos parâmetros se mostraram significantes ao longo das diferentes estratégias adotadas e foi constatado um efeito agravante na mortalidade infantil em períodos de seca no país.

**Palavras-chave:** Meio ambiente; Mudança Climática; Mortalidade Infantil; Economia Ambiental; Capital Humano

## ABSTRACT

This monograph has the general objective of evaluating the impact of climate change on Brazilian child mortality between 1997 and 2022. Climate change generates several negative externalities and is a challenge to be faced. These consequences are especially harmful to children and reflect on economic development through the loss of human capital. The study sample comes from the records of infant deaths from the Brazilian Unified Health System, to which treatments were carried out based on econometric and environmental economics literature in an attempt to build a robust and representative quasi-random experiment for the country. A literature review is carried out to understand the state of the art in this recent area of economics and to situate the work of the different layers that make up the branch. To effectively estimate the impact of climate change, the choice was to use the SPEI index and the Logit estimator, logistic regression, because the SUS sample is disaggregated at the individual level. Furthermore, a model was defined where the dependent variable is infant mortality measured weekly, that is, values of 0 in the weeks that the child remains alive and values of 1 in the week of death and estimated for Brazil and Major Regions. The results of identifying the parameters proved to be significant across the different strategies adopted and an aggravating effect on infant mortality during periods of drought in the country was found.

**Keywords:** Environment; Climate Change; Infant mortality; Environmental Economics; Human Capital

**LISTA DE FIGURAS**

Figura 1 -Mortalidade por 1000 nascimentos (crianças menores que 5 anos) .	16
Figura 2 – Estudos relacionados à área de economia ambiental .....	20
Figura 3 - Média SPEI por estado .....	27
Figura 4 – Parâmetros do Logit Mortalidade Infantil.....	39
Figura 5- Efeitos parciais médios por conjunto racial.....	43
Figura 6 - Regressão Norte.....	56
Figura 7 - Regressão Nordeste .....	58
Figura 8 - Regressão Centro-Oeste .....	60
Figura 9 - Regressão Sudeste .....	62
Figura 10 - Regressão Sul .....	64

**LISTA DE TABELAS**

Tabela 1 - SPEI por PIB <i>per capita</i> 2021.....	27
Tabela 2 – Descrição das variáveis qualitativas da amostra .....	29
Tabela 3 – Estatísticas descritivas das variáveis quantitativas.....	30
Tabela 4 - Teste de Chow de Mudança Estrutural .....	32
Tabela 5 - Médias das variáveis entre os primeiros e últimos 10 anos .....	33
Tabela 6 - Proporção das características entre períodos.....	34
Tabela 7 - Equações Estimadas .....	40
Tabela 8 - Efeitos Parciais Médios.....	41
Tabela 9 - Distribuição Racial das Grandes Regiões .....	42
Tabela 10 – Resultados por Grandes Regiões .....	44

**LISTA DE ABREVIATURAS E SIGLAS**

IBGE - Instituto Brasileiro de Geografia e Estatística

SUS – Sistema de Saúde Único

SPEI – Standard Precipitation and Evapotranspiration Index

ONU – Organização das Nações Unidas

WHO – Organização Mundial da Saúde

EPM – Efeito Parcial Médio

## SUMÁRIO

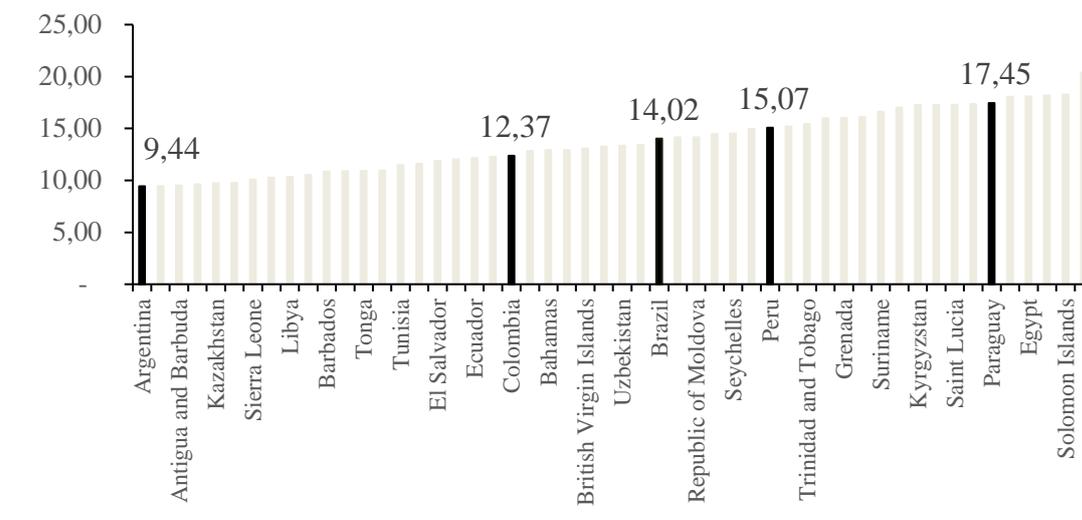
<b>1</b>	<b>INTRODUÇÃO .....</b>	<b>15</b>
1.1	OBJETIVOS .....	18
1.1.1	<b>Objetivo Geral.....</b>	<b>18</b>
1.1.2	<b>Objetivos Específicos .....</b>	<b>18</b>
1.2	DELINEAMENTO DA PESQUISA .....	18
<b>2</b>	<b>LITERATURA RELACIONADA .....</b>	<b>20</b>
<b>3</b>	<b>ESTRATÉGIA DE IDENTIFICAÇÃO.....</b>	<b>25</b>
3.1	DADOS .....	28
3.2	AMOSTRA.....	31
<b>3.2.1</b>	<b>Agrupamento Independente de Cortes Transversais.....</b>	<b>32</b>
3.3	EFEITOS FIXOS .....	35
3.4	REGRESSÃO LOGÍSTICA.....	36
<b>3.4.1</b>	<b>Efeitos Parciais Médios .....</b>	<b>37</b>
<b>4</b>	<b>RESULTADOS .....</b>	<b>39</b>
4.1	GRANDES REGIÕES .....	44
<b>5</b>	<b>CONCLUSÕES.....</b>	<b>47</b>
	<b>REFERÊNCIAS .....</b>	<b>49</b>
	<b>APÊNDICE A – EL COLOSO.....</b>	<b>53</b>
	<b>APÊNDICE B – FORMUÁRIO SUS.....</b>	<b>54</b>
	<b>APÊNDICE C – REGRESSÕES GRANDES REGIÕES.....</b>	<b>56</b>
	<b>APÊNDICE D – CÓDIGOS PYTHON .....</b>	<b>66</b>

## 1 INTRODUÇÃO

O que podem adicionar os economistas à uma área de estudo já tão sufocada? Essa foi a pergunta que Zivin e Neidell (2013) fizeram em seu artigo “Meio Ambiente, Saúde e Capital Humano”. As mudanças climáticas se tornaram uma ameaça a humanidade e os danos potenciais que decorrem desse fenômeno são observados em todo o planeta (VICENTE-SERRANO; BEGUERÍA; LÓPEZ-MORENO, 2010), entretanto, elas não são uniformes. Essas consequências apresentam heterogeneidade espacial e variam em intensidade conforme características socioeconômicas dos diferentes grupos populacionais (BROOKS; DONOVAN, 2020; CURRIE; VOORHEIS; WALKER, 2023). Assim, junto ao ideal de justiça ambiental, que, por definição, refere-se ao “tratamento justo e à participação significativa de todas as pessoas, independentemente de raça, cor, nacionalidade ou renda, no desenvolvimento, implementação e aplicação de leis, regulamentos e políticas ambientais”(EPA, 2024), reforçando a importância da fomentação de pesquisas que avaliem os efeitos sobre a população.

Ao analisar o Brasil, enquanto país em desenvolvimento, observa-se persistentes violações de direitos humanos universais, tal qual, o direito à vida, por conta sua formação em que tem em suas raízes a profunda desigualdade socioeconômica. Embora o país tenha diminuído sua taxa de mortalidade infantil devido a melhorias no saneamento básico, acesso a vacinação e serviços de saúde, ainda existe uma disparidade entre as regiões e populações que compõem esse país (CONFALONIERI; MARINHO; RODRIGUEZ, 2009). A Figura 1 apresenta as taxas de mortalidade por 1.000 nascimentos para crianças menores de cinco anos de idade, em que é possível comparar os países latinos e países com taxas similares a do Brasil, tais como, Argentina e Colômbia, nisso é evidenciado que o Brasil ainda permanece apresentando taxas elevadas, o que reforça a necessidade de esforços para mitigar essas desigualdades.

**Figura 1 -Mortalidade por 1000 nascimentos (crianças menores que 5 anos)**



Fonte: Elaboração própria a partir de dados da WHO

Na região das Américas, cerca de 100.000 crianças menores que cinco anos morrem todos os anos devido a fatores ambientais (FROES ASMUS et al., 2016). O caso brasileiro é particularmente delicado, pois devido ao seu tamanho e diversos efeitos do aquecimento global, o país acaba por expor suas crianças a uma gama de perigos (CONFALONIERI; MARINHO; RODRIGUEZ, 2009). Além disso, as mudanças naturais do clima ocorreram, ao longo da formação da Terra, pelas alterações dos ecossistemas, mas com a expansão das atividades humanas e as consequências negativas sobre o clima, outros agravantes surgem ou são potencializados em decorrência do aumento da temperatura, como uma maior propensão à propagação de doenças, tais quais malária e leishmaniose, exponenciando os prejuízos à essa população (PATZ et al., 2000).

Este estudo visa contribuir para a crescente área de estudo ao investigar os impactos das mudanças climáticas na mortalidade infantil no Brasil. Isso só é possível pelo avanço no processamento de dados climáticos em larga escala que impulsiona o desenvolvimento de uma literatura empírica voltada a compreensão desse desastre. Autores como Currie, Neidell e Schmieder (2009); Zivin e Neidell (2013) e Pereda, Menezes e Alves (2014) exploram esse tópico em populações vulneráveis, com particular ênfase na saúde infantil.

Currie (2020) afirma que a riqueza é “um recurso valioso de um jeito particular”. A autora menciona que nos estudos iniciais, o bem-estar infantil tinha valor como um insumo determinante do bom desenvolvimento acadêmico, porém, atualmente as pesquisas condicionam diretamente com a formação de capital humano, insumo de

crescimento econômico, com uma boa qualidade na saúde da criança. Em seus estudos, como “*Child Health as Human Capital*”(CURRIE, 2020) e “*Air Pollution and Infant Health: Lessons from New Jersey*”(CURRIE; NEIDELL; SCHMIEDER, 2009), Currie evidencia como a exposição à poluição atmosférica pode comprometer significativamente os resultados de saúde infantil. Ela demonstra que a poluição não só aumenta a mortalidade infantil, mas também prejudica o desenvolvimento cognitivo e físico das crianças, criando desigualdades que se perpetuam por toda a vida.

Pereda, Menezes e Alves (2014) reforçam essa perspectiva ao examinar como a poluição no ar e as mudanças climáticas aumentam a mortalidade infantil no país. Eles destacam que essas condições extremas, como ondas de calor e chuvas intensas, estão correlacionadas ao aumento de doenças respiratórias e infecciosas. A combinação de fatores socioeconômicos e ambientais torna a questão ainda mais urgente para a formulação de políticas públicas.

As análises de mudanças climática só são possíveis com formas de mensuração, uma delas é o índice de precipitação e evapotranspiração (SPEI). Ele é um indicador relevante, pois, captura a relação entre a precipitação e o potencial de evapotranspiração, permitindo a avaliação de eventos extremos como secas e chuvas excessivas. Ao integrar informações sobre precipitação e temperatura, o SPEI fornece uma medida do comportamento do clima da região, uma variável essencial para a compreensão do impacto das alterações climáticas na saúde e no bem-estar de populações vulneráveis.

No Brasil, Albert, Bustos e Ponticelli (2021) utilizam o SPEI para também contribuem para a discussão ao explorar a relação entre o clima e o desenvolvimento econômico, mostrando como os eventos climáticos têm efeitos na realocação de firmas e trabalhadores. Sua pesquisa destaca que, em países em desenvolvimento como o Brasil, a interação entre vulnerabilidades econômicas e mudanças climáticas amplifica o impacto negativo sobre as crianças, particularmente nas regiões rurais, onde a dependência de condições climáticas para a agricultura expõe as famílias a maiores riscos.

Esse nível de relevância que se dá a saúde infantil mostra como proporcionar um bom ambiente para o desenvolvimento do futuro da população é uma questão não só benéfica os cidadãos em termos sociais, mas um catalizador vital para o enriquecimento das nações. Assim, o destaque para o deterioramento das condições climáticas no Brasil pode significar um agravante social ao amplificar desigualdades existentes e afetar

negativamente o capital humano do país, corroborando para a estagnação econômica que é enfrentada pelo Brasil.

## 1.1 OBJETIVOS

A presente seção apresenta os objetivos da pesquisa.

### 1.1.1 Objetivo Geral

Analisar o impacto das mudanças climáticas na mortalidade infantil no Brasil entre 1997 e 2022.

### 1.1.2 Objetivos Específicos

Como objetivos específicos citam-se:

- I. Revisar a literatura relacionada ao tema de mudança climática, capital humano e preservação da saúde infantil.
- II. Identificar, coletar e tratar dados secundários para a avaliação preliminar do impacto das mudanças climáticas e mortalidade infantil.
- III. Estimar, via regressão logística, o impacto das mudanças climáticas na mortalidade infantil entre 1997 e 2022 para o Brasil.

## 1.2 DELINEAMENTO DA PESQUISA

O delineamento metodológico da pesquisa descreve a estrutura pela qual foi baseada a formação e caracterização da presente monografia.

Primeiramente, o nível de complexidade relacionado é visto como descritivo, pois, para Gil (2002), pesquisas descritivas são aquelas cujo objetivo é a descrição de relações entre variáveis de determinada população. Isso ocorre no trabalho por meio da compreensão entre as variáveis climáticas, socioeconômicas e de saúde pública.

A seguir, o método de pesquisa adotado foi o indutivo. Conforme descrito por Lakatos e Marconi (2003, p.86), "indução é um processo mental por intermédio do qual,

partindo de dados particulares, suficientemente constatados, infere-se uma verdade geral ou universal, não contida nas partes examinadas". Dessa forma, os argumentos indutivos têm como objetivo levar a conclusões cujo conteúdo é mais amplo do que o das premissas em que se baseiam. Cervo e Bervian (1978, p. 25) apontam que "pode-se afirmar que as premissas de um argumento indutivo correto sustentam ou atribuem certa verossimilhança à sua conclusão. Assim, quando as premissas são verdadeiras, o melhor que se pode dizer é que a sua conclusão é, provavelmente, verdadeira".

Dessa maneira, aplicado ao processo da análise do tema, o levantamento de dados secundários e estimadores econométricos em busca de auferir relações causais entre as variáveis estudadas enquadra essa pesquisa no método de indução (LAKATOS, MARCONI; 2003).

Do mesmo pensamento que as descrições anteriores, a lógica de identificação do caráter do trabalho é familiar ao tipo aplicado, esse refere-se ao ideal de gerar conhecimento por meio da aplicação da teoria em cenários práticos, ou seja, expor a teoria aos fenômenos e situações apresentados no Brasil durante o período de estudo, buscando compreender e gerar respostas à teoria. Quanto à abordagem quantitativa, essa surge ao utilizar dados provenientes de bases públicas, relacionando-os por meio de ferramentas econométricas. Esse tipo de abordagem também confere ênfase à replicabilidade dos resultados, garantindo objetividade (LAKATOS, MARCONI; 2003).

As formas de operacionalização do estudo consistem em uma revisão teórica e no levantamento de dados secundários. A pesquisa bibliográfica foi realizada pelas seguintes plataformas acadêmicas: JSTOR, Mendeley, Elsevier e CAPES. As palavras-chave utilizadas foram extraídas, majoritariamente, do título do trabalho ou de artigos base dessa área de estudo, como: "Mudança Climática", "Mortalidade", "Mortalidade Infantil", "Brasil", "Meio Ambiente" e "Capital Humano".

Em relação ao levantamento de dados secundários, as bases utilizadas foram: SIDRA/IBGE, SPEI e DATASUS. A descrição detalhada do procedimento será discutida na seção 3.1 - DADOS.

Esse delineamento foi escolhido para que o tema fosse abarcado com robustez e clareza em seus passos. É importante que o processo metodológico seja compreensível, replicável e objetivo para os leitores que visam explorar o tema dos impactos da mudança climática na mortalidade infantil.

## 2 LITERATURA RELACIONADA

O objetivo deste capítulo é apresentar uma breve revisão da literatura empírica relacionada à pesquisa. O foco é explicar e situar os estudos importantes que embasaram a estratégia deste estudo. Portanto, é apresentado na Figura 2 os principais estudos a serem analisados ao longo da seção de literatura relacionada.

**Figura 2 – Estudos relacionados à área de economia ambiental**

<b>Título</b>	<b>Autores</b>	<b>Área</b>	<b>Resultados</b>
A multiscale drought index sensitive to global warming: The standardized precipitation evapotranspiration index	Sergio M. Vicente-Serrano, Santiago Beguería, Juan I. López-Moreno	Climatologia e Recursos Hídricos	Proposição de um índice para monitorar secas sensível ao aquecimento global.
Racial Disparities in the Health Effects From Air Pollution	Kenneth Gillingham, Pei Huang	Saúde Pública e Meio Ambiente	Evidências de disparidades raciais nos impactos de saúde causados pela poluição do ar.
Sorting over flood risk and implications for policy reform	Laura A. Bakkensen, Lala Ma	Economia Ambiental e Políticas Públicas	Identificação de padrões de localização relacionados ao risco de inundação e sugestões de reforma política.
Disproportionate exposure to urban heat island intensity	Angel Hsu, Glenn Sheriff, Tirthankar Chakraborty, Diego	Ciências Ambientais e Urbanismo	Análise de populações desproporcionalmente expostas às ilhas de calor urbano.
The impact of air pollution on infant mortality	Kenneth Y. Chay, Michael Greenstone	Economia da Saúde	Avaliação de impacto entre poluição do ar e mortalidade infantil.
An assessment of the benefits of air pollution control	Theodore J. Joyce, Michael Grossman, Fred Goldman	Economia Ambiental	Benefícios econômicos e de saúde do controle da poluição do ar.
Governing the Commons	Elinor Ostrom	Economia e Gestão de Recursos Naturais	Apresenta princípios para a gestão sustentável de recursos de uso comum.
Small is Beautiful: Economics as If People Mattered	E.F. Schumacher	Economia Sustentável	Defesa de uma economia centrada nas pessoas e no meio ambiente e não no crescimento econômico.
What Caused Racial Disparities in Particulate Exposure to Fall?	Janet Currie, John Voorheis, Reed Walker	Economia Ambiental e Justiça Social	Impactos do Clean Air Act na redução de disparidades raciais na exposição a partículas.
William D. Nordhaus - Prize Lecture: Climate change: The Ultimate Challenge for Economics	William D. Nordhaus	Economia do Clima	Discussão sobre os desafios do aquecimento global para a economia.
Effects of environmental change on emerging parasitic diseases	Jonathan A. Patz, Thaddeus K. Graczyk, Nina Geller, Amy Y. Vittor	Saúde Ambiental	Impacto das mudanças ambientais na proliferação de doenças parasitárias.
Public health vulnerability to climate change in Brazil	U. E.C. Confalonieri, D. P. Marinho, R. E. Rodriguez	Saúde Pública e Mudanças Climáticas	Vulnerabilidade relacionado à saúde no Brasil devido às mudanças climáticas.
Recent Findings and Methodologies in Economics Research in Environmental Justice	Lucas Cain, Danae Hernandez-Cortes, Christopher Timmins, Paige Weber	Economia Ambiental e Justiça Social	Revisão de literatura em justiça ambiental.
The Effects of Climate Change on Labor and Capital Reallocation	Christoph Albert, Paula Bustos, Jacopo Ponticelli	Economia do Trabalho e Clima	Realocação da força de trabalho e do capital devido às mudanças climáticas.
Climate Change Impacts on Birth Outcomes in Brazil	Paula C. Pereda, Tatiane A. De Menezes, Denisard Alves	Saúde Pública e Clima	Evidências de impactos das mudanças climáticas no peso de nascimento de crianças brasileiras.
A Systematic Review of Children's Environmental Health in Brazil	Carmen I.R. Froes Asmus, Volney M. Camara, Philip J. Landrigan, Luz Claudio	Saúde Ambiental Infantil	Revisão de literatura sobre a saúde ambiental de crianças no Brasil.
Does air quality matter? Evidence from the housing market	Kenneth Y. Chay, Michael Greenstone	Economia Urbana e Meio Ambiente	Impacto da qualidade do ar nos preços do mercado imobiliário.

Fonte: Elaboração Própria

O crescimento econômico após a Revolução Industrial foi acompanhado por níveis de destruição ambiental sem precedentes. Segundo a Organização das Nações Unidas (2019), os avanços industriais e o consumo de recursos naturais desde o século XIX resultaram em degradação ambiental significativa, com impactos como desmatamento, poluição e mudanças climáticas, que ameaçam a sustentabilidade do

planeta. Esse modelo de crescimento, sustentado pelo abuso ambiental, fomentou uma ala de estudos econômicos que relacionam as consequências desse modo de produção com impactos ambientais. Um exemplo familiar aos estudantes de economia são as externalidades microeconômicas, onde os custos sociais de atividades produtivas, como a poluição, são considerados na função de maximização de lucro da firma. Nesse contexto, empresas que emitem poluentes podem pagar impostos ou adotar políticas de compensação ambiental (HAR R. VARIAN, 2010). Entretanto, distintos autores trabalham esse fenômeno humano por outro viés.

O livro *Small is Beautiful: A Study of Economics as if People Mattered* (SCHUMACHER, 1973) discorre sobre o modo que o mundo aderiu ao crescimento, especialmente após 1850, onde o prazer está intrinsecamente atrelado ao consumismo e a exploração ambiental, um princípio que surge a partir, mesmo sem os ideais ecológicos que hoje os são reconhecidos, do fetiche da mercadoria de Marx, em que as mercadorias são determinísticas para a criação de um conjunto de relações sociais formuladas a partir da produção e do capital às quais estão atreladas, que exacerbam o uso dos recursos naturais e amplificam a destruição em massa do planeta (MARX, 1877). Nessa ideia, como essas mudanças dos últimos três séculos afetam a qualidade de vida da população? É certo que nunca houve um período em que os acessos aos bens de consumo e direitos humanos básicos fossem tão amplos, porém, também nunca houve um período em que as florestas e o ar estivessem tão contaminados e destruídos.

William Nordhaus (2019), ganhador do Prêmio Nobel de Economia, destaca o aquecimento global como a mais significativa das externalidades ambientais. Ele retorna à ideia de externalidades e busca precificar, modelar e discutir políticas públicas e a emissão de carbono, fornecendo bases econômicas para enfrentar desafios ambientais globais. Segundo Nordhaus:

O aquecimento global é a mais significativa de todas as externalidades ambientais. Ameaça o nosso planeta e paira sobre o nosso futuro como um Colosso<sup>1</sup>. É particularmente pernicioso porque envolve tantas atividades da vida diária, afeta todo o planeta, dura décadas e até séculos e, acima de tudo, porque nenhum de nós, agindo individualmente, pode fazer algo para retardar as mudanças. (NORDHAUS, 2019, p)

---

<sup>1</sup> Veja Apêndice para o quadro de Francisco de Goya – Colosso

Complementando essa perspectiva, Elinor Ostrom traz uma visão menos pessimista por meio de sua teoria sobre bens comuns. Contrapondo a ideia de que bens não privados são sobre utilizados e negligenciados, a tragédia dos comuns, Ostrom defende que comunidades que dependem desses recursos frequentemente os gerem de forma sustentável, cuidando de sua preservação com o conceito de se eles os usam, eles os cuidarão (OSTROM, 1990). Essa abordagem sugere que, embora o meio ambiente enfrente desafios, se coletivamente houver um esforço, talvez seja possível reverter ou, ao menos, não agravar mais a degradação do meio que sustenta a vida.

A discussão de externalidade e bens públicos é um tema frequentemente discutido na economia, sendo a origem dessa discussão a proteção da saúde humana para todos os produtores e consumidores do mercado. Em contrapartida, ao avançar para questões mais ambientais e bem-estar, muito do que se sabe é proveniente das ciências da saúde. A epidemiologia, por exemplo, estuda as contaminações em ambientes não controlados, porém, essa prática trabalha em condições adversas ao experimento ideal que influenciam os resultados de uma maneira que foge do controle da ciência. Uma família com um padrão de vida elevado busca maximização de bem-estar para seus filhos, nesse sentido, eles optam por uma residência no subúrbio com melhor qualidade de vida, mas essa família precisa morar em uma grande metrópole poluidora por conta das ofertas de emprego mais bem remunerados. Nesse cenário, a inferência estatística é prejudicada porque há fatores que fogem do escopo inicial da pesquisa que afetam seu resultado.(ZIVIN; NEIDELL, 2013)

A pesquisa econômica agrega ao estudar três adições ao estudo ambiental, são esses: Comportamento de Maximização; Comportamento de Evasão e Respostas Esperadas. O primeiro é fortemente derivado dos princípios da microeconomia, ou seja, os agentes de mercado vão buscar maximizar o bem-estar. Pereda, Menezes e Alves (2014), discutem sobre como o bem-estar dos filhos acaba se tornando um dos componentes de uma cesta de consumo dos pais. Uma função de maximização de utilidade possui em si uma função de demanda por sobrevivência, incluindo, no estudo em questão, um componente de mortalidade neonatal relacionado a preços, eficiência, renda, preferências e custos fixos de nascimento.

No presente trabalho, o fator mais explorado é o comportamento de evasão dos indivíduos. Como as consequências de exposições tóxicas são custosas, os indivíduos podem se fazer esforços adicionais a fim de evitá-las. Esse tipo de decisão gera diferenças

entre a exposição potencial, aquela que está no ambiente e capturada pelos monitores, e a exposição realizada, a que efetivamente pode levar a prejuízos ao ser humano (ZIVIN; NEIDELL, 2013). Por isso, Chay e Greenstone (2003) e Joyce, Grossman e Goldman (1989), buscaram uma alternativa que controle a mobilidade diária ou ao longo da vida do indivíduo a fim de controlar esse comportamento de evasão. O foco dos autores é a pesquisa com crianças, em particular bebês, porque o período de vida reduzido limita a mobilidade, o que diminui a preocupação com esse fator nas estimativas. O custo dessa decisão em contrapartida é que uma amostra com infantes não é representativa para toda a população do local que também podem ser de interesse dos pesquisadores.

Os resultados esperados, ou seja, os objetivos da pesquisa, foram influenciados com a incorporação da pesquisa econômica dentro da pesquisa ambiental. Os impactos das mudanças climáticas não só alteram o nível de saúde de determinada população, mas também prejudica o próprio crescimento econômico da região afetada, dado que, de acordo com o modelo de crescimento desenvolvido por Romer (1986), o capital humano é um fator decisivo dentro da estrutura e força de um país e os impactos são prejudiciais tanto no curto, quanto no longo prazo. (BURKE; EMERICK, 2016)

O fundamento de justiça ambiental é um tema central nos estudos econômicos sobre mudanças climáticas, especialmente ao avaliar os impactos desiguais sobre a população. Hsu et al. (2021), estudaram como as ilhas de calor urbanas afetam mais a população de baixa renda e minorias raciais, reflexo das desigualdades históricas que empurram essas pessoas a uma região mais vulnerável, o exemplo dos pesquisadores é o *redlining* dos mercados imobiliários, que foi uma medida de delimitação de local. Outro cenário é de Bakkensen e Ma (2020), que avaliaram os eventos climáticos extremos, como inundações e incêndios florestais, e concluíram que esses também têm impacto desproporcional em comunidades de baixa renda, pois a desigualdade financeira força-as a viver em áreas de maior risco devido aos preços mais baixos dos imóveis. E, Currie, Voorheis e Walker (2023) e Gillingham e Huang (2021) comparam lacunas entre populações afro-americanas/pretas e brancas, provando a existência de desigualdades racial durante a exposição, na prevenção e no tratamento das doenças relacionadas a poluição.(CAIN et al., 2024)

Ainda há outros fatores a serem observados, como por exemplo, o viés de estimação. Na econometria, a identificação dos parâmetros relacionados as variáveis objeto é feita comumente através do uso de instrumentos, ferramentas e variáveis

explicativas que controlem ruídos nas variações entre as variáveis de interesse. Por exemplo, a poluição sofre de influência meteorológica como a chuva e o vento, que afetam a dispersão dos poluentes, a primeira pode reduzir a concentração de partículas no ar, enquanto a segundo pode redistribuir poluentes entre regiões. Assim, ignorar essas variáveis pode resultar em estimativas enviesadas.(ZIVIN; NEIDELL, 2013)

Por fim, a metodologia econômica amplia o debate ambiental ao integrar conhecimentos da saúde, estatísticos e teóricos da economia. Enquanto essas disciplinas fornecem dados fundamentais sobre os mecanismos biológicos e epidemiológicos, os métodos econômicos auxiliam na análise buscando entender como os fatores socioeconômicos e as desigualdades afetam a exposição da população em sua pluralidade. Esse tipo de integração multidisciplinar é importante, pois, permite a criação e adoção de políticas públicas mais eficientes para diminuir o impacto as mudanças climáticas para todo o espectro das pessoas.

### 3 ESTRATÉGIA DE IDENTIFICAÇÃO

Um experimento natural ou um quase experimento, é um experimento que ocorre de maneira não controlada, diferente dos cenários tratados nas ciências da saúde, especialmente nas pesquisas toxicológicas. Enquanto os experimentos biológicos utilizam amostras aleatórias e contaminações induzidas em busca de isolar os efeitos derivados dessa pesquisa, os quase experimentos surgem como uma alternativa onde a cenário ideal é inviável. Burke e Emerick (2016) oferecem uma boa ilustração sobre a aplicação da metodologia. A resposta que os autores buscam é “Existe, e se sim, qual o grau da adaptação dos fazendeiros dos Estados Unidos com o avanço dos efeitos negativos das mudanças climáticas?”. Em um cenário ideal, os pesquisadores poderiam observar duas cópias idênticas do planeta Terra por um determinado período em que somente uma das cópias iria sofrer alterações no clima similares as que sofrem as fazendas americanas. No estudo proposto, a variável de interesse é a mortalidade infantil, e por questões éticas, é impossível a exposição de crianças aos danos das mudanças climáticas, fazendo assim o uso do quase experimento exposto. (Wooldridge, 2006; Zivin, Neidell, 2013)

A aplicação do experimento natural geralmente ocorre quando uma população sofre de algum fator exógeno a sua existência e a partir desse evento é explorado o efeito sobre tal população. Currie et al (2011), justificam o uso da prática pela seguinte afirmativa “existe o grupo de tratamento e o grupo de controle, muito parecido com um experimento aleatório, exceto que esses grupos são definidos por um evento exógeno que torna tais tão bons quanto se fossem aleatoriamente designados”. Para isso, a principal necessidade é que o evento seja exógeno à população. Situações assim são mais bem caracterizadas e identificadas quando o meio em que a surge é através da implementação de políticas públicas, mudanças de leis ou fatores concretos no espaço-tempo.

Ao avaliar os impactos da mudança climática na mortalidade infantil no Brasil, algumas preocupações emergem. A principal é a imprecisão de localizar os eventos dentro das dimensão espaço-temporal, pois, é uma alteração gradual com consequências não inteiramente compreendidas e diversas formas de quantificação. Entretanto, a metodologia do uso de quase experimentos é aplicada no trabalho quando se entende que as variáveis explicativas e a variável dependente são isentas de endogeneidade. De acordo com Currie, Ray e Neidell (2011) e Zivin e Neidell (2013), geralmente os estudos entre

mortalidade infantil e poluição do ar não expressam endogeneidade nos dados, ou seja, a relação entre as variáveis é em uma direção. Estendendo essa hipótese, conforme o Vicente-Serrano, Beguería e López-Moreno (2010) o indicador de mudança climática SPEI têm uma tendência crescente nos últimos 100 anos de avaliação, enquanto a mortalidade infantil brasileira está em queda. Quando se assume exogenidade restrita na estimativa, é assumir que não há como escrever a equação causal em que  $x$  afeta  $y$  e  $y$  afeta  $x$ , o que leva a um beta identificado inflado, pois esse parâmetro acaba coletando o efeito das duas causas em uma. Assim, as relações entre SPEI e mortalidade dificilmente vão apresentar endogeneidade, pois, as causas que levam a mudança na tendência estrutural do SPEI não envolvem a mortalidade infantil.

O objetivo que norteia o trabalho depende da identificação de uma variável explicativa que represente as mudanças climáticas. Os objetos climáticos que visam ser explorados são a temperatura e a precipitação, pois, de acordo com Albert, Bustos e Ponticelli (2021) é esperado que a combinação entre altas temperaturas e queda na precipitação leve a crises mais frequentes e prolongadas. Portanto, a escolha da variável SPEI é uma tentativa de captar os efeitos das mudanças climáticas no Brasil.

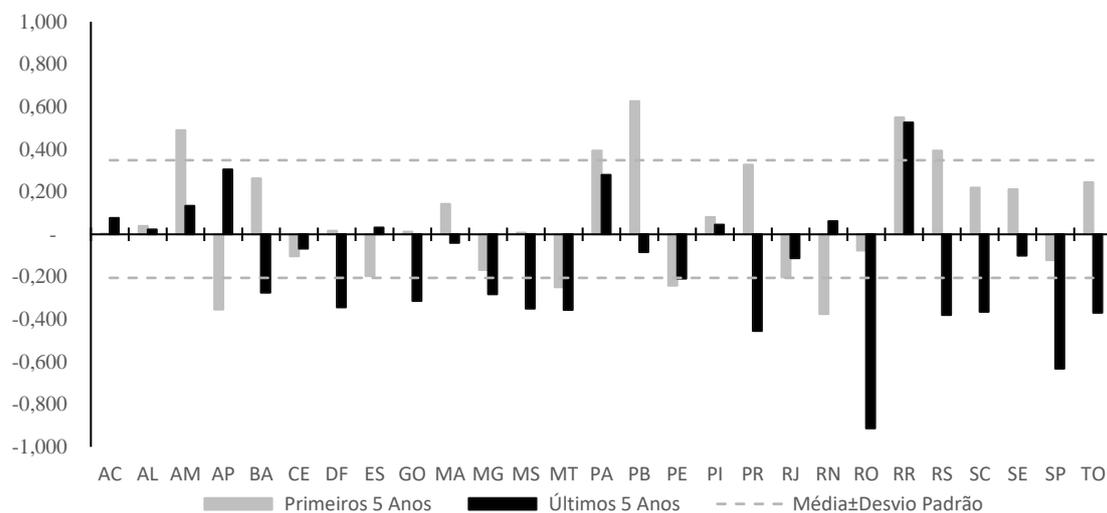
O índice foi criado por Vicente-Serrano da Universidade de East Anglia. O SPEI é uma proxy que tem como propósito detectar e acompanhar as alterações climáticas do local e é utilizado tanto na literatura climatológica quanto em trabalhos socioeconômicos. (ALBERT; BUSTOS; PONTICELLI, 2021; VICENTE-SERRANO; BEGUERÍA; LÓPEZ-MORENO, 2010)

O SPEI possui uma vantagem significativa que é a disponibilidade dos dados por tanto uma série temporal longa quanto alta uma cobertura territorial. Zivin e Neidell (2013) descrevem análises empíricas dos impactos da poluição na saúde como altamente intensivos, mesmo comparado a pesquisas econométricas, ou seja, uma grande dificuldade que os economistas encontram é a dificuldade de obter dados precisos em uma abrangência espaço temporal suficiente.

A Figura 3 é formado a partir da média do SPEI por estado entre 1997 e 2002, primeiros 5 anos da amostra, a média do SPEI por estado entre 2017 e 2022, últimos 5 anos da amostra, e a média dos primeiros 5 anos  $\pm$  desvio padrão do SPEI nos primeiros 5 anos. Esse gráfico ilustra que a variação do SPEI no período do estudo, entre 1997 e 2022, não é uma variação casual, porém, uma mudança do nível de secas no país. Os

estados do Sul foram especialmente afetados nos 25 anos de observação, com todos apresentando um clima mais seco ao decorrer do tempo.

Figura 3 - Média SPEI por estado



Fonte: Elaboração Própria

Além disso, os danos causados pelas mudanças climáticas não são aleatoriamente alocados (CHAY; GREENSTONE, 2005). Conforme Tabela 1, é identificável que os 10 municípios brasileiros mais pobres pelo PIB *per capita* 2021, tendem a serem mais expostos a chuvas mais severas comparado as 10 municipalidades mais ricas do Brasil. Esse efeito de viés de residência pode gerar parâmetros erroneamente estimados.

Tabela 1 - SPEI por PIB *per capita* 2021

10 Primeiros			10 Últimos		
Município	PIB per capita	SPEI 2021	Município	PIB per capita	SPEI 2021
<b>Catas Altas (MG)</b>	920.834	- 0,3653	<b>Santana do Maranhão (MA)</b>	5.408	0,7208
<b>Canaã dos Carajás (PA)</b>	894.806	0,0083	<b>Primeira Cruz (MA)</b>	5.732	0,6150
<b>São Gonçalo do Rio Abaixo (MG)</b>	684.169	- 0,4161	<b>Matões do Norte (MA)</b>	5.737	0,6798
<b>Itatiaiuçu (MG)</b>	610.780	- 0,5841	<b>Santo Amaro do Maranhão (MA)</b>	5.916	0,6150

<b>Presidente Kennedy (ES)</b>	580.174	0,1170	<b>Nina Rodrigues (MA)</b>	5.972	0,6643
<b>Conceição do Mato Dentro (MG)</b>	519.041	- 0,3657	<b>Araioses (MA)</b>	6.005	0,5631
<b>Maricá (RJ)</b>	511.811	- 0,3826	<b>Pedro do Rosário (MA)</b>	6.178	0,5484
<b>Saquarema (RJ)</b>	458.768	- 0,3826	<b>Cajapió (MA)</b>	6.279	0,4748
<b>Paulínia (SP)</b>	457.518	- 0,8755	<b>Manari (PE)</b>	6.294	0,2389
<b>Campos de Júlio (MT)</b>	455.838	- 0,9837	<b>Humberto de Campos (MA)</b>	6.328	0,6150
<b>Média SPEI</b>		- 0,4231			0,5735
<b>Média SPEI (Valores Absolutos)</b>		0,4481			0,5735

Fonte: Elaboração Própria

Por fim, para identificar o impacto das mudanças climáticas na mortalidade infantil, é estimado um modelo baseado nos estudos dos economistas Currie, Neidell e Schmieder (2009). A regressão consiste em uma estimativa de perigo semanal. A cada semana que o bebê permanece vivo a variável dependente assume valor 0, na semana que o infante vem a óbito, a variável dependente assume valor 1. As variáveis explicativas que não se alteram no tempo, ou seja, as variáveis determinadas no ato do nascimento (RAÇA; SEXO; IDADE DA MÃE; LOCAL DE NASCIMENTO; PESO) permanecem inalteradas para todas as semanas. As variáveis explicativas que são atualizadas semanalmente são o SPEI e o trimestre. Esse modelo foi desenvolvido para capturar impactos das mudanças climáticas em um curto período em uma população de risco.

### 3.1 DADOS

Os microdados disponíveis pelo DATASUS, no sistema de mortalidade (SIM), correspondem a cerca de 96,1%<sup>2</sup> dos óbitos estimados pelo Instituto Brasileiro de Geografia e Estatística (IBGE) para o ano de 2011. Nas regiões Centro-Oeste, sudeste e Sul, os valores se aproximam a 100% dos óbitos estimados, somente MT (95,8%) e DF (94,8%) com uma média de registros abaixo da média nacional. Já nas grandes regiões

---

<sup>2</sup> A cobertura é definida como a razão entre óbitos coletados pelo SIM e óbitos projetados pelo IBGE

mais pobres do país, a cobertura das notificações decaí, com 4 UF's acima de 90% e 8 entre 80 e 90%.

Sobre os estados que carecem de acesso ao sistema de saúde, esse problema leva a uma subnotificação das minorias presentes nessas regiões, o que pode enviesar a estimativa pelo viés de seleção, em que não há representação suficiente de um grupo para que o impacto estimado seja o que realmente incide sobre o grupo. Ainda assim, de acordo com o próprio relatório de mortalidade, os dados são virtualmente representativos da população brasileira. (BRASIL, 2013)

As demais variáveis servem para controle da mãe e do bebê. São as variáveis da mãe: Idade da Mãe e Escolaridade da Mãe; as variáveis do bebê são: Raça; Sexo e Peso. No relatório do SUS de 2011, é informado que houve um esforço para que os formulários de óbito sejam precisos, especialmente nas variáveis determinantes de condições socioeconômicas, como escolaridade e raça<sup>3</sup>. (BRASIL, 2013)

A Tabela 2 mostra a distribuição das variáveis qualitativas na amostra. A variável Raça contém uma parcela maior de brancos e indígenas, menor de pretos e uma representação semelhante de pardos e amarelos, que comparado ao censo de 2022. Já a variável sexo possui maioria masculina, sendo que o censo 2022 observou uma população brasileira de maioria feminina, 51,48% frente a 48,52%. (IBGE, 2022)

Tabela 2 – Descrição das variáveis qualitativas da amostra

<b>Sexo</b>		<b>Raça</b>		<b>Escolaridade_Mae</b>	
<b>Masculino</b>	54%	<b>Branca</b>	49,7%	<b>Fundamental II Completo</b>	33,5%
<b>Feminino</b>	46%	<b>Parda</b>	44,1%	<b>Fundamental II Incompleto</b>	27,6%
<b>Sexo</b>		<b>Raça</b>		<b>Escolaridade_Mae</b>	
<b>Ignorado</b>	0%	<b>Preta</b>	3,8%	<b>Fundamental I Completo</b>	11,1%
		<b>Indígena</b>	2,1%	<b>Ensino Médio Incompleto</b>	9,5%
		<b>Amarela</b>	0,4%	<b>Ignorado</b>	9,2%
				<b>Fundamental I Incompleto</b>	8,4%
				<b>Superior Completo</b>	0,5%
				<b>Sem Escolaridade</b>	0,1%
<b>Total</b>	100%		100%		100%

Fonte: Elaboração Própria

<sup>3</sup> Ver Apêndice para a estrutura dos formulários

As variáveis quantitativas da amostra são descritas na Tabela 3. As linhas da tabela contêm respectivamente, a média da variável, o desvio padrão, o valor mínimo observado, o primeiro, segundo e terceiro quartil e o valor máximo observado. O SPEI possui a média e a maioria das suas observações em valores abaixo de 0, ou seja, indicando seca nesses períodos (VICENTE-SERRANO; BEGUERÍA; LÓPEZ-MORENO, 2010). Entretanto, dado que a variável é um índice normalizado com média 0 e desvio padrão 1, o desastre mais grave, SPEI de 6,50 pontos, observado no Brasil, no município de Juína em outubro de 2018, foi decorrente de altos níveis de excesso de chuva e não sua falta.

Os valores registrados para as variáveis peso do bebê e idade da mãe incluíram extremos, como 0 e 9.999 para peso, e 0 e 99 para idade. Embora esses valores possam parecer incomuns ou confusos, optou-se por não os excluir. O critério de tratamento da amostra considerou apenas a exclusão de registros com valores faltantes (formulários não preenchidos), enquanto valores possivelmente preenchidos de forma incorreta foram mantidos na análise.

A última variável é o indicador de situação semanal, que como já citado anteriormente assume valores 0 e 1. A média dessa variável tende a 0 se a longevidade média dos bebês aumenta e tende a 1 conforme a amostra apresenta crianças com saúde deterioradas que vieram a óbito com poucas semanas de vida.

Tabela 3 – Estatísticas descritivas das variáveis quantitativas

<b>Variável</b>	<b>SPEI</b>	<b>Peso</b>	<b>Idade_Mae</b>	<b>Indicador_Morte</b>
<b>Média</b>	-0,0981	2.539	25,8	0,1715
<b>SD</b>	1,1212	1.034	7,4	0,3769
<b>Min</b>	-5,0963	-	-	-
<b>25%</b>	-0,9683	1.870	20,0	-
<b>50%</b>	-0,1047	2.750	25,0	-
<b>75%</b>	0,7476	3.250	31,0	-
<b>Max</b>	6,5026	9.999	99,0	1

Fonte: Elaboração Própria

### 3.2 AMOSTRA

A construção da base de dados foi organizada em três etapas principais: coleta, manipulação e unificação. Para a coleta de dados foram utilizadas duas fontes, o SPEI e os microdados do SUS – DATASUS.

O SPEI foi coletado em valores diários que são calculados com base em uma média móvel de 30 dias para ambos os insumos, precipitação e potencial de evapotranspiração. Para os microdados do sistema de mortalidade do SUS, a coleta foi feita pela biblioteca do Python disponibilizada pelo Ministério da Saúde, PYSUS. Essa forma de coleta é essencial para lidar com o volume de dados que foram necessários na pesquisa e é de suma importância que esse tipo de ferramenta seja disponibilizado pelos institutos de estatísticas (BRASIL, 2022).

Após a coleta, os dados do SPEI foram convertidos em médias semanais, não alterando as propriedades do índice. Além disso, o SPEI é geindexado somente com a localização geográfica, latitude e longitude, portanto, foram adicionadas informações identificáveis dos municípios (CÓDIGO, NOME, ESTADO E GRANDE REGIÃO) ao SPEI para passos futuros.

Pelo PYSUS, foram selecionadas seis variáveis, e, por conta da estratégia de identificação do parâmetro que depende de controles completos, os registros de óbitos que continham variáveis ausentes foram descartados. Esse tipo de alteração pode trazer viés de seleção conforme aponta Currie, Neidell e Schmieder (2009) pela possibilidade de haver alguma variável omitida que cause os registros incompletos no DATASUS.

Finalmente, os registros de óbitos infantis foram transformados em registros de situação de vida por semana através de três etapas. A primeira, foi contabilizar a idade da criança em semanas de vida, por exemplo, uma criança nascida dia 01 de janeiro de 2020, quarta-feira, com a data de óbito em 19 de março, quinta-feira de 2020 possui 12 semanas de idade, ela esteve viva em 11 semanas, mesmo que não completa a semana de nascimento, e veio a óbito na 12<sup>o</sup> semana.

Depois, foram adicionados registros a base de dados para as condições de vida da criança para cada semana que ela esteve viva até a semana de óbito, no exemplo anterior, a criança *i* representa 12 registros dentro da base de dados, 11 com valor da variável dependente em 0 e 1 valor em 1, isso feito para cada criança do SIM. Em seguida, a terceira etapa, foi realizado uma filtragem de crianças com no máximo 52 semanas de

vida, um ano, isso significa que, todas as crianças em algum período acabam por falecer, mas esse período pode não estar registrado na base final. Essa manipulação é uma tentativa de diminuir possíveis fatores omitidos da base de dados por conter somente registros de crianças que vieram a falecer.

### 3.2.1 Agrupamento Independente de Cortes Transversais

De acordo com Wooldridge (2006), se uma amostra aleatória for extraída a cada período, o agrupamento das amostras resultantes forma um agrupamento independente de cortes transversais, o que pode gerar problemas devido a diferenças entre os períodos analisados. Para tratar essas variações, o autor sugere a inclusão de variáveis dummy para cada ano, exceto uma categoria de referência. No entanto, nesse estudo, optou-se por não incluir dummies anuais, já que o modelo de Currie, Neidell e Schmieder (2009) incorpora dummies para estimativas de efeitos fixos de trimestre e localidade e a adição de dummies anuais não traz poder de explicação para o modelo visto que não é o objeto da análise propriamente, ou seja, seria adicionar variáveis puramente para captar variâncias anuais, porém, sem explicá-las com o restante das variáveis.

O teste de Chow é uma ferramenta econométrica que se baseia em um Teste F e é usualmente utilizado para avaliar quebra estrutural em modelos regressivos. Esse teste mede se o comportamento das relações entre as variáveis se altera ao longo da série temporal. Entretanto, esse teste também pode ser aplicado em um agrupamento independente de cortes transversais para avaliar se há quebra estrutural das variáveis entre as amostras agrupadas ao longo do tempo. (WOOLDRIDGE, 2006)

A Tabela 4 contém os resultados do teste de Chow, teste de quebra estrutural, com o objetivo de verificar se houve mudanças estruturais entre os primeiros 10 anos e os últimos 10 anos da amostra.

Tabela 4 - Teste de Chow de Mudança Estrutural

<b>Variável</b>	<b>Estatística F</b>	<b>P-valor</b>
<b>SPEI</b>	585	0
<b>Peso</b>	156,9429	0
<b>Idade_Mãe</b>	656,6149	0

Fonte: Elaboração Própria

As variáveis contínuas apresentaram evidências de mudança estrutural visto um p-valor  $<0,05$ , porém, esse resultado não necessariamente invalida o agrupamento, pois, a hipótese do estudo é justamente avaliar se as mudanças climáticas estão impactando a saúde do bebê. Quando se observa as mudanças nas variáveis de SPEI e Peso, peso ao nascer, e esses apresentam uma quebra estrutural, pode ser um indicador que a hipótese do trabalho é significativa, ou seja, a média do SPEI mudou indicando mudanças climáticas e a saúde do bebê está sendo afetada de alguma forma, utilizando peso como proxy para saúde ao nascer.

Ainda sobre as variáveis contínuas. A Tabela 5 apresenta a média das observações dos primeiros 10 anos comparado aos 10 últimos a nível Brasil. Os valores do SPEI foram respectivamente, -0,051818 e -0,225292, sinalizando um aumento da seca no país, e corroborando para uma das identificações da pesquisa, as alterações climáticas. Tal método comparativo entre as duas médias pode ser aplicado à variável peso ao nascer, pois, considerando os avanços da ciência, das políticas de saúde e bem-estar, e da medicina, o esperado seria uma melhora ou, pelo menos, a estabilidade no peso dos recém-nascidos ao longo do tempo. O peso ao nascer é utilizado, conforme já descrito, como uma proxy importante para a saúde neonatal. No entanto, na presente amostra, que se restringe exclusivamente a registros de crianças que vieram a óbito, observa-se que esse padrão esperado não se verifica. Isso sugere uma deterioração das condições associadas à saúde dos recém-nascidos, talvez por conta de fatores ambientais no período de gravidez da mãe, como sugere Currie, Neidell e Schmieder (2009), ou por outras influências sociais adversas.

Tabela 5 - Médias das variáveis entre os primeiros e últimos 10 anos

<b>Variável</b>	<b>Primeiros 10 anos</b>	<b>Últimos 10 anos</b>
<b>Indicador Óbito</b>	0,153	0,185
<b>SPEI</b>	-0,052	-0,225
<b>Peso</b>	2.732,74	2.389,52
<b>Idade Mãe</b>	24,753	26,888

Fonte: Elaboração Própria

A variável que pode haver discussão sobre é a idade média da mãe, onde geralmente está associado a mudança das condições socioeconômicas e liberdade financeira da mulher (NÍ BHROLCHÁIN; BEAUJOUAN, 2012). Isso poderia ter um viés significativo dentro da saúde do infante em dois caminhos, o primeiro deles sendo as condições socioeconômicas melhores, o que leva a mais acesso a saúde e poderia melhorar positivamente as estatísticas vitais da criança, ou pelo lado de mulheres com mais idade tendem a ter maiores dificuldades durante a gestação ou são mais propensas a terem filhos com uma saúde deteriorada.(U.S. DEPARTMENT OF HEALTH AND HUMAN SERVICES, 2022)

Esses cenários relatados são válidos e serão capturados pelo parâmetro estimado para a idade da mulher. Entretanto, ao utilizar outras variáveis de controle como raça do bebê, que é em grande medida a mesma da mãe, e a escolaridade da mãe, variável sugerida pelo SUS como uma aproximação as condições socioeconômicas, ambas as quais se mantiveram com as proporções estáveis, torna a amostra menos propensa a gerar vieses de variáveis omitidas.

As variáveis qualitativas da estimação são o sexo do bebê, a raça e a escolaridade da mãe. Visto a característica dessas variáveis de serem categorias, e não numerais, não é possível realizar o teste de Chow, portanto, a opção adotada para avaliar o comportamento foi observar se a proporção entre as categorias de cada variável se manteve estáveis ao longo da amostra. O resultado descrito na Tabela 6, foi um P-valor que aceita a hipótese de proporções mantidas, o que é importante por se tratarem, com destaque a raça e escolaridade da mãe, de variáveis socioeconômicas, mas, em contrapartida, a variável da escolaridade da mãe poderia ter apresentado uma quebra na proporção ao longo da amostra, sinalizando uma melhora na média de instrução da mãe brasileira, porém, não é o que ocorre<sup>4</sup>.

Tabela 6 - Proporção das características entre períodos

<b>Variável</b>	<b>Chi<sup>2</sup></b>	<b>P-valor</b>
<b>Sexo</b>	0,0003	0,9998
<b>Raça</b>	0,0138	1

---

<sup>4</sup> Esse é um teste que busca somente avaliar as características da amostra

**Escolaridade**

<b>Mãe</b>	0,424	0,9997
------------	-------	--------

---

Fonte: Elaboração Própria

**3.3 EFEITOS FIXOS**

Os efeitos fixos, descritos na equação 1, determinado pelo comportamento médio das observações, são utilizados em um modelo estatístico para capturar variações específicas de determinados grupos ou períodos. A modelagem de efeitos fixos é descrita pela equação:

$$y_{it} - \bar{y}_i = \beta_1(x_{it} - \bar{x}_i) + u_{it} - \bar{u}_i, \quad t = 1, 2, \dots, T \quad (1),$$

em que,  $y_{it}$  é a variável dependente na unidade  $i$  e no tempo  $t$ ;  $x_{it}$  são as variáveis explicativas;  $\bar{y}_i$  e  $\bar{x}_i$  a média das variáveis ao longo do tempo; e  $u_{it}$  os erros do modelo.

O método de regressão com variáveis dummy é frequentemente usado para operacionalizar os efeitos fixos. Ao alterar a equação 1 para a estimação via efeitos fixos com dummy, o resultado fica descrito pela equação 2:

$$y_{it} = \beta_0 + \beta_1 x_{it} + \sum_{j=1}^{N-1} \alpha_j \cdot D_{ij} + \sum_{k=1}^{N-1} \nu_k \cdot D_{tk} + u_{it} \quad (2),$$

em que,  $y_{it}$  é a variável dependente na unidade  $i$  e no tempo  $t$ ;  $x_{it}$  são as variáveis explicativas;  $D_{ij}$  vetor de dummy espacial;  $D_{tk}$  vetor de dummy temporal;  $u_{it}$  o resíduo do modelo.

Os coeficientes associados às variáveis dummy, que capturam os efeitos fixos espaciais e temporais são equivalentes aos estimados pela regressão de dados centrados na média, conforme descrito na equação 1. Os valores dos coeficientes estimados e dos erros padrão obtidos pelos dois métodos são idênticos (WOOLDRIDGE, 2006).

O método, conhecido como regressão com variáveis dummy, define que, em um corte transversal, sejam incluídas  $i - 1$  dummies para categorias espaciais e  $t - 1$  dummies para categorias temporais. Na regressão proposta, isso implica o uso de 26 dummies para os estados (27 menos 1) e 3 dummies para os trimestres (4 menos 1), totalizando 29 dummies que capturam os efeitos fixos.

Currie, Neidell, Schmieder, (2009) aplicam os efeitos fixos tanto no espaço quanto no tempo. O uso de efeitos fixos espaciais (e.g., estados ou municípios) é mais comum e foi adicionado à regressão. Porém, dado que variáveis climáticas como precipitações e evaporações médias, as variáveis que determinam o SPEI, sofrem influências sazonais, a adição de efeito fixos temporais captura o impacto médio das variações sazonais.

### 3.4 REGRESSÃO LOGÍSTICA

A regressão logística é modelo de probabilidade linear onde a variável dependente é vista como uma variável dependente limitada, ou seja, uma variável que assume valores restritos a 0 e 1.

Dado o objetivo principal é definir a probabilidade de resposta do óbito da criança através das variáveis explicativas que assumem diferentes características, a forma funcional do estimador para o estudo está descrita na equação 3:

$$P(Y = 1|x) = \Lambda(\beta_0 + \beta_1 \cdot SPEI_{e[i]} + \sum_{k=1}^3 \gamma_k \cdot Z_{ik} + \sum_{j=1}^2 \delta_j \cdot M_{ij} + \sum_{l=1}^3 \alpha_l \cdot T_{pl} + \sum_{m=1}^{26} \nu_m \cdot S_{em} + \zeta_e) \quad (3),$$

onde  $\Lambda$  é a função que garante que as probabilidades estimadas estarão restritas a 0 e 1. essa otimização no estimador logístico é dada pela função:

$$G(f) = \frac{\exp(f)}{[1+\exp(f)]} = \Lambda(f) \quad (4),$$

e os demais componentes da função são:  $i$  representa cada bebê, a unidade de análise do modelo;  $e$  o município de nascimento do bebê, que também identifica o SPEI de referência;  $p$  a semana de referência associada a duração de vida do bebê;  $Z_{ik}$  vetor de controles específicos do bebê;  $M_{ij}$  vetor de controles da mãe;  $T_{pl}$  efeito fixo do trimestre do ano relacionado à semana de referência  $p$ , para capturar sazonalidade;  $S_{em}$  efeito fixo do estado associado ao município de nascimento do bebê, para capturar variações regionais;  $\zeta_e$  erros clusterizados por estado, permitindo a correção de heterogeneidade entre os estados (ABADIE et al., 2023).

### 3.4.1 Efeitos Parciais Médios

O modelo Logit e o modelo Probit têm como objetivo principal explicar a direção em que as variáveis explicativas influenciam a variável dependente, ao invés de se concentrar na magnitude exata desse impacto. Isso ocorre porque a função  $\Lambda$ , usada nesses modelos, transforma o espaço linear em probabilidades, o que dificulta uma interpretação direta dos coeficientes como em modelos lineares. (WOOLDRIDGE, 2006)

Diferentemente de modelos lineares, onde os parâmetros  $\beta_w$  têm interpretações claras em termos de magnitude do impacto sobre a variável dependente. Ao definir  $x$  como o vetor de todas as variáveis explicativas, nos modelos logit e probit, todo efeito parcial de  $x_w$  sobre  $y_w$  terá o mesmo sinal do parâmetro  $\beta_w$ , indicando se a relação é positiva ou negativa. Contudo, esses modelos não fornecem uma estimativa direta do tamanho do impacto, conforme destacado por Wooldridge (2006).

Para contornar essa limitação e interpretar os parâmetros estimados, pode-se encontrar os efeitos parciais das variáveis pela primeira diferença  $\frac{\partial \hat{y}}{\partial x_w}$ , que ao seguir a regra da cadeia se torna:

$$\frac{\partial \hat{y}}{\partial x_w} = \hat{\beta}_j \cdot \Lambda(x\hat{\beta}) \quad (5),$$

onde  $\Lambda(f)$  é a Função de Probabilidade Cumulativa do modelo logit, ou função G.

Para exemplificar o efeito marginal do modelo estimado, optou-se pelo cálculo dos **efeitos parciais médios** (APE – Average Partial Effects). Como a regressão inclui variáveis qualitativas, não é possível trabalhar com os efeitos parciais na média (PEA – Partial Effects at the Average), que não depende dos resultados de todas as regressões da amostra, tornando-a mais simples de compreensão.

Em alternativa, para o vetor  $x$ , calcula-se a função de probabilidade  $P(y)$  e realiza a média do resultado, ou esperança condicional de  $y$  dado  $x$ . A partir disso, calcula-se o efeito parcial médio:

$$PEA = \hat{\beta}_j \cdot g(\bar{x}\hat{\beta}) \quad (6),$$

onde, na equação 6,  $g(\bar{x}\hat{\beta})$  é a regressão pela média do vetor  $x$ .

$$APE = \frac{1}{n} \sum_{i=1}^n \hat{\beta}_j \cdot g(x_i\hat{\beta}) \quad (7),$$

Onde, na equação 7,  $\overline{g(x\hat{\beta})}$  é a média das regressões para todo o vetor  $x$ .

## 4 RESULTADOS

Neste capítulo, serão apresentados os resultados da regressão logística; os efeitos parciais médios das variáveis explicativas; os efeitos parciais médios das regressões por raça e as regressões por grandes regiões brasileiras. A partir da abordagem empírica, o trabalho buscou elucidar as relações entre as mudanças climáticas e a mortalidade infantil.

A Figura 4 apresenta o resultado da regressão para o Brasil. O procedimento de estimação segue a Tabela 7:

**Figura 4 – Parâmetros do Logit Mortalidade Infantil<sup>5</sup>**

Brasil	1			2			3			4	
<b>Intercept</b>	-1,5770***	-1,5291***	-1,5886***	-0,0804	-0,0344	-0,0129	0,1132	0,1609*	0,1801**	0,1681*	
	0,038	0,05	0,021	0,107	0,105	0,096	0,102	0,096	0,085	0,087	
<b>SPEI</b>	-0,018***	-0,0194***	-0,011***	-0,0163***	-0,0180***	-0,0141***	-0,0160***	-0,0177***	-0,0140***	0,0126	
	0,005	0,004	0,004	0,004	0,004	0,004	0,004	0,004	0,004	0,01	
<b>Ignorado</b>				2,2159***	2,2167***	2,1851***	2,2045***	2,2051***	2,1691***	2,1683***	
				0,338	0,338	0,352	0,341	0,34	0,354	0,354	
<b>Masculino</b>				0,1421***	0,1426***	0,1446***	0,1377***	0,1382***	0,1404***	0,1401***	
				0,014	0,013	0,013	0,013	0,013	0,013	0,013	
<b>Branca</b>				-0,0314	-0,0257	0,0105	-0,0245	-0,0193	0,0231	0,0231	
				0,078	0,078	0,074	0,071	0,071	0,069	0,069	
<b>Indígena</b>				-0,3290***	-0,3303***	-0,2642***	-0,2257**	-0,2271**	-0,1526	-0,1507	
				0,095	0,095	0,1	0,091	0,091	0,099	0,1	
<b>Parda</b>				0,1384*	0,1424*	0,123	0,1644**	0,1680**	0,1452*	0,1454*	
				0,081	0,081	0,089	0,072	0,072	0,082	0,083	
<b>Preta</b>				-0,2510***	-0,2466***	-0,2213***	-0,2194***	-0,2154***	-0,1839***	-0,1840***	
				0,061	0,061	0,069	0,053	0,053	0,063	0,064	
<b>Peso</b>				-0,0007***	-0,0007***	-0,0007***	-0,0007***	-0,0007***	-0,0007***	-0,0007***	
				0	0	0	0	0	0	0	
<b>Fundamental I</b>							-0,2211***	-0,2208***	-0,2334***	-0,2338***	
<b>Completo</b>							0,037	0,037	0,04	0,04	
<b>Fundamental I</b>							-0,3632***	-0,3635***	-0,3821***	-0,3824***	
<b>Incompleto</b>							0,058	0,057	0,051	0,051	
<b>Fundamental II</b>							-0,031	-0,0311	-0,022	-0,022	
<b>Completo</b>							0,023	0,023	0,022	0,022	
<b>Fundamental II</b>							-0,1242***	-0,1237***	-0,1195***	-0,1201***	
<b>Incompleto</b>							0,02	0,02	0,02	0,02	
<b>Ignorado</b>							0,0837	0,0828	0,082	0,0813	
							0,057	0,057	0,057	0,056	
<b>Sem</b>							0,1727	0,1725	0,1043	0,1052	
<b>Escolaridade</b>							0,154	0,155	0,147	0,147	
<b>Superior</b>							-0,0755	-0,0791	-0,0499	-0,049	
<b>Completo</b>							0,144	0,146	0,147	0,146	
<b>Idade Mãe</b>							-0,0063***	-0,0063***	-0,0056***	-0,0056***	
							0,001	0,001	0,001	0,001	
<b>FE Trimestre</b>	No	Yes	Yes	No	Yes	Yes	No	Yes	Yes	Yes	Yes
<b>FE Estado</b>	No	No	Yes	No	No	Yes	No	No	Yes	Yes	Yes
<b>AIC</b>	867808	867466	863675	799145	798924	796820	797473	797260	795103	795125	
<b>BIC</b>	867832	867525	864039	799251	799066	797267	797673	797495	795644	795666	

Fonte: Elaboração Própria

<sup>5</sup> \* representa 90% de confiança; \*\* representa 95% de confiança e \*\*\* representa 99% de confiança

Tabela 7 - Equações Estimadas

Equação	Constante	SPEI	Controles Infante	Controles Mãe
1	Sim	Sim		
2	Sim	Sim	Sim	
3	Sim	Sim	Sim	Sim
4	Sim	Sim <sup>6</sup>	Sim	Sim

Fonte: Elaboração Própria

A estimativa a nível Brasil possui 946.969 observações e um  $R^2$  de 0,08394, o que não é um valor elevado, mas de acordo com o Wooldridge a interpretação de relações causais não é invalidada com valores de  $R^2$  em torno de 0,05 e 0,1. Os resultados principais a serem observados são o modelo 3 com efeitos fixos de Estado e Trimestre, pois, esse modelo obteve o menor Bayesian Information Criteria (BIC), apesar de conter o maior número de variáveis explicativas dentre todas as escolhas. Isso mostra que as escolhas das variáveis não foram insignificantes, pois, mesmo que haja características não significativas, tais quais: Raça Branca ou Ensino Fundamental II Completo, todos os controles qualitativos obtiveram significância estatística na maioria de suas características.

O resultado da estimativa em relação à hipótese do trabalho de que há impacto das mudanças climáticas na mortalidade infantil, foi a significância estatística do parâmetro estimado do SPEI, onde em todas as estimativas, sem tratamento de valor absoluto, o beta se mostrou significativo a 99% de confiança. Além da significância estatística, os valores se mantiveram estáveis com uma média de -0,01606, desvio padrão de 0,002625, o que leva a um intervalo entre [-0,01769,-0,01443] com 95% de confiança. Sobre o sinal do parâmetro, os valores do SPEI que correspondem a seca, ou seja, SPEI <0, aumentam a chance de mortalidade infantil.

Essa análise econométrica é um dos indícios das consequências que as mudanças climáticas causam sobre a população. Conforme Nordhaus (2018) e Burke e Emerick (2016), os prejuízos econômicos e sociais decorrentes dessas alterações são severos e de difícil adaptabilidade. No contexto brasileiro, os eventos climáticos extremos representam uma ameaça direta ao capital humano e à sustentabilidade do desenvolvimento.

<sup>6</sup> Na estimação 4, os valores do SPEI foram considerados em módulo.

A Tabela 8 apresenta os efeitos parciais médios. Se o Brasil sofre de uma seca que aumente o SPEI em uma unidade, isso resultaria em um efeito parcial médio na probabilidade de óbito infantil em 0,176%, o que em um cenário com base em 22 mil mortos, aproximadamente o total de crianças que morreram com menos de 1 ano em 2022, resultaria em 38 crianças a mais mortas. O EPA calcula o preço de uma vida em 4,8 milhões de dólares ou 24,768 milhões de reais (cotação média do dólar em 2022), ou seja, 941,184 milhões de reais perdidos na economia nessa mudança ambiental. Esse valor é 5,15% do PIB 2021 de Roraima; 4,68% do Amapá; 0,66% do Mato Grosso do Sul e 0,03% do PIB de São Paulo.

Tabela 8 - Efeitos Parciais Médios

<b>Variável</b>	<b>APE</b>	<b>Variável</b>	<b>APE</b>
<b>SPEI</b>	-0,176%	<b>Fundamental II Completo</b>	-0,278%
<b>Ignorado</b>	27,346%	<b>Fundamental II Incompleto</b>	-1,507%
<b>Masculino</b>	1,770%	<b>Ignorado</b>	1,033%
<b>Branca</b>	0,292%	<b>Sem Escolaridade</b>	1,315%
<b>Indígena</b>	-1,923%	<b>Superior Completo</b>	-0,629%
<b>Parda</b>	1,830%	<b>Idade_Mãe</b>	0,071%
<b>Preta</b>	-2,319%	<b>Fundamental I Completo</b>	-2,942%
<b>Peso</b>	-0,009%	<b>Fundamental I Incompleto</b>	-4,817%

Fonte: Elaboração Própria

Além disso, outras variáveis que apresentaram significância foi o Sexo Ignorado, que seguindo os pensamentos da Currie, Neidell, Schmieder, (2009), muito provavelmente há alguma variável omitida que faça com que esses bebês não tenham a mesma qualidade de informações no seu óbito e sejam mais vulneráveis ao óbito.

Sobre as condições econômicas, mensuradas pela escolaridade da mãe, se mostrou um fator relevante na redução da mortalidade infantil, alinhado a literatura de (CURRIE; NEIDELL; SCHMIEDER, 2009), que reforçam o papel determinantes sociais na saúde através da análise fatores regressivos atrelados a mãe, como renda e quantidade de cigarros consumidos. Esse tipo de associação entre níveis baixos de escolaridade e maior vulnerabilidade infantil reflete a desigualdade permanente no país.

A questão racial também é avaliada nos parâmetros, com o *threshold* sendo a raça Amarela, por isso não aparece na tabela, mas surpreendente as raças que apresentaram maior vulnerabilidade foram a parda e a branca, sendo que na literatura geralmente é apresentado como pretos e pardos as raças mais vulneráveis (CURRIE; VOORHEIS; WALKER, 2023; GILLINGHAM; HUANG, 2021; HSU et al., 2021).

Ao observar na Tabela 9, as Grandes Regiões com maior parcela de pardos são as regiões Norte e Nordeste, que também apresentam um SPEI indicando secas, além das questões econômicas, pois são regiões desfavorecidas historicamente. A raça branca representa 72,58% da população do Sul e quase 50% da população do Sudeste, pode ser que a significância negativa dessa raça seja por conta de o Sudeste em especial ser uma região que apresenta desigualdade estrutural que ameaça não só minorias, mas também uma parcela da população branca que acaba sendo marginalizada para as periferias. Esse tipo de estatística só reforça o quão prejudicial são as mudanças climáticas, pois todos acabam sendo afetados, em maior e menor grau, independente de raça, renda ou sexo.

Tabela 9 - Distribuição Racial das Grandes Regiões

<b>Grande Região</b>	<b>Amarela</b>	<b>Branca</b>	<b>Parda</b>	<b>Preta</b>	<b>Indígena</b>
<b>Norte</b>	0,17%	20,73%	67,15%	8,82%	3,11%
<b>Nordeste</b>	0,13%	26,66%	59,57%	13,04%	0,60%
<b>Sudeste</b>	0,67%	49,88%	38,70%	10,61%	0,13%
<b>Sul</b>	0,40%	72,58%	21,71%	5,03%	0,27%
<b>Centro-Oeste</b>	0,37%	37,04%	52,40%	9,15%	1,04%

Fonte: Elaboração própria a partir de dados do IBGE

A Figura 5 mostra os efeitos parciais médios por conjunto racial. Para cada Raça foi estimado a equação 3 da Tabela 7 contendo o intercepto, o SPEI, os controles do bebê e da mãe, mais efeitos fixos de estado e trimestre. O que pode ser observado é a significância do SPEI para as raças branca e parda, o que corrobora com a discussão anterior sobre os resultados das raças na estimativa Brasil. Além disso, as questões de socioeconômicas e informativas permanecem significantes para as raças citadas e para a raça preta, especialmente, quando se observa o EPM da mãe possuir ensino fundamental, mesmo que incompleto e as mães sem escolaridades, que aumentam em 16,11% a chance de mortalidade do bebê.

Figura 5- Efeitos parciais médios por conjunto racial

Variável	Amarela	Branca	Parda	Preta
<b>SPEI</b>	-0,34%	-0,12% **	-0,25% ***	-0,15%
<b>Ignorado</b>	242,55% ***	30,14% ***	26,67% ***	27,17% ***
<b>Masculino</b>	4,20% **	1,66% ***	2,00% ***	0,02%
<b>Peso</b>	-0,01% ***	-0,01% ***	-0,01% ***	-0,01% ***
<b>Idade Mãe</b>	-0,20%	-0,08% ***	-0,07% ***	0,06%
<b>Fundamental I Completo</b>	1,24%	-2,38% ***	-3,46% ***	-2,22%
<b>Fundamental I Incompleto</b>	1,22%	-3,27% ***	-6,33% ***	-3,02% *
<b>Fundamental II Completo</b>	2,57%	-0,74% **	0,18%	0,28%
<b>Fundamental II Incompleto</b>	-0,16%	-1,61% ***	-1,40% **	-1,25%
<b>Ignorado</b>	0,07%	1,71% **	0,50%	0,00%
<b>Sem Escolaridade Superior Completo</b>	0,81%	0,17%	1,92%	16,11% ***
	10,78% **	-1,16%	-0,05%	-4,04%

Fonte: Elaboração Própria

Os resultados apresentados mostram a relação entre mudanças climáticas, fatores socioeconômicos e raciais na determinação da mortalidade infantil no Brasil. A influência negativa do SPEI para todas as raças reforça o impacto das condições climáticas adversas, como secas, na vulnerabilidade infantil, especialmente entre crianças pardas, o que evidencia disparidades raciais no enfrentamento de fatores ambientais. Além disso, variáveis como escolaridade da mãe e peso ao nascer apontam para a importância de intervenções que promovam acesso à educação e cuidados pré-natais como estratégias-chave para reduzir a mortalidade infantil. Por fim, a significância dos coeficientes relacionados ao sexo e às inconsistências nos registros indica a necessidade de aprimorar políticas públicas sensíveis a questões de gênero e qualidade de dados, visando maior equidade e eficácia na redução desse indicador de saúde pública.

## 4.1 GRANDES REGIÕES

A Tabela 10 apresenta os resultados das regressões pelas grandes regiões, no mesmo modo que as regressões por raça e utilizando a equação 3 da Tabela 7. Esse processo quis avaliar melhor as diferenças regionais do Brasil permitindo identificar especificidades locais que podem não ser captadas em uma análise nacional agregada.

Tabela 10 – Resultados por Grandes Regiões

Regiões	Norte	Nordeste	Centro Oeste	Sudeste	Sul
<b>Intercept</b>	0,3091*** 0,089	0,2585 0,16	0,0138 0,166	0,0951 0,151	0,3499 0,376
<b>SPEI</b>	-0,0216 0,014	-0,0142 0,009	0,0039 0,009	-0,0105** 0,005	- 0,02000** 0,008
<b>Ignorado</b>	2,3560*** 0,388	1,6364*** 0,581	3,5076*** 0,94	2,7941*** 0,494	5,0811*** 1,275
<b>Masculino</b>	0,1413*** 0,015	0,1681*** 0,021	0,1663*** 0,032	0,1247*** 0,021	0,1078** 0,044
<b>Branca</b>	-0,1063 0,093	-0,0622 0,121	0,3575 0,242	-0,0699 0,095	0,0486 0,345
<b>Indígena</b>	-0,0472 0,112	-0,1321 0,12	-0,0195 0,222	-0,4912 0,371	-0,4421 0,456
<b>Parda</b>	0,1393 0,106	0,2026 0,124	0,4265* 0,257	-0,0374 0,141	-0,0933 0,31
<b>Preta</b>	- 0,2199*** 0,045	-0,1367 0,117	0,0585 0,215	- 0,3154*** 0,082	-0,1853 0,273
<b>Peso</b>	- 0,0007*** 0	- 0,0007*** 0	-0,0008*** 0	- 0,0006*** 0	- 0,0008*** 0
<b>Fundamental I Completo</b>	- 0,3724*** 0,046	-0,2005** 0,091	-0,1953*** 0,037	- 0,1635*** 0,03	-0,1894* 0,107
<b>Fundamental I Incompleto</b>	- 0,4539*** 0,044	-0,4909*** 0,057	-0,7463** 0,074	-0,1111* 0,061	-0,1436 0,113
<b>Fundamental II Completo</b>	-0,0683 0,071	0,0731* 0,043	-0,1059*** 0,026	-0,0648** 0,028	0,305 0,025
<b>Fundamental II Incompleto</b>	- 0,2439*** 0,075	-0,031 0,053	-0,1860*** 0,021	- 0,1218*** 0,021	- 0,0981*** 0,008
<b>Ignorado</b>	-0,0407 0,139	0,0989 0,088	0,1429** 0,058	0,1183 0,109	0,1159 0,177
<b>Sem Escolaridade</b>	-0,1544	0,0273	0,5038***	0,3952*	0,0434

	0,358	0,209	0,059	0,209	0,733
<b>Superior</b>	0,0753	0,1278	-0,0078	-0,327	0,4248***
<b>Completo</b>	0,179	0,224	0,221	0,236	0,128
	-	-	-	-	-
<b>Idade Mae</b>	0,0075***	-0,0056***	-0,0099***	0,0045***	0,0055***
	0,002	0,002	0,003	0,001	0,001
<b>FE Trimestre</b>	Yes	Yes	Yes	Yes	Yes
<b>FE Estado</b>	Yes	Yes	Yes	Yes	Yes
<b>AIC</b>	115058	219240	66026	277324	116024
<b>BIC</b>	115315	219534	66240	277569	116241

Fonte: Elaboração Própria

Um dos principais resultados observados foi a significância estatística do SPEI apenas para as regiões Sudeste e Sul. Esse valor pode estar correlacionado com as secas enfrentadas nos últimos anos que alteraram o clima dessas regiões, mas também pode ser alguma vulnerabilidade socioeconômica ou ambiental mais difícil de ser capturada.

A literatura de Confalonieri, Marinho e Rodriguez (2009) e Froes Asmus et al. (2016) relatam que as regiões do Norte e Nordeste sofrem com maiores níveis de contaminações por poluentes, mercúrio por exemplo na região amazônica, ou no caso do primeiro artigo, índices de vulnerabilidade geral elevados comparado as regiões mais ao sul, o que podem afetar a estimativa deixando-a mais turva e menos significativa. Importante ressaltar, entretanto, que a ausência de significância estatística não implica que essas regiões não sejam afetadas pelas condições climáticas. Pelo contrário, os resultados podem indicar que a abordagem utilizada não captura adequadamente a complexidade dos fatores que impactam as regiões Norte e Nordeste, frequentemente caracterizadas por condições de pobreza e desigualdades estruturais que exercem um peso considerável sobre os desfechos de saúde e mortalidade. Esse ponto reforça a necessidade de abordagens mais específicas e integradas que considerem os múltiplos fatores inter-relacionados nessas regiões.

Além disso, um fator apresentado que difere do resultado a nível Brasil é a significância estatística da raça preta para as regiões Norte e Sudeste, porém, diminuindo a probabilidade de mortalidade. É um fator positivo e que não corrobora com os autores apresentados ao longo do trabalho, porém, as causas que levam a esse fenômeno são incertas, pois, de acordo com o IBGE a expectativa de vida da população preta no país é menor que a média. Esse tipo de resultado leva a novos caminhos a serem descobertos dentro dessa área científica em busca das razões que levam a cenários assim apresentados.

A análise também reforça a importância das desigualdades educacionais como fator determinante na mortalidade, com destaque para a baixa escolaridade da mãe. Nas regiões analisadas, observou-se que mães com ensino fundamental incompleto ou sem escolaridade apresentam associações negativas e significativas com o desfecho analisado. Esses resultados corroboram a literatura nacional e internacional, que aponta a educação materna como um dos principais determinantes de saúde infantil, influenciando tanto a nutrição quanto o acesso aos serviços de saúde e informações básicas de cuidado.

Em termos gerais, os resultados da Tabela 10 apontam para uma realidade complexa e multifacetada nas diferentes regiões brasileiras. Enquanto fatores climáticos e de raça se destacam em algumas regiões, as desigualdades sociais e educacionais permanecem como determinantes amplamente consistentes em todas as áreas. Os achados destacam a importância de políticas públicas sensíveis às especificidades locais, reconhecendo que intervenções generalistas podem não ser eficazes para abordar as desigualdades regionais no Brasil. Além disso, resultados inesperados, como o impacto positivo observado para a população preta no Norte e Sudeste, indicam a necessidade de investigações adicionais para compreender melhor os fatores subjacentes, contribuindo para o avanço do conhecimento científico na área e para a formulação de políticas mais justas e eficazes.

## 5 CONCLUSÕES

O trabalho tem como seu objetivo identificar o impacto das mudanças climáticas na mortalidade infantil brasileira utilizando os dados do SUS e do SPEI. Os resultados foram satisfatórios na medida que o parâmetro do indicador de mudança climática se mostrou consistente e significativo ao longo da estratégia de identificação, porém, esse tipo de análise mostra somente uma parte do espectro, e não um determinante, que leva a morte de milhares de crianças ao longo do período da amostra. França e Lansky (2008) afirmam que não são somente fatores biológicos e ambientais os determinantes da probabilidade de óbito, a necessidade de um acesso digno a infraestrutura e serviços de saúde durante o período pré-natal e pós nascimento também são determinantes essenciais. Além deles, Currie (2020) apresenta resultados sobre o impacto significativo do seguro de saúde público nos Estados Unidos para minorias e a população de baixa renda e que enfatiza o artigo de Brown, Kowalski e Lurie (2020) “Eles descobriram que elegibilidade de seguro saúde na infância reduz deficiências, mortalidade, ainda aumenta a renda futura desses jovens adultos e sua contribuição nos impostos. Muito do efeito sobre os salários é derivado de uma maior probabilidade de estar na força de trabalho”(CURRIE, 2020, p.454).

A mudança climática é um evento que exige um esforço coletivo imensurável para ser revertido. Até esse dia o que pode ser feito é propiciar as melhores condições de cuidado para as crianças do país seguindo as ideias já presentes na instituição do SUS, mas também considerando a granularidade populacional do Brasil e as dificuldades presentes em cada região.

A expansão das pesquisas econômicas voltadas a saúde infantil é um indicador do quão importante é para os governos que possa oferecer boas condições de vida para esse pequeno cidadão. Currie (2020, p.461) conclui “Crianças mais saudáveis vivem mais e mais saudáveis, conseguem melhores níveis de educação e ganham salários melhores”, e acredito que esse seja o melhor objetivo que deve ser aspirado para os filhos do Brasil.

Para os trabalhos futuros, é interessante avaliar a exposição ao longo do tempo, pois, na estimativa do estudo, o quesito analisado foi o perigo semanal, ou seja, efeitos de curto prazo e seria interessante poder entender os efeitos da exposição a variações climáticas no longo prazo, tanto no agregado dos primeiros meses de vida e ao longo do período neonatal. Esse tipo de contribuição é fundamental para a forma como é visto o

impacto, prevenção e estratégias que diminuam as consequências das mudanças climáticas.

## REFERÊNCIAS

ABADIE, A. et al. When Should You Adjust Standard Errors for Clustering? **Quarterly Journal of Economics**, v. 138, n. 1, 2023.

ALBERT, C.; BUSTOS, P.; PONTICELLI, J. The Effects of Climate Change on Labor and Capital Reallocation. **SSRN Electronic Journal**, 2021.

BAKKENSEN, L. A.; MA, L. Sorting over flood risk and implications for policy reform. **Journal of Environmental Economics and Management**, v. 104, 2020.

BRASIL. **Sistema de Informações sobre Mortalidade-SIM Consolidação da base de dados de 2011**. Brasília: [s.n.].

BRASIL. **DATASUS (Departamento de Informática do SUS)**. Ministério da Saúde, , 2022.

BROOKS, W.; DONOVAN, K. Eliminating Uncertainty in Market Access: The Impact of New Bridges in Rural Nicaragua. **Econometrica**, v. 88, n. 5, 2020.

BROWN, D. W.; KOWALSKI, A. E.; LURIE, I. Z. Long-term impacts of childhood medicaid expansions on outcomes in adulthood. **Review of Economic Studies**, v. 87, n. 2, 2020.

BURKE, M.; EMERICK, K. Adaptation to climate change: Evidence from US agriculture. **American Economic Journal: Economic Policy**, v. 8, n. 3, 2016.

CAIN, L. et al. Recent Findings and Methodologies in Economics Research in Environmental Justice. **Review of Environmental Economics and Policy**, v. 18, n. 1, 2024.

CERVO, A. L. B. P. A. **Metodologia científica: para uso dos estudantes universitários**. 2. ed. São Paulo: McGraw-Hill do Brasil, 1978. v. Parte I, Capítulo 2

CHAY, K. Y.; GREENSTONE, M. **The impact of air pollution on infant mortality: Evidence from geographic variation in pollution shocks induced by a recession. Quarterly Journal of Economics**, 2003.

CHAY, K. Y.; GREENSTONE, M. Does air quality matter? Evidence from the housing market. **Journal of Political Economy**, v. 113, n. 2, 2005.

CONFALONIERI, U. E. C.; MARINHO, D. P.; RODRIGUEZ, R. E. Public health vulnerability to climate change in Brazil. **Climate Research**, v. 40, n. 2–3, 2009.

CURRIE, J. Child health as human capital. **Health Economics (United Kingdom)**, v. 29, n. 4, 2020.

CURRIE, J.; NEIDELL, M.; SCHMIEDER, J. F. Air pollution and infant health: Lessons from New Jersey. **Journal of Health Economics**, v. 28, n. 3, 2009.

CURRIE, J.; RAY, S. H.; NEIDELL, M. Quasi-experimental studies suggest that lowering air pollution levels benefits infants' and children's health. **Health Affairs**, v. 30, n. 12, 2011.

CURRIE, J.; VOORHEIS, J.; WALKER, R. What Caused Racial Disparities in Particulate Exposure to Fall? New Evidence from the Clean Air Act and Satellite-Based Measures of Air Quality. **American Economic Review**, v. 113, n. 1, 2023.

E.F.SCHUMACHER. **Small is Beautiful: Economics as If People Mattered**. London: [s.n.].

FRANÇA, E.; LANSKY, S. Mortalidade Infantil Neonatal no Brasil: Situação, Tendências e Perspectivas. **Abep 2008**, v. 2008, 2008.

FROES ASMUS, C. I. R. et al. **A Systematic Review of Children's Environmental Health in Brazil. Annals of Global Health**, 2016.

GIL, A. C. Como classificar as pesquisas. Como elaborar projetos de pesquisa. **Como Elaborar Projetos de Pesquisa**, 2002.

GILLINGHAM, K.; HUANG, P. Racial Disparities in the Health Effects From Air Pollution: Evidence From Ports. **SSRN Electronic Journal**, 2021.

HAR R. VARIAN. **Microeconomics: A modern approach**. [s.l: s.n.].

HSU, A. et al. Disproportionate exposure to urban heat island intensity across major US cities. **Nature Communications**, v. 12, n. 1, 2021.

IBGE – INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Censo Brasileiro de 2010**. Rio de Janeiro: IBGE, , 2022.

JOYCE, T. J.; GROSSMAN, M.; GOLDMAN, F. An assessment of the benefits of air pollution control: The case of infant health. **Journal of Urban Economics**, v. 25, n. 1, 1989.

LAKATOS, E. M. M. DE A. **Fundamentos de Metodologia Científica**. São Paulo: [s.n.]. Disponível em: <[www.atlasnet.com.br](http://www.atlasnet.com.br)>.

MARX, K. **O Capital: crítica da Economia Política**. [s.l: s.n.]. v. 1

NÍ BHROLCHÁIN, M.; BEAUJOUAN, É. Fertility postponement is largely due to rising educational enrolment. **Population Studies**, v. 66, n. 3, 2012.

NORDHAUS, W. **Climate change: The ultimate challenge for economics**. **American Economic Review**, 2019.

NORDHAUS, W. D. **William D. Nordhaus - Prize Lecture: Climate change: The Ultimate Challenge for Economics**. [s.l: s.n.].

ONU. **Global Environment Outlook 6: Healthy Planet, Healthy People.** Nairobi: [s.n.].

OSTROM, E. **Governing the Commons: The Evolution of Institutions for Collective Action.** Cambridge: [s.n.].

PATZ, J. A. et al. Effects of environmental change on emerging parasitic diseases. **International Journal for Parasitology**, v. 30, n. 12–13, 2000.

PEREDA, P. C.; MENEZES, T. A. DE; ALVES, D. **Climate Change Impacts on Birth Outcomes in Brazil.** [s.l: s.n.]. Disponível em: <<http://www.iadb.org>>.

ROMER, P. M. Increasing Returns and Long-Run Growth. **Journal of Political Economy**, v. 94, n. 5, 1986.

UNITED STATES ENVIRONMENTAL PROTECTION AGENCY (EPA). **Environmental Justice.** Disponível em: <<https://www.epa.gov/environmentaljustice>>. Acesso em: 5 dez. 2024.

U.S. DEPARTMENT OF HEALTH AND HUMAN SERVICES. **News in Health.**

VICENTE-SERRANO, S. M.; BEGUERÍA, S.; LÓPEZ-MORENO, J. I. A multiscalar drought index sensitive to global warming: The standardized precipitation evapotranspiration index. **Journal of Climate**, v. 23, n. 7, 2010.

WOOLDRIDGE. **Introductory econometrics: A modern approach (3rd ed.).** Mason, OH: Thomson South Westren., 2006.

ZIVIN, J. G.; NEIDELL, M. **Environment, health, and human capital.** **Journal of Economic Literature**, 2013.

## APÉNDICE A – EL COLOSO



[Francisco de Goya, El Coloso, Copyright ©Museo Nacional del Prado].

## APÊNDICE B – FORMUÁRIO SUS

Retirado do Relatório do Sistema de Informações Sobre Mortalidade (BRASIL, 2013, p.3)

Os formulários da DO e DN passaram por um processo de mudança discutido e aprovado no Comitê Técnico Assessor – CTA - do SIM e Sinasc no período de 2007 a 2009.

Em 2009, ocorreram duas reuniões do CTA Sim / Sinasc: uma para consolidar as definições sobre o modelo da nova DN, e planejar o teste piloto (em abril), e outra para avaliar os resultados do piloto, e planejar a implantação (em novembro). O teste piloto foi realizado no mês de julho em uma UF de cada região geográfica do país, envolvendo maternidades públicas e privadas, em zona rural e urbana, de 10 municípios, dentro destas UF.

Na reunião de avaliação dos resultados obtidos no piloto, o CTA SIM/Sinasc propôs ajustes em algumas variáveis do novo formulário, e o modelo final foi enviado para impressão no início de 2010. Outro aspecto discutido nesta reunião do CTA tratou da necessidade de se adotar uma estratégia de substituição dos formulários antigos pelos novos, que evitasse a repetição de problemas como os que ocorreram em processos anteriores de mudança de modelos.

Decidiu-se por uma estratégia de substituição gradual dos formulários, prevendo a circulação simultânea dos dois modelos de DN e DO, associado ao uso de uma versão do sistema informatizado capaz de identificar modelo novo e modelo antigo. Conseqüentemente, o sistema a ser usado neste período, deveria exibir telas distintas conforme o modelo informado, e deveria possuir também uma modelagem dos dados que assegurasse a alimentação simultânea de campos novos e antigos, e a conversão de valores captados no modelo novo para valores compatíveis no modelo antigo, quando o campo novo represente apenas uma mudança na forma de coleta de uma variável já existente. Por exemplo, a idade gestacional, que passou a ser captada em semanas de gestação no novo formulário, é gravada em semanas em um campo novo, e simultaneamente é também armazenada no campo antigo que grava idade gestacional em intervalos de semanas, para assegurar a continuidade das séries históricas.

Portanto, para dar encaminhamento à decisão de substituição gradual dos formulários o MS distribuiu em 2010 uma remessa de formulários antigos para ser utilizado até o final do ano, e uma 2ª remessa de formulários novos, distribuída no início

do 2º semestre de 2010, junto com uma orientação trabalhada em reunião nacional dos sistemas, de recolhimento gradual dos formulários antigos, e que a partir de janeiro de 2011, fosse utilizado preferencialmente os formulários novos.

Quadro 1 com as regras de conversão do campo escolaridade em séries para escolaridade em anos, para fins de divulgação durante o período de transição do uso dos modelos antigos e novos do formulário da Declaração de óbito, e futura forma de divulgação, quando o formulário novo for predominante na base de dados.

Quadro 1 – Regras de Conversão

COLETA EM DOIS CAMPOS DO NOVO FORMULÁRIO			CONVERSÃO PARA O CAMPO ANTIGO - anos de escolaridade				FUTURA FORMA DE DIVULGAÇÃO, COM BASE NA COLETA FEITA PELO NOVO FORMULÁRIO	
Nível	descreve nível	Série	Escolar agregado 2	Descreve escolar agregado 2	Escolar agregado1	Descreve escolar agregado1		
0	Sem escolaridade	desabilita	1	Nenhuma	00	Sem escolaridade		
1	Fundamental I (1a a 4a serie)	1	2	De 1 a 3	01	Fundamental I incompleto		
1	Fundamental I (1a a 4a serie)	2	2	De 1 a 3	01	Fundamental I incompleto		
1	Fundamental I (1a a 4a serie)	3	2	De 1 a 3	01	Fundamental I incompleto		
1	Fundamental I (1a a 4a serie)	4	3	De 4 a 7	02	Fundamental I completo		
1	Fundamental I (1a a 4a serie)	branco	2	De 1 a 3	10	Fundamental I incompleto ou inespecificado		
2	Fundamental II (5a a 8a serie)	5	3	De 4 a 7	03	Fundamental II incompleto		
2	Fundamental II (5a a 8a serie)	6	3	De 4 a 7	03	Fundamental II incompleto		
2	Fundamental II (5a a 8a serie)	7	3	De 4 a 7	03	Fundamental II incompleto		
2	Fundamental II (5a a 8a serie)	8	4	De 8 a 11	04	Fundamental II completo		
2	Fundamental II (5a a 8a serie)	branco	3	De 4 a 7	11	Fundamental II incompleto ou inespecificado		
3	Médio (antigo 2o grau)	1	4	De 8 a 11	05	Ensino médio incompleto		
3	Médio (antigo 2o grau)	2	4	De 8 a 11	05	Ensino médio incompleto		
3	Médio (antigo 2o grau)	3	4	De 8 a 11	06	Ensino médio completo		
3	Médio (antigo 2o grau)	branco	4	De 8 a 11	12	Ensino médio incompleto ou inespecificado		
4	Superior incompleto	desabilita	5	De 12 ou mais	07	Superior incompleto		
5	Superior completo	desabilita	5	De 12 ou mais	08	Superior completo		
9	Ignorado	desabilita	9	Ignorado	09	Ignorado		
branco	branco	desabilita	branco	não informado	branco	não informado		



<b>Fundamental I Completo</b>							-	-	-	-
							0,3609***	0,3634***	0,3724***	0,3743***
							0,04	0,041	0,046	0,045
<b>Fundamental I Incompleto</b>							-	-	-	-
							0,4566***	0,4591***	0,4539***	0,4545***
							0,039	0,039	0,044	0,043
<b>Fundamental II Completo</b>							-0,0851	-0,0867	-0,0683	-0,0687
							0,076	0,076	0,071	0,071
<b>Fundamental II Incompleto</b>							-	-	-	-
							0,2537***	0,2543***	0,2439***	0,2432***
							0,083	0,082	0,075	0,076
<b>Ignorado</b>							-0,0435	-0,0453	-0,0407	-0,0413
							0,146	0,146	0,139	0,139
<b>Sem Escolaridade</b>							-0,1917	-0,1847	-0,1544	-0,1568
							0,391	0,38	0,358	0,363
<b>Superior Completo</b>							0,0335	0,0316	0,0753	0,0747
							0,194	0,198	0,179	0,175
<b>Mother_Age</b>							-	-	-	-
							0,0075***	0,0076***	0,0075***	0,0073***
							0,002	0,002	0,002	0,002
<b>FE Quarter</b>	No	Yes	Yes	No	Yes	Yes	No	Yes	Yes	Yes
<b>FE State</b>	No	No	Yes	No	No	Yes	No	No	Yes	Yes
<b>AIC</b>	125802	125785	125109	115756	115747	115428	115405	115394	115058	115067
<b>BIC</b>	125822	125834	125218	115845	115865	115606	115573	115592	115315	115324

Figura 7 - Regressão Nordeste

Nordeste				1	2	3	4	5	6	7
<b>Intercept</b>	-	-	-	0,0381	0,0347	0,0394	0,1935	0,2005	0,2585	0,2405
	1,5486***	1,5641***	1,4906***	0,217	0,229	0,183	0,173	0,184	0,16	0,165
	0,102	0,113	0,025							
<b>SPEI</b>	-	-	-	0,0235***	0,0201***	-0,0148*	0,0211***	0,0185***	-0,0142	0,0194
	0,0228***	-0,0177**	-0,01	0,006	0,006	0,008	0,007	0,007	0,009	0,011
	0,007	0,007	0,011							
<b>Ignorado</b>				1,6637***	1,6657***	1,6583***	1,6357***	1,6370***	1,6364***	1,6356***
				0,568	0,564	0,588	0,565	0,561	0,581	0,582
<b>Masculino</b>				0,1718***	0,1710***	0,1759***	0,1642***	0,1634***	0,1681***	0,1681***
				0,018	0,018	0,019	0,02	0,02	0,021	0,021
<b>Branca</b>				-0,0495	-0,0513	-0,0376	-0,0772	-0,0779	-0,0622	-0,0626
				0,154	0,153	0,136	0,138	0,136	0,121	0,121
<b>Indígena</b>				-0,2418	-0,2425	-0,2114	-0,1563	-0,1582	-0,1321	-0,1306
				0,157	0,16	0,134	0,134	0,136	0,12	0,121
<b>Parda</b>				0,2285	0,2271	0,223	0,2035	0,203	0,2026	0,2025
				0,152	0,151	0,142	0,133	0,132	0,124	0,125
<b>Preta</b>				-0,1417	-0,1403	-0,1706	-0,1116	-0,111	-0,1367	-0,1368
				0,132	0,132	0,133	0,113	0,113	0,117	0,117
<b>Weight</b>				-	-	-	-	-	-	-
				0,0008***	0,0008***	0,0007***	0,0007***	0,0007***	0,0007***	0,0007***
				0	0	0	0	0	0	0
<b>Fundamental I Completo</b>							-	-	-0,2005**	-0,2003**
							0,2318***	0,2289***	0,091	0,091
							0,077	0,075		

<b>Fundamental I Incompleto</b>							-	-	-0,4909***	-
							0,5349***	0,5315***		0,4902***
							0,039	0,038	0,057	0,057
<b>Fundamental II Completo</b>							0,0757*	0,0760*	0,0731*	0,0742*
							0,042	0,041	0,043	0,043
<b>Fundamental II Incompleto</b>							-0,037	-0,0359	-0,031	-0,0311
							0,048	0,048	0,053	0,054
<b>Ignorado</b>							0,11	0,1103	0,0989	0,1005
							0,092	0,092	0,088	0,087
<b>Sem Escolaridade</b>							0,0856	0,0859	0,0273	0,0288
							0,248	0,25	0,209	0,208
<b>Superior Completo</b>							0,0939	0,0989	0,1278	0,132
							0,237	0,236	0,224	0,224
<b>Mother_Age</b>							-	-	-0,0056***	-
							0,0053***	0,0054***		0,0056***
							0,002	0,002	0,002	0,002
<b>FE Quarter</b>	No	Yes	Yes	No	Yes	Yes	No	Yes	Yes	Yes
<b>FE State</b>	No	No	Yes	No	No	Yes	No	No	Yes	Yes
<b>AIC</b>	244112	243992	242019	221327	221278	220342	219991	219958	219240	219243
<b>BIC</b>	244133	244044	242156	221421	221404	220552	220169	220168	219534	219537

Figura 8 - Regressão Centro-Oeste

Centro-Oeste				1	2	3	4	5	6	7
<b>Intercept</b>	-	-	-	-0,2465	-0,2389	-0,2897	0,0526	0,0601	0,0138	0,0364
	1,5951***	1,5739***	1,4792***	0,295	0,274	0,267	0,225	0,183	0,166	0,188
<b>SPEI</b>	-0,0123	-0,0137	-0,0094	0,0038	0,0028	0,0057	0,0019	0,001	0,0039	-0,019
	0,019	0,018	0,017	0,013	0,01	0,01	0,012	0,009	0,009	0,041
<b>Ignorado</b>				3,5509***	3,5545***	3,5230***	3,5300***	3,5334***	3,5076***	3,5041***
				0,881	0,879	0,898	0,927	0,926	0,94	0,94
<b>Masculino</b>				0,1772***	0,1765***	0,1710***	0,1724***	0,1716***	0,1663***	0,1661***
				0,032	0,032	0,029	0,034	0,034	0,032	0,031
<b>Branca</b>				0,3189	0,3253	0,3288	0,3603*	0,3662*	0,3575	0,3539
				0,268	0,261	0,285	0,213	0,208	0,242	0,245
<b>Indígena</b>				-0,1742	-0,169	-0,0609	-0,1057	-0,1009	-0,0195	-0,0244
				0,316	0,312	0,273	0,251	0,249	0,222	0,225
<b>Parda</b>				0,3885	0,3946	0,3838	0,444*	0,4497**	0,4265*	0,4223
				0,28	0,274	0,298	0,232	0,229	0,257	0,259
<b>Preta</b>				0,0134	0,0208	-0,0012	0,0869	0,0939	0,0585	0,0531
				0,216	0,213	0,229	0,207	0,209	0,215	0,212
<b>Weight</b>				0,0008***	0,0008***	0,0008***	0,0008***	0,0008***	0,0008***	0,0008***
				0	0	0	0	0	0	0
<b>Fundamental I Completo</b>							-	-	-	-
							0,2054***	0,2044***	0,1953***	0,1942***
							0,017	0,022	0,037	0,038
<b>Fundamental I Incompleto</b>							-0,1463**	-0,1458*	-0,7463**	-0,1454**
							0,074	0,075	0,074	0,072

<b>Fundamental II</b>										
<b>Completo</b>										
<b>Fundamental II</b>										
<b>Incompleto</b>										
<b>Ignorado</b>										
<b>Sem</b>										
<b>Escolaridade</b>										
<b>Superior</b>										
<b>Completo</b>										
<b>Mother_Age</b>										
<b>FE Quarter</b>	No	Yes	Yes	No	Yes	Yes	No	Yes	Yes	Yes
<b>FE State</b>	No	No	Yes	No	No	Yes	No	No	Yes	Yes
<b>AIC</b>	72687	72686	72333	66264	66268	66138	66118	66122	66026	66025
<b>BIC</b>	72706	72733	72407	66348	66380	66277	66276	66308	66240	66238

Figura 9 - Regressão Sudeste

<b>Sudeste</b>				<b>1</b>		<b>2</b>		<b>3</b>		<b>4</b>	
<b>Intercept</b>	-	-	-	-0,1553	-0,0682	-0,0289	-0,0307	0,0557	0,0951	0,0636	
	1,5223***	1,4179***	1,5161***	0,166	0,162	0,169	0,165	0,154	0,151	0,159	
	0,037	0,029	0,016								
<b>SPEI</b>	-0,0051	-0,01***	-0,0073*	-	-	-0,01**	-	-	-0,0105**	0,0321***	
	0,003	0,004	0,004	0,0085***	0,0125***	0,005	0,0091***	0,0131***	0,005	0,012	
				0,003	0,003	0,003	0,003	0,003	0,005	0,012	
<b>Ignorado</b>				2,7971***	2,8067***	2,7953***	2,7959***	2,8057***	2,7941***	2,7926***	
				0,507	0,499	0,491	0,51	0,501	0,494	0,494	
<b>Masculino</b>				0,1260***	0,1276***	0,1284***	0,1223***	0,1239***	0,1247***	0,1242***	
				0,022	0,02	0,021	0,022	0,021	0,021	0,021	
<b>Branca</b>				-0,1057	-0,1028	-0,0968	-0,0788	-0,0768	-0,0699	-0,0747	
				0,103	0,099	0,099	0,098	0,094	0,095	0,094	
<b>Indígena</b>				-0,5431	-0,5378	-0,5439	-0,4902	-0,4846	-0,4912	-0,4886	
				0,385	0,385	0,378	0,383	0,381	0,371	0,372	
<b>Parda</b>				-0,0699	-0,0673	-0,0737	-0,0324	-0,0309	-0,0374	-0,0421	
				0,132	0,13	0,146	0,127	0,126	0,141	0,139	
<b>Preta</b>				-	-	-	-	-	-	-	
				0,3619***	0,3606***	0,3492***	0,3277***	0,3271***	0,3154***	0,3203***	
				0,06	0,057	0,076	0,067	0,064	0,082	0,08	
<b>Weight</b>				-	-	-	-	-	-	-	
				0,0006***	0,0006***	0,0006***	0,0006***	0,0006***	0,0006***	0,0006***	
				0	0	0	0	0	0	0	
<b>Fundamental I Completo</b>							-	-	-	-	
							0,1617***	0,1601***	0,1635***	0,1634***	
							0,034	0,033	0,03	0,029	

<b>Fundamental I Incompleto</b>							-0,1072	-0,1082*	-0,1111*	-0,1122*
							0,069	0,065	0,061	0,06
<b>Fundamental II Completo</b>							-0,0623**	-0,0625**	-0,0648**	-0,0643**
							0,029	0,029	0,028	0,029
<b>Fundamental II Incompleto</b>							-	-	-	-
							0,1219***	0,1198***	0,1218***	0,1225***
							0,02	0,02	0,021	0,021
<b>Ignorado</b>							0,1185	0,1168	0,1183	0,1182
							0,111	0,109	0,109	0,108
<b>Sem Escolaridade</b>							0,3734*	0,3834*	0,3952*	0,4026*
							0,211	0,199	0,209	0,207
<b>Superior Completo</b>							-0,3109	-0,3281	-0,327	-0,324
							0,231	0,241	0,236	0,235
<b>Mother_Age</b>							-	-	-	-
							0,0044***	0,0044***	0,0045***	0,0044***
							0,001	0,001	0,001	0,001
<b>FE Quarter</b>	No	Yes	Yes	No	Yes	Yes	No	Yes	Yes	Yes
<b>FE State</b>	No	No	Yes	No	No	Yes	No	No	Yes	Yes
<b>AIC</b>	297885	297625	297458	277898	277727	277629	277599	277432	277324	277313
<b>BIC</b>	297906	297679	297544	277994	277855	277789	277780	277645	277569	277559

Figura 10 - Regressão Sul

Sul	1			2			3			4
<b>Intercept</b>	-	-	-	-0,0241	0,1637	0,2155	0,1146	0,3059	0,3499	0,339
	1,6373***	1,4898***	1,4730***	0,386	0,372	0,326	0,421	0,416	0,376	0,386
	0,055	0,048	0,006							
<b>SPEI</b>	-0,0138*	-0,0171**	-	-0,0165*	-0,0195**	-0,0188**	-0,0176*	-0,0205**	-	0,0069
	0,008	0,008	0,0171***	0,01	0,009	0,007	0,1	0,009	0,02000**	0,033
			0,006							
<b>Ignorado</b>				5,0921***	5,0590***	5,0955***	5,0747***	5,0439***	5,0811***	5,0806***
				1,269	1,263	1,261	1,282	1,277	1,275	1,271
<b>Masculino</b>				0,1085**	0,1108**	0,1119**	0,1043**	0,1064**	0,1078**	0,1073**
				0,045	0,047	0,047	0,043	0,045	0,044	0,044
<b>Branca</b>				0,0773	0,0371	0,0155	0,1095	0,069	0,0486	0,0568
				0,371	0,355	0,354	0,357	0,346	0,345	0,349
<b>Indígena</b>				-0,4729	-0,5402	-0,5396	-0,3729	-0,4435	-0,4421	-0,4345
				0,502	0,505	0,506	0,449	0,454	0,456	0,463
<b>Parda</b>				-0,0851	-0,1263	-0,1391	-0,0382	-0,0803	-0,0933	-0,085
				0,336	0,321	0,32	0,321	0,31	0,31	0,313
<b>Preta</b>				-0,201	-0,2456	-0,2216	-0,1653	-0,21	-0,1853	-0,1777
				0,312	0,295	0,295	0,284	0,273	0,273	0,274
<b>Weight</b>				-	-	-	-	-	-	-
				0,0008***	0,0008***	0,0008***	0,0008***	0,0008***	0,0008***	0,0008***
				0	0	0	0	0	0	0
<b>Fundamental I Completo</b>							-0,2028**	-0,1914*	-0,1894*	-0,1906*
							0,099	0,101	0,107	0,106
<b>Fundamental I Incompleto</b>							-0,1582	-0,1422	-0,1436	-0,1457
							0,111	0,112	0,113	0,115

<b>Fundamental</b>							0,0245	0,0315	0,305	0,0303
<b>II Completo</b>							0,027	0,025	0,025	0,027
<b>Fundamental</b>							-	-	-	-
<b>II Incompleto</b>							0,1179***	0,1102***	0,0981***	0,1001***
							0,004	0,008	0,008	0,009
<b>Ignorado</b>							0,0973	0,1036	0,1159	0,1102
							0,175	0,172	0,177	0,18
<b>Sem</b>							0,0494	0,0786	0,0434	0,0425
<b>Escolaridade</b>							0,7	0,707	0,733	0,745
<b>Superior</b>							0,3872***	0,3991***	0,4248***	0,4133***
<b>Completo</b>							0,112	0,117	0,128	0,121
<b>Mother_Age</b>							-	-	-	-
							0,0055***	0,0057***	0,0055***	0,0054***
							0,001	0,001	0,001	0,001
<b>FE Quarter</b>	No	Yes	Yes	No	Yes	Yes	No	Yes	Yes	Yes
<b>FE State</b>	No	No	Yes	No	No	Yes	No	No	Yes	Yes
<b>AIC</b>	126869	126600	126457	116500	116276	116183	116334	116113	116024	116034
<b>BIC</b>	126888	126649	126526	116589	116395	116321	116502	116310	116241	116251

## APÊNDICE D – CÓDIGOS PYTHON

```

import pandas as pd
import numpy as np
from datetime import datetime
from scipy.stats import logistic
import statsmodels.formula.api as smf
import matplotlib.pyplot as plt
import scipy.stats as stats
from scipy.special import expit

# Carregamento do arquivo principal
file_path = PATH
data = pd.read_pickle(file_path)
df = pd.DataFrame(data) # Converte em DataFrame pandas

def convert_to_datetime(date_str):
    """
    Converte uma string de data no formato '%d%m%Y' para datetime.
    Retorna None caso a string seja inválida.
    """
    date_str = date_str.strip() if isinstance(date_str, str) else ''
    try:
        return datetime.strptime(date_str, '%d%m%Y') if date_str else
None
    except ValueError:
        return None

# Aplicar a conversão de datas
df['DTNASC'] = df['DTNASC'].apply(convert_to_datetime)
df['DTOBITO'] = df['DTOBITO'].apply(convert_to_datetime)
# Calcular idade
def calculate_age(row):
    birth_date = convert_to_datetime(row['DTNASC'])
    death_date = convert_to_datetime(row['DTOBITO'])

    if birth_date is not None and death_date is not None:
        age_days = (death_date - birth_date).days
        age_years = age_days // 365
        age_months = (age_days % 365) // 30
        age_days_remaining = (age_days % 365) % 30
        return age_years, age_months, age_days_remaining
    else:
        return None, None, None

# Aplicar o cálculo de idade
df[['Age_Years', 'Age_Months', 'Age_Days']] = df.apply(calculate_age,
axis=1, result_type='expand')

```

```

# Remover linhas com informações incompletas
df_cleaned = df.dropna(subset=['Age_Years', 'Age_Months', 'Age_Days'])

# Conversão de colunas numéricas
df_cleaned['RACACOR'] = pd.to_numeric(df_cleaned['RACACOR'],
errors='coerce')
df_cleaned['GESTACAO'] = pd.to_numeric(df_cleaned['GESTACAO'],
errors='coerce')

# Mapear valores categóricos
sexo_map = {0: 'Ignorado', 1: 'Masculino', 2: 'Feminino'}
racacor_map = {1: 'Branca', 2: 'Preta', 3: 'Amarela', 4: 'Parda', 5:
'Indígena'}
gestacao_map = {
    1: 'Menos de 22 semanas', 2: '22 a 27 semanas', 3: '28 a 31 semanas',
    4: '32 a 36 semanas', 5: '37 a 41 semanas', 6: '42 semanas e mais',
    9: 'Ignorado'
}

df_cleaned['SEXO'] = df_cleaned['SEXO'].map(sexo_map)
df_cleaned['RACACOR'] = df_cleaned['RACACOR'].map(racacor_map)
df_cleaned['GESTACAO'] = df_cleaned['GESTACAO'].map(gestacao_map)

# Função auxiliar para conversão de datas com tratamento de erros
def converter_data(data_str):
    try:
        # Apenas tenta converter se a string não estiver vazia
        return pd.to_datetime(data_str, format='%d%m%Y',
errors='coerce') # 'coerce' transforma erros em NaT
    except (ValueError, TypeError):
        # Retorna NaT (Not a Time) se a conversão falhar
        return pd.NaT

# Converte as datas de nascimento e óbito usando a função auxiliar
df_cleaned['DTNASC'] = df_cleaned['DTNASC'].apply(converter_data)
df_cleaned['DTOBITO'] = df_cleaned['DTOBITO'].apply(converter_data)

# Verifica os tipos para garantir que estão no formato datetime
print(df_cleaned['DTNASC'].dtype) # Deve retornar datetime64[ns]
print(df_cleaned['DTOBITO'].dtype) # Deve retornar datetime64[ns]
df_cleaned['death_weeks'] = (((df_cleaned['DTOBITO'] -
df_cleaned['DTNASC']).dt.days) // 7).fillna(52).astype(int)

# Expandir formato "person-week"
person_week_data = []

for _, row in df_cleaned.iterrows():
    birth_date = row['DTNASC']

```

```

death_weeks = row['death_weeks']
max_weeks = min(death_weeks, 52)

for week in range(max_weeks + 1):
    week_data = row.to_dict()
    week_data['death_indicator'] = int(week == death_weeks)
    week_data['current_age_weeks'] = week
    person_week_data.append(week_data)

person_week_df = pd.DataFrame(person_week_data)

escolaridade_2010_dict = {
    0: "Sem Escolaridade",
    1: "Fundamental I Incompleto",
    2: "Fundamental I Completo",
    3: "Fundamental II Incompleto",
    4: "Fundamental II Completo",
    5: "Ensino Médio Incompleto",
    6: "Ensino Médio Completo",
    7: "Superior Incompleto",
    8: "Superior Completo",
    9: "Ignorado",
    10: "Fundamental I Incompleto ou Inespecífico",
    11: "Fundamental II Incompleto ou Inespecífico",
    12: "Ensino Médio Incompleto ou Inespecífico"
}

# Converter a coluna 'ESMAE' para tipo numérico, substituindo valores
# inválidos por 9 (Ignorado)
person_week_df['ESMAE'] = person_week_df['ESMAE'].replace(["A",
""], None, 9).astype(int)

# Mapear os valores utilizando o dicionário atualizado
# 'escolaridade_2010_dict'
person_week_df['ESMAE'] =
person_week_df['ESMAE'].map(escolaridade_2010_dict)

spei = pd.read_pickle('PATH')
spei['time'] = pd.to_datetime(spei['time'])

# Converter SPEI para semanas e agregar por município e tempo
spei['Week'] = spei['time'].dt.isocalendar().week
grouped_spei = spei.groupby(['CD_MUN', 'Year', 'Month',
'Week']).agg({'spei': 'mean'}).reset_index()

# Ajustar chaves para junção
person_week_df['CODMUNRES'] =
person_week_df['CODMUNRES'].astype(str).str[:6].astype(int)

```

```
grouped_spei['CD_MUN'] =
grouped_spei['CD_MUN'].astype(str).str[:6].astype(int)

# Junção das bases
df = pd.merge(person_week_df, grouped_spei, left_on=['year', 'month',
'semana_do_mes', 'CODMUNRES'],
              right_on=['Year', 'Month', 'Week', 'CD_MUN'], how='inner')

formula = 'death_indicator ~ spei + Race_Color + Sex + Weight +
Mother_Age + Escolaridade_Mae + Quarter + State'
reg_logit = smf.logit(formula=formula, data=df)
results_logit = reg_logit.fit(cov_type='cluster', cov_kwds={'groups':
df['State']})

# Salvar resultados
with open('modelo_logit.txt', 'w') as f:
    f.write(results_logit.summary().as_text())

def calcular_pe_logit(results_logit):
    xb_medio = np.mean(results_logit.fittedvalues)
    factor_logit = logistic.pdf(xb_medio)

    pe_logit = {param: results_logit.params[param] * factor_logit for
param in results_logit.params.index}
    return pe_logit

impactos = calcular_pe_logit(results_logit)
df_impactos = pd.DataFrame(impactos.items(), columns=['Variável',
'Impacto'])
df_impactos.to_excel('impactos_logit.xlsx', index=False)
```