



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
DEPARTAMENTO DE ENGENHARIA DE PRODUÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO

EDUARDO DA SILVA

**MODELAGEM ESTATÍSTICA DE CASOS DE DENGUE EM PERNAMBUCO: UMA
ABORDAGEM COM MODELOS INFLACIONADOS DE ZEROS
E DADOS EM PAINEL**

Recife

2025

EDUARDO DA SILVA

**MODELAGEM ESTATÍSTICA DE CASOS DE DENGUE EM PERNAMBUCO: UMA
ABORDAGEM COM MODELOS INFLACIONADOS DE ZEROS
E DADOS EM PAINEL**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, como requisito parcial para a obtenção do título de Mestre em Engenharia de Produção.

Área de concentração: Gerência da Produção.

Orientadora: Profa. Dra. Máisa Mendonça Silva.

Recife

2025

.Catalogação de Publicação na Fonte. UFPE - Biblioteca Central

Silva, Eduardo da.

Modelagem estatística de casos de dengue em Pernambuco: uma abordagem com modelos inflacionados de zeros e dados em painel / Eduardo da Silva. - Recife, 2025.

94f.: il.

Dissertação (Mestrado) - Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, Programa de Pós-Graduação em Engenharia de Produção, 2025.

Orientação: Maísa Mendonça Silva.

Inclui referências e apêndice.

1. Dengue; 2. Modelos inflacionados de zeros; 3. Dados em painel; 4. Regressão Binomial Negativa; 5. Saúde Pública. I. Silva, Maísa Mendonça. II. Título.

UFPE-Biblioteca Central

EDUARDO DA SILVA

**MODELAGEM ESTATÍSTICA DE CASOS DE DENGUE EM PERNAMBUCO: UMA
ABORDAGEM COM MODELOS INFLACIONADOS DE ZEROS
E DADOS EM PAINEL**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, como requisito parcial para a obtenção do título de Mestre em Engenharia de Produção.

Área de concentração: Gerência da Produção.

Aprovada em: 21/02/2025.

BANCA EXAMINADORA

Participação por videoconferência

Profa. Dra. Máisa Silva Mendonça (Orientadora)

Universidade Federal de Pernambuco

Participação por videoconferência

Profa. Dra. Ana Paula Cabral Seixas Costa (Examinadora Interna)

Universidade Federal de Pernambuco

Participação por videoconferência

Prof. Dr. Erlandson Ferreira Saraiva (Examinador Externo)

Universidade Federal de Mato Grosso do Sul

Aos meus pais, Lenilda Maria e João Paulo (*in memoriam*).

AGRADECIMENTOS

Agradeço a Deus, por sempre direcionar meus passos, concedendo-me saúde, sabedoria e discernimento para tomar decisões corretas. Sua presença foi essencial para superar desafios e alcançar meus objetivos. Sou profundamente grato pelas bênçãos e pelo suporte constante.

Ao Programa de Pós-Graduação em Engenharia de Produção (PPGEP) e a todos os professores que participaram dessa jornada, meu sincero reconhecimento. O suporte, a orientação e o conhecimento oferecidos foram essenciais para o meu desenvolvimento acadêmico e profissional. Agradeço profundamente pelos ensinamentos e pela dedicação de todos.

A minha orientadora, Maisa Mendonça, pela orientação excepcional e apoio constante. Sua experiência, paciência e dedicação foram fundamentais para o meu sucesso. Sou imensamente grato por sua contribuição inestimável e por acreditar no meu potencial.

Aos meus familiares, sou profundamente grato pelo apoio incondicional e pela paciência ao longo desta jornada. Peço desculpas pela minha ausência em momentos importantes e agradeço pela compreensão e pelo suporte contínuo.

Um agradecimento especial ao meu amigo Ewerton, cuja amizade e incentivo foram fundamentais para que eu continuasse com determinação e coragem.

Aos meus amigos Ana Alice, Danilo, Hellen M., Hellen R., João, Juliana, Maria, Matias, Moisés e Yan, meu sincero reconhecimento por todo o apoio e companheirismo. Cada um de vocês contribuiu de maneira única para a realização deste sonho, e sou imensamente grato por ter pessoas tão especiais ao meu lado.

Agradeço profundamente ao meu companheiro Bruno Leonardo, por todo o apoio, paciência e compreensão. Sua presença constante e amor me deram força nos momentos mais desafiadores. Sou muito grato por ter você ao meu lado.

Por fim, expresso minha gratidão à CAPES pela concessão da bolsa, que foi essencial para o desenvolvimento da minha pesquisa. O suporte financeiro e institucional oferecido foi fundamental para a realização deste trabalho, e sou muito grato por essa oportunidade.

“Depois do medo, vem o mundo.”

(Clarice Lispector)

RESUMO

A dengue é uma das arboviroses mais prevalentes no Brasil e sua distribuição espacial apresenta grande heterogeneidade. Em Pernambuco, há variações significativas entre mesorregiões, com municípios que frequentemente apresentam nenhum caso e outros em que 75% das observações registram até dois casos. Diante desse padrão, este estudo empregou modelos de regressão para dados em painel a fim de investigar um conjunto de variáveis que são determinantes na incidência da dengue no estado no período de janeiro de 2020 a junho de 2023, utilizando dados mensais. A partir do teste de equidispersão, observou-se que os modelos baseados na distribuição de Poisson não eram adequados para os dados (p -valor $< 0,05$), justificando assim a necessidade de modelos mais flexíveis. O modelo com distribuição Binomial Negativa e Inflação de Zeros (ZINB) foi considerado o mais adequado, devido à presença de sobredispersão e excesso de zeros nos dados. Os resultados indicam que fatores como temperatura e precipitação influenciam significativamente a incidência de dengue em Pernambuco. Além disso, variáveis estruturais como gestão de resíduos sólidos e acesso a saneamento básico desempenham um papel relevante na probabilidade de um município pertencer ao grupo inflado de zeros, ou seja, de estruturalmente não registrar casos da doença. Este estudo reforça a importância da análise estatística aplicadas na formulação de estratégias de saúde pública e sugere que modelos inflacionados de zeros podem ser ferramentas úteis para identificar padrões de transmissão e direcionar esforços de combate à dengue de forma mais eficiente.

Palavras-chave: Dengue; Modelos inflacionados de zeros; Dados em painel; Regressão Binomial Negativa; Saúde Pública.

ABSTRACT

Dengue is one of the most prevalent arboviral diseases in Brazil, and its spatial distribution exhibits great heterogeneity. In Pernambuco, there are significant variations among mesoregions, with some municipalities frequently reporting no cases and others where 75% of observations record up to two cases. Given this pattern, this study employs panel data regression models to investigate the determinants of dengue in the state during the period from January 2020 to June 2023, using monthly data. Based on the equidispersion test, it was observed that Poisson-based models were not suitable for the data ($p\text{-value} < 0.05$), thus justifying the need for more flexible models. The Zero-Inflated Negative Binomial (ZINB) model was considered the most appropriate due to the presence of overdispersion and excess zeros in the data. The results indicate that factors such as temperature and precipitation significantly influence the incidence of dengue in Pernambuco. Additionally, structural variables such as solid waste management and access to basic sanitation play a relevant role in the probability of a municipality belonging to the zero-inflated group, meaning structurally not registering dengue cases. This study reinforces the importance of statistical analysis in the formulation of public health strategies and suggests that zero-inflated models can be useful tools for identifying transmission patterns and directing dengue control efforts more efficiently.

Keywords: Dengue; Zero-inflated models; Panel data; Negative Binomial Regression; Public Health.

LISTA DE FIGURAS

Figura 1 - Agenda de Saúde Sustentável para as Américas 2018-2030	19
Figura 2 – ODS 6, 12 e 13	20
Figura 3 – Fluxograma da Pesquisa.....	22
Figura 4 – Etapas da Pesquisa	23
Figura 5 – Precipitação média anual por Mesorregião	26
Figura 6 – Temperatura média por Mesorregião	27
Figura 7 – Mesorregiões do estado de Pernambuco	28
Figura 8 – Casos de dengue em 2022	28
Figura 9 – Incidência de casos de dengue por trimestre/ano e Mesorregião.....	29
Figura 10 - Sintomas de Dengue, Chikungunya e Zika.....	34
Figura 11 – Distribuição de Poisson.....	43
Figura 12 - Distribuição de Binomial Negativa	48
Figura 13 – Gráfico de barras da variável dependente	62
Figura 14 – Resíduos ZINB fixo e aleatório.....	67
Figura 15 – Casos de dengue em 2020	84
Figura 16 - Casos de dengue em 2021	84
Figura 17 - Casos de dengue em 2023.....	85

LISTA DE TABELAS

Tabela 1 – Casos de dengue por ano e por Mesorregião em Pernambuco	30
Tabela 2 – Modelo de painel para representação dos dados.....	38
Tabela 3 – Quantidade de observações com zero caso de dengue	63
Tabela 4 – Pressupostos dos modelos	64
Tabela 5 – Estatística descritiva das variáveis.....	64
Tabela 6 – ZINB com efeito aleatório	68
Tabela 7 – ZINB com variáveis significativas	69
Tabela 8 – ZINB com alteração na parte inflacionada	70
Tabela 9 – Temperatura e Precipitação em diferentes mesorregiões	71
Tabela 10 – Inflação de casos por município em 2020	86
Tabela 11 - Inflação de casos por município em 2021	87
Tabela 12 - Inflação de casos por município em 2022	89
Tabela 13 - Inflação de casos por município em 2023	91

LISTA DE ABREVIATURAS E SIGLAS

ABRELPE	Associação Brasileira de Empresas de Limpeza Pública e Resíduos Especiais
ACS	Agente Comunitário de Saúde
APAC	Agência Pernambucana de Águas e Clima
CPRH	Agência Estadual de Meio Ambiente
IDH	Índice de Desenvolvimento Humano
ODS	Objetivos de Desenvolvimento Sustentável
PNRS	Política Nacional de Resíduos Sólidos
RSU	Resíduos Sólidos Urbanos
SNIS	Sistema Nacional de Informações sobre Saneamento
SUS	Sistema Único de Saúde
ZINB	Zero-Inflated Negative Binomial Regression
ZIP	Zero-inflated Poisson
IBGE	Instituto Brasileiro de Geografia e Estatística

SUMÁRIO

1	INTRODUÇÃO	14
1.1	DESCRIÇÃO DO PROBLEMA.....	16
1.2	JUSTIFICATIVA.....	17
1.3	OBJETIVOS.....	20
1.3.1	Objetivo Geral	20
1.3.2	Objetivos Específicos.....	21
1.4	METODOLOGIA DA PESQUISA.....	21
1.4.1	Caracterização da Pesquisa	21
1.4.2	Etapas da Pesquisa	22
1.4.3	Descrição da área de estudo.....	23
1.4.4	Coleta e tratamento de dados	24
1.4.5	Mapeamento dos casos de dengue em Pernambuco.....	27
1.5	ESTRUTURA DO TRABALHO	30
2	BASE CONCEITUAL E REVISÃO DA LITERATURA	32
2.1	BASE CONCEITUAL	32
2.1.1	A Dengue como problema de saúde pública no Brasil.....	32
2.1.2	Condições estruturais e seus impactos na transmissão da Dengue.....	36
2.1.3	Regressão com dados em Painel.....	37
2.1.4	Modelos para dados de contagem com distribuição de Poisson.....	43
2.1.5	Modelo Inflacionada de Zero com distribuição de Poisson	45
2.1.6	Modelo Inflacionado de Zero com distribuição Binomial Negativa	47
2.1.7	Escolha do modelo	50
2.2	REVISÃO DA LITERATURA.....	51
2.2.1	Estudos sobre fatores estruturais e ambientais na transmissão da dengue	51
2.2.2	Estratégias de controle da dengue.....	56
2.2.3	Modelos estatísticos aplicados na modelagem de casos de dengue	57
2.3	SÍNTESE DO ESTADO DA ARTE	60
3	ANÁLISE DE MODELOS ELEGÍVEIS PARA CASOS DE DENGUE	62
4	AJUSTE DOS MODELOS PARA CASOS DE DENGUE.....	66
5	CONSIDERAÇÕES FINAIS.....	73
5.1	LIMITAÇÃO DA PESQUISA.....	74
5.2	SUGESTÕES PARA TRABALHOS FUTUROS.....	75

REFERÊNCIAS	77
APENDICE A – MAPAS DE CALOR PARA CASOS DE DENGUE EM PE	84
APENDICE B – PROBABILIDADES DE INFLAÇÃO POR MUNICÍPIO.....	86

1 INTRODUÇÃO

A dengue é conhecida como uma doença não contagiosa e infecciosa, que é transmitida pelo mosquito *Aedes Aegypt*. Essa doença faz parte de um grupo de doenças denominadas arboviroses, que se caracterizam por serem causadas por vírus transmitidos por vetores artrópodes (Dalbem *et al.*, 2014). No Brasil, o vetor da dengue é a fêmea do mosquito, até o momento são conhecidos quatro sorotipos, sendo: DENV-1, DENV-2, DENV-3 e DENV-4. Caires *et al.* (2024) relataram a possível existência de um quinto sorotipo, porém este foi detectado apenas na Indonésia.

A primeira epidemia de dengue registrada no Brasil ocorreu em 1982, na capital do estado de Roraima. Quatro anos depois, em 1986, novos surtos foram identificados no estado do Rio de Janeiro e em algumas capitais do Nordeste (Brasil, 2009). Desde então, a doença tem se mantido em circulação endêmica, alternando períodos de surtos epidêmicos, o que impacta diretamente o sistema de saúde, sobrecarregando as unidades de atendimento. Essa sobrecarga resulta em um impacto econômico significativo no Sistema Único de Saúde (SUS), aumentando os custos com internações hospitalares, exames laboratoriais, medicamentos, contratação emergencial de profissionais de saúde e campanhas de prevenção e controle do vetor (Silva *et al.*, 2021).

De acordo com Sousa e Paradella (2024), de janeiro de 2014 a de março de 2024, aconteceram, no Brasil, 6.929 mortes confirmadas por dengue, representando uma taxa de letalidade de 0,6%. Nesse período, a taxa anual de mortalidade por dengue foi em média, 0,55 morte por 100.000 habitantes. Por se tratar de um país tropical com clima quente e úmido, o país possui um ambiente propício para proliferação do vetor da dengue. Além disso, outros fatores são determinantes, como: a evolução do vírus; fatores socioeconômicos, recursos governamentais limitados e a urbanização não planejada (Florenzano *et al.*, 2024).

Os casos de dengue em Pernambuco apresentaram um padrão epidemiológico marcante entre 2015 e 2020, refletindo variações sazonais e diferenças demográficas significativas. De acordo com Filho *et al.* (2022), foram notificados 252.695 casos no estado durante esse período, com maior incidência entre mulheres (59%), predominantemente na faixa etária de 20 a 39 anos (36,08%) e em indivíduos pardos (40,5%). O ano de 2015 concentrou 44% das notificações, seguido por 2016 (24,9%), enquanto o menor número de casos ocorreu em 2017 (3,1%). Além disso, identificou-se um padrão sazonal, com aumento expressivo das infecções entre novembro e março, meses de maior temperatura e precipitação, seguido por uma redução significativa

entre abril e julho, o que evidencia a influência direta das condições climáticas na proliferação do *Aedes aegypti* e na dinâmica da transmissão da doença.

Diversos estudos apontam que a ausência ou insuficiência na prestação de serviços de saneamento contribui para a criação de ambientes propícios à proliferação do *Aedes aegypti* (Klafke; Barros; Henning, 2023a; Pereira *et al.*, 2024; Silva; Scalize, 2023). De acordo com Dickin e Schuster-Wallace (2014), uma das principais medidas sanitárias que ajuda a prevenir a proliferação de doenças em zonas urbanas e rurais é a coleta de lixo. Isso devido ao lixo doméstico e urbano proporcionar condições favoráveis de desenvolvimento do mosquito, onde recipientes descartados se enchem de água da chuva e os resíduos sólidos que podem bloquear a drenagem também fornecem importantes habitats para mosquitos. Outro problema é o acesso limitado ou a falta de abastecimento de água, sendo necessário o armazenamento local como tanques, cisternas e barris, que fornecem criadouros de larvas para mosquitos (Teillet *et al.*, 2024).

O lixo também pode ser considerado um agravante para casos de dengue, pois a gestão inadequada de resíduos sólidos urbanos representa um desafio ambiental significativo, impactando diretamente a qualidade de vida nas cidades (Santiago *et al.*, 2023). Segundo o autor, a Política Nacional de Resíduos Sólidos (PNRS) enfrenta dificuldades em sua implementação, o que resulta na disposição inadequada de resíduos. A ineficiência na gestão dos resíduos sólidos, aliada à urbanização acelerada, contribui para a degradação ambiental e pode intensificar problemas de saúde pública como no caso da dengue (Cruvinel *et al.*, 2020a).

O descarte de resíduos sólidos urbanos (RSU) em locais inapropriados é um problema que perpassa por tempos e isso impacta diretamente no meio ambiente, na saúde e na qualidade de vida da população. Segundo dados do Panorama dos Resíduos Sólidos no Brasil, a geração saiu de 60,87 milhões de toneladas em 2010 para 81,8 milhões em 2022, com uma diferença de 20,93 milhões de toneladas. O mesmo estudo diz ainda que cada brasileiro produz, em média, 378,4kg de lixo por ano, o que corresponde a mais de 1kg por dia (ABRELPE, 2022).

À luz dessas discussões e considerando a relevância epidemiológica da dengue, este estudo propõe um ajuste de um modelo de regressão com dados em painel, destacando-se por sua capacidade de analisar informações tanto ao longo do tempo quanto entre diferentes localidades (Wooldridge, 2023). Esse modelo possibilita a identificação das variações temporais dentro de cada município, ao mesmo tempo em que permite comparar diferenças entre eles, proporcionando uma abordagem mais abrangente para compreender a dinâmica da doença (Baltagi, 2021).

Além disso, a modelagem tem como principal objetivo a seleção de variáveis que influenciam a incidência da dengue, permitindo uma melhor compreensão dos fatores associados à sua disseminação. Diante das características dos dados epidemiológicos, como possíveis padrões de sobredispersão e excesso de zeros, este estudo explorará a adequação de modelos de contagem, como o Zero-Inflated Poisson (ZIP) e o Zero-Inflated Negative Binomial (ZINB), cuja viabilidade será analisada empiricamente.

1.1 DESCRIÇÃO DO PROBLEMA

A dengue continua sendo um dos principais desafios de saúde pública no Brasil e, particularmente, no estado de Pernambuco, onde sua incidência não ocorre de forma homogênea. Estudos demonstram que diversos fatores climáticos e estruturais podem influenciar a propagação da doença, tornando essencial uma análise integrada dessas variáveis para compreender melhor essa dinâmica.

Nascimento *et al.* (2024) realizaram um estudo retrospectivo sobre o perfil epidemiológico da dengue em Pernambuco entre 2015 e 2017, analisando a distribuição dos casos por faixa etária, sexo e etnia. Os autores observaram que a maioria dos casos ocorreu em mulheres, principalmente na faixa etária de 20 a 39 anos, e que a incidência foi maior na região metropolitana do estado. Além disso, identificaram que a distribuição dos casos acompanhava períodos de maior pluviosidade.

Mendonça *et al.* (2023) investigaram os fatores associados à mortalidade por dengue e Chikungunya em Pernambuco durante um período epidêmico. O estudo utilizou modelos de regressão logística para identificar que fatores como idade avançada, sexo masculino e presença de comorbidades estavam significativamente associados ao risco de óbito. Os autores destacam a necessidade de análises que levem em conta tanto aspectos individuais quanto estruturais para uma melhor compreensão da gravidade da doença.

Carmo *et al.* (2020) analisaram a relação entre infraestrutura urbana e incidência da dengue, mostrando que municípios com maior densidade populacional e infraestrutura sanitária deficiente apresentavam maior número de casos. Segundo os autores, a precariedade no abastecimento de água e a falta de coleta eficiente de resíduos sólidos podem contribuir significativamente para a proliferação do *Aedes aegypti*, especialmente em períodos chuvosos.

Morais *et al.* (2020) investigaram a influência de fatores climáticos na disseminação da dengue no estado, destacando que a variação na temperatura e na umidade relativa do ar que impacta diretamente a reprodução e a sobrevivência do vetor. O estudo também identificou que,

apesar da relação entre clima e incidência da dengue, outros fatores estruturais podem ter um papel ainda mais determinante na disseminação da doença.

Vasconcelos *et al.* (2024) desenvolveram um estudo em Agrestina-PE avaliando estratégias para o monitoramento da população do *Aedes aegypti* por meio de armadilhas de oviposição. Os resultados sugeriram que a presença de matéria orgânica em criadouros artificiais influencia a densidade do vetor, reforçando a importância de políticas de controle ambiental para a redução dos casos de dengue.

Farias *et al.* (2023) analisaram a co-circulação dos vírus da dengue, Zika e Chikungunya em Recife e investigaram se a introdução dos novos vírus alterou o perfil epidemiológico da dengue. O estudo concluiu que, apesar da co-circulação viral, não houve mudanças significativas no padrão de distribuição da dengue, mas identificou variações na distribuição etária e no perfil clínico dos pacientes.

Embora esses estudos tenham fornecido contribuições para a compreensão da dinâmica da dengue em Pernambuco, nenhum deles utilizou um modelo de regressão com dados em painel para a seleção de variáveis associadas à incidência da doença. As pesquisas existentes adotam abordagens de seção transversal ou temporais, o que limita a capacidade de capturar simultaneamente as variações da dengue no estado.

Diante disso, esta pesquisa propõe o ajuste de um modelo de regressão com dados em painel, permitindo analisar de forma integrada os fatores que determinam a incidência da dengue em Pernambuco no período de janeiro de 2020 a junho de 2023, considerando as variações ao longo do tempo e entre diferentes municípios. As questões norteadoras desta pesquisa, portanto, são: **Quais variáveis determinam a incidência da dengue em Pernambuco e como um modelo de regressão ajustado pode auxiliar nessa análise?**

1.2 JUSTIFICATIVA

A dengue é uma das arboviroses mais prevalentes no Brasil, impactando significativamente a saúde pública e causando altas taxas de morbidade e mortalidade. Estudos anteriores destacam a importância de compreender os fatores climáticos e socioeconômicos que influenciam a incidência da doença. Esta pesquisa visa aprofundar essa compreensão, especificamente no estado de Pernambuco, onde a dengue continua a ser uma preocupação crítica.

Os autores Azevedo, Lorenz e Chiaravalloti-Neto (2020), realizaram uma análise da evolução espaço-temporal dos surtos de dengue no Brasil entre 2000 e 2018, investigando

padrões e tendências de surtos em diferentes regiões. O objetivo foi identificar áreas de alto risco para concentrar esforços de saúde pública e compreender como fatores climáticos e populacionais influenciam a transmissão da dengue. Concluíram que os surtos de dengue variam conforme o tempo e a região, com maior incidência no Nordeste e uma expansão gradual pelo Brasil. A probabilidade de surtos foi maior em regiões com temperaturas elevadas, e a mobilidade populacional e sorotipos circulantes influenciaram os ciclos de transmissão.

Nascimento *et al.* (2020), identificaram que entre 2015 e 2017, o perfil epidemiológico dos casos de dengue em Pernambuco revelou uma predominância entre indivíduos de 20 a 39 anos, com maior incidência em mulheres e na população mulata. Em 2015, houve um número elevado de casos, especialmente nas regiões intermediárias de Recife e Caruaru. Observou-se uma tendência de uniformização nas características demográficas dos casos ao longo dos anos, com uma distribuição mais equitativa entre gêneros e grupos etários, especialmente em casos de dengue sem sinais de alerta, que corresponde à forma mais comum e menos grave da doença, caracterizada por febre alta, dor de cabeça, dores musculares, náusea e manchas vermelhas na pele, sem apresentar complicações como sangramentos ou choque circulatório. Apesar de fatores como temperatura e umidade influenciarem a incidência, a chuva foi identificada como o principal determinante na variação dos casos, ressaltando a necessidade de um entendimento local para a formulação de políticas de saúde pública mais eficazes.

As pesquisas anteriores indicam que fatores como a gestão de resíduos sólidos, condições socioeconômicas e variáveis ambientais estão interligados à incidência de dengue. A proposta de analisar esses fatores de forma integrada através de um modelo de regressão com dados em painel permitirá identificar quais elementos estão significativamente associados à incidência da dengue em Pernambuco, tais como a precipitação, gestão de resíduos sólidos, condições climáticas e estruturais. Essa abordagem fornecerá subsídios para que órgãos de saúde pública possam desenvolver estratégias de controle mais eficazes e direcionadas.

Sendo assim, a análise de dados em painel permitirá explorar a interação entre variáveis, como coleta de resíduos sólidos, condições climáticas e fatores estruturais, proporcionando uma visão mais holística da situação da dengue. Isso poderá auxiliar na identificação de fatores que podem ter sido negligenciadas em estudos anteriores.

Como forma de contribuição social, esta pesquisa é justificada pelo estudo de fatores associados à ocorrência de casos de dengue. Ao investigar as condições que favorecem a proliferação do mosquito transmissor e o impacto de políticas de saneamento e manejo de resíduos sólidos, o estudo fornece subsídios para a criação de estratégias eficazes de combate à dengue, especialmente na saúde e bem-estar da população, de acordo com Objetivos de

Desenvolvimento Sustentável 3. Isso pode gerar benefícios diretos para a sociedade ao possibilitar a transferência de conhecimento com o intuito de ajudar nas formulações de ações sociais mais precisas e direcionadas, reduzindo a incidência de surtos e promovendo a conscientização da população sobre medidas preventivas, objetivo 6 e 7 da Agenda de Saúde Sustentável para as Américas 2018-2030 de acordo com a Figura 1.

Figura 1 - Agenda de Saúde Sustentável para as Américas 2018-2030



Fonte: O Autor (2024).

Nota: Adaptado de Organização Mundial da Saúde (2017).

Como justificativa ambiental, este trabalho se alinha com os Objetivos de Desenvolvimento Sustentável (ODS), especialmente com o ODS 6, Figura 2a, que visa assegurar a gestão sustentável da água e do saneamento; ODS 12, Figura 2b, que busca padrões de consumo e produção sustentáveis. A investigação sobre os fatores ambientais e estruturais no contexto de controle da dengue, pode apoiar a participação comunitária para melhorar o saneamento e a gestão da água, além de contribuir para a redução da geração de resíduos,

promovendo práticas mais sustentáveis e colaborando no combate à mudança climática, ODS 13, Figura 2c.

Figura 2 – ODS 6, 12 e 13



Fonte: Organização das Nações Unidas (2015).

Sob o aspecto financeiro, a pesquisa demonstra a relevância de agir de forma preventiva para minimizar os custos relacionados ao atendimento de pacientes com dengue no Sistema Único de Saúde (SUS), alinhado com o objetivo 8 da Figura 1. A análise dos casos mostra que o investimento em medidas de controle e prevenção pode reduzir substancialmente a sobrecarga no sistema de saúde, resultando em economia de recursos públicos e otimização dos serviços de atendimento. Isso reforça a importância de políticas proativas que reduzam a incidência da doença e o impacto financeiro no setor público.

Destarte, esta pesquisa se justifica não apenas pela relevância da dengue como um problema de saúde pública, mas também pela aplicação de uma abordagem estatística para analisar os fatores que influenciam a incidência da doença. Ao utilizar um modelo já consolidado na literatura em uma análise específica para Pernambuco, este estudo contribui significativamente para a formulação de estratégias de saúde pública mais eficazes no estado.

1.3 OBJETIVOS

Para alcançar os resultados deste trabalho, foi definido um objetivo geral e, em seguida, o desmembramento em objetivos específicos. Essa divisão permite o desenvolvimento por etapas que facilita na construção do trabalho.

1.3.1 Objetivo Geral

O objetivo geral desta pesquisa é ajustar um modelo de regressão com dados em painel para analisar os casos de dengue no Estado de Pernambuco, considerando as diferenças na distribuição da doença entre os municípios e sua evolução ao longo do tempo. A pesquisa busca identificar padrões e fatores determinantes, avaliando o impacto de variáveis estruturais, ambientais e climáticas sobre a incidência da dengue.

1.3.2 Objetivos Específicos

Para atingir o objetivo geral é importante considerar alguns objetivos específicos:

- Analisar a evolução temporal dos casos de dengue nos diferentes municípios de Pernambuco;
- Identificar os fatores estruturais, ambientais e climáticos que influenciam a incidência dos casos;
- Realizar testes estatísticos e selecionar o modelo que mais se adequa aos dados analisados;
- Propor recomendações baseadas nos resultados obtidos para melhorar a prevenção e o combate à dengue em Pernambuco.

1.4 METODOLOGIA DA PESQUISA

A seguir, será apresentada a caracterização da pesquisa, as etapas, a descrição da área de estudo, coleta e tratamento dos dados e algumas análises preliminares da variável de estudo.

1.4.1 Caracterização da Pesquisa

Esta pesquisa tem como finalidade a aplicação de um modelo de regressão com dados em painel para analisar os casos de dengue nos municípios do estado de Pernambuco. O presente estudo seguirá o rigor metodológico quanto à abordagem, natureza, objetivos e procedimentos.

A abordagem dessa pesquisa será tanto quantitativa quanto qualitativa. Na abordagem quantitativa há a mensuração dos dados através da coleta e a análise dos dados numéricos para identificar os resultados (Gil, 2022). De acordo com Cauchick (2022), inicialmente a dedução teórica, em seguida a operacionalização das hipóteses, depois a coleta e o processamento dos dados e no fim a indução que corresponde a análise dos resultados. Esse processo é recursivo e a teoria pode ser alimentada sempre que os resultados forem satisfatórios. Além disso, a abordagem quantitativa deve ser mensurável, de causalidade, de generalização e de replicação. No tocante a abordagem qualitativa procura descrever, decodificar, traduzir, e qualquer outro termo relacionado com o entendimento e não com a frequência de ocorrência das variáveis de determinado fenômeno (Lakatos e Marconi, 2010). Quando ocorre a mistura de métodos

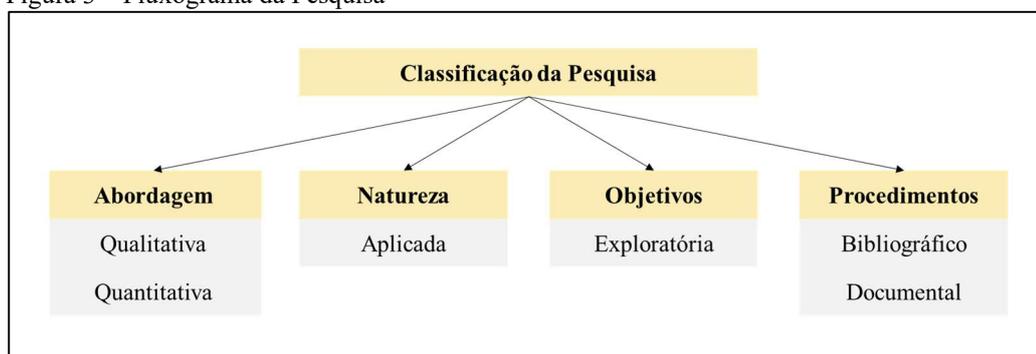
quantitativos e qualitativos, podemos dizer que houve uma pesquisa mista, de natureza *quali-quantitativa*, pois os dados são uma mistura de variáveis e palavras.

A natureza do estudo será aplicada, desta forma concentra-se na resolução de problemas do mundo real, que de acordo com Silva e Menezes (2005), os resultados encontrados terão aplicações práticas e servirão para solução de problemas sociais e de saúde pública. Essa pesquisa é de uso prático para a atividade atual, citando como exemplo de usos: Estudo casos individuais ou específicos sem o objetivo de generalizar; Aponta qualquer variável que faça a diferença desejada; Realiza a busca de alguns fatores que podem ser alterados; Realiza a correção de fatos que são problemáticos; Apresenta relatórios em linguagem comum (Melo, 2014).

Quanto aos objetivos desta pesquisa podem ser exploratórios, descritivos e explicativos. No objetivo exploratório buscou-se levantamentos e estudos bibliográficos que auxiliassem na compreensão do problema. Para o objetivo descritivo buscou-se a descrição do fenômeno e a correlação entre as variáveis. No objetivo explicativo o método experimental foi empregado, servindo para identificação dos fatores que determinam a ocorrência do fenômeno.

Por fim, o procedimento técnico utilizado é o de pesquisa bibliográfica e pesquisa documental, ou seja, são avaliados dados secundários, a diferença entre esses procedimentos é que, no sentido bibliográfico se utiliza da fundamental fruto da contribuição de vários autores, enquanto a pesquisa documental não passou ainda por um tratamento analítico, sendo assim, o resultado analítico será de acordo com os objetivos da pesquisa (Gil, 2002; Matias-Pereira, 2016; Cauchick, 2018). A Figura 3 apresenta o esquema da estrutura metodológica do trabalho.

Figura 3 – Fluxograma da Pesquisa



Fonte: O Autor (2024).

1.4.2 Etapas da Pesquisa

Esta pesquisa foi estruturada em quatro etapas, a saber:

I.Revisão bibliográfica e pesquisa documental: A pesquisa iniciou-se com uma revisão bibliográfica e pesquisa documental, visando compreender o estado da arte sobre o tema estudado. Foram consultadas fontes científicas e bases de dados relevantes para identificar teorias, metodologias e estudos prévios, além de documentos oficiais que subsidiaram a definição das variáveis e do contexto da análise;

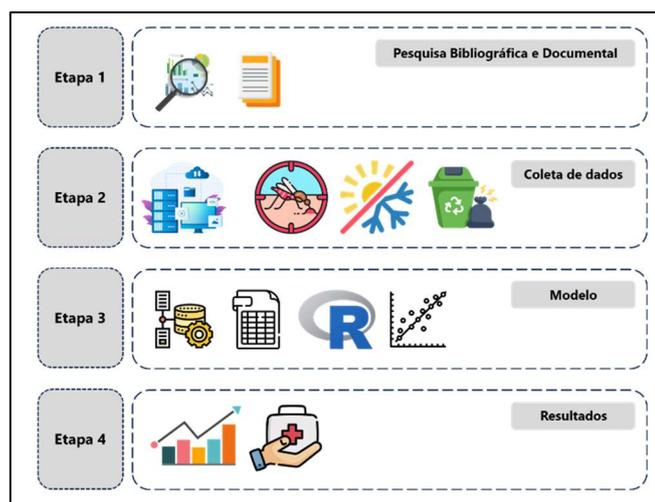
II.Coleta e tratamento de dados: Nesta etapa, foram coletados dados secundários de diversas fontes, incluindo registros climáticos, estruturais e indicadores de saúde pública dos municípios selecionados. Os dados passaram por um processo de tratamento que incluiu a verificação de consistência, remoção de *outliers* e imputação de valores ausentes;

III.Ajustes dos modelos de regressão: Com os dados tratados, foram ajustados modelos de regressão utilizando dados em painel na linguagem R no RStudio que é o ambiente de desenvolvimento integrado;

IV.Análise e validação dos resultados: Os resultados obtidos pelos modelos foram analisados e validados por meio de testes estatísticos, como verificação da significância das variáveis e análise dos resíduos.

As etapas da pesquisa são ilustradas a seguir na Figura 4:

Figura 4 – Etapas da Pesquisa



Fonte: O Autor (2024).

1.4.3 Descrição da área de estudo

Para a realização desta pesquisa, foram selecionados os municípios do estado de Pernambuco, localizado na região Nordeste do Brasil. Pernambuco apresenta uma grande diversidade geográfica e climática, variando desde áreas litorâneas e zonas da mata até regiões

semiáridas do sertão. Esse estado é um dos mais populosos do Nordeste, com uma população estimada de aproximadamente 9,6 milhões de habitantes, distribuída em 184 municípios mais a Ilha de Fernando de Noronha, de acordo com o IBGE (2022). A escolha dos municípios foi feita com base na disponibilidade dos dados.

A ausência de informações para algumas localidades impôs limitações à análise, restringindo o estudo aos municípios que possuíam dados mais completos e confiáveis. Essa limitação ressalta a importância da melhoria na coleta e disponibilidade de dados para uma avaliação mais abrangente das dinâmicas municipais em Pernambuco. Mesmo com essas restrições, a amostra utilizada abrange (107) municípios com diferentes realidades, contribuindo para uma compreensão dos fatores estudados e permitindo a formulação de conclusões e recomendações relevantes para o contexto da dengue.

1.4.4 Coleta e tratamento de dados

Neste estudo, as informações foram coletadas de diversas fontes, cada uma fornecendo perspectivas importantes sobre saúde pública, meio ambiente e climatologia. O recorte temporal considera 4 anos (01/2020 a 06/2023), já o recorte transversal é composto por 185 municípios do estado de Pernambuco. No entanto, importa referir que a análise é limitada por diversas lacunas na informação disponível, o que impossibilitou a inclusão de todas as cidades. Uma breve descrição das variáveis pode ser vista no Quadro 1, que reúne as informações como tipo, descrição e a fonte de onde foram obtidos os dados da pesquisa.

Quadro 1 – Descrição das variáveis do estudo

Variável	Unidade/Tipo	Descrição	Fonte
Dengue	Casos (discreta)	Quantidade de casos de dengue positivos	DATASUS
Temperatura	°C (contínua)	Temperatura média mensal em graus Celsius	APAC
Precipitação	mm (contínua)	Precipitação total mensal em milímetros	APAC
Umidade	% (contínua)	Umidade relativa do ar mensal em porcentagem	APAC
Resíduos Sólidos Urbanos	ton. (contínua)	Quantidade de resíduos sólidos gerados em toneladas por mil habitantes	CPRH

Continua...

Continuação.

Variável	Unidade/Tipo	Descrição	Fonte
Plano Municipal de Saneamento	binária	Indicador binário: 0 = Não possui, 1 = Possui	SNIS
Abastecimento de Água	% (contínua)	Porcentagem da população com acesso a abastecimento de água	SNIS
Esgotamento Sanitário	% (contínua)	Porcentagem da população com acesso a esgotamento sanitário	SNIS
Coleta de Lixo	% (contínua)	Porcentagem da população com acesso à coleta de lixo	SNIS
Agente Comunitário de Saúde	% (contínua)	Cobertura de território	DATASUS

Fonte: O Autor (2024).

Os casos de dengue analisados neste estudo, assim como os dados relacionados aos Agentes Comunitários de Saúde (ACS), foram extraídos do Departamento de Informática do Sistema Único de Saúde (DATASUS). Esse órgão, vinculado à Secretaria de Informação e Saúde Digital (SEIDIGI) do Ministério da Saúde, é responsável por coletar, processar e custodiar dados de saúde no Brasil. O DATASUS desempenha um papel fundamental no suporte às políticas públicas, oferecendo informações que subsidiam análises da situação sanitária, a tomada de decisões baseadas em evidências e a formulação de programas e ações em saúde. Para compreender melhor o comportamento da dengue no estado de Pernambuco mapas de calor e análise de incidência foram elaborados para a próxima seção.

Para os dados de saneamento foram considerados o do Sistema Nacional de Informações sobre Saneamento, que é o maior e mais importante sistema de informações do setor de saneamento brasileiro. Desenvolvido em 1995, o Sistema possui uma base de dados que contém informações e indicadores sobre a prestação de serviços de Água e Esgotos (1995), de Manejo de Resíduos Sólidos Urbanos (2002) e Drenagem e Manejo das Águas Pluviais Urbanas (2015).

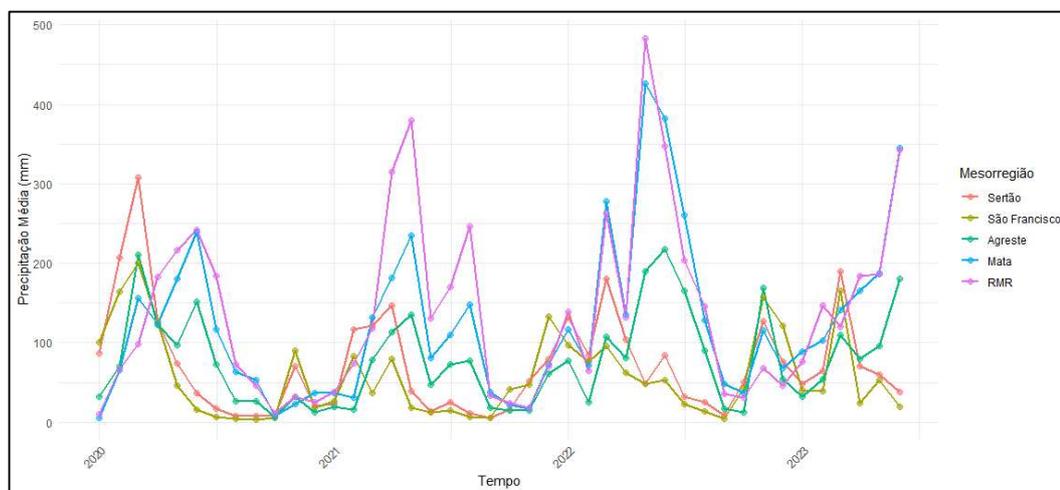
Em consonância com a temática de resíduos sólidos, os dados foram obtidos da Companhia Pernambucana do Meio Ambiente (CPRH). Essa companhia foi criada pela Lei nº 7.276, de 16 de dezembro de 1976, sendo uma sociedade de economia mista vinculada à Secretaria de Ciência, Tecnologia e Meio Ambiente (SECTMA). O Sistema Nacional de Informações sobre Saneamento, disponibiliza dados anuais; no entanto, para a análise de dados mensais, especificamente do estado de Pernambuco, optou-se pelos dados da CPRH, onde foram solicitados através do Registro de Pedido de Acesso à Informação, como resposta, o

órgão enviou os dados de 2020, 2021, 2022 e 2023. Desta forma, não foi possível considerar o ano de 2024.

Por fim, os dados de climatologia (precipitação, temperatura e umidade) foram obtidos da Agência Pernambucana de Águas e Clima (APAC), criada pela Lei Estadual nº 14.028, de 26 de março de 2010. O objetivo da APAC é fortalecer o planejamento e a regulação dos usos múltiplos dos recursos hídricos do estado, além de gerenciar o Sistema Integrado de Gerenciamento dos Recursos Hídricos (SIGRH).

A Apac emite mensalmente um boletim contendo os principais dados referente ao estado. De acordo com a Figura 5 é possível analisar a precipitação média (mm) de janeiro/20 a junho/23 no estado de Pernambuco. É possível observar uma maior precipitação na região metropolitana do estado acompanhada também pela zona da Mata, onde precipitações mais elevadas ocorreram em meados de 2022. Ainda no gráfico, observa-se volumes de chuva elevados na região do Sertão no início de 2020. Por outro lado, as mesorregiões do São Francisco e do Agreste apresentam valores mais baixos ao longo do tempo.

Figura 5 – Precipitação média anual por Mesorregião

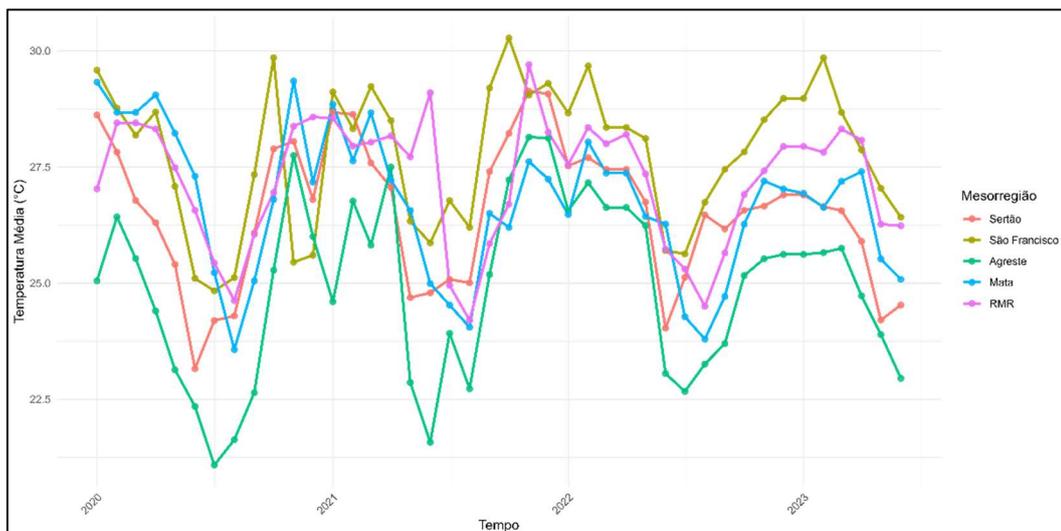


Fonte: O Autor (2024).

Nota: Elaborado a partir dos dados da Apac.

A partir dos dados analisados da Agência Pernambucana de Águas e Clima, também foi possível observar a temperatura média nas mesorregiões na Figura 6. As temperaturas mais altas estão predominantemente na região do São Francisco, onde a média ultrapassou os 30°C no final de 2021. A Região Metropolitana do estado também apresenta temperaturas elevadas ao longo dos anos.

Figura 6 – Temperatura média por Mesorregião



Fonte: O Autor (2024).

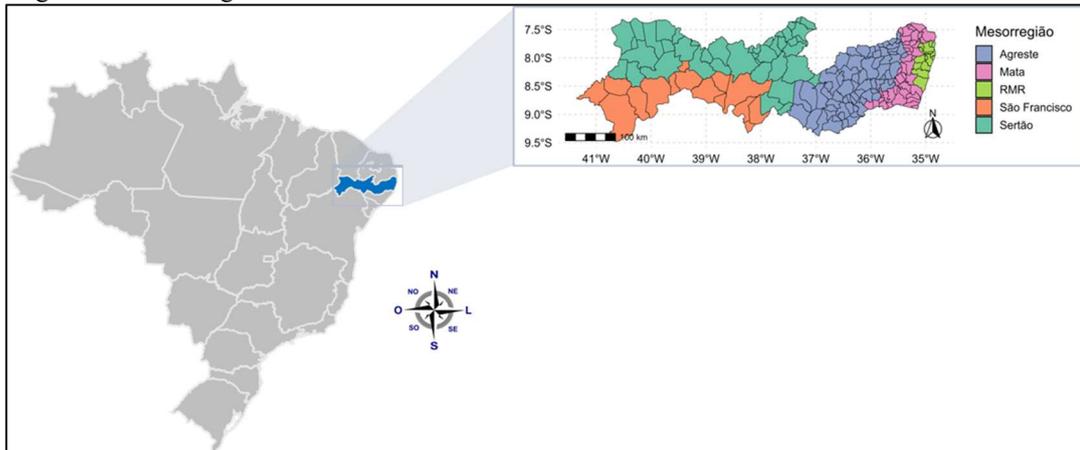
Nota: Elaborado a partir dos dados da Apac.

1.4.5 Mapeamento dos casos de dengue em Pernambuco

Para o mapeamento dos casos de dengue em Pernambuco, utilizou-se o pacote “*geobr*” (versão 1.9.0), que permite o acesso a dados geoespaciais oficiais do Brasil. O *shapefile* correspondente aos limites municipais considerados nesta pesquisa é o de 2022 do Instituto Brasileiro de Geografia e Estatística (IBGE). A partir desses dados, foi possível gerar mapas de calor que ilustram a distribuição espacial dos casos de dengue no estado, facilitando a identificação de mesorregiões com maior incidência. É importante salientar que a presente análise se baseia na contagem original de casos de dengue em cada região, sem aplicação de qualquer técnica de normalização. A decisão de trabalhar com os dados brutos se justifica pelo objetivo de apresentar o número real de casos observados, permitindo uma visualização direta da distribuição da doença nas diferentes localidades.

A Figura 7 demarca as diferentes mesorregiões do estado, servindo como base para a análise espacial apresentada no mapa de calor a seguir. A classificação das áreas em cores distintas permite contextualizar melhor os padrões regionais observados nos casos de dengue ao longo dos anos analisados.

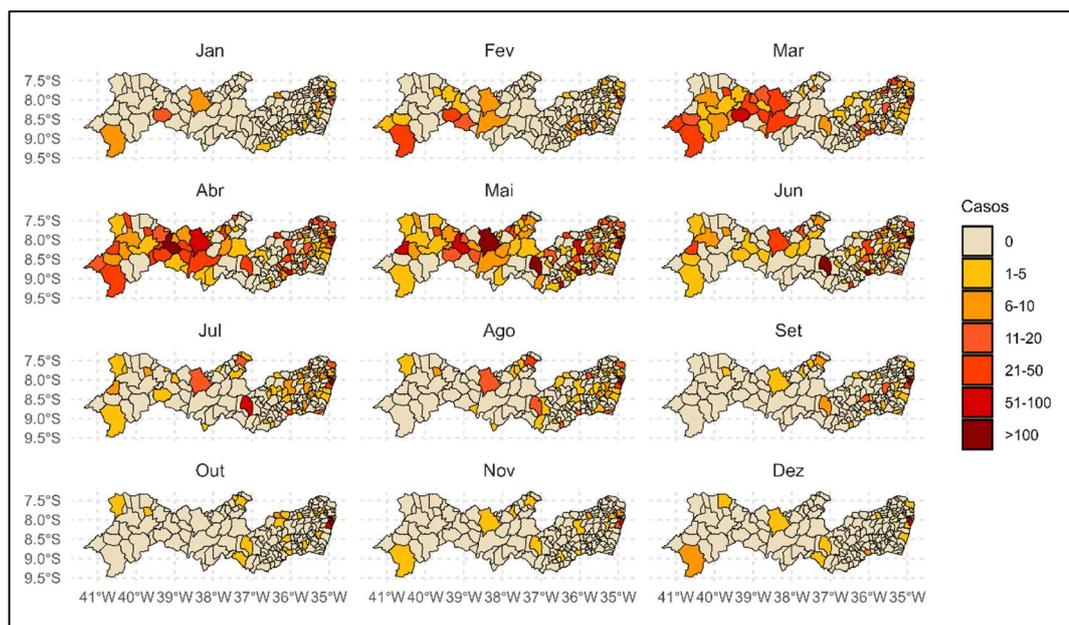
Figura 7 – Mesorregiões do estado de Pernambuco



Fonte: O Autor (2024).

O mapa de calor referente ao ano de 2022 é apresentado na Figura 8, destacando a distribuição mensal dos casos de dengue nos municípios pernambucanos. A escala de cores varia do amarelo ao vermelho, onde tons mais claros indicam menor quantidade de casos e tons mais escuros representam maior concentração de dengue. Áreas claras no mapa correspondem a municípios com registro de zero casos de dengue no respectivo mês. Nota-se que, nos meses de março a junho, há uma intensificação da dengue em várias regiões, principalmente no centro e nas mesorregiões do São Francisco e do Sertão. Os mapas de calor referentes aos anos de 2020, 2021 e 2023 seguem uma estrutura semelhante à apresentada para 2022 e estão disponíveis no Apêndice A deste trabalho.

Figura 8 – Casos de dengue em 2022

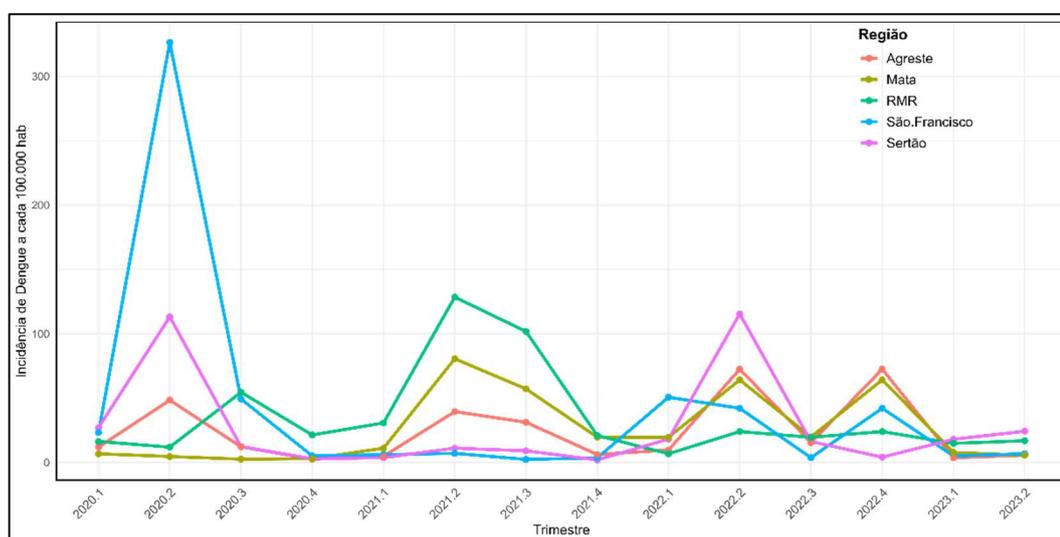


Fonte: O Autor (2024).

Nota: Elaborado a partir dos dados do DATASUS.

O gráfico anterior mostra os casos sem levar em consideração a população, sendo assim, a Figura 9 apresenta uma evolução por trimestre nas mesorregiões do estado levando em consideração a população. Nos três primeiros trimestres de 2020 pode ser observado uma quantidade de casos elevados na região do São Francisco, onde no segundo trimestre a região apresentava mais de 300 casos a cada cem mil habitantes. A RMR apresenta um pico elevando no segundo trimestre de 2021. A mesorregião do Sertão apresenta também mais de cem casos a cada cem mil no segundo trimestre de 2022. Por fim, o Agreste também apresenta valores mais altos no quarto trimestre de 2022, tendo a região da zona da Mata apresentado valores semelhantes.

Figura 9 – Incidência de casos de dengue por trimestre/ano e Mesorregião



Fonte: O Autor (2024).

Nota: Elaborado a partir dos dados do Apac.

Na Tabela 1 pode ser observado os casos de dengue por ano e por mesorregião em Pernambuco, detalhando a distribuição de casos entre as mesorregiões ao longo dos anos de 2020 a 2023. A região do São Francisco teve um comportamento variável, com 15,76% dos casos em 2020, uma queda para 1,71% em 2021, seguida por um aumento para 19,48% em 2022 e uma nova queda para 15,65% em 2023. A região do Sertão, por sua vez, teve uma variação significativa, com 25,49% dos casos em 2020, caindo drasticamente para 0,82% em 2021, mas voltando a registrar um aumento para 8% em 2022, seguido por uma queda para 3,04% em 2023. A região do Agreste apresentou um padrão de aumento nos casos de dengue, passando de 17,11% em 2020 para 12,27% em 2021, e 28,05% em 2022, mas com uma redução significativa para 8,62% em 2023. A região da Mata, inicialmente com 2,27% dos casos em 2020, viu um aumento substancial para 14,73% em 2021, mas uma redução nos anos seguintes,

com 16,40% em 2022 e 8,74% em 2023. Os dados mostram que a região metropolitana do Recife (RMR) teve a maior proporção de casos ao longo do período, com 39,37% dos casos em 2020, subindo para 70,48% em 2021, antes de cair para 28,06% em 2022 e aumentar novamente para 63,95% em 2023.

Tabela 1 – Casos de dengue por ano e por Mesorregião em Pernambuco

Ano	Região					Total
	São Francisco	Sertão	Agreste	Mata	RMR	
2020	1678 (15,76%)	2715 (25,49%)	1822 (17,11%)	242 (2,27%)	4193 (39,37%)	10650 (100%)
2021	279 (1,71%)	133 (0,82%)	1998 (12,27%)	2399 (14,73%)	11481 (70,48%)	16290 (100%)
2022	1634 (19,48%)	671 (8%)	2353 (28,05%)	1376 (16,40%)	2354 (28,06)	8388 (100%)
2023	541 (15,65%)	105 (3,04%)	298 (8,62%)	302 (8,74%)	2210 (63,95%)	3456 (100%)

Fonte: O Autor (2024).

Nota: Elaborado a partir dos dados do DATASUS.

Nessa análise preliminar foi identificado um aumento sucessivo no número de casos de dengue ao comparar os anos de 2020 com 2021 e 2021 com 2022 em alguns municípios de Pernambuco. Essa análise foi baseada na observação dos dados disponíveis, sem a aplicação de testes estatísticos formais. Os municípios onde esse padrão foi observado incluem Jaboatão dos Guararapes, Nazaré da Mata, Quipapá, Cabrobó, Timbaúba, Serra Talhada, Orobó, Abreu e Lima, Cupira, Goiana, Sairé, Brejinho, Lajedo, São Benedito do Sul, Canhotinho, Ipubi, Ferreiros, Macaparana, Camutanga, Floresta, Taquaritinga do Norte, Iguaracy, Tabira, Venturosa, Condado e Aliança. Embora esta análise não implique necessariamente uma relação causal direta, é possível que o aumento sucessivo dos casos esteja relacionado a fatores estruturais, como a falta de investimentos em ações de controle e prevenção da dengue nesses municípios. A ausência de medidas eficazes, como a intensificação da vigilância epidemiológica, campanhas de conscientização e controle do vetor pode ter contribuído para esse cenário.

1.5 ESTRUTURA DO TRABALHO

Este trabalho está estruturado em cinco capítulos. O Capítulo 1, a introdução, aborda o contexto geral, bem como a descrição do problema, a justificativa, os objetivos e a metodologia.

No Capítulo 2, apresenta-se a base conceitual e a revisão da literatura. A primeira parte foca nas definições gerais, utilizadas nas etapas seguintes, enquanto a segunda parte aborda a revisão da literatura dos últimos cinco anos.

No Capítulo 3, são analisados os modelos de regressão para verificar a adequação de seu uso. Além disso, esses modelos são ajustados, acompanhados de uma análise de seu comportamento frente aos testes estatísticos aplicados.

No Capítulo 4, o modelo selecionado é ajustado e os resultados são discutidos.

Por fim, o Capítulo 5 apresenta as conclusões, aponta as limitações do estudo e sugere trabalhos futuros.

2 BASE CONCEITUAL E REVISÃO DA LITERATURA

Este Capítulo está dividido em duas seções. A primeira seção aborda a base conceitual do trabalho, desta forma busca discutir aspectos relacionados a Dengue e a questão do Resíduos Sólidos, além disso, o aporte conceitual é feito para a Regressão com Dados em Painel, um tipo de regressão que será utilizada neste trabalho. A segunda seção traz o estado da arte, ou seja, aborda trabalhos atuais, além disso é identificada a lacuna da pesquisa.

2.1 BASE CONCEITUAL

Esta seção apresenta os conceitos fundamentais para a compreensão da dengue como problema de saúde pública no Brasil, destacando seus impactos e os desafios no controle do vetor. Além disso, discute-se como condições estruturais podem influenciar a transmissão da doença e como estratégias baseadas em dados podem contribuir para seu monitoramento e combate. Além disso, serão apresentados modelos estatísticos, que servirão como base para a análise dos dados ao longo do trabalho. Entre eles, destacam-se a regressão com dados em painel, os modelos para dados de contagem e os modelos inflacionados de zero, que serão utilizados para a seleção de variáveis.

2.1.1 A Dengue como problema de saúde pública no Brasil

A dengue é uma das arboviroses de grande impacto na saúde pública brasileira, sendo causada por vírus transmitidos pelo *Aedes aegypti*, um vetor altamente adaptado ao meio urbano. De acordo com Araújo *et al.* (2020), o vírus da dengue (DENV) pertence à família Flaviviridae e ao gênero Flavivírus, apresentando quatro sorotipos conhecidos (DENV-1, DENV-2, DENV-3 e DENV-4), cada um com variações genéticas distintas.

De acordo com Consoli e Oliveira (2008), acredita-se que o *Aedes aegypti* tenha sido introduzido no Brasil durante o período colonial, trazido em navios que transportavam escravizados da África. A primeira epidemia documentada de dengue no Brasil ocorreu entre 1981 e 1982, em Boa Vista (RR), causada pelos sorotipos DENV-1 e DENV-4. Em 1986, novas epidemias surgiram no Rio de Janeiro e em algumas capitais do Nordeste. Desde então, a dengue se mantém endêmica no Brasil, com surtos recorrentes, muitas vezes associados à introdução de novos sorotipos ou à mudança do sorotipo predominante, conforme o mosquito vetor se espalha pelo país.

Nos últimos anos, a introdução e a cocirculação desses sorotipos em diferentes regiões do Brasil têm sido fatores determinantes para o aumento da incidência e da gravidade da doença.

Gurgel-Gonçalves *et al.* (2024) apontam que a predominância do DENV-2 está associada ao crescimento das taxas de mortalidade por dengue no país, além do surgimento de epidemias com casos mais severos e maior número de hospitalizações. Em 2024, a cocirculação dos quatro sorotipos foi um dos principais fatores para a maior epidemia de dengue já registrada no Brasil, com aproximadamente 6 milhões de casos prováveis e 4.000 óbitos confirmados até junho.

De acordo com o Instituto Butantan (2024), os sintomas das arboviroses transmitidas pelo *Aedes aegypti*, como dengue, chikungunya e zika, apresentam algumas semelhanças, mas possuem características específicas que ajudam na diferenciação clínica. A Figura 10 ilustra essas distinções, destacando os principais sinais e complicações de cada uma dessas doenças. A dengue é caracterizada por febre alta (até 40°C), dor intensa no corpo e nas articulações, podendo evoluir para formas graves, com sangramentos e choque hemorrágico. A chikungunya, por sua vez, causa febre e dores no corpo, mas tem como principal marca dores articulares intensas e persistentes, que podem se prolongar por meses. Já a zika apresenta sintomas geralmente mais leves, como febre baixa, erupções cutâneas e coceira, mas sua maior preocupação está na relação com casos de microcefalia em bebês de mães infectadas durante a gestação.

Figura 10 - Sintomas de Dengue, Chikungunya e Zika

	Dengue	Chikungunya	Zika
 Febre	Alta (39-40°C), de início súbito e sempre presente	Alta (39-40°C), de início súbito, pode ou não estar presente	Baixa (38°C), nem sempre presente
 Dor de cabeça	Intensa	Moderada	Leve
 Dor nas articulações	Pode estar presente, moderada	Sempre presente, intensa e com inchaço	Pode estar presente, leve
 Manchas vermelhas no corpo	Pode estar presente, com ou sem coceira	Pode estar presente, com ou sem coceira	Quase sempre presente, com coceira intensa
 Conjuntivite	Não	Pouco provável	Muito provável
 Dor atrás dos olhos	Moderada	Leve	Moderada
Possíveis complicações	Hemorragias e falência múltipla dos órgãos.	Dores crônicas que podem durar anos. Raramente: agravos neurológicos	Microcefalia em bebês de gestantes infectadas e Síndrome de Guillain-Barré (paralisia) em adultos. Risco de parto prematuro e aborto espontâneo.

Fonte: Instituto Butantan (2024).

Abordagens intersetoriais têm emergido como uma estratégia essencial para orientar as políticas públicas de controle. Lima e Vilasbôas (2011) citam um exemplo dessa abordagem, onde foi implementado o Comitê Estadual de Mobilização Social de Prevenção e Controle da Dengue durante o período de 2008 a 2009 no estado da Bahia. O estudo implementado por meio de uma pesquisa avaliativa identificou que a articulação intersetorial foi um desafio persistente, com o apoio político de órgãos governamentais sendo um dos fatores facilitadores mais significativos. No entanto, a concentração de responsabilidades em um único setor e a falta de planejamento adequado foram apontados como barreiras para a efetividade das ações. Isso evidencia a importância de superar limitações setoriais para garantir a integração de diferentes saberes e práticas na luta contra a dengue.

Visto que a importância das abordagens intersetoriais foi destacada no controle da dengue, Marteis *et al.* (2013) aprofundam-se na identificação dos "imóveis-chave" para o *Aedes aegypti* em Aracaju, Sergipe, como uma forma de potencializar as estratégias de controle vetorial. O estudo realizado na área do bairro Porto Dantas revelou que a presença de pupas em imóveis com foco contínuo para o vetor, independentemente das condições ambientais, contribui para a manutenção da infestação e disseminação do mosquito. A partir dos resultados obtidos, os autores enfatizam a necessidade de priorizar esses imóveis-chave nas campanhas de vigilância e controle, uma vez que são eles que funcionam como focos geradores de mosquitos, contribuindo para a expansão da infestação para áreas adjacentes. O estudo reforça a importância de estratégias específicas e localizadas, complementando as abordagens intersetoriais como uma ferramenta eficaz para o controle da dengue.

A Lei nº 13.301 (Brasil, 2016), exemplifica esse aspecto ao estabelecer medidas emergenciais para o controle de doenças transmitidas pelo *Aedes aegypti*, incluindo a dengue, a chikungunya e a zika. Essa legislação confere à autoridade máxima do Sistema Único de Saúde (SUS), em níveis federal, estadual, distrital e municipal, a prerrogativa de determinar e executar ações de controle e prevenção em situações de iminente perigo à saúde pública. Entre as ações previstas, destaca-se a possibilidade de realizar visitas programadas – e, em casos de recusa ou abandono, até o ingresso forçado – a imóveis que possam estar abrigando focos de reprodução do vetor. Essas medidas jurídicas complementam as estratégias intersetoriais apontadas por Marteis *et al.* (2013), uma vez que visam garantir que os imóveis identificados como “chave” sejam efetivamente inspecionados e tratados, interrompendo a cadeia de transmissão.

Nesse sentido, Xavier *et al.* (2012) também contribuem para essa reflexão ao analisarem a epidemiologia da dengue, onde destacam a relevância do monitoramento contínuo, mesmo em áreas com índices baixos de infestação. Embora a região de estudo tenha apresentado uma taxa reduzida de focos, os autores indicam que a vigilância constante e a ação coordenada são fundamentais para prevenir surtos. Esse estudo reforça que, além da identificação de áreas com alta concentração de criadouros, é fundamental a realização de campanhas de educação e mobilização, envolvendo a comunidade na eliminação de focos e no cuidado preventivo. Juntas, essas abordagens mostram que o controle efetivo da dengue depende da combinação de estratégias específicas para áreas críticas, juntamente com a participação ativa da sociedade e a integração de ações intersetoriais.

2.1.2 Condições estruturais e seus impactos na transmissão da Dengue

A Lei nº 12.305, de 2 de agosto de 2010, estabelece a Política Nacional de Resíduos Sólidos (Brasil, 2010), regulamentando os princípios, objetivos e mecanismos necessários para uma gestão integrada e sustentável dos resíduos sólidos no Brasil. A legislação define diretrizes para o gerenciamento adequado de resíduos, incluindo os perigosos, e atribui responsabilidades claras aos geradores, ao poder público e à sociedade. Além disso, a lei prevê o uso de instrumentos econômicos como incentivo à redução, reutilização e reciclagem, promovendo uma abordagem compartilhada e sustentável para a gestão dos resíduos no país.

A Lei 11.445/2007, estabelece diretrizes relacionadas ao abastecimento de água, à coleta, ao tratamento e à disposição final de esgotos, bem como à drenagem pluvial (Brasil, 2007). Além disso, aborda a coleta, o tratamento e a disposição final de resíduos sólidos e de efluentes líquidos industriais, que são de interesse das empresas responsáveis pelo tratamento. Os efluentes industriais, que consistem na água residual gerada pelos processos produtivos, devem ser tratados antes de serem devolvidos aos corpos hídricos, como rios e lagos. Esse tratamento deve ser realizado por meio de equipamentos especializados e requer a obtenção de licença ambiental.

O saneamento básico é um componente essencial para o desenvolvimento social e econômico, além de ser um direito fundamental garantido pela Constituição Federal. No Brasil, a Política Nacional de Saneamento Básico foi formalizada pela Lei nº 11.445/2007, estabelecendo diretrizes para a prestação dos serviços de abastecimento de água, esgotamento sanitário, manejo de resíduos sólidos e drenagem urbana. O Plano Nacional de Saneamento Básico (Plansab) surge como uma estratégia de longo prazo para garantir a universalização desses serviços, buscando reduzir desigualdades regionais e melhorar as condições de vida da população (Silveira, Heller e Rezende, 2013).

Historicamente, a prestação dos serviços de saneamento no Brasil tem sido marcada por desafios estruturais e institucionais. Desde a década de 1970, quando o Plano Nacional de Saneamento (Planasa) foi instituído, o setor passou por diversas reformulações, mas ainda enfrenta entraves relacionados à descentralização e ao financiamento dos serviços. Estudos indicam que a hegemonia das empresas estaduais de saneamento condicionou o processo decisório da política pública, tornando o setor resistente a inovações regulatórias e dificultando a ampliação dos investimentos necessários para a universalização dos serviços (Sousa & Costa, 2016).

O déficit de infraestrutura sanitária é uma das principais barreiras para a efetivação do Plansab. Segundo Leoneti, Prado e Oliveira (2011), o Brasil apresenta uma grande desigualdade no acesso aos serviços de saneamento, especialmente no que se refere ao tratamento de esgoto. Enquanto regiões metropolitanas dispõem de uma cobertura mais ampla, áreas periféricas e municípios menores ainda enfrentam limitações significativas. A falta de planejamento sustentável e de investimentos adequados tem levado a problemas ambientais e de saúde pública, agravando o cenário de vulnerabilidade social.

De acordo com Silveira, Heller e Rezende (2013) um dos aspectos fundamentais do Plansab é a integração entre os diferentes setores governamentais e a participação social no planejamento e execução das políticas de saneamento. O plano prevê mecanismos de governança que envolvem os municípios, estados e União, além da sociedade civil, buscando garantir maior eficiência na alocação de recursos e na implementação das metas estabelecidas. Entretanto, a efetivação dessas diretrizes ainda encontra desafios, como a necessidade de investimentos contínuos e a adaptação das políticas às realidades locais.

A universalização do saneamento básico exige uma abordagem integrada que contemple aspectos técnicos, institucionais e financeiros. Além do fortalecimento das políticas públicas, é necessário ampliar os investimentos em infraestrutura e inovação tecnológica, garantindo a sustentabilidade dos serviços a longo prazo. A experiência brasileira mostra que, apesar dos avanços obtidos com a criação do Plansab, ainda há um longo caminho a percorrer para garantir que toda a população tenha acesso a condições sanitárias adequadas, reduzindo as desigualdades e promovendo o desenvolvimento sustentável (Leoneti, Prado e Oliveira, 2011).

2.1.3 Regressão com dados em Painel

Os modelos de regressão com dados em painel possuem uma característica especial devido a sua dimensionalidade, sendo uma dimensão espacial e outra temporal. Sendo assim, esses modelos são cada vez mais utilizados devido a necessidade de avaliar diversos recortes temporais, ou seja, incorporam várias *cross section* (Cameron; Trivedi, 2005). Além disso, essa abordagem consiste em observar n entidades para dois ou mais períodos. Esses recortes temporais podem ser semanais, mensais, trimestrais ou anuais, por exemplo (Fávero; Belfiore, 2022).

De acordo com Gujarati e Porter (2011), em séries temporais, os valores de uma ou mais variáveis são observados em um período. Nos dados de corte transversal, coletam-se dados

relativos a uma ou mais variáveis para várias unidades ou entidades amostrais no mesmo período. Nos dados em painel, a mesma unidade de corte transversal é acompanhada ao longo do tempo.

A estrutura de um modelo geral com dados longitudinais pode ser representada de acordo com a Tabela 2 a seguir.

Tabela 2 – Modelo de painel para representação dos dados

Observação	Indivíduo	Período t	Variável Resposta	Variáveis explicativas			
			Y_{it}	X_1	X_2	...	X_k
1	1	1	Y_{11}	X_{111}	X_{211}	...	X_{k11}
2	1	2	Y_{12}	X_{112}	X_{212}	...	X_{k12}
⋮	⋮	⋮	⋮	⋮	⋮	...	⋮
T_1	1	T_1	Y_{1T_1}	X_{11T_1}	X_{21T_1}	...	X_{k1T_1}
$T_1 + 1$	2	1	Y_{21}	X_{121}	X_{221}	...	X_{k21}
$T_1 + 2$	2	2	Y_{22}	X_{122}	X_{222}	...	X_{k22}
⋮	⋮	⋮	⋮	⋮	⋮	...	⋮
T_2	2	T_2	Y_{2T_2}	X_{12T_2}	X_{22T_2}	...	X_{k2T_2}
⋮	⋮	⋮	⋮	⋮	⋮	...	⋮
$T_{n-1} + 1$	n	1	Y_{n1}	X_{1n1}	X_{2n1}	...	X_{kn1}
$T_{n-1} + 2$	n	2	Y_{n2}	X_{1n2}	X_{2n2}	...	X_{kn2}
⋮	⋮	⋮	⋮	⋮	⋮	...	⋮
T_n	n	T_n	Y_{nT_n}	X_{1nT_n}	X_{2nT_n}	...	X_{knT_n}

Fonte: Adaptado de Favero e Belfiore (2017).

Os dados em painel podem ser considerados balanceados ou desbalanceados, se $T_1 = T_2 = T_3 = T_n$ então o painel é considerado balanceado, pois a quantidade de informações será igual a $n.T$. Caso contrário, a quantidade de observações contidas no banco de dados será igual a $\sum_i T_i$.

Considerando que a relação entre a variável resposta Y e as variáveis explicativas X 's seja do tipo linear, o modelo para dados em painel é dado por:

$$Y_{it} = \beta_{0it} + \beta_{1it}x_{1it} + \beta_{2it}x_{2it} + \dots + \beta_{kit}x_{kit} + \varepsilon_{it}, \quad (2.1)$$

onde β_{0it} é o intercepto, β_{jit} é o coeficiente da variável explicativa X_k e $\varepsilon_{it} \sim \mathcal{N}(\mu, \sigma^2)$, sendo i o índice associado ao indivíduo, para $j=1, \dots, k$ e $i=1, \dots, n..$ Sendo a sua representação matricial dada a seguir:

$$Y_i = x_i\beta_i + \varepsilon_i \quad (2.2)$$

Onde,

$$Y_i = \begin{bmatrix} Y_{i1} \\ Y_{i2} \\ \dots \\ Y_{iT_i} \end{bmatrix}, x_i = \begin{bmatrix} 1 & x_{1i1} & x_{2i1} & \dots & x_{ki1} \\ 1 & x_{1i2} & x_{2i1} & \dots & x_{ki2} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & x_{1iT_i} & x_{2iT_i} & \dots & x_{kiT_i} \end{bmatrix}, \beta_1 = \begin{bmatrix} \beta_{0it} \\ \beta_{1it} \\ \vdots \\ \beta_{kit} \end{bmatrix}, e \ \varepsilon_i = \begin{bmatrix} \varepsilon_{i1} \\ \varepsilon_{i2} \\ \vdots \\ \varepsilon_{iT_i} \end{bmatrix}$$

Para $i = 1, \dots, n$.

Sendo assim, de acordo com Favero e Belfiore (2017), a estimação dos parâmetros que considera Y_{it} em função de X_{1it} , X_{2i} , ..., X_{kit} , pode ser definida de acordo com a Equação 2.3.

$$Y_{it} = a_i + b_1 \cdot X_{1it} + b_2 \cdot X_{2it} + \dots + b_k \cdot X_{kit} + \varepsilon_{it} \quad (2.3)$$

Sendo:

Y_{it} → Fenômeno de estudo (variável dependente ao logo do tempo);

a_i → Representa o intercepto para cada indivíduo, pode assumir efeito fixo ou aleatório;

b_j → São coeficientes de cada variável X_j são variáveis explicativas, onde b_j ($j = 1, 2, \dots, k$);

ε → Representa os termos de erro idiosincrático.

Sendo assim, podemos reescrever a Equação 2.3 com base no valor esperado (estimativa) da variável dependente, para cada observação i em cada período t , conforme segue:

$$\hat{Y}_{it} = \alpha_i + \beta_1 X_{1it} + \beta_2 X_{2it} + \dots + \beta_k X_{kit}$$

Essa expressão considera que a variável Y é quantitativa. Porém, caso a variável Y seja qualitativa dicotômica, teremos um modelo longitudinal logístico (modelo longitudinal não linear), assim podemos reescrever a Equação 2.3 da seguinte forma:

$$\ln(\text{chance}_{y_{it}=1}) = \alpha_i + \beta_1 X_{1it} + \beta_2 X_{2it} + \dots + \beta_k X_{kit}$$

Para valores quantitativos em que Y assume valores discretos positivos e restritos a determinado número de ocorrências, ou seja, dados de contagem, teremos um modelo longitudinal Poisson ou um modelo longitudinal binomial negativo (modelos longitudinais não lineares), sendo a equação modificada para:

$$\ln(\hat{Y}_{it}) = \alpha_i + \beta_1 X_{1it} + \beta_2 X_{2it} + \dots + \beta_k X_{kit}$$

Quando o modelo assume que a variável Y é contínua será considerado um modelo longitudinal linear de regressão. Por outro lado, se a variável Y for qualitativa dicotômica, teremos um modelo longitudinal logístico, que é um caso particular dos Modelos Lineares Generalizados (GLM), Equação 2.4. Sendo assim, a escolha do modelo para análise de dados longitudinais depende da natureza da variável dependente Y (Fávero; Belfiore, 2022).

$$p_i = \mathbb{E}(Y_i | x_i, \beta_i) = \frac{\exp\{x_i \beta_i\}}{1 + x_i \beta_i} \quad (2.4)$$

Onde p_i representa a probabilidade de sucesso, i.e., a probabilidade de ocorrência do evento de interesse, para $i = 1, \dots, n$.

O modelo *Pooled* "empilha" todas as observações da base de dados, desconsiderando a estrutura de dados em painel de acordo com a Equação 2.5. Assim, trata todas as observações como não correlacionadas entre os indivíduos e assume erros homoscedásticos. É, portanto, a abordagem mais simplista e ingênua, pois ignora as dimensões combinadas de tempo e espaço, estimando a regressão pelo método dos Mínimos Quadrados Ordinários (Wooldridge, 2010).

$$Y_{it} = \alpha + b_1 X_{1it} + b_2 X_{2it} + \dots + b_k X_{kit} + u_{it} \quad (2.5)$$

De acordo Fávero e Belfiore (2022), embora a estimação POLS suponha que todas as variáveis explicativas sejam exógenas e que os termos de erro sejam representados por u_{it} , a inferência requer que haja o controle da autocorrelação destes termos de erro u_{it} , para dado indivíduo (efeito *within*), por meio da utilização de erros-padrão robustos com agrupamento no nível do próprio indivíduo, ainda que esta estimação não leve em consideração a existência de efeitos fixos ou aleatórios, este método é bastante utilizado e aplicado.

O modelo de regressão com efeitos fixos assume o intercepto varia de indivíduo para indivíduo enquanto os coeficientes de inclinação das variáveis independentes permanecem constantes para todos os indivíduos (Gujarati; Porter, 2011). Dessa forma, captura as diferenças entre os indivíduos por meio dos interceptos, mantendo a relação entre as variáveis independentes e a variável dependente para todos, conforme a equação a seguir na Equação 2.6.

$$(Y_{it} - \bar{Y}_i) = b_1(X_{1it} - \bar{X}_{1i}) + b_2(X_{2it} - \bar{X}_{2i}) + \dots + b_k(X_{kit} - \bar{X}_{ki}) + (\varepsilon_{it} - \bar{\varepsilon}_i) \quad (2.6)$$

para $i = 1, \dots, n$ e $t = 1, \dots, T_n$.

Por fim, na estimação por efeitos aleatórios, os efeitos individuais são tratados como variáveis aleatórias, diferentemente do modelo de efeitos fixos. Nesse contexto, o intercepto de cada indivíduo varia aleatoriamente em torno de um valor médio, com essas variações sendo capturadas por um termo de erro. O intercepto de cada indivíduo é representado pela soma de um valor médio e um termo de erro específico para esse indivíduo (Baltagi, 2021). Assim, as diferenças entre os interceptos das unidades individuais refletem esse erro aleatório, que tem média zero e variância constante, de acordo com a Equação 2.7.

$$Y_{it} = b_1 X_{1it} + b_2 X_{2it} + \dots + b_k X_{kit} + (a_i + \varepsilon_{it}) \quad (2.7)$$

em que o termo a_i captura o comportamento dos efeitos individuais entre indivíduos e apresenta média a e variância σ_a^2 (variância *between*), e ε_{it} corresponde ao comportamento dos termos de erro idiossincrático com média zero e variância $\sigma^2\varepsilon$ (variância *within*), ou seja, representa as variações do erro “dentro” do próprio indivíduo.

Os termos de erro do modelo são, portanto:

$$u_{it} = a_i + \varepsilon_{it}$$

Após a apresentação dos modelos de regressão, sejam eles agrupados (pooled), de efeitos fixos ou de efeitos aleatórios, é fundamental realizar testes estatísticos para determinar qual dos modelos é mais adequado para a análise de dados em painel. A escolha do modelo mais apropriado deve basear-se nos resultados desses testes, pois o modelo selecionado influenciará diretamente na interpretação e validade das conclusões (Wooldridge, 2010). Esses testes incluem, entre outros, o teste de Chow, o teste de Breusch-Pagan e o teste de Hausman, que comparam os diferentes modelos para identificar aquele que melhor se ajusta aos dados, garantindo uma análise robusta e confiável.

O Teste de Chow é utilizado para decidir entre a utilização do modelo de Mínimos Quadrados Ordinários (MQO/Pooled) ou o modelo de Efeitos Fixos. Esse teste avalia se os coeficientes dos indivíduos no painel são estatisticamente diferentes entre si, o que indicaria a necessidade de um modelo com interceptos variáveis. Sendo assim, temos:

$$\text{Modelo restrito: } Y_{it} = \alpha + X_{it}\beta + u_{it} \text{ (Intercepção única – MQO/Pooled)}$$

$$\text{Modelo irrestrito: } Y_{it} = X_{it}\beta + D_i\alpha + u_{it} \text{ (Intercepção variável – LSDV)}$$

Então a seguinte estatística é avaliada:

$$F(n-1, nT - n - K) = \frac{(R_{LSDV}^2 - R_{Pooled}^2) / (n-1)}{(1 - R_{LSDV}^2) / (nT - n - K)}$$

Onde LSDV (*Least Squares Dummy Variable*) é um método utilizado para estimar modelos de Efeitos Fixos em dados em painel. Ele consiste em incluir variáveis dummy (indicadoras) para capturar interceptos específicos de cada indivíduo ou unidade no painel.

Sendo a hipótese nula $d_i = 0 \quad \forall i \in (1, I) \Rightarrow$ Modelo MQO/Pooled é mais adequado que o de efeitos fixos.

O Teste de Breusch-Pagan é utilizado para determinar se o modelo de Efeitos Aleatórios é mais adequado do que o modelo Pooled (MQO) (Breusch; Pagan, 1980). Esse teste verifica a

presença de variância nos efeitos individuais, onde a hipótese nula seria: $\sigma_c^2 = 0$. Se essa hipótese for aceita, o modelo MQO/Pooled é mais adequado do que o de Efeitos Aleatórios. A seguinte estatística é considerada (Chi-2):

$$LM = \frac{nT}{2(T-1)} \left[\frac{\left(\sum_{i=1}^n \sum_{t=1}^T e_{it} \right)^2}{\sum_{i=1}^n \sum_{t=1}^T e_{it}^2} - 1 \right] = \frac{nT}{2(T-1)} \left[\frac{\sum_{i=1}^n (T\bar{e}_i)^2}{\sum_{i=1}^n \sum_{t=1}^T e_{it}^2} - 1 \right]^2$$

Onde e_{it} é obtido por meio do resíduo da regressão de MQO.

O último teste a ser considerado é o teste de Hausman que é utilizado para decidir entre o modelo de Efeitos Fixos (EF) e o modelo de Efeitos Aleatórios (EA), avaliando a presença de correlação entre os efeitos individuais e as variáveis explicativas (Hausman, 1978). Sob as duas hipóteses:

Hipótese nula: Presença de autocorrelação → O modelo de Efeitos Aleatórios (EA) é mais eficiente.

Hipótese alternativa: Ausência de autocorrelação → O modelo de Efeitos Aleatórios (EA) é inconsistente.

Estatística do teste (Qui-quadrado):

$$W = \chi^2[K-1] = (\mathbf{b} - \hat{\boldsymbol{\beta}})' \hat{\Psi}^{-1} (\mathbf{b} - \hat{\boldsymbol{\beta}})$$

onde:

\mathbf{b} representa o vetor de coeficientes estimados pelo modelo de Efeitos Fixos;

$\hat{\boldsymbol{\beta}}$ representa o vetor de coeficientes estimados pelo modelo de Efeitos Aleatórios;

$\hat{\Psi}$ é a matriz de variância-covariância da diferença dos estimadores.

Se o valor da estatística W for significativamente alto (acima do valor crítico da distribuição Qui-quadrado para um nível de significância α), rejeitamos a hipótese nula e concluímos que os efeitos individuais estão correlacionados com as variáveis explicativas, indicando que o modelo de Efeitos Fixos é o mais adequado.

Os modelos de pooled, efeitos fixos e efeitos aleatórios são amplamente utilizados na análise de dados em painel, proporcionando diferentes formas de lidar com a heterogeneidade individual entre as unidades observadas. No entanto, esses modelos são tradicionalmente formulados para variáveis contínuas e podem não ser os mais adequados quando a variável dependente é discreta e representa contagens.

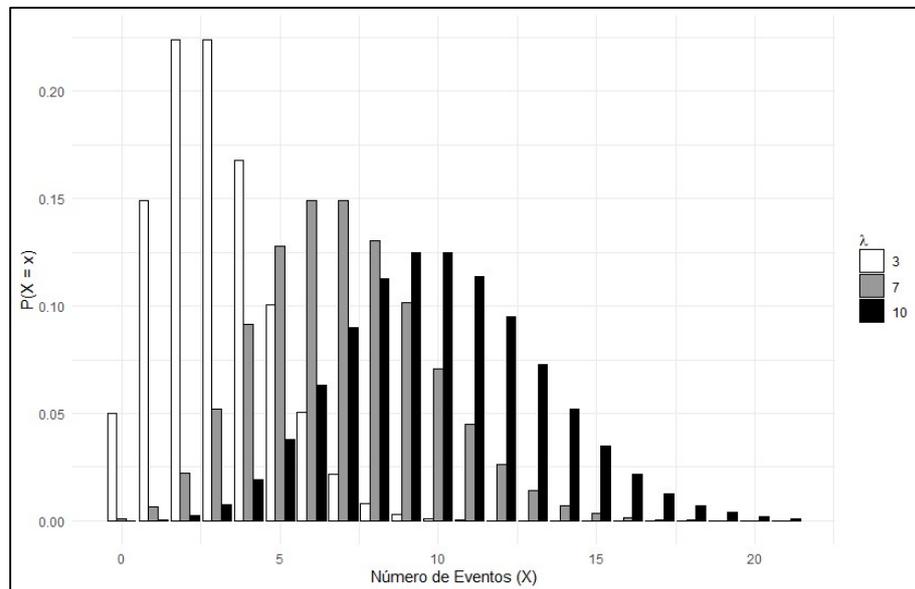
Dado que a variável de interesse no presente estudo é uma contagem, ou seja, assume apenas valores inteiros não negativos e pode apresentar características como sobredispersão e excesso de zeros, torna-se necessário considerar abordagens mais apropriadas para esse tipo de dado. Dessa forma, nas próximas seções, serão explorados modelos de contagem que levam essas especificidades em consideração.

2.1.4 Modelos para dados de contagem com distribuição de Poisson

A distribuição de Poisson é amplamente utilizada para modelar dados de contagem, assumindo que a variância da variável resposta é igual à sua média condicional. No entanto, essa suposição pode ser violada na presença de sobredispersão, isto é, quando a variância dos dados excede a média. Para testar essa condição, Cameron e Trivedi (1990) propuseram um teste baseado em regressão auxiliar, que verifica se a equidade entre média e variância é válida.

A Figura 11 apresenta o gráfico das probabilidades de uma variável aleatória Y com distribuição de Poisson de parâmetro λ , para $\lambda = \{3, 7, 10\}$ e $y = \{0, \dots, 21\}$. Para valores y 's maiores do que 21, as probabilidades são todas muito próximas a zero e foram omitidas.

Figura 11 – Distribuição de Poisson



Fonte: O Autor (2024).

Sejam os dados $\{(y_i, X_i)\}$, para $i = 1, \dots, N$, onde X_i é um vetor K -dimensional de variáveis explicativas. O modelo assume que a média dependente de y_i condicional a X_i é dada por:

$$\mathbb{E}[Y_i] = \mu_i = \mu(X_i, \beta) \quad (2.8)$$

onde μ é uma função diferenciável que mapeia valores para o conjunto dos números reais positivos e é identificável na primeira ordem, isto é:

$$\mu(X_i, \beta_0) = \mu(X_i, \beta_1) \Leftrightarrow \beta_0 = \beta_1 \quad (2.9)$$

Para testar a suposição de equidade entre média e variância, uma característica do modelo de Poisson, considera-se a seguinte hipótese nula:

$$H_0 : \text{Var}(Y_i) = \mu_i.$$

Caso essa suposição não seja válida, considera-se a seguinte hipótese alternativa, que permite a presença de sobredispersão:

$$H_1 : \text{Var}(Y_i) = \mu_i + \alpha \cdot g(\mu_i),$$

onde $g(\mu_i)$ é uma função especificada da média μ_i e α é o parâmetro de sobredispersão a ser testado.

Para testar H_0 uma regressão auxiliar é ajustada onde relaciona a dispersão dos dados à média condicional μ_i . Esta regressão é dada por:

$$E[(y_i - \mu_i)^2 - y_i] = \alpha \cdot g(\mu_i) \quad (2.10)$$

Se a suposição de equidispersão for válida, espera-se que $\alpha = 0$, o que confirmaria a adequação do modelo de Poisson. Caso contrário, um valor significativo de α indicaria sobredispersão.

A estatística do teste para $H_0 : \alpha = 0$ pode ser obtida a partir da regressão auxiliar como um teste t sobre o coeficiente α :

$$T = \frac{\hat{\alpha}}{\text{EP}(\hat{\alpha})} \sim \mathcal{N}(0,1), \quad (2.11)$$

onde, $\hat{\alpha}$ é a estimativa do parâmetro de sobredispersão e $\text{EP}(\hat{\alpha})$ é o erro padrão associado. Se T for significativamente diferente de zero (e.g., para um nível de significância de 5%), rejeita-se H_0 e conclui-se que há evidências de sobredispersão, com isso outros modelos são mais adequados para lidar com esse pressuposto.

Após apresentar a formulação do modelo de Poisson e sua suposição de equidispersão, é necessário verificar se essa suposição é válida. Para isso, podem ser utilizados índices estatísticos que avaliam a relação entre a média e a variância dos dados observados. Dentre esses, destacam-se o Índice de Dispersão de Pearson e a Estatística da Deviance Normalizada (Hinde; Demétrio, 1998).

Sobre o Índice de Dispersão de Pearson Hinde e Demétrio (1998) propõem:

$$D = \frac{\sum_{i=1}^n (y_i - \hat{\mu}_i)^2 / \hat{\mu}_i}{n - p},$$

Esse índice é amplamente utilizado para verificar se um modelo de Poisson apresenta sobredispersão:

Se $D \approx 1$, o modelo de Poisson é adequado.

Se $D > 1$, há sobredispersão (variância maior do que a média).

Além disso, a Estatística da Deviance também é discutida como:

$$D^* = \frac{\sum_{i=1}^n 2 \left[y_i \log \left(\frac{y_i}{\hat{\mu}_i} \right) - (y_i - \hat{\mu}_i) \right]}{n - p}.$$

sendo, similar ao Índice de Dispersão de Pearson, mas baseado na deviance do modelo.

2.1.5 Modelo Inflacionada de Zero com distribuição de Poisson

Os modelos de regressão inflacionados de zeros são amplamente utilizados para modelar dados de contagem que apresentam um número excessivo de observações com valor zero. Entre as principais abordagens, destacam-se os modelos baseados na distribuição de Poisson e na distribuição Binomial Negativa, devido à sua flexibilidade na análise desse tipo de dado (Cameron; Trivedi, 1998). Essas técnicas têm sido aplicadas em diversas áreas, permitindo um melhor ajuste estatístico em situações em que a presença de zeros estruturais e amostrais influencia a interpretação dos resultados.

No contexto da produção industrial, Lambert (1992) analisou o número de defeitos em processos de fabricação, propondo uma abordagem baseada na combinação das distribuições de Bernoulli e Poisson para modelar o excesso de zeros em dados de contagem. Na área da medicina, Böhning et al. (1999) utilizaram a regressão ZIP para estudar a incidência de cáries dentárias em crianças, enquanto Lewsey e Thomson (2004) compararam os modelos ZIP e ZINB em um estudo sobre dentes com cáries. Na epidemiologia, Cheung (2002) utilizou modelos de regressão inflacionados de zeros para estudar o crescimento e desenvolvimento infantil. Já na ecologia, Potts e Elith (2006) investigaram a abundância de espécies de plantas vulneráveis, enquanto Martin et al. (2005) analisaram a presença de determinadas espécies em habitats específicos utilizando modelos de contagem com excesso de zeros.

Diante da ampla aplicabilidade dos modelos inflacionados de zeros em diferentes áreas do conhecimento, sua formulação matemática torna-se essencial para compreender como esses modelos capturam a presença excessiva de zeros nos dados. Em particular, o modelo de Poisson inflacionado de zeros (ZIP) é uma abordagem estatística que combina um componente que modela a presença de zeros estruturais e outro que segue a distribuição de Poisson para representar a contagem dos eventos observados.

Seja y_1, \dots, y_n um conjunto de realizações da variável resposta Y_i , $i = 1, 2, \dots, n$ o modelo de Poisson inflacionado de zeros é definido da seguinte forma:

$$P(Y_i = y_i | x_i) = \begin{cases} \pi_i + (1 - \pi_i)e^{-\mu_i}, & y_i = 0, \\ (1 - \pi_i) \frac{e^{-\mu_i} \mu_i^{y_i}}{y_i!}, & y_i > 0. \end{cases}$$

em que $0 < \pi_i < 1$ e $\mu_i > 0$.

Sendo assim, a média e a variância da distribuição são dados por:

$$\mathbb{E}(Y_i) = (1 - \pi_i)\mu_i$$

$$\text{Var}(Y_i) = \mu_i(1 - \pi_i)(1 + \pi_i\mu_i)$$

O modelo de regressão de Poisson inflacionado de zeros representa a média μ de uma variável de Poisson por meio de uma regressão de Poisson (Equação 2.14), enquanto a probabilidade π é modelada por uma regressão logística (Equação 2.15), utilizando a função de ligação $\eta_i = \text{logit}(\pi_i)$. Dessa forma, a estrutura do modelo permite capturar tanto a contagem dos eventos quanto o excesso de zeros nos dados.

$$\log(\mu_i) = X_i\beta \quad (2.12)$$

$$\text{logit}(\pi_i) = \log\left(\frac{\pi_i}{1 - \pi_i}\right) = G_i\gamma \quad (2.13)$$

em que X_i e G_i são as matrizes de covariáveis. Nestas duas equações de regressão, as duas matrizes de covariáveis podem ou não coincidir (Lambert, 1992).

Os parâmetros do modelo são estimados pelo método de máxima verossimilhança. Como o ajuste do modelo de regressão de Poisson inflacionado de zeros envolve duas regressões, a função de verossimilhança é definida como:

$$L = \prod_{i:y_i=0} [\pi_i + (1 - \pi_i)e^{-\mu_i}] \prod_{i:y_i>0} \left[(1 - \pi_i) \frac{e^{-\mu_i} \mu_i^{y_i}}{y_i!} \right]$$

E o logaritmo da função de verossimilhança é expresso por:

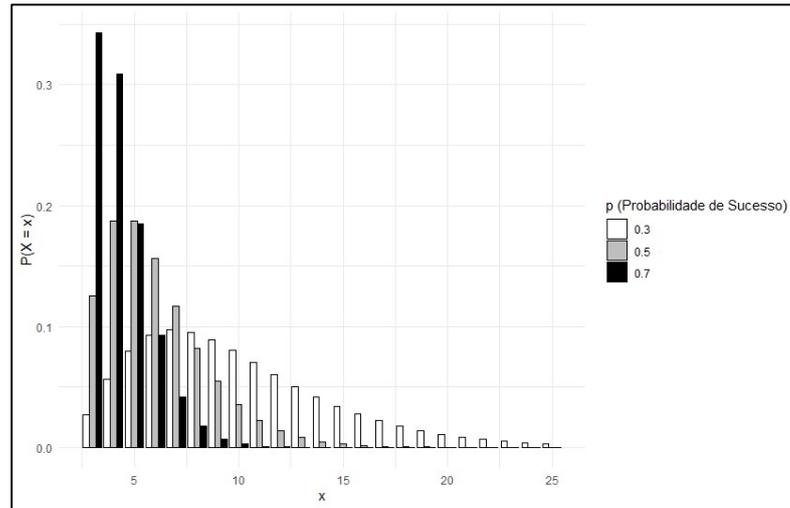
$$\ell = \sum_{i:y_i=0} \ln \left(e^{G_i^T \gamma} + e^{-e^{X_i^T \beta}} \right) + \sum_{i:y_i>0} \left(y_i X_i^T \beta - e^{X_i^T \beta} - \ln(y_i!) \right) - \sum_{i=1}^n \ln \left(1 + e^{G_i^T \gamma} \right)$$

2.1.6 Modelo Inflacionado de Zero com distribuição Binomial Negativa

O modelo Zero-Inflated Negative Binomial (ZINB) pode ser utilizados para modelar dados de contagem que apresentam um excesso significativo de zeros, além de sobredispersão, isto é, quando a variabilidade observada nos dados é maior do que aquela prevista por um modelo de Poisson (Hilbe, 2012; Cheung, 2002). Esses modelos são amplamente empregados em diversas áreas, incluindo epidemiologia, economia e ciências sociais, devido à sua capacidade de capturar simultaneamente os processos geradores de zeros estruturais e contagens positivas.

A Figura 12 ilustra distribuições Binomiais Negativas para diferentes valores da probabilidade de sucesso p , destacando como esse parâmetro afeta a dispersão e a forma da distribuição. O eixo horizontal representa o número de tentativas até a ocorrência de um número fixo de falhas, enquanto o eixo vertical exibe a função de massa de probabilidade (PMF, *Probability Mass Function*), que descreve a probabilidade associada a cada valor discreto de x . Para $p = 0.7$ (barras pretas), a distribuição apresenta maior concentração de probabilidade em valores menores de x , indicando que, com maior probabilidade de sucesso em cada tentativa, menos tentativas são necessárias para atingir um número fixo de falhas. Já com $p = 0.5$ (barras cinza), observa-se um deslocamento do pico para valores ligeiramente maiores de x , refletindo uma maior variabilidade no número de tentativas até atingir o critério definido. Por fim, para $p = 0.3$ (barras brancas), a distribuição se torna mais dispersa, com probabilidades significativas distribuídas ao longo de valores maiores de x . Isso ocorre porque, com uma menor probabilidade de sucesso em cada tentativa, são necessárias mais tentativas para alcançar o número fixo de falhas, aumentando a dispersão da distribuição.

Figura 12 - Distribuição de Binomial Negativa



Fonte: O Autor (2024).

Os modelos Inflacionado de Zero com distribuição Binomial Negativa possuem uma variável dependente do tipo contagem, ou seja, uma variável quantitativa que assume valores não negativos e discretos (Hilbe, 2012). Além disso, o autor complementa que esses modelos podem incluir diversas variáveis preditoras, e o objetivo estatístico é ajustar um modelo de regressão e consequentemente classificar as variáveis preditoras que maximizam a capacidade de prever os valores da variável dependente.

O modelo ZINB combina dois componentes distintos: (i) Componente binário (inflacionado de zeros) – Modela a probabilidade de um zero estrutural por meio de um processo logístico ou probit. Esses zeros estruturais representam situações em que a contagem nunca poderia ocorrer devido a um mecanismo subjacente específico; (ii) Componente de contagem (binomial negativa) – Modela os valores de contagem positivos e os zeros amostrais que podem surgir devido ao processo de contagem propriamente dito.

A função de log-verossimilhança do modelo ZINB é definida por Hilbe (2012) da seguinte forma:

Quando a parte inflacionada de zeros segue uma distribuição logística, temos:

Se $y = 0$

$$\sum_{i=1}^n \ln \left(\frac{1}{1 + \exp(-x_i \beta_1)} + \frac{1}{1 + \exp(x_i \beta_1)} \cdot \frac{1}{(1 + \alpha \exp(x_i \beta))^{1/\alpha}} \right) \quad (2.14)$$

Se $y > 0$, então:

$$\sum_{i=1}^n \ln \left(\frac{1}{1 + \exp(-x_i \beta_1)} \right) + \ln \left(\frac{1}{\alpha} \right) + y_i - \ln(y_i + 1) \quad (2.15)$$

$$-\ln\left(\frac{1}{\alpha}+1\right)+\frac{1}{\alpha}\ln\left(\frac{1}{1+\alpha\exp(x_i\beta)}\right)+y_i\ln\left(1-\frac{1}{1+\alpha\exp(x_i\beta)}\right)$$

Quando a parte inflacionada de zeros segue um processo probit, a função de log-verossimilhança se ajusta para usar a função de distribuição acumulada da normal padrão

$\Phi(x_i\beta_1)$:

Se $y = 0$:

$$\sum_{i=1}^n \ln\left(\Phi(x_i\beta_1) + (1 - \Phi(x_i\beta_1))\left(\frac{1}{1 + \alpha\mu_i}\right)^{1/\alpha}\right) \quad (2.16)$$

Se $y > 0$:

$$\sum_{i=1}^n \left\{ \ln(1 - \Phi(x'_i, \beta_1)) + \ln\Gamma\left(\frac{1}{\alpha} + y_i\right) - \ln\Gamma(y_i + 1) \right. \\ \left. - \ln\Gamma\left(\frac{1}{\alpha}\right) + \left(\frac{1}{\alpha}\right)\ln\left(\frac{1}{1 + \alpha\exp(x'_i, \beta)}\right) + y_i\ln\left[1 - \frac{1}{1 + \alpha\exp(x'_i, \beta)}\right] \right\} \quad (2.17)$$

Onde $(\exp(x\beta_1))$ representa o ajuste, ou μ , do processo binário, e $\exp(x\beta)$ é o mesmo em relação ao processo de contagem. ϕ representa a função de distribuição acumulada normal ou Gaussiana. Esses termos às vezes são representados por símbolos completamente diferentes, por exemplo, $x\beta_1$ é comumente denotado por z para a covariável binária e γ seus coeficientes associados.

De acordo com Zurr *et al.* (2012) a única diferença entre um modelo ZIP (Zero-Inflated Poisson) e um modelo ZINB (Zero-Inflated Negative Binomial) é que, no ZINB, a distribuição de Poisson utilizada para os dados de contagem é substituída pela distribuição binomial negativa. Isso permite lidar com a superdispersão presente nos casos em que há excesso de contagens não nulas. A média e a variância para o modelo ZINB é dada por:

$$E(Y_i) = \mu_i \times (1 - \pi_i) \quad (2.18)$$

$$\text{var}(Y_i) = (1 - \pi_i) \times \mu_i \times \left(1 + \pi_i \times \mu_i + \frac{\mu_i}{k}\right) \quad (2.19)$$

No modelo *Zero-Inflated Negative Binomial* (ZINB), de acordo com Fávero e Belfiore (2022), a denominação "binomial negativa" tem origem na relação matemática entre essa distribuição e a distribuição binomial tradicional. Enquanto a distribuição binomial calcula a probabilidade de um número fixo de sucessos em um número fixo de tentativas, a distribuição binomial negativa objetiva-se no número de tentativas necessárias para alcançar um número

fixo de sucessos. A distribuição Binomial negativa conta o número de fracassos antes de ocorrer o k -ésimo sucesso. Ou seja, um experimento de Bernoulli com probabilidade de sucesso p é repetido de maneira independente e a variável aleatória X conta o número de fracassos anteriores ao k -ésimo sucesso. De acordo com Magalhaes (2006), sua função de probabilidade é dada por:

$$P(X = x | k, p) = \binom{x+k-1}{k-1} p^k (1-p)^x \quad (2.20)$$

para $x = 0, 1, 2, \dots$, sendo k o número fixo de sucessos desejados e p Probabilidade de sucesso em cada tentativa.

De acordo com Baltagi (2021), para testar e comparar os modelos é sugerido o teste de Vuong que é utilizado para comparar modelos não aninhados, como o ZIP e o modelo de Poisson simples, avaliando qual deles oferece um melhor ajuste aos dados. Ele é especialmente útil quando há uma quantidade significativa de zeros em excesso, como ocorre no ZIP, e permite verificar se esse modelo lida melhor com os dados em comparação ao Poisson simples. Além disso, o teste pode ser estendido para o modelo Zero-Inflated Negative Binomial (ZINB), uma alternativa ao ZIP adequada para situações em que há também sobredispersão, ou seja, quando a variabilidade dos dados é maior do que a esperada para o modelo de Poisson.

2.1.7 Escolha do modelo

A seleção de modelos pode ser realizada através de critérios de informação, sendo assim, dois métodos serão discutidos a seguir: O primeiro é o Critério de informação de Akaike (AIC), desenvolvido por Akaike (1973). Calculado da seguinte forma:

$$AIC = -2 \sum_{i=1}^n \ln L(\hat{\mu}_i, y_i) + 2 \times (\text{número de parâmetros}) \quad (2.21)$$

onde, y_i é o i -ésimo valor da resposta e $\hat{\mu}_i$ é a estimativa de y_i quando se ajusta um modelo de p parâmetros por meio da maximização da Função de Log-Verossimilhança. O termo que se adiciona à Função de Log-Verossimilhança, é chamado de função de penalidade, tem a finalidade de corrigir um viés proveniente da comparação de modelos de diferentes números de parâmetros. Entre vários modelos candidatos, deve ser escolhido aquele que apresentar o menor valor de AIC.

O outro critério é foi proposto por Schwarz (1978), sendo o Critério de Informação Bayesiano (BIC). Esse critério é derivado da abordagem bayesiana e se baseia na maximização da função de verossimilhança penalizada pelo número de parâmetros do modelo, de forma a

evitar o sobreajuste. O BIC considera a complexidade do modelo ao incluir um termo de penalização proporcional ao logaritmo do tamanho da amostra. Assim, ele favorece modelos mais simples quando a amostra é grande. A equação do BIC é dada por:

$$BIC = -2 \ln L + p \ln n \quad (2.22)$$

onde L é a Função de Log-Verossimilhança, p é o número de parâmetros estimado e n é o tamanho da amostra.

Além da seleção de modelos é preciso realizar a seleção de variáveis para um modelo de regressão. De acordo com Allen (1974) a seleção de variáveis é fundamental tanto para reduzir sua complexidade quanto para aprimorar a capacidade preditiva do modelo ajustado. No entanto, essa estratégia não garante, por si só, um melhor ajuste da previsão. A escolha das variáveis pode ser baseada no conhecimento do especialista sobre o problema, mas esse processo está sujeito a imprecisões e vieses.

2.2 REVISÃO DA LITERATURA

Nesta etapa, buscou-se analisar e descrever referências que vão fornecer embasamento teórico para o trabalho. Os artigos utilizados nesta seção consideram um período de 2020 a 2024 e a base utilizada nesta pesquisa foi a Web of Science e a SciELO. A primeira seção discute a questão estruturais na transmissão da dengue no Brasil. Em seguida, foi discutido estratégias de controle contra a dengue. E por fim, trabalhos que empregaram abordagens estatísticas no cenário da dengue.

2.2.1 Estudos sobre fatores estruturais e ambientais na transmissão da dengue

Em uma pesquisa desenvolvida por Silva e Silva (2024b), o objetivo do trabalho foi analisar o cenário de resíduos sólidos urbanos com o uso das ferramentas de Machine Learning, através de uma revisão da literatura. O trabalho resultou nos temas mais abordados na literatura, sendo “previsão” e “geração de resíduos” o principal interesse dos achados dos artigos analisados. Além disso, a produção científica é liderada por países como China e Índia, refletindo a relevância local do tema. A conclusão do trabalho destacou a lacuna na literatura em relação aos estudos sobre a relação entre RSU e Saúde Pública, sob a ótica do aprendizado de máquina, apontando para a necessidade de mais pesquisas nessa área. A gestão de resíduos sólidos no Brasil não apresentou avanços otimistas nos últimos anos, apesar da existência do

PNRS. Isso sugere que, embora haja políticas e diretrizes claras, a implementação efetiva dessas políticas ainda enfrenta grandes desafios, particularmente na triagem e na destinação adequada de resíduos (Matias *et al.*, 2022).

De acordo com Juca, Barbosa e Sobral (2020), os indicadores de sustentabilidade são ferramentas de apoio importantes para definir ações de desempenho voltadas ao desenvolvimento sustentável municipal. Sendo assim, os autores desenvolveram uma pesquisa para avaliar as quatro dimensões da sustentabilidade (social, ambiental, econômica e legal/institucional) por meio de indicadores de sustentabilidade aplicados à gestão de RSU na Região Metropolitana do Recife (RMR), no Nordeste do Brasil. Constatou-se que alguns avanços foram alcançados nos últimos anos, como o fechamento de lixões, a redução da massa per capita de RSU coletada e o aumento da cobertura de coleta de resíduos domiciliares. No entanto, a coleta seletiva e a autonomia financeira ainda estão muito aquém das metas estabelecidas para a região. Isso revela que a população necessita de mais acesso à educação ambiental e de ações conjuntas envolvendo o governo.

Cruvinel *et al.* (2020b), investigaram a prevalência de infecções autorrelatadas por dengue, Zika e Chikungunya entre catadores de materiais recicláveis no Aterro Sanitário Estrutural em Brasília, analisando sua relação com as condições sanitárias de suas residências e locais de trabalho. A pesquisa, que utilizou métodos quantitativos e qualitativos, revelou que 29,2% dos 1.025 respondentes relataram ter contraído uma dessas doenças. Foram encontradas associações significativas entre o local de residência, as condições de trabalho, o uso de equipamentos de proteção e a carga horária semanal. Os dados confirmaram a vulnerabilidade dos catadores em relação às doenças transmitidas pelo mosquito *Aedes aegypti*, enfatizando a necessidade de abordagens interdisciplinares para melhorar a gestão de resíduos e a saúde pública.

Em um estudo feito por Sim *et al.* (2020), foi observado que a eficiência na coleta e disposição adequada de resíduos em Cingapura ajudou a eliminar criadouros do mosquito *Aedes aegypti*, responsável pela transmissão da doença. Campanhas de conscientização incentivaram a população a manter áreas limpas, enquanto inspeções domiciliares identificaram e removeram locais propícios para a reprodução dos mosquitos. Além disso, a colaboração entre diferentes agências governamentais e organizações não governamentais possibilitou uma abordagem integrada que uniu saúde pública e limpeza ambiental. A implementação de legislações que penalizavam a falta de conformidade também motivou as comunidades a adotarem práticas adequadas de gestão de resíduos, contribuindo para a redução da incidência de dengue.

Um estudo empírico foi realizado por Akmal e Jamil (2021), em Islamabad e Rawalpindi, Paquistão, para avaliar os impactos à saúde do descarte inadequado de resíduos sólidos. O objetivo foi identificar as consequências da gestão deficiente de resíduos, especialmente para moradores próximos a locais de descarte. A pesquisa coletou dados por meio de entrevistas com domicílios e analisou a relação entre a proximidade a depósitos de lixo e doenças como malária, dengue e problemas respiratórios. Os resultados mostraram que residências a menos de 100 metros de locais de descarte eram mais vulneráveis a essas doenças, e apenas 51,4% dos residentes tinham acesso aos serviços de coleta, com 75,9% não segregando adequadamente os resíduos. Isso destacou a necessidade urgente de melhorar as políticas de gestão de resíduos para proteger a saúde pública e o meio ambiente.

Uma análise da situação atual em relação ao controle do *Aedes aegypti* foi realizada por meio da Matriz "Fortalezas/Oportunidades/Ameaças e Fraquezas" (FOFA) pelos Agentes de Combate às Endemias (ACE's) de Aracaju-SE (Feitosa; Silva; Sobral, 2021). O objetivo da aplicação da Matriz FOFA foi fortalecer a organização e refletir sobre as potencialidades e dificuldades na implementação de ações mais efetivas de controle. Os resultados mostraram aspectos positivos, como a regulamentação legal e a quantidade satisfatória de supervisores de campo, mas também apontaram dificuldades, como a falta de ações integradas, um número reduzido de ACEs em campo e a baixa participação comunitária. Além disso, a política de saneamento ambiental em Aracaju enfrenta desafios, como a interrupção no abastecimento de água e a destinação inadequada de resíduos sólidos, que favorecem a propagação de doenças como Dengue, Chikungunya e Zika, indicando que os desafios estão mais na implementação do programa do que em sua estrutura.

O estudo realizado por Jeyapal *et al.* (2022), evidenciou a transmissão local da dengue em Puducherry, na Índia, destacando que 23 casos primários não apresentavam histórico de viagens. A pesquisa revelou que 78,3% dos bairros investigados tinham condições de sanitárias inadequadas, com terrenos vagos e áreas abertas sendo utilizados como depósitos de lixo, criando focos favoráveis para a reprodução de mosquitos. Além disso, a falta de conscientização da população sobre a dengue foi evidente, com muitos participantes desconhecendo que a doença é transmitida por mosquitos. A expectativa de que o governo cuidasse da limpeza dos bairros, somada à ausência de ações imediatas de controle após os primeiros casos, sublinha a necessidade de campanhas eficazes de sensibilização sobre a gestão de resíduos sólidos e a prevenção da dengue, promovendo a participação ativa da comunidade e dos profissionais de saúde.

Klafke, Barros e Henning (2023b), analisaram a relação entre indicadores de gestão de resíduos sólidos e a infestação do mosquito *Aedes aegypti* no Brasil, utilizando dados do Sistema Nacional de Informações sobre Saneamento (SNIS). A pesquisa destacou a importância da gestão adequada de resíduos sólidos na redução da proliferação do mosquito, evidenciando a necessidade de políticas de resíduos sólidos urbanos para apoiar a saúde pública e a qualidade ambiental. Além disso, a integração de elementos, participação de todas as partes envolvidas e educação da sociedade foram apontadas como fundamentais para um modelo de gestão integrado e sustentável. Os autores concluíram que a ausência de condições sanitárias mínimas e infraestrutura adequada pode contribuir para a propagação do mosquito, aumentando o risco de transmissão de doenças como zika, dengue e chikungunya.

Pesquisadores investigaram a distribuição de casos de dengue, depósitos de resíduos sólidos, fragmentos de floresta, drenagem de água, e a possível associação com surtos de dengue em Presidente Prudente, São Paulo, Brasil (Prestes-Carneiro *et al.*, 2024). Eles coletaram dados de agências de 2015 a 2021, foram relatados 33.026 casos de dengue, com a maior incidência e taxa de mortalidade em 2016. O número de casos diminuiu durante a pandemia de COVID-19 em 2020 e 2021 em comparação com 2019, mas taxas alarmantes foram registradas em 2022. Em 2015, foram identificados 56 pontos de depósitos de resíduos sólidos, com um aumento de 1,6 vezes em 2020 e 2021. A análise multivariada mostrou uma correlação positiva entre a densidade de casos de dengue e os depósitos de resíduos sólidos, com a maior correlação em 2020. Identificar essas áreas pode orientar as autoridades de saúde pública em medidas de vigilância e melhorias na infraestrutura de saúde.

Um estudo foi realizado para analisar como a qualidade do serviço de coleta de resíduos, a percepção sobre os benefícios dos objetos em desuso e outros fatores influenciam a presença de criadouros de mosquitos, contribuindo assim para a prevenção da dengue e promovendo a gestão adequada de resíduos sólidos (Lima-Pereira, 2024). Foram coletados dados de 350 residências, e foram realizadas análises estatísticas, incluindo o teste qui-quadrado e a análise de regressão logística, com o suporte de softwares específicos para processamento e análise dos dados. Os resultados indicaram que a qualidade do serviço de coleta, a percepção de benefícios dos objetos em desuso e a falta de gestão adequada de resíduos sólidos são fatores significativos na presença de criadouros. Com base nessas conclusões, os autores recomendaram a implementação de intervenções, como a criação de pontos de doação, a reparação de eletrodomésticos e a instalação de centros de recuperação de materiais, como estratégias para enfrentar essa problemática.

Em um trabalho realizado por Silva e Silva (2024a), os autores analisaram a relação entre resíduos sólidos, saneamento básico, renda e casos de dengue através de uma Regressão Linear Múltipla. Como resultado os autores concluíram que os casos de dengue são influenciados por resíduos sólidos e por saneamento básico. No tocante a precariedade do acesso a esgoto sanitário, populações mais carentes sofrem com os transtornos causados. Além disso, a falta de coleta e o acúmulo de lixo em locais inadequados provocam o aumento nos casos de dengue.

Andrioli, Busato e Lutinski (2020), descreveram as características da epidemia de dengue em Pinhalzinho, Santa Catarina, Brasil, e investigaram os efeitos das variáveis climáticas sobre a infestação pelo mosquito *Aedes aegypti*. Os resultados indicaram que a temperatura média e a umidade relativa do ar apresentaram uma relação positiva com o aumento dos focos do mosquito. Além disso, a incidência de dengue durante a epidemia foi a maior já registrada no país. Portanto, as condições climáticas devem ser consideradas no planejamento das ações de controle vetorial e na prevenção da dengue.

Bavia *et al.* (2020), realizaram um estudo epidemiológico sobre dengue no sul do Brasil entre 2012 e 2014, os autores investigaram a relação entre a doença, clima e pobreza em uma área metropolitana. Foram coletados dados demográficos e clínicos de 878 pacientes com sintomas sugestivos, dos quais 249 foram diagnosticados com dengue. A pesquisa revelou que, à medida que a renda média diminui, a incidência da doença aumenta, sugerindo uma ligação com a pobreza. Além disso, identificou-se uma distribuição sazonal da dengue, associada a atrasos em relação à precipitação e temperatura.

Em uma pesquisa realizada por Nakase *et al.* (2024), os autores consideram que o aumento nos casos de dengue registrados no Brasil, especialmente no estado de São Paulo, pode ser atribuído a diversos fatores, com destaque para as mudanças climáticas, a ausência de medidas eficazes de controle e prevenção, e a intensa urbanização de áreas naturais (Geraldini; Johansen; Justus, 2024). Além disso, condições que normalmente controlariam a população de mosquitos têm sido menos eficazes. Foi concluído que a elevação das médias pluviométricas e a manutenção de temperaturas adequadas criam um ambiente propício à proliferação dos mosquitos, intensificando a transmissão da doença. Fujita *et al.* (2023), complementam que o crescimento de casos naturalmente ocorrem durante o inverno é especialmente preocupante, uma vez que a dengue está tipicamente associada aos meses mais quentes.

Figueredo *et al.* (2023) observaram que o mosquito possui necessidades reprodutivas específicas e regiões tropicais que proporcionem condições climáticas favoráveis ao desenvolvimento do vetor. Através de uma análise de correlação cruzada entre as variáveis

climáticas temperatura do ar, umidade relativa, precipitação média semanal e casos de dengue no período de 2017 até o início de 2021 no município de Alagoinhas, Bahia, Brasil. Para isso, os autores aplicaram uma correlação cruzada sem tendência, que é uma generalização da análise de flutuação sem tendência, onde foram calculadas a correlação cruzada entre séries temporais para estabelecer a influência dessas variáveis na ocorrência da doença dengue. Os resultados obtidos mostram uma correlação moderada entre a umidade relativa e a incidência de casos de dengue, e uma correlação baixa para a temperatura do ar relativa e precipitação. No entanto, o fator predominante na incidência de casos de dengue na cidade de Alagoinhas é a umidade relativa do ar, e não a temperatura e a precipitação.

2.2.2 Estratégias de controle da dengue

Em um estudo realizado por Scott *et al.* (2023) foram exploradas perspectivas dos moradores de Fortaleza, Brasil, sobre a aceitação de uma vacina hipotética segura e eficaz contra a dengue, os fatores que influenciam a aceitação ou hesitação vacinal, e o impacto esperado da vacinação contra a dengue em suas práticas pessoais de controle do vetor. Os resultados encontrados indicam que os entrevistados demonstraram bom conhecimento sobre transmissão, sintomas e métodos de prevenção da dengue. Os participantes relataram estar dispostos a aceitar uma vacina hipotética contra a dengue para si mesmos e seus filhos, desde que sua segurança e eficácia fossem claramente comprovadas.

Educação em saúde pode ser considerada uma estratégia para o controle da dengue. Sendo assim, Pérez *et al.* (2024), avaliaram a eficácia de uma intervenção educativa realizada por enfermeiros no controle da dengue. Foram identificados que fatores de risco para a dengue são amplamente influenciados pelas condições de vida na comunidade, principalmente devido à presença de reservatórios artificiais ou tanques desprotegidos em residências. Além disso, a falta de informação dificulta a identificação dos sintomas da doença e a adoção de medidas eficazes.

De acordo com Costa *et al.* (2021) a eliminação dos criadouros de água parada passa, primeiramente, pela conscientização da população – promovendo hábitos que evitem o acúmulo de água em recipientes, pneus, caixas d'água e outros locais propícios ao desenvolvimento do mosquito. Complementarmente, estratégias de controle químico e biológico são adotadas para tratar áreas onde a eliminação total dos criadouros não seja possível de imediato. O controle químico envolve a aplicação de larvicidas e inseticidas, enquanto o controle biológico aposta

na utilização de organismos que podem reduzir a população do vetor, como alguns tipos de peixes ou bactérias específicas.

O estudo de Lage *et al.* (2022) apresenta uma metodologia inovadora para identificar áreas urbanas de alto risco para a presença do mosquito *Aedes aegypti*, empregando armadilhas para mosquitos, visitas domiciliares para identificar criadouros e imagens de sensoriamento remoto. Ao utilizar coordenadas geográficas dos locais de captura e a ferramenta de análise espacial, os autores geraram mapas preditivos que indicam a distribuição do vetor. Este modelo de classificação espacial não só valida as características das áreas de risco, mas também possibilita a visualização das áreas prioritárias para o desenvolvimento de medidas de controle. A integração dos dados coletados e os resultados das imagens de satélite fornecem aos serviços de saúde e controle vetorial uma metodologia eficaz para otimizar o uso dos recursos, com potencial para reduzir a incidência de doenças como dengue, zika e chikungunya, direcionando os esforços de vigilância para as regiões mais vulneráveis.

Estratégias mais eficazes no atendimento dos pacientes são consideradas por Pedrotti *et al.* (2022), onde os autores realizaram um estudo sobre a telemedicina durante um surto de dengue, analisando sua eficácia na redução da necessidade de consultas presenciais em um hospital de campanha. Durante períodos de superlotação, pacientes positivos para dengue e classificados como de baixo a moderado risco puderam optar por consulta por telemedicina, realizada por vídeo. Os autores concluíram que, dos 267 pacientes atendidos por telemedicina, 94,4% receberam alta após a consulta, enquanto apenas 5,6% necessitaram de avaliação médica presencial imediata.

Por fim, Albarado *et al.* (2021) investigaram a estratégia de comunicação adotada pelo Ministério da Saúde na prevenção das doenças transmitidas pelo *Aedes aegypti*, com foco na percepção da comunidade em relação aos vídeos institucionais veiculados entre 2014 e 2017. O estudo envolveu uma entrevista em profundidade com um informante-chave do Centro de Comunicação do Ministério da Saúde, bem como rodas de conversa realizadas em quatro regiões do Brasil. Os autores identificaram que os vídeos, por si só, não atendem plenamente às necessidades da população e sugerem que sua eficácia pode ser aprimorada por meio da integração com outras ações de informação, educação e comunicação em saúde, contribuindo assim para um controle mais eficaz das doenças.

2.2.3 Modelos estatísticos aplicados na modelagem de casos de dengue

Os autores Monteiro e Araújo (2020) aplicaram regressões quantílicas para analisar os impactos de variáveis socioeconômicas e climáticas na incidência de dengue em municípios brasileiros entre 2008 e 2011. Essa metodologia permitiu identificar variações no impacto das variáveis explicativas em diferentes quantis da distribuição dos casos de dengue. Os resultados indicaram que despesas em saneamento básico apresentaram impacto negativo em todos os quantis analisados, com coeficientes que variaram de -0,23 a -0,18 ($p < 0,01$). Em contraste, a densidade demográfica teve impacto positivo, com coeficientes entre 0,12 e 0,15 ($p < 0,05$). No que diz respeito às variáveis climáticas, precipitação total e temperatura máxima apresentaram efeitos crescentes nos quantis superiores, com coeficientes que variaram de 0,08 a 0,16 ($p < 0,05$). Esses resultados indicam que políticas públicas que combinem melhorias em saneamento e estratégias de controle populacional podem ter um impacto significativo na redução de casos de dengue, especialmente em áreas mais vulneráveis.

Martins *et al.* (2020) conduziram uma análise espaço-temporal detalhada no estado do Ceará, Brasil, abrangendo o período de 2001 a 2019. Utilizando modelos de regressão segmentada, identificaram três períodos distintos: uma redução inicial na incidência de dengue de -20,9% ao ano (IC: -65,1 a 44,8) de 2001 a 2004; um aumento de 7,9% ao ano (IC: -6,0 a 98,9) de 2005 a 2015; e uma queda acentuada de 48,8% ao ano (IC: -83,0 a -6,1) de 2016 a 2019. Durante o período analisado, foram identificados clusters de alto risco em regiões específicas, com riscos relativos (RR) que variaram de 3,57 a 14,38. Esses clusters estavam associados a áreas com alta densidade populacional e condições climáticas favoráveis à proliferação do vetor, reforçando a importância de análises espaço-temporais para identificar regiões prioritárias para intervenções.

Tran *et al.* (2020) ampliaram essa discussão ao investigar os limites críticos de temperatura no índice larval do mosquito *Aedes aegypti* em Taiwan, utilizando dados semanais de 2012 a 2019. Modelos de regressão binomial negativa foram aplicados para avaliar os impactos de diferentes regimes de temperatura na proliferação vetorial. O estudo revelou que, para cada aumento de 1°C na temperatura média, o índice de Breteau (IB) aumentava em 0,09 unidades abaixo de 27,21°C e em 0,26 unidades acima desse valor ($p < 0,01$). No sul de Taiwan, os efeitos foram ainda mais pronunciados, com aumentos de 0,29 a 1,49 unidades dependendo do intervalo de temperatura. Além disso, a precipitação e a umidade relativa apresentaram efeitos mais fortes em temperaturas superiores aos limites críticos, indicando a importância de considerar a interação entre fatores climáticos ao planejar estratégias de controle.

Por outro lado, Mol *et al.* (2020) analisaram a influência de fatores estruturais na incidência de dengue em 853 municípios de Minas Gerais, Brasil, entre 2007 e 2016. A

cobertura de coleta seletiva apresentou uma relação inversa significativa com a incidência da doença, com coeficientes que variaram de -0,12 a -0,15 ($p < 0,05$). Em contrapartida, o índice de Gini, que mede desigualdade social, apresentou uma associação positiva significativa, com coeficientes entre 0,23 e 0,28 ($p < 0,01$). Esses achados destacam como desigualdades sociais e infraestrutura deficiente amplificam a vulnerabilidade à dengue, complementando os resultados obtidos por Monteiro e Araújo (2020).

No contexto da Indonésia, Wijaya *et al.* (2021), analisaram dados de painel para explorar a relação entre variabilidade climática e casos de dengue entre 2017 e 2019. Modelos de efeitos aleatórios revelaram associações positivas significativas entre a incidência de dengue e fatores como precipitação e temperatura, com coeficientes de 0,18 a 0,25 ($p < 0,05$). O estudo também destacou limitações no sistema de saúde e alta densidade populacional como fatores que amplificam a proliferação do vetor, reforçando a necessidade de intervenções integradas que considerem tanto fatores climáticos quanto estruturais.

Kalbus *et al.* (2021), trouxeram outra perspectiva ao avaliar o impacto do desmatamento no estado do Amazonas entre 2007 e 2017. Embora análises bivariadas tenham indicado um aumento médio de 55,47 casos por 100.000 habitantes três anos após o desmatamento ($p = 0,002$), modelos ajustados não encontraram associação direta entre desmatamento e dengue. No entanto, o acesso à saúde foi identificado como um preditor significativo, com uma razão de incidência (RI) de 1,45 (IC: 1,12–1,87). Esses achados reforçam a importância de uma abordagem multifacetada que combine esforços ambientais e melhorias nos sistemas de saúde.

Mudele *et al.* (2021) utilizaram dados de observação da Terra (EO) para modelar a distribuição temporal da população de *Aedes aegypti* em Vila Velha, Brasil, usando um modelo linear generalizado (GLM). Os resultados mostraram que a vegetação (NDVI), a temperatura da superfície terrestre (LST) e a precipitação tiveram efeitos significativos na população de mosquitos. A análise revelou que variáveis como a temperatura da superfície (coeficiente $\beta = 0,12$) e a precipitação ($\beta = 0,08$) foram preditores robustos da dinâmica do vetor. Embora técnicas de aprendizado de máquina, como Random Forest, tenham mostrado melhor desempenho preditivo, o GLM foi preferido por sua interpretabilidade e capacidade de visualização das incertezas.

Einloft *et al.* (2021) analisaram os fatores associados à dengue em mulheres grávidas e não grávidas no Brasil, utilizando dados de 2007 a 2017. A gravidez aumentou em 1,8 vezes o risco de formas graves de dengue (*Odds Ratio* (OR) = 1,8; IC: 1,2–2,6). Além disso, variáveis como baixa escolaridade (OR = 1,5; IC: 1,1–2,1) e a ausência de saneamento básico (OR = 2,3; IC: 1,6–3,4) foram associadas a um aumento significativo no risco de infecção. Estes resultados

indicam que fatores sociais e de infraestrutura têm um impacto importante na propagação da dengue, especialmente em populações vulneráveis.

Saraiva *et al.* (2022) aplicaram o modelo de regressão Poisson Inverse Gaussian (PIG) para analisar dados de dengue em Campo Grande, MS, Brasil, no período de 2008 a 2019. O estudo utilizou as seguintes variáveis: X_1 , que representa o mês do ano codificado de 1 a 12; X_2 , a temperatura média no mês; X_3 , a umidade média no mês; X_4 , o número de dias chuvosos no mês; e X_5 , a precipitação total do mês. O modelo foi comparado com as regressões de Poisson e Binomial Negativa, utilizando critérios de qualidade de ajuste, como o AIC. Os resultados indicaram que o modelo PIG foi mais eficaz em lidar com a sobredispersão dos dados, capturando padrões sazonais e destacando a precipitação e a temperatura como os principais fatores associados ao aumento dos casos de dengue.

Hossain (2023), analisou dados em painel em Bangladesh de janeiro de 2000 a dezembro de 2021, identificando uma forte correlação entre mudanças climáticas e transmissão da dengue. Os modelos indicaram que temperaturas médias entre 28°C e 30°C representavam o maior risco para surtos, com coeficientes de 0,32 a 0,45 ($p < 0,01$). Além disso, precipitações mensais entre 90 mm e 360 mm dobraram o risco de surtos, destacando o impacto crítico de mudanças climáticas em escala global. A autora ajustou dois modelos sendo a regressão Quasi-Poisson e a regressão Zero-Inflated Poisson (ZIP). O melhor modelo foi o Quasi-Poisson, que apresentou um AIC de 9.027, enquanto o modelo Zero-Inflated Poisson teve um AIC de 12114, indicando um pior ajuste aos dados.

2.3 SÍNTESE DO ESTADO DA ARTE

A síntese do estado da arte evidencia que os surtos de dengue estão intimamente relacionados a uma série de fatores que, de forma conjunta, influenciam a dinâmica da doença. Consoante a literatura, tanto as variáveis climáticas – como variações na temperatura, precipitação e umidade – quanto as condições estruturais dos ambientes urbanos, como a gestão de resíduos sólidos, o acesso a saneamento básico e a eficiência na coleta de lixo, são determinantes na propagação da doença. Esses elementos afetam a transmissão de maneira espacial e temporal, especialmente em regiões tropicais, onde o clima favorece a proliferação do vetor.

As variáveis selecionadas para esta pesquisa foram definidas com base no conhecimento de especialistas, o que garantiu que os elementos mais relevantes para a transmissão da dengue em Pernambuco fossem considerados. Essas variáveis fundamentadas nos artigos buscam

refletir a complexidade do fenômeno e captar nuances que podem ser perdidas em abordagens mais generalizadas.

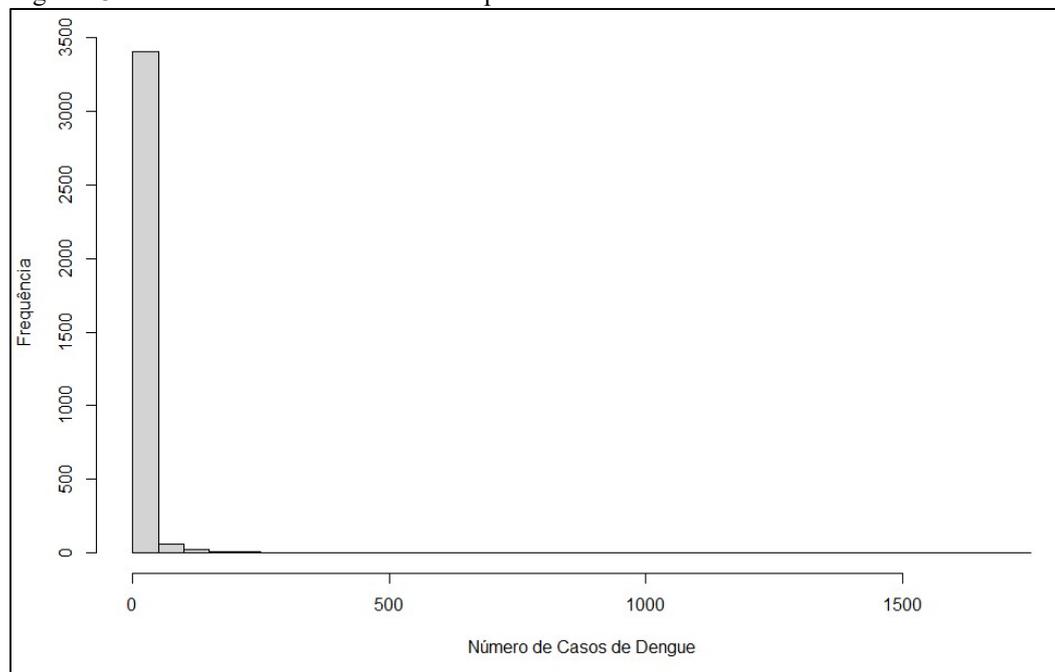
Outro ponto relevante é o uso de modelos de regressão para análise dos dados de dengue. Embora essa abordagem seja empregada em contextos epidemiológicos, nota-se uma lacuna na literatura no que tange à aplicação de modelos de dados em painel para analisar a incidência da dengue especificamente em Pernambuco. Essa ausência representa uma oportunidade de investigação, permitindo a identificação dos determinantes com maior impacto na região.

3 ANÁLISE DE MODELOS ELEGÍVEIS PARA CASOS DE DENGUE

Antes de avançar para a modelagem estatística, é necessário avaliar a variável dependente. O número de casos de dengue constitui uma variável de contagem, que assume apenas valores inteiros não negativos e, portanto, requer distribuições discretas para sua adequada modelagem. Entre as distribuições mais utilizadas para esse tipo de dado, destaca-se a Poisson, que assume equidispersão, e a Binomial Negativa, que permite modelar casos em que a variância é superior à média. A adequação da distribuição de Poisson para os dados será verificada posteriormente por meio do teste de equidispersão.

A variável dependente corresponde ao número de casos de dengue registrados no estado de Pernambuco, desagregados por município, mês e ano, no período de janeiro de 2020 a junho de 2023, conforme os dados disponibilizados pelo DATASUS. A Figura 13 apresenta a distribuição do número de casos de dengue. Nota-se uma forte concentração de observações em valores próximos de zero, evidenciando uma alta frequência de registros com poucos ou nenhum caso de dengue. Além disso, observa-se a presença de alguns valores mais elevados, embora em menor quantidade.

Figura 13 – Gráfico de barras da variável dependente



Fonte: O Autor (2024).

A distribuição de Poisson pressupõe que a média e a variância da variável são iguais, condição raramente observada em dados epidemiológicos, nos quais é comum a presença de superdispersão — isto é, uma variância superior à média. Nesses casos, a distribuição Binomial

Negativa surge como uma alternativa mais apropriada, pois permite acomodar essa característica dos dados. Assim, antes da definição do modelo estatístico, será realizada uma análise exploratória da variável dependente para identificar sua distribuição empírica e verificar a necessidade de modelagens que contemplem a superdispersão.

Para verificar a presença de superdispersão, foi realizado o teste de Cameron e Trivedi, implementando no pacote *overdispersion* através da função *overdisp* na linguagem R (Souza e Correa, 2023). O teste aplicado à variável dependente deste estudo resultou em um *p-valor* $< 0,05$, fornecendo evidências estatísticas de superdispersão. Esse resultado indica que a variância dos dados é significativamente maior que a média, violando o pressuposto de equidispersão do modelo de regressão de Poisson.

Dessa forma, tanto o modelo de Poisson quanto o modelo Zero-Inflated Poisson (ZIP) devem ser descartados, pois a utilização dessas abordagens não seria adequada para dados que apresentam superdispersão. Além disso, outro aspecto relevante é a quantidade expressiva de observações com zero casos de dengue. Como apresentado na Tabela 3, 59,67% das observações correspondem a períodos e municípios sem registros da doença. Esse excesso de zeros indica que um modelo inflacionado de zeros (Zero-Inflated) pode ser mais indicado para capturar adequadamente a estrutura dos dados e melhorar a precisão das estimativas.

Tabela 3 – Quantidade de observações com zero caso de dengue

Observações Totais	Frequência de Zeros	%
3521	2101	59,67%

Fonte: O Autor (2024).

Diante dessas características, a distribuição Binomial Negativa surge como uma alternativa mais apropriada para modelagem dos casos de dengue, uma vez que permite acomodar a superdispersão observada nos dados. Além disso, sua versão inflacionada de zeros (Zero-Inflated Negative Binomial – ZINB) possibilita lidar simultaneamente com a elevada frequência de valores zero e a variabilidade excessiva da variável dependente, tornando-se uma opção metodológica mais robusta para a análise.

A escolha do modelo estatístico mais adequado deve considerar essas especificidades, garantindo que as características dos dados sejam corretamente incorporadas à modelagem. Nesse sentido, Fávero *et al.* (2021) apresentam uma sistematização dos modelos estatísticos que podem ser utilizados em cenários com superdispersão e excesso de zeros, destacando a importância da verificação desses pressupostos antes da definição do modelo. A Tabela 4

sintetiza essas informações, indicando quais abordagens estatísticas são mais apropriadas para lidar com cada uma dessas condições.

Tabela 4 – Pressupostos dos modelos

Verificação	Poisson	Binomial Negativo	ZIP	ZINB
Sobredispersão nos dados da variável dependente	Não	Sim	Não	Sim
Quantidade excessiva de Zeros na variável dependente	Não	Não	Sim	Sim

Fonte: Adaptado de (Fávero *et al.*, 2021).

Após a análise da variável dependente e a escolha do modelo adequado, a Tabela 5 apresenta a estatística descritiva da base de dados utilizada nesta pesquisa. São exibidas as medidas de mínimo, primeiro quartil, mediana, média, terceiro quartil e máximo, permitindo uma visão geral da distribuição dos dados. Observa-se que o número de casos de dengue na Tabela 4 varia de 0 a 1710, sendo o valor mínimo, primeiro quartil e mediana iguais a 0, e um terceiro quartil igual a 2, indicando que 75% das observações registram até dois casos. A média de 8,48 casos sugere que a distribuição é assimétrica, com a maioria das observações registrando valores baixos e poucos municípios apresentando quantidades elevadas da doença. Destaca-se ainda a presença *outlier* onde o maior número de casos foi registrado em junho de 2021, onde 1710 casos foram registrados no município do Recife, capital do estado.

Tabela 5 – Estatística descritiva das variáveis

Variável	Min	1º Quartil	Mediana	Média	3º Quartil	Máximo
Casos de dengue	0	0	0	8,48	2	1710
Temperatura Máxima	22,20	31,35	33,51	33,28	35,40	40,40
Temperatura Mínima	15,00	17,50	19,10	19,13	20,60	30,00
Precipitação	0,00	18,08	59,60	88,20	123,20	812,20
Umidade	10,00	10,00	10,00	12,71	10,00	51,00
ACS	0,51	1,00	1,00	0,96	1,00	1,00
RSU	5,40	154,00	388,00	1954,20	1069,40	47616,90
Plano de Saneamento	0,00	0,00	0,00	0,20	0,00	1,00
Acesso Água	0,19	0,62	0,79	0,78	1,00	1,00
Acesso Esgoto	0,00	0,22	0,43	0,46	0,68	1,00
Acesso Coleta	0,30	0,62	0,78	0,76	0,94	1,00

Fonte: O Autor (2024).

Os indicadores de infraestrutura sanitária (Acesso à Água, Acesso a Esgotamento Sanitário e Acesso à Coleta de Lixo) apresentam uma mediana de 0,79, 0,43 e 0,78,

respectivamente, sugerindo que, em metade dos municípios, o acesso a esses serviços ainda é limitado. Além disso, observa-se que o acesso à água e à coleta de resíduos apresentam valores próximos ao máximo em alguns municípios, enquanto o acesso a esgotamento sanitário tem menor cobertura.

4 AJUSTE DOS MODELOS PARA CASOS DE DENGUE

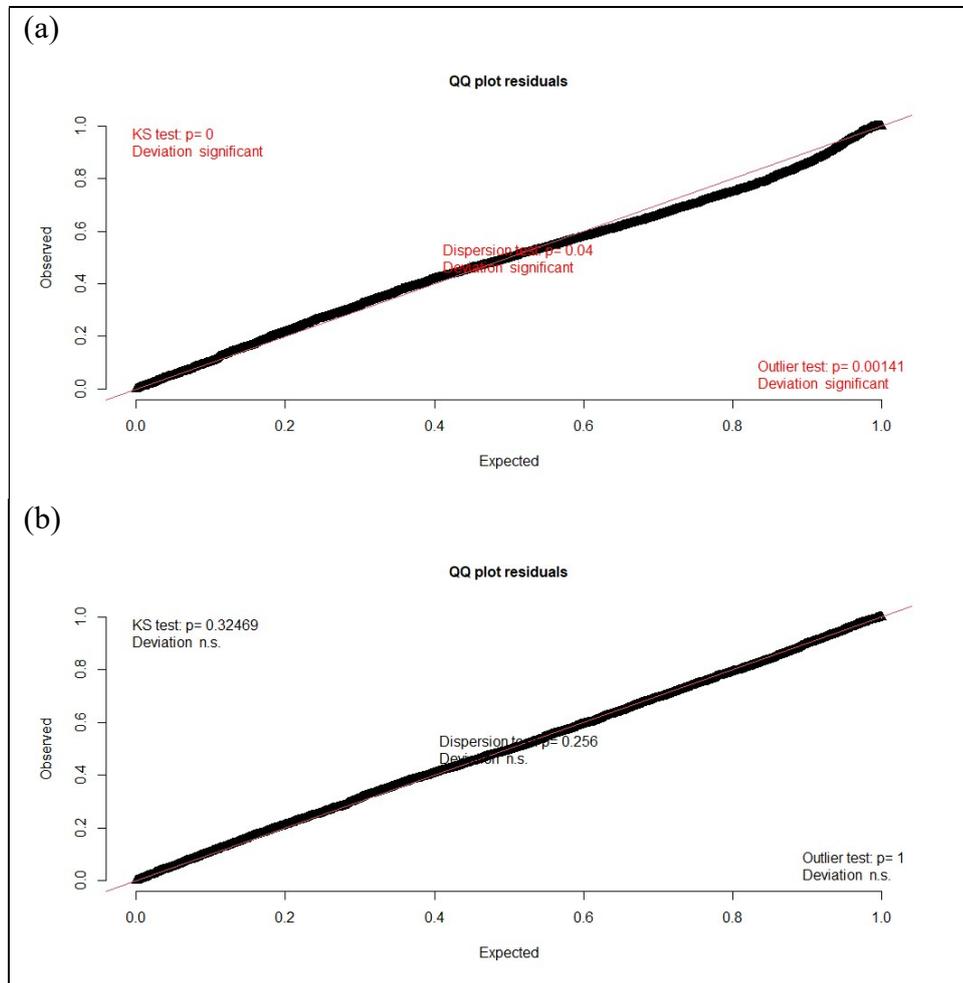
Diante das considerações expostas no capítulo anterior, o modelo adotado neste estudo é o *Zero-Inflated Negative Binomial* (ZINB), que permite capturar tanto a superdispersão dos dados quanto o excesso de zeros. O ajuste dos modelos foi realizado utilizando o pacote *glmmTMB* (versão 1.1.9) na linguagem R, que possibilita a incorporação de efeitos aleatórios, uma abordagem essencial para considerar a estrutura dos dados em painel. Embora o pacote *pscl* seja amplamente utilizado para modelagem de inflação de zeros, sua limitação em relação à inclusão de efeitos aleatórios tornou o *glmmTMB* a escolha mais adequada para este estudo. Além disso, a estimação do modelo foi conduzida utilizando o otimizador *BFGS* (*Broyden-Fletcher-Goldfarb-Shanno*), um método baseado em gradientes. Durante o ajuste, os modelos realizaram entre 40 e 85 iterações, garantindo a convergência e a obtenção dos coeficientes estimados.

A comparação entre os modelos ZINB sem efeito aleatório e com efeito aleatório permite avaliar o impacto da inclusão da estrutura hierárquica nos resultados. Para escolha dos modelos foi adotado o critério de informação de Akaike (AIC) e o Critério de Informação Bayesiano (BIC). A inclusão dos efeitos aleatórios reduziu o valor de AIC (de 13055,2 para 12263,9) e do BIC (de 13134,9 para 12355,9), indicando que com efeito aleatório apresenta um melhor ajuste aos dados. Além disso, o log-verossimilhança aumentou de -6514,6 para -6116,9, reforçando a melhoria do ajuste ao considerar variações entre municípios e ao longo do tempo.

O modelo ZINB com efeito aleatório inclui um termo de intercepto aleatório para município e período (mês/ano), o que captura possíveis heterogeneidades não explicadas pelas variáveis fixas. Os resultados mostram que há variação significativa entre municípios (variância = 2,1754; desvio padrão = 1,4749) e dentro dos municípios ao longo do tempo (variância = 0,6961; desvio padrão = 0,8343). Isso sugere que a incidência de dengue varia consideravelmente entre municípios e dentro de um mesmo município ao longo do tempo, justificando a inclusão desses efeitos.

Essa melhoria no modelo também pode ser observada através dos resíduos por meio do Teste Kolmogorov-Smirnov. No primeiro diagnóstico (Figura 14a, modelo com efeito fixo), os resíduos apresentavam desvio em relação à distribuição esperada, com indícios de problemas de adequação, dispersão e presença de outliers. No segundo diagnóstico (Figura 14b, modelo com efeito aleatório), os resíduos mostram uma distribuição mais homogênea e alinhada com o esperado, sem indícios significativos de dispersão ou problemas com outliers.

Figura 14 – Resíduos ZINB fixo e aleatório



Fonte: O Autor (2024).

No modelo com efeito aleatório na Tabela 6 as variáveis climáticas foram incluídas na contagem e as variáveis estruturais na inflação de zeros. O modelo pode ser interpretado da seguinte forma: (i) O IRR (*Incidence Rate Ratio*) está relacionado ao modelo de contagem e indica o quanto a taxa esperada do evento (como número de casos de dengue) muda com o aumento de uma unidade em um preditor. Já o OR (*Odds Ratio*) está relacionado ao modelo de inflação de zeros, onde indica como as chances de um evento ser zero mudam com o aumento de uma unidade em um preditor. Sendo assim, A temperatura máxima (Max) foi estatisticamente significativa ($p < 0.001$), com um coeficiente de -0.106 (IC 95%: -0.145 a -0.068), indicando que um aumento de 1°C na temperatura máxima está associado a uma redução de aproximadamente 10,06% na incidência de casos de dengue ($\exp(-0.106) = 0.8994$, IC 95%: 0.8649 a 0.9342). A precipitação defasada em um mês (Precipitação) permaneceu significativa

em ambos os modelos ($p < 0.001$), com um coeficiente de 0.0043 (IC 95%: 0.0033 a 0.0053), indicando que chuvas no mês anterior aumentam a incidência de dengue, mas com um efeito pequeno. Temperatura mínima e umidade não apresentaram significância estatística no modelo.

Na parte de inflação de zeros na Tabela 6 apenas as variáveis acesso a água encanada (Água) e toneladas de resíduos sólidos urbanos (RSU) foram estatisticamente significativas. A variável acesso a água foi estatisticamente significativa ($p = 0.0002$), com um coeficiente de -2.61224 (IC 95%: -4.00006 a -1.22443), indicando que um aumento de uma unidade na disponibilidade de água está associado a uma redução de aproximadamente 92,66% na chance de um município pertencer ao excesso de zeros ($\exp(-2.61224) = 0.07337$, IC 95%: 0.0183 a 0.2935). A variável resíduos sólidos urbanos (RSU) também foi estatisticamente significativa ($p = 0.0074$), com um coeficiente de -0.042 (IC 95%: -0.0736 a -0.0114), indicando que um aumento na coleta de resíduos está associado a uma redução de aproximadamente 4,11% na chance de um município pertencer ao excesso de zeros ($\exp(-0.042) = 0.95887$, IC 95%: 0.9290 a 0.9887).

Tabela 6 – ZINB com efeito aleatório

	Variáveis	Binomial Negativo Inflacionado de Zeros - ZINB			
		Estimativas	Erro padrão	p-valor	IC 95%
(i)	Intercepto	-6,6530***	0,7174	< 0,001	-8,06 a -5,25
	Max	-0,1062***	0,0197	< 0,001	-0,14 a -0,07
	Min	-0,0225	0,0218	0,3020	-0,07 a 0,02
	Umidade	-0,0018	0,0058	0,7580	-0,01 a 0,01
	Precipitacao	0,0043***	0,0005	< 0,001	0 a 0,01
(ii)	Intercepto	-715,8388	1173,4530	0,5418	-3015,76 a 1584,09
	Coleta	1,0965	0,8578	0,2011	-0,58 a 2,78
	Esgoto	-0,7769	0,4970	0,1180	-1,75 a 0,2
	Água	-2,6122***	0,7081	0,0002	-4,0 a -1,22
	Plano	-1,0551	0,6454	0,1021	-2,32 a 0,21
	ACS	716,9204	1173,4359	0,5412	-1582,97 a 3016,81
	RSU1000	-0,0425**	0,0159	0,0074	-0,07 a -0,01
GLOBAL	AIC	12263,9			
	BIC	12355,9			
	Log-verossimilhança	-6116,9			
	Deviance	12233,9			
	alpha	0,535			

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

(i) Não inflacionado; (ii) Inflacionado de zero

Fonte: O Autor (2024).

Em continuidade às análises, outro modelo foi ajustado considerando apenas as variáveis que foram estatisticamente significativas no modelo anterior. Assim, o novo modelo da Tabela 7 inclui temperatura máxima (Max) e precipitação defasada (Precipitação) na parte de contagem e acesso à água encanada (Água) e toneladas de resíduos sólidos urbanos coletados (RSU) na parte inflacionada. Os critérios de informação AIC e BIC permaneceram praticamente inalterados (AIC = 12288.2, BIC = 12343.4), indicando que a simplificação do modelo manteve um ajuste similar ao anterior. No entanto, as estimativas dos coeficientes sofreram alterações. Na parte de contagem, a variável temperatura máxima (Max) manteve-se significativa, com um coeficiente de -0.11471 (IC 95%: -0.15 a -0.08), indicando que um aumento de 1°C na temperatura máxima está associado a uma redução na incidência de casos de dengue em 10,83% ($\exp(-0.11471) = 0,8916$). A variável precipitação defasada (Precipitação) também permaneceu significativa, com um coeficiente de 0.00451 (IC 95%: 0.00352 a 0.00551), indicando que chuvas no mês anterior aumentam a incidência de casos de dengue, embora o efeito continue pequeno. Na parte inflacionada, apenas a variável água encanada (Água) permaneceu significativa, com um coeficiente de -7.72 (IC 95%: -11.08 a -4.36), reforçando que um maior acesso à água encanada reduz a probabilidade de um município pertencer ao excesso de zeros no modelo. A variável RSU perdeu significância, sugerindo que sua relação com a inflação de zeros pode não ser robusta ao ajustar o modelo apenas com as variáveis significativas.

Tabela 7 – ZINB com variáveis significativas

	Variáveis	Binomial Negativo Inflacionado de Zeros - ZINB			
		Estimativas	Erro padrão	p-valor	IC 95%
(i)	Intercepto	-7,0379***	0,6597	< 0,001	-8,33 a -5,74
	Max	-0,1147***	0,0192	< 0,001	-0,15 a -0,08
	Precipitacao	0,0045***	0,0005	< 0,001	0 a 0,01
(ii)	Intercepto	2,6859***	0,6021	< 0,001	1,51 a 3,87
	Água	-7,7240***	1,7169	< 0,001	-11,09 a -4,36
	RSU1000	-0,0299	0,0213	0,1600	-0,07 a 0,01
GLOBAL	AIC	12288,2			
	BIC	12343,4			
	Log-verossimilhança	-6135,1			
	Deviance	12270,2			
	alpha	0,462			

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

(i) Não inflacionado; (ii) Inflacionado de zero

Fonte: O Autor (2024).

Considerando que a temperatura máxima (Max) está associada à redução da incidência de dengue na parte de contagem, também é necessário avaliar se essa variável influencia a inflação de zeros, alterando a estrutura do modelo na Tabela 8. Dessa forma, a temperatura máxima (Max) foi incluída no componente de inflação de zeros, resultando em um coeficiente de 0.39711 (IC 95%: 0.20302 a 0.59119, $p < 0.001$). Isso indica que um aumento de 1°C na temperatura máxima está associado a um aumento de 48,75% na chance de um município pertencer ao grupo com excesso de zeros ($\exp(0.3971) = 1.4875$). Esse resultado sugere que temperaturas mais altas podem estar associadas a uma maior probabilidade de ausência de casos de dengue, possivelmente devido aos efeitos do calor sobre a reprodução e sobrevivência do mosquito vetor.

Tabela 8 – ZINB com alteração na parte inflacionada

	Variáveis	Binomial Negativo Inflacionado de Zeros - ZINB			
		Estimativas	Erro padrão	p-valor	IC 95%
(i)	Intercepto	-8,5448***	0,6944	< 0,001	-9,91 a -7,18
	Max	-0,0632**	0,0207	0,0023	-0,1 a -0,02
	Precipitacao	0,0037***	0,0005	< 0,001	0 a 0
(ii)	Intercepto	-10,5424**	3,4778	0,0024	-17,36 a -3,73
	Água	-4,8574***	0,8730	< 0,001	-6,57 a -3,15
	RSU1000	-0,0395*	0,0195	0,04326	-0,08 a 0
	Max	0,3971***	0,0990	< 0,001	0,2 a 0,59
	Precipitacao	-0,0220*	0,0102	0,0303	-0,04 a 0
GLOBAL	AIC	12251,8			
	BIC	12319,3			
	Log-verossimilhança	-6114,9			
	Deviance	12229,8			
	alpha	0,467			

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

(i) Não inflacionado; (ii) Inflacionado de zero

Fonte: O Autor (2024).

Uma análise por mesorregião também foi ajustada para avaliar a relação entre temperatura máxima e precipitação nos casos de dengue. Os resultados da Tabela 9 mostram variações no efeito dessas variáveis entre as diferentes regiões. Na Região do Sertão, um aumento de 1°C na temperatura máxima está associado a uma redução de 14,6% nos casos de dengue, enquanto um aumento na precipitação tem um efeito positivo, aumentando os casos em

0,5%. Na Região do São Francisco, o efeito da temperatura máxima é ainda mais expressivo, com uma redução de 29,8% na incidência de dengue para cada 1°C adicional, enquanto a precipitação aumenta os casos em 1,0%. No Agreste, a temperatura máxima não foi significativa (NS), e a precipitação teve um efeito pequeno, aumentando os casos em 0,4%. Para a região da zona da Mata, o modelo não convergiu (SC), impossibilitando a interpretação dos resultados. Na Região Metropolitana do Recife (RMR), um aumento de 1°C na temperatura máxima foi associado a uma redução de 13,6% na incidência de dengue, enquanto o impacto da precipitação foi menor, elevando os casos em apenas 0,2%. Esses resultados indicam que o impacto da temperatura máxima na incidência de dengue varia entre as mesorregiões, sendo mais expressivo no São Francisco e Sertão, enquanto a precipitação apresenta um efeito positivo em todas as regiões onde houve convergência do modelo.

Tabela 9 – Temperatura e Precipitação em diferentes mesorregiões

Região	Temperatura Máxima	Precipitação
Sertão	-14,6%	0,5%
São Francisco	-29,8%	1,0%
Agreste	NS	0,4%
Mata	SC	SC
RMR	-13,6%	0,2%

NS – Não significativo; SC – Sem convergência

Fonte: O Autor (2024)

O aumento da temperatura mostrou-se relevante no contexto da dengue, principalmente na análise por mesorregião. O resultado encontrado está alinhado com Leite (2023), que identificou uma redução nos casos de dengue em anos com médias mensais de temperatura máxima acima de 30°C. Essa relação sugere que temperaturas elevadas podem impactar negativamente a reprodução e sobrevivência do vetor da dengue, corroborando a importância da temperatura como um fator regulador da dinâmica da doença.

Em sequência, considerações feitas na parte de contagem mostram que o acesso ao esgotamento sanitário na mesorregião do Sertão está associado a uma redução de 87,09% nos casos de dengue ($\exp(-2.047) = 0.129$). Ainda no Sertão, foi possível observar que a porcentagem da população com acesso à coleta de lixo está associada a uma redução de 85,02% ($\exp(-1.89) = 0.129$). Na região do São Francisco e na RMR, a quantidade de resíduos coletados (em toneladas) também está associada à diminuição nos casos de dengue (5,48% e 5,03%, respectivamente). Por outro lado, na região da Zona da Mata, o aumento nas toneladas de resíduos coletados está associado ao aumento de 11,4% nos casos de dengue.

Análises mais detalhadas foram extraídas da parte inflacionada do modelo, considerando o modelo da Tabela 9 com apenas variáveis significativas e a variável temperatura máxima na modelagem de inflação. Essa modelagem permitiu identificar municípios e períodos em que a probabilidade de inflação de zeros é elevada, sugerindo uma baixa incidência real de dengue ou possíveis problemas de subnotificação. A tabela completa está disponível no Apêndice B deste trabalho.

Os resultados indicam que municípios como Carnaubeira da Penha, Santa Maria da Boa Vista e Dormentes apresentam valores sistematicamente altos de inflação de zeros, com probabilidades superiores a 90% em diversos meses. Essa tendência pode estar relacionada a fatores como condições climáticas desfavoráveis à proliferação do *Aedes aegypti*, políticas eficazes de controle do vetor ou fragilidades no sistema de notificação epidemiológica.

Por outro lado, municípios como Caruaru, Garanhuns, Paulista, Recife, Jaboatão dos Guararapes e Petrolina registram probabilidades mais baixas de inflação de zeros ao longo dos anos, o que sugere uma maior regularidade na notificação de casos. A análise temporal também indica que, em algumas localidades, a chance de inflação de zeros diminui durante os meses chuvosos, uma possível relação entre a precipitação e o aumento da incidência de dengue.

5 CONSIDERAÇÕES FINAIS

O objetivo central desta pesquisa foi ajustar um modelo de regressão com dados em painel para identificar os determinantes da incidência da dengue em Pernambuco, abrangendo o período de janeiro de 2020 a junho de 2023. Para isso, foram exploradas diferentes abordagens de modelagem, com destaque para os modelos inflacionados de zeros, que se mostraram essenciais para lidar com a natureza dos dados de contagem.

Inicialmente, foi realizado o teste de equidispersão, que indicou que os modelos baseados na distribuição de Poisson não eram adequados para o conjunto de dados, evidenciando a violação desse pressuposto devido à presença de sobredispersão e um elevado número de observações com zero casos. Com base nesse resultado, essa abordagem foi descartada, e optou-se pelo modelo Binomial Negativa Inflacionado de Zeros (ZINB), que melhor capturou a heterogeneidade e as particularidades dos registros de dengue nos municípios analisados.

Do ponto de vista dos resultados, os achados confirmaram que variáveis climáticas, em especial a temperatura máxima e a precipitação, desempenham um papel fundamental na incidência da dengue. Durante períodos de altas temperaturas, observou-se uma diminuição nos casos de dengue, enquanto o aumento da precipitação está associado ao incremento dos casos, corroborando a literatura que relaciona condições ambientais favoráveis à proliferação do mosquito *Aedes aegypti*.

Além dos fatores climáticos, o estudo evidenciou a importância de variáveis estruturais como a gestão de resíduos sólidos, a cobertura de saneamento básico e a eficiência na coleta de lixo. Essas variáveis influenciaram significativamente a probabilidade de um município pertencer ao grupo "inflacionado de zeros", sugerindo que estruturas inadequadas podem ocultar a real incidência da doença ou, em alguns casos, contribuir para uma menor detecção dos casos.

A análise dos modelos permitiu identificar variações espaciais relevantes entre as mesorregiões de Pernambuco. Enquanto regiões como a Região Metropolitana do Recife apresentaram picos de incidência, outras, como parte do Sertão e Agreste, exibiram padrões distintos, o que enfatiza a necessidade de intervenções regionalizadas e estratégias específicas para cada contexto local.

A integração de dados provenientes de fontes diversas – como DATASUS, APAC, CPRH e SNIS – foi fundamental para proporcionar uma visão holística dos determinantes da dengue. Essa abordagem permitiu analisar tanto a evolução temporal dos casos quanto as disparidades

estruturais entre os municípios, atendendo ao objetivo de capturar a complexidade do fenômeno epidemiológico na região.

Os resultados dos testes estatísticos, como os testes de equidispersão e critérios de escolha de modelo reforçaram a adequação do modelo ZINB. A escolha por esse modelo possibilitou não apenas ajustar a distribuição dos dados, mas também interpretar de maneira mais refinada a presença de zeros estruturais, que podem estar associados a condições socioeconômicas e de infraestrutura mais robustas em determinados municípios.

Do ponto de vista das implicações para a saúde pública, os achados desta pesquisa sublinham a importância de políticas integradas que articulem ações de controle do vetor com melhorias na infraestrutura urbana e sanitária. A identificação dos determinantes ambientais e estruturais pode orientar a alocação de recursos e a implementação de estratégias preventivas mais eficientes, contribuindo para a redução dos surtos de dengue.

Em síntese, a pesquisa atingiu seus objetivos ao demonstrar que tanto os fatores climáticos quanto os estruturais influenciam significativamente a incidência da dengue em Pernambuco. A aplicação do modelo ZINB não só proporcionou uma análise robusta dos dados, mas também apontou caminhos para a formulação de políticas públicas mais direcionadas e efetivas. Essas contribuições abrem perspectivas para investigações futuras que ampliem o recorte temporal e incorporem novas variáveis, consolidando a base para ações integradas de controle e prevenção da dengue na região.

5.1 LIMITAÇÃO DA PESQUISA

Esta pesquisa enfrentou limitações significativas devido à ausência de dados e à presença de informações incorretas, como as temperaturas extremas de $-33\text{ }^{\circ}\text{C}$ e $47\text{ }^{\circ}\text{C}$, que não refletem os dados reais da área estudada. A falta de dados confiáveis dificulta uma análise robusta das condições climáticas e seus impactos na saúde pública. Dados não verificados podem induzir interpretações errôneas, comprometendo a análise e levando a decisões inadequadas em políticas públicas e intervenções para mitigar os efeitos das mudanças climáticas nos casos de dengue.

Embora este estudo tenha se baseado em dados secundários para análise estatística da incidência de dengue, alguns fatores exigem observação direta no local para uma compreensão mais precisa do contexto epidemiológico. Entre eles, destacam-se: (i) a presença e a quantidade de criadouros do mosquito *Aedes aegypti*, pois, embora existam dados sobre saneamento e infraestrutura urbana, apenas a observação direta no local pode identificar recipientes com água

parada em quintais, terrenos baldios, calhas, vasos de plantas e outros locais propícios para a proliferação do vetor; (ii) a qualidade da infraestrutura urbana e do saneamento básico, incluindo vazamentos, lixo exposto e problemas na coleta de resíduos, que podem favorecer a proliferação do vetor e que muitas vezes não são captados em registros oficiais; (iii) os hábitos e práticas da população em relação à prevenção da dengue, pois dados estatísticos não captam comportamentos culturais, como o armazenamento inadequado de água ou a adesão às campanhas de combate ao vetor; e (iv) a atuação de agentes de saúde e políticas de fiscalização locais, que podem influenciar diretamente o controle da dengue, mas cuja efetividade só pode ser avaliada por meio de pesquisa de campo e entrevistas.

5.2 SUGESTÕES PARA TRABALHOS FUTUROS

Uma abordagem futura seria expandir o horizonte temporal de coleta de dados à medida que novos registros se tornem disponíveis, explorando como as melhorias na gestão de resíduos sólidos se correlacionam com indicadores ambientais e de saúde pública, como a incidência de doenças transmitidas por mosquitos, incluindo a dengue. Além disso, seria benéfico realizar estudos que investiguem o efeito das políticas de destinação correta dos resíduos sólidos em indicadores econômicos e sociais dos municípios. Explorar como a infraestrutura de saneamento e manejo de resíduos se alinha com as metas de desenvolvimento sustentável (ODS) poderia fornecer novos insights sobre a gestão de resíduos e sua relação com a saúde e o meio ambiente.

Em resposta ao cenário epidemiológico crítico de incidência de casos, hospitalizações e óbitos por dengue, o Ministério da Saúde do Brasil incorporou, ainda em dezembro de 2023, a vacina contra a dengue no Calendário Nacional de Vacinação. Inicialmente, a vacina foi incorporada para crianças e adolescentes de 10 a 14 anos, sendo a Atenção primária à saúde a maior aliada na resposta à epidemia da dengue no Brasil (Elidio *et al.*, 2024). Em Pernambuco, 20 municípios foram beneficiados com 65,8 mil doses da vacina (Brasil, 2024). Sendo assim, pesquisas futuras poderão considerar dois cenários para os casos antes e após a inclusão da vacina no SUS.

Para futuras pesquisas, recomenda-se a aplicação de modelos mais avançados de análise e tomada de decisão, como métodos de Machine Learning e de Decisão Multicritério (MCDA). Esses modelos podem ampliar as possibilidades de análise e permitir uma compreensão mais profunda dos fatores que afetam a gestão de resíduos sólidos e a incidência de doenças, como a dengue.

A utilização de técnicas de IA, como redes neurais artificiais, algoritmos de aprendizado de máquina (machine learning) e aprendizado profundo (*deep learning*), poderiam melhorar a capacidade preditiva para a variável de estudo. Essas ferramentas permitem capturar padrões complexos em grandes volumes de dados, o que pode levar a previsões mais precisas sobre a geração de resíduos sólidos e os seus impactos em diversos indicadores socioambientais e de saúde pública. Ademais, a aplicação de Métodos de Decisão Multicritério (MCDM), como o FITradeoff, PROMETHEE e ELECTRE, podem contribuir na análise de problemas complexos envolvendo múltiplos critérios, como a seleção de estratégias voltadas para a priorização de municípios para intervenções em saúde pública. Esses métodos permitem que decisões sejam tomadas considerando diversos fatores, ponderando critérios econômicos, ambientais, sociais e de saúde.

REFERÊNCIAS

- ABRELPE. Panorama dos Resíduos Sólidos no Brasil. São Paulo, 2022. Disponível em: <https://www.abrema.org.br/panorama/>.
- AKMAL, T.; JAMIL, F. Assessing Health Damages from Improper Disposal of Solid Waste in Metropolitan Islamabad-Rawalpindi, Pakistan. **SUSTAINABILITY**, [s. l.], v. 13, n. 5, 2021.
- ALBARADO, Á. J. *et al.* Controle do Aedes: criação, recepção e percepções de campanhas audiovisuais em saúde pública em diferentes comunidades do Brasil. **Ciência & Saúde Coletiva**, [s. l.], v. 26, n. 2, p. 409–416, 2021.
- ALLEN, D. M. The Relationship Between Variable Selection and Data Augmentation and a Method for Prediction. **Technometrics**, [s. l.], v. 16, n. 1, p. 125–127, 1974.
- ANDRIOLI, D. C.; BUSATO, M. A.; LUTINSKI, J. A. Characteristics of the dengue epidemic in Pinhalzinho, Santa Catarina, Brazil, 2015-2016. **EPIDEMIOLOGIA E SERVICOS DE SAUDE**, [s. l.], v. 29, n. 4, 2020.
- ARAÚJO, D. D. C. *et al.* Determining the association between dengue and social inequality factors in north-eastern Brazil: A spatial modelling. **Geospatial Health**, [s. l.], v. 15, n. 1, 2020. Disponível em: <https://geospatialhealth.net/index.php/gh/article/view/854>. Acesso em: 2 fev. 2025.
- ARAÚJO, J. R. D.; FERREIRA, E. F. E.; ABREU, M. H. N. G. D. Revisão sistemática sobre estudos de espacialização da dengue no Brasil. **Revista Brasileira de Epidemiologia**, [s. l.], v. 11, n. 4, p. 696–708, 2008.
- BALTAGI, B. H. **Econometric analysis of panel data**. Sixth editioned. Cham, Switzerland Springer: [s. n.], 2021. (Springer texts in business and economics).
- BAVIA, L. *et al.* Epidemiological study on dengue in southern Brazil under the perspective of climate and poverty. **SCIENTIFIC REPORTS**, [s. l.], v. 10, n. 1, 2020.
- BÖHNING, D. *et al.* The Zero-Inflated Poisson Model and the Decayed, Missing and Filled Teeth Index in Dental Epidemiology. **Journal of the Royal Statistical Society Series A: Statistics in Society**, [s. l.], v. 162, n. 2, p. 195–209, 1999.
- BRASIL. **Diretrizes nacionais para a prevenção e controle de epidemias de dengue**. 1. ed. Brasília, DF: Ministério da Saúde, 2009. (Série A. Normas e Manuais Técnicos). Disponível em: https://bvsms.saude.gov.br/bvs/publicacoes/diretrizes_nacionais_prevencao_controle_dengue.pdf.
- BRASIL. **LEI Nº 11.445, DE 5 DE JANEIRO DE 2007**. Estabelece as diretrizes nacionais para o saneamento básico. Brasília, 2007. Disponível em: https://www.planalto.gov.br/ccivil_03/_ato2007-2010/2007/lei/111445.htm. Acesso em: 5 ago. 2024.

BRASIL. **LEI Nº 12.305, DE 2 DE AGOSTO DE 2010.** Institui a Política Nacional de Resíduos Sólidos; altera a Lei no 9.605, de 12 de fevereiro de 1998; e dá outras providências. Brasília, 2010. Disponível em: https://www.planalto.gov.br/ccivil_03/_ato2007-2010/2010/lei/112305.htm. Acesso em: 13 out. 2024.

BRASIL. **LEI Nº 13.301, DE 27 DE JUNHO DE 2016.** 2016.

BREUSCH, T. S.; PAGAN, A. R. The Lagrange Multiplier Test and its Applications to Model Specification in Econometrics. **The Review of Economic Studies**, [s. l.], v. 47, n. 1, p. 239, 1980.

CAIRES, L. T. V. *et al.* Aspectos gerais da dengue, apresentações clínicas e seus diferentes tipos de manifestações. **Brazilian Journal of Health Review**, [s. l.], v. 7, n. 2, p. e68220, 2024.

CAMERON, A. C.; TRIVEDI, P. K. **Microeconometrics: methods and applications.** Cambridge; New York: Cambridge University Press, 2005.

CAMERON, A. C.; TRIVEDI, P. K. **Regression Analysis of Count Data.** Cambridge: Cambridge University Press, 1998. Disponível em: <https://www.cambridge.org/core/books/regression-analysis-of-count-data/4E25812F8271C66442FD9EE0FC6EEA57>. Acesso em: 14 fev. 2025.

CAMERON, A. C.; TRIVEDI, P. K. Regression-based tests for overdispersion in the Poisson model. **Journal of Econometrics**, [s. l.], v. 46, n. 3, p. 347–364, 1990.

CARMO, R. F. do *et al.* Spatiotemporal dynamics, risk areas and social determinants of dengue in Northeastern Brazil, 2014-2017: an ecological study. **INFECTIOUS DISEASES OF POVERTY**, [s. l.], v. 9, n. 1, 2020.

CAUCHICK, P. **Metodologia De Pesq. Em Engenharia De Prod E Gestao De Oper.** 3. ed. RIO DE JANEIRO, RJ: Grupo Gen, 2022.

CHEUNG, Y. B. Zero-inflated models for regression analysis of count data: a study of growth and development. **Statistics in Medicine**, [s. l.], v. 21, n. 10, p. 1461–1469, 2002.

COSTA, G. B. *et al.* MEDIDAS DE CONTROLE DE VETORES DA DENGUE. In: I CONGRESSO BRASILEIRO DE DOENÇAS INFECTOCONTAGIOSAS ON-LINE, 2021. **Anais do I Congresso Brasileiro de Doenças Infectocontagiosas On-line.** [S. l.]: Revista Multidisciplinar em Saúde, 2021. Disponível em: <https://editoraime.com.br/revistas/index.php/rem/s/article/view/2169>. Acesso em: 13 fev. 2025.

CRUVINEL, V. R. N. *et al.* Vector-borne diseases in waste pickers in Brasilia, Brazil. **Waste Management**, [s. l.], v. 105, p. 223–232, 2020a.

CRUVINEL, V. R. N. *et al.* Vector-borne diseases in waste pickers in Brasilia, Brazil. **WASTE MANAGEMENT**, [s. l.], v. 105, p. 223–232, 2020b.

DALBEM, A. G. *et al.* Dengue clássica e febre hemorrágica da dengue: etiologia, fisiologia, epidemiologia e fatores de risco. **Revista Ciência e Estudos Acadêmicos de Medicina**, [s. l.], v. 1, p. 18–36, 2014.

DE AZEVEDO, T. S.; LORENZ, C.; CHIARAVALLOTI-NETO, F. Spatiotemporal evolution of dengue outbreaks in Brazil. **TRANSACTIONS OF THE ROYAL SOCIETY OF TROPICAL MEDICINE AND HYGIENE**, [s. l.], v. 114, n. 8, p. 593–602, 2020.

DICKIN, S. K.; SCHUSTER-WALLACE, C. J. Assessing changing vulnerability to dengue in northeastern Brazil using a water-associated disease index approach. **Global environmental change-human and policy dimensions**, [s. l.], v. 29, p. 155–164, 2014.

EINLOFT, A. B. do N. *et al.* **Data quality and arbovirus infection associated factors in pregnant and non-pregnant women of childbearing age in Brazil: A surveillance database analysis.** **ONE HEALTHRADARWEG** 29, 1043 NX AMSTERDAM, NETHERLANDSEELSEVIER, , 2021.

ELIDIO, G. A. *et al.* Atenção primária à saúde: a maior aliada na resposta à epidemia da dengue no Brasil. **Revista Panamericana de Salud Pública**, [s. l.], v. 48, p. 1, 2024.

FARIAS, P. C. S. *et al.* Epidemiological profile of arboviruses in two different scenarios: dengue circulation vs. dengue, chikungunya and Zika co-circulation. **BMC INFECTIOUS DISEASES**, [s. l.], v. 23, n. 1, 2023.

FÁVERO, L. P. *et al.* Zero-Inflated Generalized Linear Mixed Models: A Better Way to Understand Data Relationships. **Mathematics**, [s. l.], v. 9, n. 10, p. 1100, 2021.

FÁVERO, L. P.; BELFIORE, P. **Manual De Análise De Dados - Estatística E Modelagem Multivariada com Excel®, SPSS® E Stata®.** RIO DE JANEIRO, RJ: Grupo Gen, 2022.

FEITOSA, F. R. S.; SILVA, M. do S. F. da; SOBRAL, I. S. The Influence of Social-Environmental Factors On Infestation Control For *Aedes Aegypti* In Cidade Nova Neighborhood, Aracaju, Sergipe. **REVISTA ACTA GEOGRAFICA**, [s. l.], v. 15, n. 38, p. 47–64, 2021.

FIGUEREDO, M. B. *et al.* Analysis of the correlation between climatic variables and Dengue cases in the city of Alagoinhas/BA. **SCIENTIFIC REPORTS**, [s. l.], v. 13, n. 1, 2023.

FILHO, C. A. D. L. *et al.* Perfil epidemiológico dos casos de dengue no estado de Pernambuco, Brasil. **Research, Society and Development**, [s. l.], v. 11, n. 2, p. e36711225891, 2022.

FLORENZANO, B. M. *et al.* Análise comparativa do perfil epidemiológico dos casos de dengue no Brasil durante o primeiro trimestre dos anos de 2023 e 2024: um estudo ecológico. **Brazilian Journal of Implantology and Health Sciences**, [s. l.], v. 6, n. 8, p. 1459–1470, 2024.

FUJITA, D. M. *et al.* Dengue and climate changes: Increase of DENV-1 in São Paulo/Brazil – 2023. **Travel Medicine and Infectious Disease**, [s. l.], v. 56, p. 102668, 2023.

GERALDINI, B.; JOHANSEN, I. C.; JUSTUS, M. Influence of temperature and precipitation on dengue incidence in Campinas, São Paulo State, Brazil (2013-2022). **REVISTA DA SOCIEDADE BRASILEIRA DE MEDICINA TROPICAL**, [s. l.], v. 57, 2024.

GIL, A. C. **Como Elaborar Projetos De Pesquisa.** 7. ed. São Paulo, SP: Editora Atlas Ltda, 2022.

- GUJARATI, D.; PORTER, D. **Econometria básica**. 5ªed. Brasil: Amgh Editora Ltda., 2011.
- GURGEL-GONÇALVES, R.; OLIVEIRA, W. K. D.; CRODA, J. The greatest Dengue epidemic in Brazil: Surveillance, Prevention, and Control. **Revista da Sociedade Brasileira de Medicina Tropical**, [s. l.], v. 57, p. e00203-2024, 2024.
- HAUSMAN, J. A. Specification Tests in Econometrics. **Econometrica**, [s. l.], v. 46, n. 6, p. 1251, 1978.
- HINDE, J.; DEMÉTRIO, C. G. B. Overdispersion: Models and estimation. **Computational Statistics & Data Analysis**, [s. l.], v. 27, n. 2, p. 151–170, 1998.
- INSTITUTO BUTANTAN. **Saiba diferenciar os sintomas de dengue, chikungunya e zika e conheça as possíveis complicações de cada doença**. [S. l.], 2024. Disponível em: <https://butantan.gov.br/noticias/saiba-diferenciar-os-sintomas-de-dengue-chikungunya-e-zika-e-conheca-as-possiveis-complicacoes-de-cada-doenca>. .
- JEYAPAL, D. R. *et al.* Probable sociobehavioural and environmental risk factors for dengue transmission in Puducherry, India - An exploratory study. **JOURNAL OF FAMILY MEDICINE AND PRIMARY CARE**, [s. l.], v. 11, n. 7, p. 3593–3599, 2022.
- JUCA, J. F. T.; BARBOSA, K. R. M.; SOBRAL, M. C. Sustainability indicators for municipal solid waste management: A case study of the Recife Metropolitan Region, Brazil. **WASTE MANAGEMENT & RESEARCH**, [s. l.], v. 38, n. 12, p. 1450–1454, 2020.
- KALBUS, A. *et al.* **Exploring the influence of deforestation on dengue fever incidence in the Brazilian Amazonas state**. PLOS ONE1160 BATTERY STREET, STE 100, SAN FRANCISCO, CA 94111 USAPUBLIC LIBRARY SCIENCE, , 2021.
- KLAFKE, F.; BARROS, V. G.; HENNING, E. Solid waste management and *Aedes aegypti* infestation interconnections: A regression tree application. **Waste Management & Research: The Journal for a Sustainable Circular Economy**, [s. l.], v. 41, n. 11, p. 1684–1696, 2023a.
- KLAFKE, F.; BARROS, V. G.; HENNING, E. Solid waste management and *Aedes aegypti* infestation interconnections: A regression tree application. **WASTE MANAGEMENT & RESEARCH**, [s. l.], v. 41, n. 11, p. 1684–1696, 2023b.
- LAGE, M. D. O. *et al.* Ovipositional Reproduction of the Dengue Vector for Identifying High-Risk Urban Areas. **EcoHealth**, [s. l.], v. 19, n. 1, p. 85–98, 2022.
- LAMBERT, D. Zero-Inflated Poisson Regression, with an Application to Defects in Manufacturing. **Technometrics**, [s. l.], v. 34, n. 1, p. 1, 1992.
- LEITE, E. S. **Análise temporal da relação entre dengue e variáveis climáticas na cidade de Uberlândia - MG**. 2023. 101 f. Tese (Doutorado em Geografia) - Universidade Federal de Uberlândia, Uberlândia, Brasil, 2023.
- LEWSEY, J. D.; THOMSON, W. M. The utility of the zero-inflated Poisson and zero-inflated negative binomial models: a case study of cross-sectional and longitudinal DMF data examining the effect of socio-economic status. **Community Dentistry and Oral Epidemiology**, [s. l.], v. 32, n. 3, p. 183–189, 2004.

LIMA, E. C. D.; VILASBÔAS, A. L. Q. Implantação das ações intersetoriais de mobilização social para o controle da dengue na Bahia, Brasil. **Cadernos de Saúde Pública**, [s. l.], v. 27, n. 8, p. 1507–1519, 2011.

LIMA-PEREIRA, P. Subjective and material factors influencing the presence of mosquito breeding sites in large-scale household waste in Asunción, Paraguay. **LETRAS VERDES**, [s. l.], n. 35, 2024.

MARTEIS, L. S. *et al.* Identificação e distribuição espacial de imóveis-chave de *Aedes aegypti* no bairro Porto Dantas, Aracaju, Sergipe, Brasil entre 2007 e 2008. **Cadernos de Saúde Pública**, [s. l.], v. 29, n. 2, p. 368–378, 2013.

MARTIN, T. G. *et al.* Zero tolerance ecology: improving ecological inference by modelling the source of zero observations. **Ecology Letters**, [s. l.], v. 8, n. 11, p. 1235–1246, 2005.

MARTINS, A. B. S. *et al.* **Dengue in northeastern Brazil: a spatial and temporal perspective.** **REVISTA DA SOCIEDADE BRASILEIRA DE MEDICINA TROPICAL** UNIV BRASILIA, NUCLEO MEDICINA TROPICAL E NUTRICAÇÃO, CAIXA POSTAL 4356, BRASILIA, DF 70919-970, BRAZILSOC BRASILEIRA MEDICINA TROPICAL, , 2020.

MATIAS, M. S. *et al.* **Solid waste policy in Brazil: learnings and challenges after a decade of implementation.** **INTERNATIONAL JOURNAL OF ENVIRONMENT AND WASTE MANAGEMENT** WORLD TRADE CENTER BLDG, 29 ROUTE DE PRE-BOIS, CASE POSTALE 856, CH-1215 GENEVA, SWITZERLAND INDERSCIENCE ENTERPRISES LTD, , 2022.

MELO, C. M. Abordagens e procedimentos qualitativos: implicações para pesquisas em organizações. [s. l.], v. 21, n. 2, p. 324–349, 2014.

MENDONÇA, M. F. S. de; SILVA, A. P. de S. C.; LACERDA, H. R. Factors associated with death from dengue and chikungunya virus infection during an epidemic period in Northeast Brazil: A cohort. **REVISTA DA SOCIEDADE BRASILEIRA DE MEDICINA TROPICAL**, [s. l.], v. 56, 2023.

MONTEIRO, V. B.; ARAÚJO, J. A. Aspectos sócioeconômicos e climáticos que impactam a ocorrência de dengue no Brasil: análise municipal de 2008 a 2011 por regressões quantílicas para dados em painel. **Brazilian Journal of Development**, [s. l.], v. 6, n. 5, p. 28126–28145, 2020.

MORAIS, P. L. L. de; CASTANHA, P. M. S.; MONTARROYOS, U. R. Incidence and spatial distribution of cases of dengue, from 2010 to 2019: an ecological study. **SAO PAULO MEDICAL JOURNAL**, [s. l.], v. 138, n. 6, p. 554–560, 2020.

MUDELE, O. *et al.* Modeling dengue vector population with earth observation data and a generalized linear model. **ACTA TROPICA**, [s. l.], v. 215, 2021.

NAKASE, T. *et al.* Population at risk of dengue virus transmission has increased due to coupled climate factors and population growth. **COMMUNICATIONS EARTH & ENVIRONMENT**, [s. l.], v. 5, n. 1, 2024.

NASCIMENTO, I. D. S. do *et al.* Retrospective cross-sectional observational study on the epidemiological profile of dengue cases in Pernambuco state, Brazil, between 2015 and 2017. **BMC PUBLIC HEALTH**, [s. l.], v. 20, n. 1, 2020.

ORGANIZAÇÃO PAN-AMERICANA DA SAÚDE (PAHO). **Agenda de Saúde Sustentável para as Américas 2018-2030: Um chamado à ação para a saúde e o bem-estar na região**. Washington, D.C., EUA: Organização Mundial da Saúde, 2017. Disponível em: <https://iris.paho.org/bitstream/handle/10665.2/49172/CSP296-por.pdf?sequence=1&isAllowed=y>. Acesso em: 20 dez. 2024.

PEDROTTI, C. H. S. *et al.* Telemedicine medical evaluation of low-risk patients with dengue during an outbreak may be an option in reducing the need for on-site physicians. **International Journal of Infectious Diseases**, [s. l.], v. 121, p. 106–111, 2022.

PEREIRA, E. D. A. *et al.* Spatial distribution of arboviruses and its association with a social development index and the waste disposal in São Luís, state of Maranhão, Brazil, 2015 to 2019. **Revista Brasileira de Epidemiologia**, [s. l.], v. 27, p. e240017, 2024.

PÉREZ, Y. J. L. *et al.* Effectiveness of a Nursing Educational Intervention in Adults to Promote Control Behaviors Against Dengue: Protocol for a Randomized Controlled Trial. **JMIR Research Protocols**, [s. l.], v. 13, p. e54286, 2024.

POTTS, J. M.; ELITH, J. Comparing species abundance models. **Ecological Modelling**, [s. l.], v. 199, n. 2, p. 153–163, 2006.

PRESTES-CARNEIRO, L. E. *et al.* Dengue outbreaks in a city with recent transmission in Sao Paulo state, Brazil. **INTERNATIONAL JOURNAL OF ENVIRONMENTAL HEALTH RESEARCH**, [s. l.], v. 34, n. 3, p. 1370–1383, 2024.

SANTIAGO, C. D. *et al.* Política Nacional de Resíduos Sólidos: perspectivas após um decênio de sua promulgação. **Desenvolvimento e Meio Ambiente**, [s. l.], v. 62, 2023. Disponível em: <https://revistas.ufpr.br/made/article/view/81833>. Acesso em: 14 ago. 2024.

SARAIVA, E. F. *et al.* Modeling Overdispersed Dengue Data via Poisson Inverse Gaussian Regression Model: A Case Study in the City of Campo Grande, MS, Brazil. **ENTROPY**, [s. l.], v. 24, n. 9, 2022.

SCHWARZ, G. Estimating the Dimension of a Model. **The Annals of Statistics**, [s. l.], v. 6, n. 2, 1978. Disponível em: <https://projecteuclid.org/journals/annals-of-statistics/volume-6/issue-2/Estimating-the-Dimension-of-a-Model/10.1214/aos/1176344136.full>. Acesso em: 3 fev. 2025.

SCOTT, V. K. *et al.* Acceptability of a hypothetical dengue vaccine and the potential impact of dengue vaccination on personal vector control behavior: a qualitative study in Fortaleza, Brazil. **BMC Public Health**, [s. l.], v. 23, n. 1, p. 2408, 2023.

SILVA, G. H. da *et al.* Profile of hospitalization and death records associated to dengue and severe dengue in Minas Gerais between 2000 and 2015 from the Brazilian Public Health System perspective. **Journal of Vector Borne Diseases**, [s. l.], v. 58, n. 1, p. 54–62, 2021.

SILVA, A. C. da; SCALIZE, P. S. Environmental Variables Related to *Aedes aegypti* Breeding Spots and the Occurrence of Arbovirus Diseases. **Sustainability**, [s. l.], v. 15, n. 10, p. 8148, 2023.

SILVA, E.; SILVA, M. M. Análise da interação entre resíduos sólidos e saneamento na incidência de Dengue utilizando Regressão Linear Múltipla. Fortaleza - CE, v. 56, n. LVI Simpósio Brasileiro de Pesquisa Operacional, Caderno de Resumos do LVI Simpósio Brasileiro de Pesquisa Operacional, 2024a.

SILVA, E.; SILVA, M. M. Análise das principais Ferramentas de Machine Learning voltadas para as aplicações em Resíduos Sólidos: um estudo bibliométrico. Porto Alegre - RS, n. XLIV Encontro Nacional de Engenharia de Produção, 2024b.

SIM, S. *et al.* A greener vision for vector control: The example of the Singapore dengue control programme. **PLOS NEGLECTED TROPICAL DISEASES**, [s. l.], v. 14, n. 8, 2020.

SOUSA, F. A. C. G. D.; PARADELLA, T. C. Fatores de risco de morte por dengue no brasil: um estudo ecológico. **Revista Baiana de Saúde Pública**, [s. l.], v. 48, n. 2, p. 181–190, 2024.

TEILLET, C. *et al.* Exploring fine-scale urban landscapes using satellite data to predict the distribution of *Aedes* mosquito breeding sites. **International Journal of Health Geographics**, [s. l.], v. 23, n. 1, p. 18, 2024.

TRAN, B.-L. *et al.* Estimating the Threshold Effects of Climate on Dengue: A Case Study of Taiwan. **International Journal of Environmental Research and Public Health**, [s. l.], v. 17, n. 4, p. 1392, 2020.

VASCONCELOS, C. alberto alves de *et al.* Evaluation of the efficiency of beetroot peel (*beta vulgaris*) in ovitraps as an attractant for surveillance of arbovirus vectors in the municipality of Agrestina, state of Pernambuco, Brazil. **Journal of the American Mosquito Control Association**, [s. l.], v. 40, n. 3, p. 145–148, 2024.

WIJAYA, K. P. *et al.* Learning from panel data of dengue incidence and meteorological factors in Jakarta, Indonesia. **STOCHASTIC ENVIRONMENTAL RESEARCH AND RISK ASSESSMENT**, [s. l.], v. 35, n. 2, p. 437–456, 2021.

WOOLDRIDGE, J. M. **Econometric analysis of cross section and panel data**. 2nd eded. Cambridge, Mass: MIT Press, 2010.

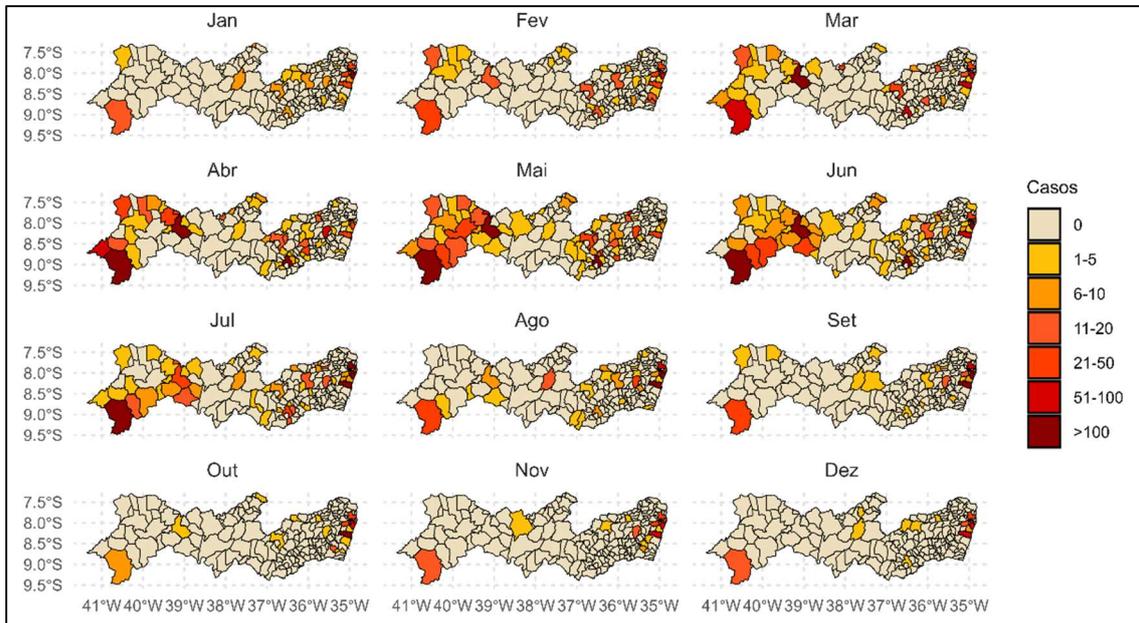
WOOLDRIDGE, J. M. **Introdução à econometria – Uma abordagem moderna Tradução da 7ª edição norte-americana**. Tradução: Heloisa Pinna Bernardo. 4. ed. São Paulo, SP: Cengage Learning, 2023.

XAVIER, I. *et al.* Fatores epidemiológicos do dengue na região central do estado do Rio Grande do Sul, Brasil, 2007 - 2010. **Ciência Rural**, [s. l.], v. 43, n. 1, p. 87–90, 2012.

ZUUR, A. F.; SAVEL'EV, A. A.; IENO, E. N. **Zero inflated models and generalized linear mixed models with R**. Reprinted with correctionsed. Newburgh, United Kingdom: Highland Statistics, 2012.

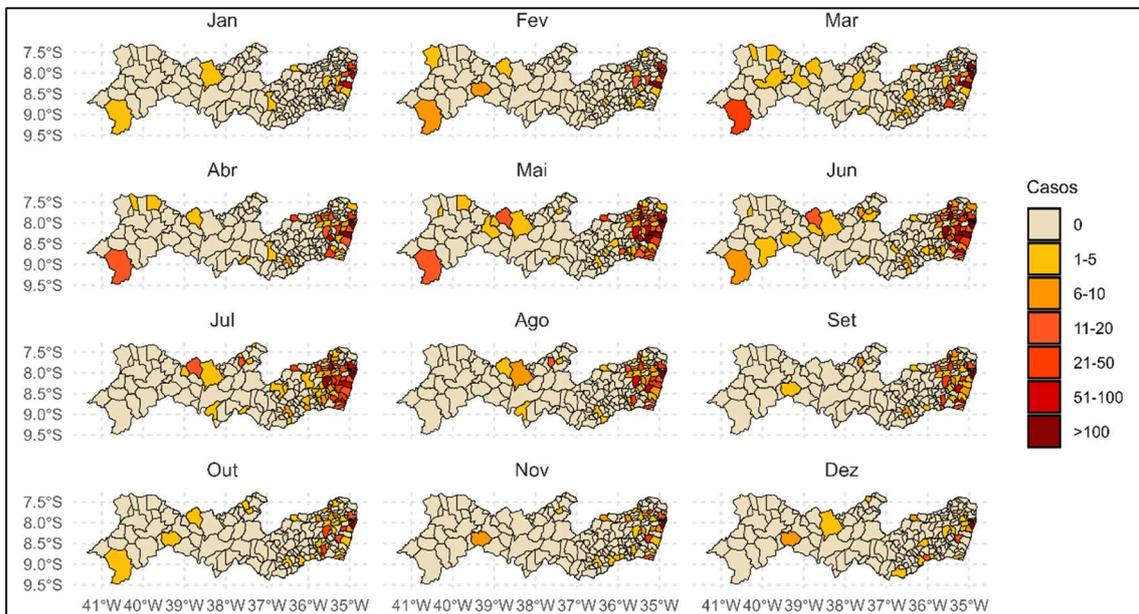
APENDICE A – MAPAS DE CALOR PARA CASOS DE DENGUE EM PE

Figura 15 – Casos de dengue em 2020



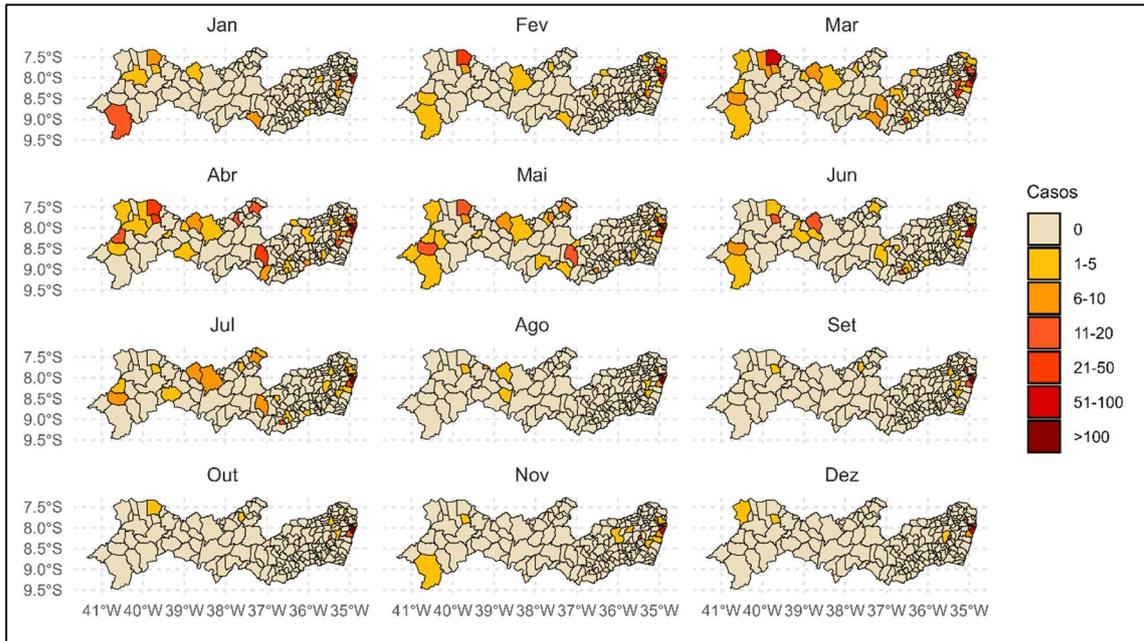
Fonte: O Autor (2024).

Figura 16 - Casos de dengue em 2021



Fonte: O Autor (2024).

Figura 17 - Casos de dengue em 2023



Fonte: O Autor (2024).

APENDICE B – PROBABILIDADES DE INFLAÇÃO POR MUNICÍPIO

Tabela 10 – Inflação de casos por município em 2020

Municípios	2020										
	2	3	4	5	6	7	8	9	10	11	12
Abreu e Lima	0,08	0,03	0,01	0,00	0,00	0,00	0,00	0,00	0,01	0,17	0,12
Afogados da Ingazeira	0,03	0,00	0,00	0,00	0,00	0,01	0,02	0,07	0,09	0,05	0,00
Agrestina	0,03	0,01	0,00	0,00	0,00	0,00	0,00	0,01	0,02	0,11	0,04
Alagoíinha	0,37	0,07	0,00	0,01	0,01	0,01	0,07	0,16	0,53	0,66	0,08
Araripina	0,03	0,00	0,00	0,00	0,01	0,05	0,32	0,69	0,38	0,21	0,03
Arcoverde	0,05	0,01	0,00	0,00	0,00	0,00	0,00	0,02	0,07	0,03	0,01
Belém do São Francisco	0,04	0,00	0,01	0,01	0,04	0,05	0,08	0,19	0,44	0,07	0,01
Belo Jardim	0,03	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,05	0,08	0,01
Bezerros	0,05	0,01	0,00	0,00	0,00	0,00	0,00	0,02	0,08	0,15	0,07
Bodocó	0,16	0,00	0,03	0,03	0,04	0,13	0,21	0,45	0,51	0,36	0,15
Bom Jardim	0,18	0,06	0,01	0,01	0,00	0,00	0,01	0,04	0,14	0,30	0,14
Brejo da Madre de Deus	0,45	0,02	0,00	0,01	0,04	0,02	0,02	0,17	0,46	0,63	0,32
Buíque	0,50	0,06	0,00	0,00	0,13	0,02	0,02	0,23	0,67	0,73	0,14
Cabo de Santo Agostinho	0,09	0,10	0,08	0,05	0,04	0,02	0,02	0,03	0,04	0,21	0,17
Cabrobó	0,05	0,00	0,05	0,01	0,03	0,04	0,06	0,12	0,37	0,05	0,01
Cachoeirinha	0,05	0,03	0,00	0,00	0,00	0,00	0,00	0,01	0,04	0,13	0,06
Camagibe	0,09	0,03	0,02	0,02	0,00	0,00	0,00	0,01	0,02	0,31	0,14
Canhotinho	0,20	0,22	0,00	0,01	0,03	0,02	0,03	0,07	0,26	0,36	0,21
Carnaíba	0,04	0,00	0,00	0,01	0,02	0,06	0,08	0,31	0,32	0,24	0,02
Carnaubeira da Penha	0,43	0,00	0,02	0,10	0,46	0,40	0,58	0,83	0,95	0,64	0,24
Caruaru	0,00	0,03	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,07	0,01
Casinhas	0,56	0,53	0,10	0,12	0,03	0,00	0,05	0,23	0,61	0,78	0,55
Cedro	0,12	0,00	0,00	0,01	0,03	0,18	0,19	0,40	0,44	0,31	0,09
Chã Grande	0,50	0,26	0,11	0,09	0,04	0,00	0,01	0,07	0,17	0,52	0,52
Cupira	0,03	0,02	0,00	0,00	0,00	0,00	0,00	0,01	0,03	0,09	0,02
Dormentes	0,03	0,03	0,00	0,01	0,23	0,30	0,36	0,60	0,83	0,32	0,05
Exu	0,09	0,00	0,00	0,01	0,02	0,09	0,14	0,39	0,44	0,30	0,05
Fernando de Noronha	0,00	0,01	0,01	0,00	0,02	0,01	0,01	0,01	0,01	0,03	0,00
Floresta	0,02	0,00	0,00	0,01	0,03	0,03	0,05	0,16	0,41	0,02	0,00
Granito	0,10	0,00	0,00	0,06	0,04	0,16	0,17	0,38	0,43	0,30	0,15
Gravatá	0,05	0,02	0,00	0,00	0,00	0,00	0,00	0,00	0,04	0,07	0,03
Ibimirim	0,22	0,01	0,00	0,02	0,05	0,62	0,22	0,49	0,69	0,70	0,07
Igarassu	0,13	0,01	0,00	0,00	0,00	0,00	0,00	0,01	0,01	0,26	0,07
Ipojuca	0,07	0,02	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,21	0,12
Itapetim	0,00	0,00	0,00	0,00	0,00	0,05	0,07	0,22	0,26	0,16	0,04
Itapissuma	0,24	0,08	0,02	0,02	0,00	0,00	0,00	0,02	0,06	0,46	0,30
Jaboatão dos Guararapes	0,16	0,18	0,14	0,10	0,07	0,04	0,04	0,05	0,07	0,34	0,30
João Alfredo	0,35	0,08	0,03	0,02	0,00	0,00	0,02	0,08	0,23	0,54	0,25
Jurema	0,10	0,03	0,00	0,00	0,00	0,00	0,00	0,00	0,03	0,15	0,01
Lagoa dos Gatos	0,20	0,14	0,01	0,00	0,00	0,00	0,01	0,04	0,16	0,45	0,16
Lagoa Grande	0,23	0,03	0,04	0,09	0,21	0,29	0,38	0,63	0,85	0,36	0,05
Mirandiba	0,04	0,00	0,00	0,01	0,00	0,02	0,04	0,13	0,16	0,10	0,00
Moreno	0,14	0,06	0,03	0,00	0,00	0,00	0,00	0,01	0,03	0,31	0,22
Olinda	0,05	0,02	0,01	0,00	0,00	0,00	0,00	0,00	0,01	0,13	0,09
Orobó	0,39	0,24	0,02	0,05	0,01	0,00	0,03	0,17	0,44	0,68	0,42
Orocó	0,24	0,06	0,01	0,04	0,02	0,31	0,37	0,62	0,84	0,35	0,06

continua...

continuação.

Panelas	0,10	0,06	0,01	0,01	0,00	0,00	0,00	0,02	0,09	0,25	0,10
Parnamirim	0,36	0,00	0,00	0,02	0,16	0,29	0,33	0,60	0,66	0,51	0,24
Paulista	0,05	0,00	0,01	0,00	0,00	0,00	0,00	0,00	0,01	0,11	0,03
Pesqueira	0,18	0,18	0,00	0,00	0,00	0,01	0,02	0,08	0,25	0,43	0,09
Petrolina	0,01	0,04	0,01	0,01	0,02	0,03	0,04	0,13	0,24	0,11	0,00
Poção	0,39	0,14	0,00	0,00	0,03	0,00	0,03	0,10	0,38	0,55	0,32
Quipapá	0,20	0,07	0,00	0,01	0,01	0,00	0,00	0,01	0,04	0,26	0,20
Quixaba	0,07	0,00	0,00	0,02	0,03	0,05	0,13	0,35	0,41	0,27	0,02
Recife	0,05	0,02	0,01	0,00	0,00	0,00	0,00	0,01	0,02	0,10	0,08
Riacho das Almas	0,01	0,23	0,00	0,01	0,03	0,00	0,04	0,12	0,40	0,54	0,35
Rio Formoso	0,65	0,28	0,06	0,09	0,02	0,00	0,01	0,11	0,27	0,69	0,51
Salgueiro	0,05	0,00	0,00	0,00	0,01	0,04	0,04	0,10	0,16	0,03	0,01
Santa Cruz	0,17	0,01	0,00	0,02	0,04	0,16	0,24	0,57	0,62	0,47	0,09
Santa Filomena	0,24	0,07	0,00	0,12	0,16	0,41	0,43	0,70	0,74	0,55	0,22
Santa Terezinha	0,04	0,00	0,00	0,00	0,00	0,04	0,05	0,23	0,27	0,17	0,06
São Joaquim do Monte	0,10	0,07	0,00	0,00	0,00	0,00	0,00	0,01	0,06	0,30	0,13
São José do Belmonte	0,00	0,00	0,00	0,00	0,02	0,15	0,28	0,57	0,60	0,47	0,03
São Vicente Férrer	0,53	0,11	0,02	0,03	0,00	0,00	0,00	0,09	0,33	0,61	0,43
Serra Talhada	0,04	0,00	0,00	0,00	0,00	0,01	0,05	0,19	0,07	0,09	0,00
Serrita	0,15	0,01	0,00	0,02	0,05	0,17	0,19	0,42	0,48	0,34	0,10
Sertânia	0,40	0,03	0,00	0,04	0,09	0,23	0,26	0,65	0,69	0,56	0,11
Solidão	0,16	0,00	0,00	0,02	0,02	0,17	0,39	0,66	0,71	0,57	0,12
Surubim	0,14	0,06	0,00	0,00	0,01	0,00	0,01	0,04	0,28	0,18	0,08
Tacaimbó	0,11	0,03	0,00	0,00	0,01	0,00	0,01	0,04	0,19	0,34	0,11
Tamandaré	0,07	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,07	0,04
Taquaritinga do Norte	0,47	0,09	0,01	0,00	0,01	0,00	0,00	0,07	0,30	0,64	0,43
Terra Nova	0,13	0,01	0,00	0,03	0,07	0,06	0,09	0,20	0,45	0,08	0,02
Trindade	0,02	0,00	0,00	0,00	0,01	0,03	0,04	0,10	0,13	0,07	0,02
Tuparetama	0,04	0,00	0,00	0,00	0,00	0,02	0,03	0,09	0,11	0,06	0,01
Venturosa	0,35	0,13	0,00	0,00	0,01	0,02	0,04	0,11	0,41	0,48	0,14
Verdejante	0,01	0,00	0,00	0,02	0,01	0,06	0,09	0,23	0,27	0,17	0,03

Fonte: O Autor (2024).

Tabela 11 - Inflação de casos por município em 2021

Municípios	2021											
	1	2	3	4	5	6	7	8	9	10	11	12
Abreu e Lima	0,02	0,04	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,04	0,09	0,03
Afogados da Ingazeira	0,16	0,17	0,01	0,03	0,00	0,00	0,07	0,04	0,25	0,22	0,28	0,13
Afrânio		0,56	0,22	0,33	0,06	0,16	0,62	0,51	0,87	0,84	0,61	0,27
Agrestina	0,03	0,09	0,06	0,02	0,00	0,00	0,01	0,00	0,01	0,10	0,07	0,15
Águas Belas		0,85	0,72	0,60	0,02	0,00	0,02	0,03	0,12	0,68	0,79	0,77
Alagoinha	0,31	0,62	0,31	0,14	0,00	0,00	0,08	0,04	0,24	0,68	0,29	0,66
Araripina	0,19	0,30	0,01	0,04	0,03	0,07	0,22	0,10	0,40	0,42	0,40	0,10
Arcoverde	0,02	0,07	0,01	0,01	0,00	0,00	0,01	0,01	0,05	0,13	0,12	0,08
Barra de Guabiraba		0,03	0,05	0,00	0,00	0,00	0,00	0,00	0,00	0,05	0,11	0,09
Belém do São Francisco	0,21	0,12	0,07	0,10	0,02	0,02	0,19	0,12	0,52	0,47	0,20	0,12
Bom Jardim	0,14	0,49	0,30	0,09	0,01	0,00	0,06	0,02	0,17	0,54	0,51	0,55
Bonito		0,04	0,06	0,02	0,00	0,00	0,00	0,00	0,00	0,08	0,12	0,16
Brejo da Madre de Deus	0,12	0,34	0,02	0,05	0,00	0,00	0,05	0,04	0,26	0,45	0,46	0,27
Buíque	0,46	0,77	0,67	0,14	0,08	0,00	0,10	0,05	0,43	0,90	0,87	0,87
Cabo de Santo Agostinho	0,03	0,08	0,03	0,03	0,02	0,02	0,02	0,01	0,04	0,06	0,09	0,06

continua...

continuação.

Cabrobó	0,25	0,18	0,03	0,26	0,01	0,07	0,34	0,24	0,71	0,67	0,41	0,27
Cachoeirinha	0,04	0,12	0,06	0,02	0,00	0,00	0,00	0,00	0,02	0,09	0,18	0,16
Camaragibe	0,04	0,04	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,04	0,10	0,09
Carnaíba	0,56	0,63	0,05	0,04	0,00	0,05	0,24	0,24	0,59	0,58	0,64	0,60
Caruaru	0,01	0,03	0,02	0,01	0,01	0,00	0,00	0,00	0,01	0,02	0,03	0,04
Casinhas	0,68	0,91	0,82	0,48	0,27	0,02	0,40	0,16	0,70	0,91	0,93	0,92
Cedro	0,17	0,31	0,04	0,00	0,01	0,03	0,20	0,12	0,47	0,48	0,47	0,15
Chã Grande	0,30	0,22	0,33	0,03	0,01	0,00	0,01	0,01	0,01	0,15	0,19	0,13
Cupira	0,02	0,05	0,05	0,01	0,00	0,00	0,00	0,00	0,02	0,07	0,11	0,10
Dormentes	0,88	0,80	0,08	0,52	0,22	0,38	0,84	0,77	0,95	0,94	0,76	0,80
Exu	0,59	0,72	0,11	0,08	0,01	0,07	0,39	0,26	0,69	0,74	0,71	0,53
Fernando de Noronha	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
Floresta	0,17	0,03	0,06	0,07	0,01	0,01	0,09	0,04	0,35	0,30	0,11	0,07
Garanhuns		0,01	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,03	0,07	0,07
Goiana		0,04	0,03	0,00	0,00	0,00	0,01	0,00	0,00	0,08	0,15	0,08
Granito	0,61	0,66	0,11	0,11	0,02	0,14	0,40	0,39	0,69	0,70	0,75	0,39
Gravatá	0,02	0,05	0,04	0,01	0,00	0,00	0,00	0,00	0,03	0,09	0,08	0,09
Ibimirim	0,55	0,62	0,16	0,09	0,01	0,03	0,32	0,18	0,69	0,70	0,69	0,54
Ibirajuba		0,38	0,25	0,04	0,02	0,00	0,03	0,01	0,14	0,32	0,52	0,49
Igarassu	0,04	0,06	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,08	0,15	0,13
Iguaracy		0,62	0,08	0,05	0,01	0,05	0,28	0,20	0,60	0,65	0,64	0,44
Ipojuca	0,01	0,04	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,04	0,05	0,04
Itapetim	0,20	0,32	0,01	0,00	0,00	0,01	0,10	0,08	0,25	0,28	0,33	0,26
Itapissuma	0,08	0,18	0,03	0,03	0,00	0,00	0,00	0,00	0,00	0,16	0,30	0,23
Jaboatão dos Guararapes	0,08	0,14	0,07	0,07	0,05	0,04	0,03	0,03	0,08	0,12	0,18	0,12
Jatobá		0,10	0,16	0,03	0,02	0,01	0,06	0,04	0,35	0,31	0,09	0,14
João Alfredo	0,10	0,36	0,30	0,10	0,00	0,00	0,04	0,02	0,04	0,49	0,50	0,55
Lagoa dos Gatos	0,09	0,22	0,24	0,01	0,01	0,00	0,03	0,01	0,11	0,44	0,52	0,37
Lagoa Grande	0,61	0,45	0,29	0,29	0,12	0,12	0,58	0,43	0,86	0,79	0,55	0,44
Mirandiba	0,26	0,42	0,08	0,00	0,03	0,03	0,10	0,09	0,32	0,35	0,42	0,18
Moreno	0,04	0,05	0,01	0,01	0,00	0,00	0,00	0,00	0,00	0,04	0,09	0,07
Nazaré da Mata		0,04	0,06	0,00	0,00	0,00	0,00	0,00	0,00	0,03	0,06	0,04
Olinda	0,01	0,02	0,01	0,01	0,00	0,00	0,00	0,00	0,00	0,02	0,05	0,03
Panelas	0,13	0,34	0,22	0,04	0,01	0,00	0,04	0,01	0,10	0,30	0,47	0,48
Parnamirim	0,43	0,69	0,04	0,22	0,02	0,14	0,32	0,49	0,87	0,84	0,77	0,35
Paulista	0,01	0,02	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,03	0,05	0,03
Pesqueira	0,06	0,41	0,11	0,06	0,00	0,00	0,03	0,02	0,12	0,45	0,52	0,15
Petrolândia		0,15	0,30	0,18	0,03	0,02	0,28	0,16	0,55	0,54	0,27	0,14
Petrolina	0,14	0,05	0,03	0,09	0,01	0,02	0,15	0,10	0,37	0,36	0,07	0,03
Poção	0,23	0,51	0,32	0,15	0,01	0,00	0,05	0,02	0,05	0,56	0,59	0,58
Quipapá	0,09	0,06	0,05	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,07	0,04
Quixaba	0,49	0,52	0,10	0,10	0,00	0,06	0,23	0,24	0,39	0,60	0,54	0,58
Recife	0,02	0,02	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,02	0,03	0,04
Riacho das Almas	0,24	0,56	0,33	0,06	0,06	0,00	0,11	0,07	0,38	0,61	0,65	0,60
Rio Formoso	0,39	0,24	0,36	0,02	0,01	0,00	0,03	0,01	0,01	0,20	0,35	0,31
Salgueiro	0,15	0,20	0,04	0,01	0,02	0,01	0,09	0,08	0,17	0,23	0,17	0,05
Santa Cruz do Capibaribe		0,36	0,14	0,05	0,04	0,00	0,05	0,03	0,18	0,40	0,44	0,41
Santa Maria da Boa Vista		0,71	0,49	0,78	0,41	0,36	0,83	0,75	0,96	0,93	0,71	0,44
São Bento do Una		0,59	0,42	0,11	0,01	0,00	0,07	0,03	0,18	0,61	0,69	0,68
São João		0,37	0,21	0,03	0,00	0,00	0,01	0,01	0,02	0,24	0,43	0,42
São Lourenço da Mata		0,08	0,06	0,01	0,00	0,00	0,01	0,00	0,00	0,04	0,07	0,08
Serra Talhada	0,15	0,24	0,01	0,00	0,00	0,01	0,07	0,05	0,24	0,26	0,10	0,10

continua...

continuação.

Serrita	0,53	0,66	0,26	0,11	0,12	0,13	0,44	0,39	0,73	0,75	0,79	0,43
Sertânia	0,60	0,77	0,04	0,34	0,02	0,08	0,43	0,26	0,68	0,74	0,74	0,71
Surubim	0,03	0,12	0,08	0,03	0,00	0,00	0,01	0,00	0,02	0,11	0,14	0,14
Tacaimbó	0,07	0,23	0,14	0,05	0,01	0,00	0,02	0,02	0,08	0,27	0,36	0,11
Toritama		0,22	0,12	0,02	0,00	0,00	0,01	0,01	0,05	0,28	0,32	0,26
Trindade	0,11	0,20	0,00	0,00	0,01	0,01	0,05	0,04	0,15	0,16	0,19	0,01
Venturosa	0,26	0,49	0,26	0,03	0,00	0,00	0,08	0,03	0,32	0,56	0,71	0,69
Verdejante	0,11	0,23	0,01	0,01	0,02	0,02	0,09	0,08	0,25	0,26	0,29	0,02
Vitória de Santo Antão		0,08	0,12	0,01	0,00	0,00	0,01	0,00	0,00	0,06	0,13	0,12

Fonte: O Autor (2024).

Tabela 12 - Inflação de casos por município em 2022

Municípios	2022											
	1	2	3	4	5	6	7	8	9	10	11	12
Abreu e Lima	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,02	0,00
Afogados da Ingazeira	0,04	0,01	0,01	0,00	0,02	0,01	0,02	0,05	0,12	0,11	0,10	0,00
Agrestina	0,01	0,04	0,05	0,01	0,01	0,00	0,00	0,00	0,00	0,03	0,04	0,00
Águas Belas	0,08	0,49	0,56	0,27	0,03	0,01	0,00	0,00	0,04	0,34	0,37	0,00
Alagoinha	0,41	0,07	0,49	0,15	0,04	0,02	0,00	0,02	0,05	0,29	0,36	0,01
Altinho		0,10	0,05	0,01	0,02	0,00	0,00	0,00	0,00	0,04	0,05	0,00
Arcoverde	0,07	0,01	0,04	0,01	0,00	0,00	0,00	0,00	0,03	0,05	0,04	0,00
Barra de Guabiraba	0,01	0,04	0,02	0,00	0,00	0,00	0,00	0,00	0,00	0,02	0,02	0,01
Belém do São Francisco	0,05	0,12	0,06	0,04	0,20	0,07	0,08	0,22	0,36	0,28	0,27	0,02
Belo Jardim	0,06	0,03	0,06	0,01	0,01	0,00	0,00	0,00	0,00	0,04	0,04	0,00
Betânia		0,09	0,35	0,20	0,36	0,24	0,36	0,55	0,76	0,58	0,12	0,16
Bom Jardim	0,12	0,10	0,15	0,03	0,06	0,00	0,00	0,00	0,03	0,19	0,22	0,07
Bonito	0,03	0,05	0,04	0,00	0,01	0,00	0,00	0,00	0,00	0,03	0,04	0,00
Brejo da Madre de Deus	0,18	0,03	0,33	0,08	0,08	0,03	0,03	0,06	0,20	0,24	0,36	0,02
Buíque	0,45	0,23	0,66	0,30	0,23	0,00	0,00	0,00	0,02	0,37	0,61	0,01
Cabo de Santo Agostinho	0,04	0,05	0,03	0,03	0,03	0,02	0,02	0,01	0,03	0,01	0,01	0,01
Cabrobó	0,02	0,19	0,08	0,01	0,06	0,04	0,09	0,18	0,32	0,22	0,01	0,00
Cachoeirinha	0,00	0,06	0,06	0,01	0,00	0,00	0,00	0,00	0,00	0,04	0,05	0,00
Calumbi		0,07	0,12	0,01	0,07	0,22	0,20	0,44	0,58	0,56	0,55	0,24
Camargibe	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,02	0,01
Carnaíba	0,08	0,12	0,01	0,00	0,04	0,04	0,05	0,11	0,51	0,32	0,25	0,07
Carnaubeira da Penha	0,95	0,59	0,63	0,13	0,79	0,69	0,58	0,91	0,94	0,94	0,78	0,74
Caruaru	0,01	0,01	0,00	0,00	0,01	0,00	0,00	0,00	0,00	0,02	0,01	0,00
Casinhas	0,70	0,74	0,77	0,37	0,60	0,00	0,02	0,11	0,21	0,71	0,74	0,62
Cedro	0,01	0,01	0,05	0,00	0,01	0,03	0,01	0,12	0,22	0,13	0,03	0,04
Chã Grande	0,05	0,03	0,11	0,00	0,03	0,00	0,00	0,00	0,02	0,09	0,19	0,11
Cupira	0,01	0,03	0,05	0,01	0,01	0,00	0,00	0,00	0,00	0,02	0,03	0,00
Dormentes	0,37	0,65	0,34	0,30	0,61	0,60	0,66	0,78	0,87	0,80	0,78	0,21
Exu	0,12	0,05	0,13	0,02	0,11	0,10	0,11	0,26	0,57	0,46	0,30	0,07
Fernando de Noronha	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,01
Floresta	0,03	0,07	0,11	0,08	0,09	0,04	0,08	0,28	0,35	0,27	0,23	0,02
Garanhuns	0,01	0,01	0,03	0,00	0,01	0,00	0,00	0,00	0,00	0,01	0,00	0,00
Goiana	0,01	0,07	0,04	0,00	0,00	0,00	0,00	0,00	0,00	0,04	0,05	0,01
Granito	0,35	0,07	0,12	0,00	0,14	0,14	0,06	0,32	0,56	0,32	0,13	0,14
Gravatá	0,01	0,04	0,06	0,03	0,02	0,00	0,00	0,00	0,00	0,02	0,05	0,01
Ibimirim	0,11	0,05	0,11	0,01	0,08	0,07	0,09	0,22	0,45	0,39	0,28	0,05
Ibirajuba	0,08	0,15	0,26	0,04	0,11	0,00	0,00	0,00	0,02	0,14	0,10	0,00

continua...

continuação.

Igarassu	0,02	0,00	0,02	0,00	0,00	0,00	0,00	0,00	0,00	0,02	0,03	0,01
Ipojuca	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,02	0,01	0,00
Ipubi		0,11	0,37	0,01	0,03	0,17	0,35	0,44	0,65	0,44	0,28	0,18
Itapetim	0,10	0,00	0,10	0,00	0,04	0,06	0,07	0,12	0,36	0,25	0,26	0,04
Itapissuma	0,04	0,01	0,08	0,01	0,01	0,00	0,00	0,00	0,01	0,06	0,09	0,06
Jaboatão dos Guararapes	0,09	0,10	0,07	0,07	0,08	0,04	0,03	0,03	0,05	0,06	0,07	0,08
Jatobá	0,09	0,05	0,04	0,14	0,15	0,02	0,01	0,05	0,21	0,22	0,21	0,03
Jurema	0,07	0,06	0,08	0,01	0,00	0,00	0,00	0,00	0,00	0,02	0,04	0,00
Lagoa dos Gatos	0,11	0,12	0,19	0,02	0,04	0,00	0,01	0,00	0,02	0,11	0,11	0,00
Lagoa Grande	0,07	0,19	0,17	0,12	0,32	0,17	0,26	0,53	0,67	0,58	0,40	0,07
Lajedo		0,04	0,02	0,01	0,01	0,00	0,00	0,00	0,01	0,03	0,03	0,00
Mirandiba	0,02	0,01	0,01	0,00	0,01	0,02	0,05	0,12	0,27	0,13	0,01	0,07
Moreilândia		0,04	0,24	0,02	0,04	0,26	0,17	0,33	0,72	0,51	0,26	0,27
Moreno	0,01	0,01	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,02	0,02	0,00
Olinda	0,01	0,04	0,02	0,02	0,03	0,01	0,01	0,01	0,02	0,02	0,02	0,02
Orobó	0,69	0,33	0,54	0,12	0,18	0,00	0,00	0,02	0,14	0,57	0,61	0,31
Panelas	0,03	0,16	0,19	0,03	0,02	0,00	0,00	0,00	0,01	0,08	0,10	0,00
Parnamirim	0,26	0,08	0,21	0,08	0,04	0,08	0,12	0,33	0,23	0,33	0,10	0,01
Passira		0,09	0,19	0,03	0,16	0,00	0,00	0,01	0,04	0,22	0,22	0,06
Paulista	0,01	0,00	0,02	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,01	0,01
Pesqueira	0,08	0,00	0,23	0,03	0,09	0,00	0,00	0,01	0,01	0,13	0,14	0,00
Petrolândia	0,04	0,04	0,03	0,06	0,13	0,04	0,04	0,14	0,25	0,20	0,22	0,05
Petrolina	0,00	0,02	0,03	0,02	0,06	0,02	0,07	0,12	0,20	0,10	0,04	0,00
Poção	0,33	0,40	0,34	0,01	0,05	0,01	0,00	0,01	0,05	0,22	0,25	0,01
Quipapá	0,02	0,04	0,06	0,00	0,01	0,00	0,00	0,00	0,00	0,03	0,06	0,00
Quixaba	0,11	0,08	0,00	0,02	0,04	0,04	0,02	0,14	0,38	0,27	0,13	0,01
Recife	0,03	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,01	0,01
Riacho das Almas	0,15	0,03	0,27	0,14	0,10	0,00	0,01	0,03	0,06	0,29	0,29	0,01
Rio Formoso	0,03	0,09	0,12	0,00	0,01	0,00	0,00	0,00	0,02	0,12	0,21	0,06
Salgueiro	0,02	0,03	0,02	0,01	0,04	0,00	0,04	0,11	0,24	0,11	0,02	0,04
Saloá		0,08	0,29	0,24	0,36	0,01	0,00	0,00	0,06	0,35	0,37	0,00
Santa Cruz do Capibaribe	0,12	0,21	0,09	0,06	0,10	0,00	0,01	0,01	0,03	0,09	0,10	0,01
Santa Filomena	0,73	0,21	0,45	0,38	0,12	0,25	0,67	0,68	0,85	0,70	0,49	0,16
Santa Maria da Boa Vista	0,05	0,66	0,24	0,24	0,51	0,36	0,65	0,70	0,88	0,80	0,57	0,14
Santa Terezinha	0,16	0,01	0,03	0,00	0,02	0,02	0,03	0,09	0,08	0,09	0,09	0,01
São Bento do Una	0,12	0,16	0,27	0,06	0,09	0,00	0,00	0,00	0,03	0,18	0,22	0,01
São João	0,06	0,35	0,20	0,02	0,04	0,00	0,00	0,00	0,02	0,12	0,19	0,00
São José do Belmonte	0,30	0,13	0,13	0,01	0,05	0,09	0,13	0,35	0,64	0,46	0,17	0,05
São José do Egito		0,01	0,02	0,00	0,02	0,01	0,02	0,05	0,15	0,10	0,06	0,01
São Lourenço da Mata	0,01	0,01	0,03	0,00	0,01	0,00	0,00	0,00	0,00	0,03	0,06	0,03
São Vicente Férrer	0,33	0,02	0,40	0,01	0,05	0,00	0,00	0,00	0,05	0,11	0,35	0,15
Serra Talhada	0,01	0,01	0,01	0,00	0,03	0,02	0,03	0,11	0,16	0,11	0,03	0,01
Serrita	0,21	0,23	0,13	0,02	0,08	0,04	0,09	0,43	0,61	0,43	0,19	0,05
Sertânia	0,19	0,04	0,28	0,08	0,16	0,06	0,15	0,23	0,39	0,44	0,36	0,03
Sirinhaém		0,00	0,01	0,00	0,00	0,00	0,00	0,00	0,01	0,03	0,09	0,02
Surubim	0,02	0,03	0,04	0,02	0,03	0,00	0,00	0,00	0,01	0,04	0,05	0,03
Tacaimbó	0,09	0,03	0,09	0,14	0,09	0,01	0,00	0,01	0,02	0,12	0,12	0,00
Tacaratu		0,18	0,15	0,11	0,26	0,13	0,20	0,45	0,62	0,44	0,26	0,04
Tamandaré	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,02	0,01
Terra Nova	0,17	0,10	0,03	0,03	0,03	0,04	0,02	0,22	0,33	0,21	0,16	0,02
Toritama	0,03	0,10	0,10	0,01	0,05	0,00	0,00	0,00	0,01	0,06	0,06	0,01
Trindade	0,06	0,01	0,06	0,00	0,03	0,06	0,04	0,14	0,19	0,14	0,13	0,01

continua...

continuação.

Tupanatinga	0,04	0,50	0,04	0,15	0,01	0,00	0,00	0,01	0,21	0,36	0,05	
Venturosa	0,41	0,15	0,23	0,13	0,01	0,01	0,00	0,01	0,04	0,07	0,20	0,05
Verdejante	0,02	0,01	0,02	0,02	0,03	0,03	0,03	0,15	0,27	0,15	0,02	0,03
Vitória de Santo Antão	0,01	0,03	0,04	0,00	0,00	0,00	0,00	0,01	0,04	0,06	0,02	

Fonte: O Autor (2024).

Tabela 13 - Inflação de casos por município em 2023

Municípios	2023					
	1	2	3	4	5	6
Abreu e Lima	0,01	0,01	0,00	0,00	0,00	0,00
Afogados da Ingazeira	0,05	0,11	0,01	0,00	0,00	0,00
Agrestina	0,01	0,01	0,00	0,00	0,00	0,00
Águas Belas	0,37	0,51	0,22	0,04	0,05	0,02
Alagoinha	0,36	0,48	0,15	0,02	0,01	0,01
Altinho	0,01	0,04	0,01	0,00	0,00	0,00
Araripina	0,09	0,10	0,01	0,00	0,01	0,02
Arcoverde	0,05	0,04	0,00	0,00	0,00	0,00
Barra de Guabiraba	0,00	0,01	0,00	0,00	0,00	0,00
Belém do São Francisco	0,04	0,25	0,08	0,00	0,03	0,02
Belo Jardim	0,02	0,03	0,01	0,00	0,00	0,00
Betânia	0,18	0,38	0,25	0,03	0,03	0,05
Bom Jardim	0,17	0,20	0,03	0,01	0,01	0,00
Bonito	0,02	0,02	0,00	0,00	0,00	0,00
Brejo da Madre de Deus	0,33	0,22	0,07	0,00	0,01	0,01
Buíque	0,47	0,71	0,05	0,06	0,01	0,01
Cabo de Santo Agostinho	0,01	0,02	0,01	0,01	0,01	0,01
Cabrobó	0,04	0,25	0,06	0,00	0,01	0,00
Cachoeirinha	0,02	0,08	0,01	0,00	0,00	0,00
Calumbi	0,16	0,47	0,03	0,00	0,03	0,04
Camaragibe	0,02	0,00	0,00	0,00	0,00	0,00
Carnaíba	0,14	0,40	0,02	0,00	0,00	0,02
Carnaubeira da Penha	0,46	0,96	0,85	0,09	0,29	0,18
Caruaru	0,01	0,03	0,00	0,00	0,00	0,00
Casinhas	0,63	0,76	0,33	0,12	0,07	0,06
Cedro	0,04	0,03	0,01	0,00	0,01	0,00
Chã Grande	0,12	0,05	0,02	0,01	0,00	0,00
Cupira	0,01	0,04	0,01	0,00	0,00	0,00
Dormentes	0,63	0,37	0,05	0,03	0,30	0,25
Exu	0,18	0,37	0,04	0,00	0,02	0,04
Fernando de Noronha	0,00	0,00	0,00	0,00	0,00	0,00
Floresta	0,03	0,22	0,05	0,00	0,02	0,01
Garanhuns	0,00	0,01	0,00	0,00	0,00	0,00
Goiana	0,05	0,02	0,01	0,01	0,00	0,00
Granito	0,10	0,49	0,00	0,00	0,05	0,05
Gravatá	0,03	0,02	0,00	0,00	0,00	0,00
Ibimirim	0,15	0,37	0,10	0,00	0,01	0,02
Ibirajuba	0,04	0,17	0,06	0,02	0,01	0,00
Igarassu	0,03	0,01	0,00	0,00	0,00	0,00
Ipojuca	0,01	0,00	0,00	0,00	0,00	0,00
Ipubi	0,43	0,52	0,13	0,01	0,11	0,04
Itapetim	0,21	0,41	0,03	0,00	0,00	0,01

continua...

continuação.

Itapissuma	0,08	0,12	0,01	0,01	0,00	0,00
Jaboatão dos Guararapes	0,08	0,08	0,05	0,06	0,02	0,02
Jatobá	0,02	0,35	0,07	0,00	0,02	0,02
Jurema	0,01	0,08	0,03	0,00	0,00	0,00
Lagoa dos Gatos	0,04	0,18	0,06	0,01	0,00	0,00
Lagoa Grande	0,12	0,55	0,19	0,01	0,08	0,06
Lajedo	0,04	0,08	0,00	0,00	0,00	0,00
Mirandiba	0,01	0,12	0,02	0,00	0,00	0,00
Moreilândia	0,21	0,13	0,16	0,00	0,10	0,02
Moreno	0,02	0,00	0,00	0,00	0,00	0,00
Nazaré da Mata	0,03	0,00	0,01	0,01	0,00	0,00
Olinda	0,02	0,02	0,01	0,02	0,01	0,01
Orobó	0,51	0,55	0,13	0,05	0,02	0,01
Panelas	0,05	0,11	0,03	0,01	0,00	0,00
Parnamirim	0,06	0,56	0,08	0,00	0,10	0,02
Passira	0,11	0,13	0,02	0,01	0,00	0,00
Paulista	0,01	0,01	0,00	0,00	0,00	0,00
Pesqueira	0,13	0,16	0,07	0,00	0,01	0,00
Petrolândia	0,00	0,20	0,01	0,01	0,01	0,01
Petrolina	0,02	0,08	0,03	0,01	0,01	0,01
Poção	0,28	0,30	0,09	0,00	0,01	0,01
Quipapá	0,04	0,03	0,02	0,00	0,00	0,00
Quixaba	0,12	0,11	0,04	0,00	0,00	0,03
Recife	0,01	0,01	0,00	0,00	0,00	0,00
Riacho das Almas	0,04	0,19	0,01	0,00	0,00	0,01
Rio Formoso	0,11	0,05	0,02	0,01	0,00	0,00
Salgueiro	0,03	0,12	0,02	0,00	0,01	0,01
Saloá	0,43	0,49	0,21	0,04	0,03	0,01
Santa Cruz do Capibaribe	0,05	0,14	0,03	0,00	0,00	0,00
Santa Filomena	0,57	0,51	0,13	0,05	0,17	0,10
Santa Maria da Boa Vista	0,85	0,93	0,54	0,05	0,29	0,23
Santa Terezinha	0,10	0,05	0,00	0,00	0,00	0,00
São Bento do Una	0,13	0,24	0,05	0,01	0,01	0,00
São João	0,08	0,21	0,03	0,01	0,01	0,00
São José do Belmonte	0,10	0,21	0,04	0,00	0,05	0,00
São José do Egito	0,02	0,06	0,01	0,00	0,00	0,01
São Lourenço da Mata	0,02	0,01	0,00	0,00	0,00	0,00
São Vicente Férrer	0,23	0,25	0,03	0,05	0,00	0,00
Serra Talhada	0,01	0,04	0,01	0,00	0,00	0,00
Serrita	0,15	0,27	0,10	0,01	0,03	0,03
Sertânia	0,45	0,52	0,17	0,05	0,03	0,08
Sirinhaém	0,04	0,03	0,00	0,00	0,00	0,00
Surubim	0,05	0,06	0,01	0,00	0,00	0,00
Tacaimbó	0,06	0,12	0,05	0,00	0,01	0,00
Tacaratu	0,07	0,46	0,13	0,01	0,05	0,04
Tamandaré	0,00	0,00	0,00	0,00	0,00	0,00
Terra Nova	0,01	0,13	0,05	0,00	0,03	0,01
Toritama	0,04	0,10	0,02	0,00	0,00	0,00
Trindade	0,03	0,13	0,04	0,00	0,02	0,02
Tupanatinga	0,05	0,32	0,21	0,03	0,02	0,00
Venturosa	0,22	0,47	0,08	0,01	0,02	0,03
Verdejante	0,03	0,12	0,02	0,00	0,00	0,00

continua...

continuação.

Vitória de Santo Antão	0,06	0,01	0,01	0,00	0,00	0,00
------------------------	------	------	------	------	------	------

Fonte: O Autor (2024).