



**UNIVERSIDADE DA INTEGRAÇÃO INTERNACIONAL DA LUSOFONIA
AFRO-BRASILEIRA – (UNILAB)
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO (PROPPG)
PROGRAMA DE PÓS-GRADUAÇÃO EM ENERGIA E AMBIENTE (PGEA)
INSTITUTO DE ENGENHARIAS E DESENVOLVIMENTO SUSTENTÁVEL
(IEDS)**

JÉSSICA SILVA

**IMPACTO DO CLIMA NOS CASOS DE DENGUE EM CAMPINA GRANDE,
PARAÍBA**

REDENÇÃO – CE

2023

JÉSSICA SILVA

**IMPACTO DO CLIMA NOS CASOS DE DENGUE EM CAMPINA GRANDE,
PARAÍBA**

Dissertação apresentada à Banca Examinadora do Programa de Programa de Pós-Graduação em Energia e Meio Ambiente da Universidade da Integração Internacional da Lusofonia Afro-Brasileira (UNILAB) como requisito para conclusão do Mestrado Acadêmico em Energia e Meio Ambiente.

Área de concentração: Energia e Ambiente.

Linha de pesquisa: Sistemas energéticos, desenvolvimento rural e recursos hídricos.

Orientador: Dr. Alexandre Cunha Costa

REDENÇÃO - CE

2023

Universidade da Integração Internacional da Lusofonia Afro-Brasileira
Sistema de Bibliotecas da UNILAB
Catalogação de Publicação na Fonte.

Silva, Jéssica.

S586i

Impacto do clima nos casos de dengue em Campina Grande, Paraíba
/ Jéssica Silva. - Redenção, 2024.
Of: il.

Dissertação - Curso de Mestrado Acadêmico Em Energia E Ambiente,
Programa De Pós-graduação Em Energia E Ambiente, Universidade da
Integração Internacional da Lusofonia Afro-Brasileira, Redenção,
2024.

Orientador: Prof. Dr. Alexandre Cunha Costa.

1. Doenças transmitidas por vetores. 2. Dengue. 3. Regressão
linear e Não-linear. I. Costa, Dr. Alexandre Cunha. II. Título.

CE/UF/BSCA

CDD 616.989

JÉSSICA SILVA

**IMPACTO DO CLIMA NOS CASOS DE DENGUE EM CAMPINA GRANDE,
PARAÍBA**

Dissertação apresentada à Universidade de Integração Internacional da Lusofonia Afro-Brasileira, UNILAB – Campus Redenção/CE, para obtenção do título de Mestre em Energia e Ambiente, Programa de Pós-Graduação em Energia e Ambiente.

Aprovada em: 28/09/2023

BANCA EXAMINADORA

Prof. Dr. Alexandre Cunha Costa (Orientador)

Universidade da Integração Internacional da Lusofonia Afro-Brasileira (UNILAB)

Prof. Dr. Luiz Martins de Araújo Junior (Examinador interno)

Universidade da Integração Internacional da Lusofonia Afro-Brasileira (UNILAB)

Prof. Dr. Cleiton da Silva Silveira (Examinador externo)

Universidade Federal do Ceará (UFC)

AGRADECIMENTOS

Agradeço, primeiramente, a Deus por me dar a capacidade de aprender e de ser capaz de melhorar cada vez mais, tanto na minha vida pessoal como acadêmica. Agradeço por guiar meus passos ao longo desta jornada de pesquisa e por me conceder força nos momentos desafiadores. Sua graça e orientação foram fundamentais para que eu pudesse alcançar este marco em minha vida. Que a sabedoria e a luz divina continuem a me iluminar em futuros desafios.

Segundo, quero expressar minha profunda gratidão ao meu orientador, Prof. Dr. Alexandre Cunha Costa, por sua orientação excepcional, dedicação incansável e inestimáveis contribuições ao longo de toda a jornada de pesquisa. Suas visões, discernimentos e experiência foram cruciais para a concretização deste estudo. Agradeço não apenas pelo apoio acadêmico, mas também pelo apoio emocional e incentivo constantes.

Aos membros da banca, Coordenador Prof. Luiz Martins de Araújo Junior e Prof. Dr. Cleiton da Silva Silveira, por dedicarem seu tempo e expertise na avaliação deste trabalho. Suas observações críticas e sugestões construtivas desempenharam um papel fundamental na melhoria desta dissertação. Estou honrado por ter recebido suas contribuições.

À minha instituição acadêmica, Universidade da Integração Internacional da Lusofonia Afro-Brasileira (UNILAB), e ao Programa de Pós-Graduação em Energia e Meio Ambiente, por fornecerem o melhor ensino e recursos necessários para conduzir esta pesquisa. O ambiente acadêmico e a infraestrutura da universidade desempenharam um papel essencial em minha formação como pesquisador.

Não posso deixar de agradecer aos meus colegas, Moises Willson, José Francisco, José Micael, Ticiane Freire e Vitória, pela ajuda, trocas de ideias e colaborações ao longo destes anos.

Aos amigos e familiares que sempre estiveram ao meu lado, oferecendo seu apoio inabalável e encorajamento. Seu suporte moral foi meu refúgio nos momentos de desafio. Agradeço, em especial, aos meus pais, Maria das Neves e Francisco Alves, pelo seu amor incondicional, compreensão e incentivo ao longo de toda a minha trajetória acadêmica. Esta conquista também é dedicada a vocês.

Aos meus amigos e irmãos da igreja de Cristo no Brasil, que compartilharam essa jornada comigo, compartilhando alegrias e desafios, cuidando de mim tanto fisicamente como em oração. Agradeço, em especial, ao irmão Welitânia Lira, Edson Freitas, Simone Ferreira, Juliana Ferreira, Robson Ferreira, Josy e Ozana, por estarem sempre ao meu lado nesta caminhada; vocês foram meu maior apoio.

Este agradecimento não estaria completo sem expressar minha profunda gratidão àqueles que, por meio de seu trabalho, produziram o conhecimento que fundamentou esta pesquisa. Os acadêmicos e pesquisadores que abriram caminho neste campo, cujos estudos foram a base sobre a qual está dissertação foi construída, merecem todo o reconhecimento.

Concluir esta dissertação de mestrado é um marco em minha jornada acadêmica e profissional, e devo isso a cada uma das pessoas mencionadas acima. Suas contribuições e apoio foram cruciais para o meu crescimento e para o sucesso desta pesquisa. Esta conquista é verdadeiramente compartilhada por todos vocês.

Que este trabalho possa contribuir, de alguma forma, para o avanço do conhecimento em nosso campo e, em última instância, para a melhoria da sociedade. Estou ansioso para continuar minha jornada de pesquisa, construindo sobre o que aprendi durante este mestrado e enfrentando novos desafios.

Muito obrigado a todos!

*Dedico este trabalho ao meu melhor amigo e
Pai que me orientou e ensinou tudo que eu
precisava até o fim desta caminhada:
“Deus”.*

RESUMO

O clima da Terra está sofrendo alterações significativas, resultando em impactos relevantes e potencialmente devastadores no ambiente, na sociedade e na economia global. As mudanças climáticas têm efeitos diretos na propagação de doenças transmitidas por vetores, como a dengue. Portanto, estudar a variação da temperatura e outros fatores climáticos em relação às condições de transmissão da dengue é essencial para a adoção de medidas preventivas de saúde pública e adaptação às mudanças climáticas. O objetivo geral deste trabalho é avaliar os efeitos das variações climáticas nos casos de dengue na cidade de Campina Grande – PB. Para tanto, estudou-se a associação entre o número de casos de dengue e as variáveis climáticas, por meio do cálculo do coeficiente de correlação de Pearson. Em seguida, foram ajustados e comparados modelos de regressão de séries temporais: regressão linear múltipla com erros independentes, regressão linear múltipla com erros correlacionados e modelos aditivos generalizados. Por fim, foi avaliado o impacto das mudanças climáticas na incidência da dengue, assumindo a tendência geral das variáveis climáticas na região de acordo com os cenários RCP4.5 e RCP8.5 no final deste século. A correlação positiva entre dengue e chuvas, com atraso de um mês, destaca a importância das chuvas como fator impulsionador da proliferação do mosquito. Por outro lado, as temperaturas máximas e médias do mês atual apresentaram correlação negativa com a dengue, sugerindo que temperaturas mais altas podem limitar a sobrevivência do mosquito, o que pode ser contrabalançado pela correlação positiva entre dengue e temperatura mínima. O melhor modelo de regressão linear para dengue é aquele que tem como variável dependente a temperatura máxima do mês atual e uma distribuição de erros seguindo um modelo autorregressivo de primeira ordem. Seu SRMSE foi de 0,90, o que significa que o modelo é 10% superior que o valor esperado da variável dependente (logaritmo dos casos de dengue) como preditor. O ajuste do modelo aditivo generalizado apresentou melhor desempenho com um SRMSE igual a 0,85. Esse modelo contou, com a adição da precipitação com um mês de antecedência como variável independente, mostrando a influência da precipitação no número de casos de dengue de forma não linear. As projeções indicam aumentos de temperatura de 1,8°C no cenário RCP4.5 e de 4,1°C no cenário RCP8.5 na região Nordeste do Brasil. Estas tendências indicam uma possível redução de aproximadamente 50% na taxa de incidência de dengue para o cenário RCP4.5 e uma redução de 100% nos casos no cenário RCP8.5, uma vez que as temperaturas podem tornar-se demasiado altas para a proliferação do mosquito da dengue. Este estudo fornece uma visão regional da variabilidade climática e seu impacto local na incidência de dengue em um município da região Nordeste do Brasil. Os resultados apresentados podem ter implicações importantes para a saúde pública no presente e nos cenários futuros de alterações climáticas.

Palavras-chave: Doenças transmitidas por vetores. Dengue. Variabilidade climática. Regressão linear e Não-linear. Saúde pública.

ABSTRACT

The Earth's climate is undergoing significant changes, resulting in relevant and potentially devastating impacts on environment, society and the global economy. Climate change has direct effects on the spread of vector-borne diseases such as dengue fever. Therefore, studying the variation in temperature and other climatic factors in relation to dengue transmission conditions is essential for adopting preventive public health measures and adapting to climate change. The general objective of this work is to evaluate the effects of climate variations on dengue cases in the city of Campina Grande – PB. To this end, the association between the number of dengue cases and climatic variables was studied, by calculating the Pearson correlation coefficient. Then, time series regression models were adjusted and compared: multiple linear regression with independent errors, multiple linear regression with correlated errors, and generalized additive models. Finally, the impact of climate change on the incidence of dengue fever was assessed, assuming the general trend for climate variables in the region according to the RCP4.5 and RCP8.5 scenarios at the end of this century. The positive correlation between dengue fever and rainfall, with a delay of one month, highlights the importance of rainfall as a factor that drives mosquito proliferation. On the other hand, the current month's maximum and average temperatures showed a negative correlation with dengue, suggesting that higher temperatures may limit mosquito survival, which may be counterbalanced by the positive correlation between dengue and minimum temperature. The best linear regression model for dengue is one that has the maximum temperature in the current month as a dependent variable and a distribution of errors following a first-order autoregressive model. Its SRMSE was 0.90, which means that the model is 10% better than the expected value of the dependent variable (logarithm of dengue cases) as a predictor. The adjustment of the generalized additive model showed however better performance with an SRMSE equal to 0.85, with the addition of precipitation as an independent variable, showing the influence of precipitation on the number of dengue cases in a non-linear form. Projections indicate temperature increases of 1.8°C in the RCP4.5 scenario and 4.1°C in the RCP8.5 scenario in the Northeast region of Brazil. These trends may lead to a reduction of approximately 50% in the dengue incidence rate for the RCP4.5 scenario and a 100% reduction in cases in the RCP8.5 scenario, as temperatures could become too high for the dengue mosquito to proliferate. This study provides a regional view of climate variability and its local impact on dengue incidence in a municipality in the Northeast region of Brazil. The results presented may have important implications for public health in the present and in future climate change scenarios.

Key words: Vector-borne diseases. Dengue. Climate variability. Linear and Non-linear regression. Public health.

LISTA DE FIGURAS, TABELAS E GRÁFICOS

Figura 1: Distribuição anual dos casos de dengue em Campina Grande-PB.	28
Figura 2: Casos de Dengue em Campina Grande - PB para o período de 2011 a 2021.....	29
Figura 3: Fluxograma de atividades realizadas no trabalho.	30
Figura 4: Localização da cidade de Campina Grande-PB.....	31
Figura 5: Series temporais mensais dos casos de Dengue, precipitação (mm), temperatura média (°C) e temperatura máxima (°C).....	44
Figura 6: QQ - plot dos erros do modelo linear ajustado.	45
Figura 7: Função de autocorrelação dos erros do modelo linear ajustado.	46
Figura 8: Função de autocorrelação parcial dos erros do modelo linear ajustado.	46
 Tabela 1: Coeficiente de correlação para variáveis do estudo.	 43
Tabela 2: Cálculos das métricas de avaliação do ajuste do modelo aditivo generalizado.	47
Tabela 3: Cálculo das medias e DP. das variáveis preditoras.	47
Tabela 4: Projeção dos casos de dengue em Campina Grande-PB.	48

LISTA DE SIGLAS E ABREVIATURAS

AIC - Akaike Information Criterion

ARMA - Modelos Auto-Regressivos De Médias Móveis

ε - Erro Aleatório

GAM - Modelos Aditivos Generalizados

GLS - Método Dos Mínimos Quadrados Generalizados

INMET - Instituto Nacional de Meteorologia

MMQ - Método dos Mínimos Quadrados

MQO - Método Dos Mínimos Quadrados Ordinários

MRLM - Modelo de Regressão Linear Múltipla

OLS - Ordinary Least Squares

P – Precipitação

R² - Coeficiente de determinação

RCP - Vias Representativas de Concentração

RLS - Regressão Linear Simples

RMSE - Raiz do Erro Quadrático Médio

SINAN - Sistema de Informação de Agravos de Notificação

SRMSE - Raiz Quadrada Média do Erro Padronizado

UNILAB - Universidade da Integração Internacional da Lusofonia Afro-Brasileira

SUMÁRIO

1.	INTRODUÇÃO	12
2.	OBJETIVOS	15
2.1	Objetivo Geral	15
2.2	Objetivo Específico	15
3.	FUNDAMENTAÇÃO TEÓRICA.....	16
3.1	Mudanças Climáticas	16
3.1.1	Política Nacional Sobre Mudança Do Clima.....	19
3.1.2	Plano Nacional De Adaptação À Mudança No Clima.....	20
3.2	Doenças Arbovirais	21
3.2.1	Malária	21
3.2.2	Chikungunya.....	21
3.2.3	Zika	22
3.2.4	Dengue	22
3.3	Variáveis Climáticas E Os Impactos Na Incidência Da Dengue	23
3.4	Casos Graves De Dengue No Brasil E Mundo	25
3.5	Casos Dengue Na Cidade De Campina Grande-Pb.....	27
4.	METODOLOGIA.....	30
4.1	Caracterização Da Área De Estudo	31
4.2	Período Da Coleta De Dados	32
4.3	Operacionalização Da Coleta De Dados	32
4.4	Análise Dos Dados	32
4.4.1	Coeficiente De Correlação Linear De Pearson	32
4.5	Modelos Empíricos	33
4.5.1	Regressão Linear	34
4.5.2	Modelo Aditivo Generalizado.....	35

4.5.3	Resíduos.....	35
4.5.4	Colinearidade E Multicolinearidade.....	36
4.5.5	Teste De Significância Da Regressão Linear Múltipla.....	36
4.6	Métricas De Avaliação Do Ajuste Do Modelo.....	39
4.6.1	Coeficiente De Determinação	39
4.6.2	Coeficiente De Determinação Ajustado.....	39
4.6.3	Raiz Do Erro Quadrático Médio	40
4.7	Modelagem Dos Casos De Dengue Em Função De Séries Temporais	40
4.8	Projeções Da Incidência De Dengue A Partir Das Mudanças Climáticas Na Região Nordeste	41
5.	RESULTADOS E DISCUSSÃO	43
5.1	Correlação Entre As Variáveis.....	43
5.2	Regressão Linear	45
5.3	Modelo Aditivo Generalizado.....	46
5.4	Estimativa Da Mudanças Da Incidência De Dengue Para O Final Deste Século	47
6.	CONCLUSÃO.....	50
	REFERENCIA	50
	ANEXO I.....	62
	ANEXO II.....	67

1. INTRODUÇÃO

As mudanças climáticas têm se tornado uma das questões mais prementes e desafiadoras enfrentadas pela humanidade no século XXI. O clima da Terra está passando por alterações significativas, resultando em impactos relevantes e potencialmente devastadores no meio ambiente, na sociedade e na economia global (Ebi et al., 2018).

De acordo com o Quinto Relatório do Painel Intergovernamental das Mudanças Climáticas (IPCC), a temperatura da superfície global deve aumentar entre 0,3 e 0,7 °C no período de 2016 a 2035, em relação ao intervalo de 1986 a 2005 (IPCC, 2012). O relatório também concluiu que, embora os impactos das alterações climáticas na saúde humana sejam variáveis em comparação com outros fatores, as relações identificadas até o momento não devem ser descartadas (Barcellos, 2016). Isso ocorre, em parte, devido às alterações climáticas que têm provocado modificações nos padrões esperados dos vetores de doenças, assim como o surgimento de doenças e agravos diretos em decorrência de fenômenos climáticos extremos (IPCC, 2012).

Entre as preocupações com as doenças transmitidas por vetores e pelas mudanças climáticas, a dengue é uma das mais alarmantes. A dengue é transmitida principalmente pelo mosquito *Aedes Aegypti* (Krug et al., 2019). O tempo de vida e a reprodução desse mosquito variam de acordo com o tipo de clima, podendo ser maior ou menor em diferentes regiões.

No período de 1994 a 2002, foram notificados quase três milhões de casos de dengue no Brasil, com um aumento da incidência de 37 para 454 por 100.000 habitantes no período. Embora grandes surtos tenham sido observados na estação chuvosa, uma parte considerável dos casos (em torno de 500 mil) foram registrados em estação sem chuva, demonstrando, assim, o aumento da atividade do vírus da dengue durante todo o ano. No Nordeste do Brasil, os períodos sem chuvas podem contribuir para o aumento da abundância de vetores por meio de reservatórios de armazenamento de água, que podem servir como locais de reprodução para os mosquitos vetores (Pontes, 2000). Aproximadamente 50% dos casos de dengue ocorreram em adultos entre 20 e 40 anos de idade. Assim, a incidência de dengue foi consistentemente maior em adultos, atingindo até 433 por 100.000 habitantes na faixa etária de 30 a 49 anos em 2002 (Siqueira et al., 2005).

Estudos sobre a difusão da transmissão da dengue no Brasil revelam que a doença vem expandindo sua área de transmissão em quase todo o território nacional, tornando-se hiperendêmica ao longo do litoral leste e regiões centrais (Barcellos; Lowe, 2014). Os surtos se concentram principalmente no Nordeste e surpreendentemente, também no Sul.

De fato, entre 2001 e 2019, a zona de transmissão da doença se expandiu para o Sul do país, a região Centro-Oeste e a região Amazônica, quando foram registrados quase 13 milhões de casos de dengue 558 microrregiões do Brasil. A sazonalidade da dengue variou entre as regiões do país, com a alta temporada de transmissão ocorrendo no início do ano em alguns locais, como é o caso da região Norte do Brasil. Além disso, foi reportada alta variabilidade interanual com grandes epidemias ocorrendo, na região Nordeste em 2010, 2013, 2015, 2016 e 2019 (Lowe et al., 2021).

Uma explicação para o aumento da zona de transmissão no Brasil é o aumento da temperatura nessas regiões. Sophie et al. (2021) destacou um aumento no número de meses em que as temperaturas variam de 16,2°C a 24,5°C em áreas do Sul e Sudeste do Brasil. Essas regiões que eram consideradas anteriormente como sendo protegidas contra a transmissão da dengue, por causa das temperaturas relativamente mais baixas.

No Nordeste do Brasil, durante o período de chuva, as temperaturas variam entre 25°C e 35°C, que são condições ideais para a propagação da doença (Lira, 2020). Nesse intervalo de temperatura o mosquito *Aedes aegypti* é mais ativo e eficiente na transmissão da dengue (Gomes, 2018), pois se alimenta com mais frequência, busca hospedeiros humanos e realiza a postura de ovos com maior eficácia. Além, disso, o ciclo de vida do mosquito, que inclui o desenvolvimento do ovo, larva e pupa até a fase adulta, é mais curto. Isso significa que a população de mosquitos pode aumentar rapidamente em áreas onde as temperaturas são mais quentes (Ferreira, 2018).

Enquanto o clima frio pode reduzir a velocidade de replicação e a sobrevivência do mosquito (Hales et al., 2002). Estudar a variação da temperatura e de outros fatores climáticos em relação às condições do mosquito é fundamental para adotar medidas preventivas em regiões com maior propensão à antecipação do mosquito e possíveis epidemias, além de providenciar medidas em áreas menos propensas, levando em consideração a população suscetível.

Estudos sobre a influência climática na saúde humana não se limitam apenas às doenças transmitidas pelo mosquito *Aedes Aegypti*. Segundo Caminade et al. (2013), o clima contribuiu parcialmente para a expansão da endemidade da malária no século XX em regiões da África Ocidental e América do Sul, onde foram observadas mudanças na duração da estação de transmissão da doença. Essas áreas foram identificadas por meio de mapas que mostram mudanças na duração da estação de transmissão da malária (ETM) e locais com uma taxa de acerto superior a 60% foram identificadas. O aumento da ETM foi consistente em regiões como

a África oriental, África do Sul, centro de Angola, Madagascar, América Central, sul do Brasil, leste da Austrália e fronteira entre Índia e Nepal.

Liu-Helmersson et al. (2019) empregaram a modelagem de nicho ecológico como uma abordagem científica para analisar os fatores socioeconômicos e de saúde pública que influenciam a presença ou a ausência do mosquito *Aedes Aegypti*. Observou-se que o ciclo reprodutivo do mosquito está fortemente condicionado por variáveis climáticas, tais como temperatura do ar, umidade relativa do ar e pluviosidade. É importante notar que variações extremas de temperatura, tanto em direção ao calor quanto ao frio, podem resultar na redução ou expansão das populações de mosquitos. Essas constatações são de relevância para a compreensão das dinâmicas de transmissão de doenças transmitidas por mosquitos, como a malária e a dengue.

2. OBJETIVOS

2.1 Objetivo Geral

O objetivo geral deste trabalho é avaliar os efeitos das variações do clima nos casos de dengue na cidade de Campina Grande - PB. Este estudo tem como objetivo fornecer informações valiosas para a formulação de políticas públicas de saúde e ajudar a desenvolver estratégias de prevenção e controle de doenças na região.

2.2 Objetivo Específico

- Associar a variação da incidência de dengue com variáveis climáticas;
- Ajustar um modelo de regressão de séries temporais, considerando os erros independentes ou correlacionados;
- Ajustar um modelo não-linear aditivo generalizado;
- Comparar os modelos ajustados;
- Avaliar o impacto das mudanças climáticas na incidência de dengue, assumindo a tendência geral para as variáveis climáticas em Campina Grande-PB em função dos cenários de RCP4.5 e RCP8.5.

3. FUNDAMENTAÇÃO TEÓRICA

3.1 Mudanças Climáticas

Nos séculos XIX e XX, estudos em geomorfologia e paleontologia revelaram informações sobre o clima passado da Terra, abrangendo períodos de centenas de milhões de anos. Durante a Era Paleozoica, iniciada há cerca de 600 milhões de anos, as evidências mostram variações climáticas mais quentes e mais frias do que as atuais. No Período Terciário, entre 65 e 2,6 milhões de anos atrás, as temperaturas foram predominantemente mais quentes, enquanto no Período Quaternário, desde 2,6 milhões de anos até o presente, se testemunhou oscilações entre condições glaciais e interglaciais (Treut et al., 2007).

Descobertas de mudanças climáticas abruptas, eventos regionais com diversas variações de temperatura ao longo de décadas, foram identificadas pela primeira vez através da análise de núcleos de gelo da Groenlândia em 1984. Essas mudanças abruptas, ocorridas no final da última era glacial, foram associadas a alterações nos padrões de circulação do Oceano Atlântico. No final dos anos 1990, ficou claro que as mudanças climáticas abruptas, especialmente nas regiões do Atlântico Norte, registradas nos núcleos de gelo da Groenlândia, foram excepcionais e de grande magnitude. Esses eventos são conhecidos como eventos Dansgaard-Oeschger (Treut et al., 2007).

Os cientistas Treut et al. (2007) concluíram que, embora vários fatores influenciem o clima, a atividade humana foi a principal força responsável pela maior parte do aquecimento global distribuído nos últimos 50 anos. As mudanças climáticas causadas pelo homem resultam principalmente da alteração dos níveis de gases de efeito estufa na atmosfera, bem como de mudanças nas partículas em suspensão (aerossóis) e do uso da terra. Há mais de um século, Arrhenius (1896) fez uma previsão baseada em gases de efeito estufa, indicando que uma variação de 40% na concentração atmosférica de CO₂ poderia desencadear mudanças significativas no clima, incluindo avanços e retrocessos glaciais. Cerca de cem anos depois, foi confirmado que a concentração de CO₂ variava nessa proporção entre os períodos glaciais e interglaciais (Treut et al., 2007).

Callendar (1938) desenvolveu equações que relacionavam os gases de efeito estufa às mudanças climáticas. Ele descobriu que a duplicação da concentração atmosférica de CO₂ resultaria em um aumento médio de temperatura global de 2°C, com um aquecimento mais pronunciado nas regiões polares (Marengo, 2007). Ele também associou o aumento da queima de combustíveis fósseis ao aumento de CO₂ e aos efeitos estufa. Em 1947, Ahlmann sugeriu

um aquecimento de 1,3°C no Ártico setentrional desde o século XIX e atribuiu essa variação climática ao aquecimento causado pelos gases de efeito estufa.

O 4º Relatório de Avaliação das Mudanças Climáticas Globais (IPCC-AR4) publicado pelo IPCC em 2004 destaca os riscos decorrentes do aumento da concentração de gases de efeito estufa na atmosfera, enfatizando a dificuldade dos países industrializados em reduzir suas emissões e a resistência das nações em desenvolvimento em adotar medidas para estabilizar e diminuir suas emissões.

O relatório também enfatiza que é "muito provável" (com até 90% de probabilidade) que as atividades humanas, em especial a queima de combustíveis fósseis, estejam contribuindo para o aquecimento global desde meados do século XX, aumentando a confiança na ligação entre atividades humanas e mudanças climáticas.

O 5º Relatório de Avaliação do Painel Intergovernamental sobre Mudanças Climáticas, publicado em 2013, representa uma avaliação abrangente e fundamental do conhecimento científico sobre as mudanças climáticas globais. Este relatório se concentra principalmente nos aspectos físicos da mudança climática, sendo um marco crucial para a compreensão das interações que moldam o clima da Terra (IPCC, 2013).

O relatório apresenta evidências sólidas de que o clima global está esquentando e que a concentração de gases de efeito estufa na atmosfera está em ascensão, principalmente devido às atividades humanas, como a queima de combustíveis fósseis e o desmatamento. Esses gases retêm o calor do sol na atmosfera, criando um efeito de estufa ampliado, que é o principal motor do aquecimento global (IPCC, 2013).

Uma das principais conclusões do relatório é a confirmação de que a influência humana é a principal causa do aquecimento global observado nas últimas décadas. As emissões de gases de efeito estufa são apontadas como o fator dominante nesse processo (IPCC, 2013).

O relatório também aborda os impactos atuais e futuros das mudanças climáticas em diferentes regiões do mundo. Isso inclui questões como o aumento do nível do mar, eventos climáticos extremos, mudanças nos ecossistemas, ameaças à segurança alimentar e hídrica, entre outros. Ele alerta para a necessidade urgente de adaptação e de mitigação das mudanças climáticas (IPCC, 2013).

Os planos de emissões futuras, como o RCP4.5 e o RCP8.5 (Vias Representativas de Concentração), são apresentados como ferramentas essenciais para avaliar os possíveis impactos futuros da mudança climática e direcionar a tomada de decisões. O relatório enfatiza a importância de agir para evitar cenários de alto aquecimento, destacando a necessidade de medidas como a transição para energias renováveis e a redução das emissões de carbono (IPCC,

2013). Para o cenário de RCP4.5 foi representada uma trajetória de emissões em que as ações são tomadas para reduzir as emissões de gases de efeito estufa, com uma prevenção do aumento da temperatura média global de aproximadamente 1,1°C a 2,6°C até o final do século em comparação com os níveis pré-industriais, incluindo menor aumento do nível do mar, eventos climáticos extremos menos intensos e menor ameaça à biodiversidade. O cenário RCP4.5 representa um futuro em que a comunidade global toma medidas eficazes para limitar as emissões, enquanto o RCP8.5 representa um cenário em que as emissões continuam aumentando sem controle (IPCC, 2013).

As revisões do 5º Relatório do IPCC destacam a importância de reduzir as emissões e tomar medidas para limitar o aquecimento global, a fim de evitar cenários de alto aquecimento e minimizar os impactos adversos das mudanças climáticas. Esses cenários também desempenharam um papel fundamental na formulação de políticas climáticas, incluindo o Acordo de Paris, que busca limitar o aumento da temperatura global abaixo de 2°C acima dos níveis pré-industriais, com esforços para limitar o aumento a 1,5°C (IPCC, 2013).

Cada uma das RCP foi formulada por um grupo de cenários diferentes de forçantes climáticas, sendo designadas de acordo com as forçante radiativas durante o século XXI. O RCP 3-PD (Pico e Declínio) denota um ápice da forçante radiativa em torno de meados do século, com 3 W/m², seguido de um declínio para 2,6 W/m² até o ano 2100 (também chamado de RCP2.6). O segundo cenário, denominado como RCP 4.5, implica na estabilização da forçante em 4,5 W/m² antes do final do século XXI. O RCP 6.0, por sua vez, projeta uma estabilização em 6 W/m² após o ano 2100. O RCP com maior concentração de Gases de Efeito Estufa (GEE), o RCP 8.5, projeta uma estabilização em 12 W/m² após o fim do século, alcançando uma forçante radiativa de 8,5 W/m² em 2100 (Costa et al., 2015).

Em relação às questões pertinentes aos modelos globais de mudanças climáticas do CMIP5, é relevante destacar a resolução espacial limitada desses modelos, o que resulta na incapacidade de produzir determinados processos físicos, além da incerteza quanto às emissões futuras de gases de efeito estufa. Os RCPs, como explicados anteriormente, desempenham um papel crucial como entradas para os experimentos numéricos de modelagem climática e química atmosférica no contexto do CMIP5

O relatório sobre o Clima do INPE publicado em 2007 oferece cenários das mudanças climáticas no Brasil até o final do século XXI (Marengo et al., 2007). Este relatório descreve cenários regionalizados de clima futuro (2071-2100), estabelecendo três modelos climáticos regionais (Eta-CCS, HadRM3P e RegCM3), com resolução espacial de 50 km de latitude-longitude. Esses modelos foram forçados com o modelo atmosférico global do Hadley Centre

do Reino Unido (HadAM3P), para os cenários de emissão A2 (pessimista-alta emissões) e B2 (otimista-baixas emissões). As projeções de mudanças de temperatura para o Nordeste do Brasil para o período de 2071-2100, em comparação com o período de referência (1961-1990), foram obtidas para os dois cenários climáticos supracitados para a média dos 3 modelos regionais. Segundo este relatório do INPE, no cenário climático pessimista as temperaturas aumentariam de 2 a 4 °C e as chuvas teriam uma redução de 15 a 20% (2-4 mm.dia⁻¹) para o Semiárido do Brasil. No cenário otimista o aquecimento seria entre 1 e 3 °C e a chuva ficaria entre 10 e 15% (1-2 mm.dia⁻¹) menor que no presente a nível anual. (Marengo et al., 2011).

3.1.1 Política Nacional sobre Mudança do Clima

A Política Nacional de Mudança do Clima (PNMC) é um importante marco jurídico brasileiro criado para enfrentar os desafios das mudanças climáticas globais e promover ações de mitigação e adaptação no país. A PNMC foi instituída pela Lei nº 12.187/2009 e posteriormente regulamentada pelo Decreto nº 9.578/2018. A PNMC busca garantir que o desenvolvimento econômico e social do país contribua para a proteção do sistema climático global. Para possibilitar o alcance desses objetivos, o texto da PNMC estabelece algumas diretrizes, como fomento a práticas que efetivamente reduzam emissões de GEE e o estímulo e apoio dos governos – federal, estadual, distrital e municipal – à adoção de atividades e tecnologias de baixas emissões desses gases, além de padrões sustentáveis de produção e consumo. Devem-se considerar, ainda, as diretrizes voltadas para a redução nas incertezas das projeções nacionais e regionais futuras da mudança do clima, identificação das vulnerabilidades e adoção de medidas de adaptação adequadas para reduzir os efeitos adversos da mudança do clima (BRASIL, 2016).

A PNMC é uma lei federal e, portanto, é regida pelas normas e princípios do sistema legal brasileiro, criados pelo Decreto presidencial nº 6.263/2007. Dentre os instrumentos institucionais para a execução da PNMC estão o Plano Nacional sobre Mudança do Clima, o Fundo Nacional sobre Mudança do Clima e a Comunicação do Brasil à Convenção-Quadro das Nações Unidas sobre a Mudança do Clima (UNFCCC), além de medidas que estimulem o desenvolvimento de processos e tecnologias que contribuam para a mitigação e adaptação. A PNMC estabelece ações e medidas para mitigação e adaptação à mudança do clima, com objetivos específicos como fomentar aumentos de eficiência nos setores da economia, manter a participação de energia renovável na matriz elétrica, fomentar o aumento sustentável de biocombustíveis na matriz de transportes, reduzir o desmatamento ilegal e eliminar a perda líquida da área de cobertura florestal no Brasil, além de identificar os impactos ambientais da

mudança do clima e desenvolver pesquisas científicas para minimizar os custos socioeconômicos de adaptação. A formulação dos Planos Setoriais embasou a revisão do Plano Nacional de Mudanças Climáticas e deu início à construção do Plano Nacional de Adaptação à Mudança do Clima (PNA). A Rede Brasileira de Pesquisas sobre Mudanças Climáticas Globais - Rede Clima - e a Comissão de Coordenação das Atividades de Meteorologia, Climatologia e Hidrologia são instrumentos institucionais da PNMCM.

3.1.2 Plano Nacional de Adaptação à Mudança no Clima

Considerando a adaptação como um elemento crucial do esforço global para lidar com a mudança do clima e seus impactos, o Governo Federal instituiu, em 2012, o Grupo Técnico de Adaptação. Em 2013, foram realizados estudos, oficinas de capacitação, definição de setores prioritários e mobilização de atores-chave para a elaboração do PNA, coordenado pelo Ministério do Meio Ambiente (MMA). Ministérios adicionais também contribuíram para a elaboração do PNA, bem como governos estaduais, especialistas, centros de pesquisa, empresas e a sociedade civil.

A Portaria nº 15019 do MMA foi responsável por publicar a versão final do PNA, em 10 de maio de 2016. O PNA apresenta diretrizes e recomendações para onze temas considerados de interesse nacional, em relação à vulnerabilidade às mudanças do clima. Seu objetivo geral é promover a gestão e a redução do risco climático no país, diante dos efeitos negativos associados à mudança do clima. Com isso, busca-se aproveitar as oportunidades emergentes, prevenir perdas e danos e desenvolver instrumentos que permitam a adaptação dos sistemas naturais, humanos, produtivos e de infraestrutura.

A partir de estudos realizados por Revi et al. (2014) e PBMC (2016), foi constatado que as principais ameaças associadas às mudanças climáticas para as áreas urbanas estão no aumento da frequência e intensidade dos eventos extremos. Isso porque, em geral, muitas cidades brasileiras já possuem problemas socioambientais decorrentes de padrões de desenvolvimento e transformação do espaço, o que as tornaram vulneráveis aos impactos das mudanças do clima. Como consequência, a intensificação dos eventos extremos inerentes às mudanças climáticas tende a potencializar os riscos já existentes nas áreas urbanas. Problemas como deficiências no planejamento urbano, infraestrutura e serviços básicos (como saneamento e coleta de resíduos) combinados com o aumento da densidade demográfica podem gerar inundações bruscas, deslizamentos de terra, ondas de calor, impactos na qualidade e distribuição de água, doenças respiratórias e intestinais, além da multiplicação de mosquitos e

outros vetores de doenças tropicais, como malária, dengue, Zica e febre amarela, entre outros (Huq et al., 2007; Revi et al., 2014).

Devido às diferenças entre os níveis de vulnerabilidade das populações urbanas, é necessário que haja uma colaboração interinstitucional e conjunta para criar políticas sociais, estratégias e programas integrados de adaptação que sejam eficazes e de longo alcance em todo o país, conforme indicado pelo Governo Federal em 2016.

3.2 Doenças Arboviroses

3.2.1 Malária

A malária é causada por cinco espécies de parasitas plasmódios que são transmitidos por mosquitos *Anopheles*. A taxa de anos de vida perdidos ajustados por incapacidade (DALY) de malária diminuiu quase 40% globalmente entre 2007 e 2017. A maior carga de doenças ocorre na África, onde ocorrem mais de 90% de todas as mortes relacionadas à malária (M’Bra RK et al., 2018). Entretanto a vacina contra a malária RTS, S/AS01 para a prevenção da malária por *Plasmodium falciparum* em crianças que vivem em regiões com transmissão moderada a alta em combinação com quimio prevenção deve diminuir ainda mais a carga da doença (Bejon et al., 2008). Embora tenha havido surtos locais e recorrentes de malária na Europa, o risco de transmissão generalizada é relativamente baixo (Sudre et al., 2013).

A malária expandiu seu alcance geográfico para altitudes mais altas durante os anos mais quentes nas áreas montanhosas da Colômbia e da Etiópia (Midekisa, 2015). Assim, sem intervenções, é possível que as tendências de declínio no número de DALYs de malária sejam compensadas por mudanças climáticas. As vias de risco em cascata de vários furacões interromperam os programas de controle de vetores antimalária e resultaram no ressurgimento da malária por *P. falciparum* no Haiti, Guatemala e Nicarágua nas décadas de 1980 e 1990 (Paho, 1998). Na região amazônica, a estação seca está ficando mais longa e a estação chuvosa que começava no final de outubro agora começa no início de dezembro; isso exacerba e acelera a queima da floresta tropical. Estresse térmico e incêndios na floresta amazônica juntamente com desmatamento, densidade de estradas e extração seletiva de madeira estão associados ao risco de malária na Amazônia (Hahn, 2014).

3.2.2 Chikungunya

O vírus Chikungunya foi identificado pela primeira vez na Tanzânia em 1952, onde causou um surto localizado na África e partes da Ásia, e depois se espalhou para países ao redor do Oceano Índico. As viagens e o comércio contribuíram para uma disseminação geográfica

contínua para áreas temperadas (Yactayo et al., 2016). O vírus também foi repetidamente importado para a Europa, onde condições climáticas favoráveis contribuíram para dois grandes surtos na Itália em 2007 e 2017 (Rocklöv et al., 2017). As projeções do risco de Chikungunya sob os cenários de RCP4.5 e RCP8.5, indicam uma expansão das áreas propícias para transmissão da doença na China, na África Subsaariana, na América do Sul, nos EUA e na Europa continental. Por outro lado, há contração do risco de transmissão ao longo de partes da costa adriática na Europa como resultado de condições climáticas desfavoráveis, por exemplo (Tjaden et al., 2017).

3.2.3 Zika

O vírus Zika também se expandiu globalmente, causando grandes surtos na América do Sul em 2016, após um período de altas temperaturas recordes e severas condições de seca em 2015. O armazenamento de água potável em recipientes em casa como resultado da seca pode ter criado condições ideais de reprodução e exposição de vetores que contribuíram para o surto. O Zika tem o potencial de se expandir em direção ao latitudes mais elevadas à medida que as temperaturas se aproximam da faixa térmica ótima prevista, estimada em 29°C (Tesla et al., 2018).

3.2.4 Dengue

A dengue é uma enfermidade febril aguda causada por arbovírus pertencentes à família *Flaviviridae*, transmitidos por fêmeas do mosquito *Aedes Aegypti*. A dengue é responsável por cerca de 10.000 mortos e 100 milhões de infectados sintomáticos por ano em mais de 125 países (Stanaway et al., 2016). O vírus da dengue é composto por quatro sorotipos (DENV-1, DENV-2, DENV-3 e DENV-4). A infecção por um sorotipo provoca imunidade de longa duração para o mesmo sorotipo, mas não para os demais. Os quatro sorotipos do vírus da dengue circulam nas Américas, e no Brasil, DENV-1, DENV-2 e DENV-3 estão em circulação simultânea desde 1991 (Lung, 2007).

Em julho de 2010, houve a detecção do sorotipo DENV-4 no Brasil, após um intervalo de 28 anos, ocasionando dez casos na região de Roraima, sendo nove na cidade de Boa Vista. A dengue apresenta uma duração de até sete dias, com resolução espontânea sem sequelas em muitos casos, mas pode evoluir para formas graves. Para identificar casos de dengue em áreas com transmissão conhecida ou presença do mosquito, é definido como caso suspeito de dengue clássico o paciente que apresenta doença febril aguda com duração de no máximo sete dias, acompanhada de pelo menos dois dos seguintes sintomas: cefaleia, dor retroorbital, mialgia,

artralgia ou prostração. Já o caso suspeito de febre hemorrágica da dengue (FHD) é caracterizado por manifestações hemorrágicas além dos sintomas clássicos da dengue (Arcari, 2007).

Durante uma epidemia, a confirmação de um caso de dengue pode ser feita por critério clínico-epidemiológico. A FHD requer não somente confirmação laboratorial, mas também a verificação de determinados critérios (exame específico). Quando nem todos os critérios para encerrar um caso como FHD são atendidos, o caso é classificado como dengue com complicações.

Os países tropicais são os mais atingidos pela dengue, em razão das suas características ambientais, climáticas e sociais. O espaço habitado pelos seres humanos tem uma função fundamental na determinação da circulação dos sorotipos do vírus da dengue e na infecção. No processo de ocupação do espaço urbano, os seres humanos criaram condições favoráveis à ocorrência de muitas doenças (Gomes, 2018).

O artrópode vetor da dengue é infectado pelo vírus durante sua alimentação sanguínea em indivíduos com viremia, que ocorre 24 horas antes do início da febre e permanece por seis a oito dias após o início da doença. Após a infecção do mosquito, o vírus se multiplica e conclui seu ciclo de maturação em um período de 8 a 12 dias, dependendo da temperatura ambiente. Esse é o período extrínseco, após o qual o mosquito torna-se um vetor infectante, capaz de transmitir o vírus da dengue por toda a sua vida através da saliva (Hasan, 2016).

Os criadouros, tanto dentro como fora das casas, são abundantes durante a estação seca e chuvosa. Durante a estação chuvosa, os mosquitos tendem a se proliferar em criadouros criados pela interceptação da água da chuva. Durante a estação seca, as pessoas tendem a armazenar água dentro de casa em regiões secas, o que facilita a proliferação do mosquito *Aedes Aegypti* e a postura de seus ovos (Gomes, 2018).

O *Aedes Aegypti* também é, o principal vetor da Chikungunya, febre amarela e Zika. Ele experimentou uma expansão global, ameaçando quase metade da população mundial (Bhatt et al., 2013). Essa expansão é atribuída em parte ao aumento da temperatura global, mas também ao movimento globalizado da população por meio do tráfego aéreo e da urbanização, além de medidas insuficientes de controle de vetores (Semenza et al., 2014).

3.3 Variáveis Climáticas e os impactos na incidência da Dengue

Existe uma série de estudos que projeta o impacto das mudanças climáticas em doenças sensíveis ao clima. Há um conjunto de evidências que sugere um aumento no alcance geográfico da transmissão do vírus da dengue em um clima futuro. As condições climáticas,

como temperatura do ar, chuva e umidade relativa do ar, têm impacto na multiplicação e desenvolvimento das infecções por dengue (Mutheneni et al., 2017; Thai e Anders 2011; Wu et al., 2016; Costa et al., 2022).

Estudos científicos têm demonstrado que a temperatura ambiente exerce impacto significativo sobre o tamanho populacional, período de maturação, atividade hematofagia da fêmea e a taxa de sobrevivência do vetor da dengue. Com o aumento da temperatura, a população de vetores tende a crescer, e a atividade hematofagia do mosquito aumenta, chegando a dobrar à temperatura de 32°C em relação à temperatura de 24°C. Outro fato relacionado à temperatura é que a taxa de metabolismo do vetor acelera seu ciclo evolutivo, que geralmente dura entre 9 e 12 dias, podendo chegar a 8 dias em meses quentes ou se prolongar por cerca de 22 dias em meses frios. A temperatura também exerce influência no comportamento do vírus dentro do vetor, acelerando a replicação e maturação do vírus no inseto (período extrínseco) conforme a temperatura aumenta (Ferreira, 2018).

Por outro lado, estudos apontam que o vírus não é capaz de se amplificar no vetor em uma temperatura ambiente abaixo ou muito elevada como 6°C ou acima de 42°C, respectivamente. Em geral, em temperaturas muito baixas, o desenvolvimento viral é mais lento e o mosquito não sobrevive o tempo suficiente para se tornar infeccioso e transmitir o vírus. Uma temperatura entre 16 e 29°C seria adequada para o mosquito *Aedes aegypti* se desenvolver (Torres, 1998; Kramer, 2023).

A precipitação pode ser o principal agente climático associado à distribuição e ao aumento na incidência da dengue em regiões tropicais (Arcari, 2007). Entretanto, a relação entre a precipitação e a incidência de casos de dengue pode não seguir uma proporcionalidade, como conhecida entre dengue e temperatura ambiente. O aumento na precipitação pode aumentar o número de locais de reprodução do vetor devido ao acúmulo de água, mas pode também eliminar os criadouros devido a enchentes, resultando em uma redução da população vetorial. Por um outro lado, níveis pluviométricos muito baixos podem levar ao armazenamento de água em recipientes que servem como criadouros. Assim, a associação entre a precipitação e a incidência da doença pode não ser direta, dependendo das características urbanas locais e de abastecimento de água.

Diferentes estudos apontam que a umidade relativa do ar afeta significativamente a sobrevivência do vetor *Aedes Aegypti*, tanto na fase de ovo como na forma adulta (Gomes, 2018). O aumento da umidade pode favorecer a taxa de sobrevivência do mosquito e influenciar hábitos alimentares e de atração entre eles. Em ambientes com baixa umidade, há uma maior propensão das fêmeas do mosquito em buscar a alimentação em humanos, o que pode promover

a transmissão da doença (Lira, 2020). Além disso, estudos indicam que a velocidade do vento pode estar inversamente associada com a incidência da dengue, pois o aumento da velocidade do vento pode levar a uma redução na densidade vetorial. Embora haja especialistas que afirmam que o vento possa contribuir para a dispersão passiva do vetor. Além disso a altitude é considerada um fator limitante na dispersão do vetor, no entanto, já foi relatada a presença do vetor e a ocorrência de epidemias em altitudes acima de mil metros (Siqueira, 2018).

Um estudo realizado em Singapura demonstrou que há uma relação linear entre o aumento da incidência de dengue e o aumento da temperatura, com um atraso de 5 a 16 semanas, e com a precipitação, com um atraso de 5 a 20 semanas (Sousa, 2020). Outro estudo encontrou correlação significativa entre a incidência de dengue e a temperatura máxima (com atraso de 1 a 4 meses), temperatura mínima (com atraso de 1 a 3 meses), umidade relativa (com atraso de 1 a 3 meses) e precipitação (com atraso de 2 meses) (Ferreira, 2018).

Diversas pesquisas estabeleceram a dinâmica entre a ocorrência de casos positivos de dengue e fatores climáticos, como temperatura, umidade e pluviosidade, embora com algum tempo de defasagem. Esses estudos foram cruciais na elaboração de modelos de alerta antecipado capazes de projetar casos de dengue com base em dados meteorológicos (Colón-González et al., 2013; Wang et al., 2014; Struchiner et al., 2015; Li et al., 2017).

Mais recentemente, o impacto de fatores sociais na transmissão do vírus da dengue, como o controle de vetores, qualidade de habitação, renda, entre outros, vem sendo estudados como forma de redução do risco de dengue (Åström, 2012). Por exemplo, já foi demonstrado que parte do aumento da transmissão do vírus pelas mudanças climáticas poderia ser compensado pelas o aumento do produto interno bruto (Banu, 2011).

3.4 Casos Graves de Dengue no Brasil e Mundo

A dengue na sua forma mais grave é a febre hemorrágica viral mais disseminada em regiões tropicais e subtropicais, especialmente nas áreas urbanas, sendo um dos principais problemas de saúde pública em todo o mundo. Segundo a Organização Mundial de Saúde, cerca de 2,5 bilhões de pessoas (ou seja, 2/5 da população mundial) estão sob o risco de contrair dengue. Nos últimos 35 anos, a incidência de dengue e o número de epidemias têm aumentado em todo o mundo. Até a década de 1950, apenas nove países haviam notificado a doença, mas esse número aumentou para 26 nos anos seguintes e, desde a década de 1990, mais de 100 países tiveram casos de dengue notificados. O ano de 2002 foi o de maior número de casos notificados no mundo, com a doença atingindo 69 países. Somente nas Américas, foram notificados 1.015.420 casos de dengue (World Health, 2007).

O *Aedes Aegypti* está amplamente disseminado nas Américas, do Uruguai ao sul dos Estados Unidos, e é responsável por epidemias significativas em países como Cuba, Venezuela, Brasil e Paraguai. O vetor tem papel crucial nas características das epidemias de dengue, no controle vetorial e na variedade de habitats urbanos. Devido ao atual cenário socioepidemiológico, espera-se que a expansão geográfica da dengue continue, como já ocorreu em partes da Argentina, onde a transmissão do vírus foi registrada pela primeira vez em 2009 (Gomez, 2009).

No território brasileiro, houve uma epidemia de dengue no estado de Roraima entre 1981 e 1982, com isolamento dos sorotipos 1 e 4 do vírus. Um inquérito sorológico subsequente revelou que onze mil indivíduos foram infectados pelo vírus da dengue (Santiago, 2022). Após um breve período de baixa atividade epidemiológica, o sorotipo DENV-1 emergiu em 1986 no Estado do Rio de Janeiro, mais precisamente na cidade de Nova Iguaçu, e causou uma epidemia entre 1986 e 1987, com 91.853 casos notificados (Silva, 2020). Desses casos, 75% ocorreram na região metropolitana do Estado, conhecida como Grande Rio. Com a entrada do DENV-1 na região Sudeste, iniciou-se a disseminação do vírus pelo Brasil (Oliveira, 2019).

Entre os anos de 1990 e 1991, houve uma nova ocorrência de epidemia de dengue no Brasil, com a introdução do sorotipo DENV-2, que se espalhou pelo Rio de Janeiro e pela Região Nordeste. Essa epidemia foi caracterizada pelo surgimento dos primeiros casos de febre hemorrágica dengue (Viana, 2020). Em 2000, o sorotipo DENV-3 foi isolado no município de Nova Iguaçu, e em 2001-2002, foi responsável pela maior epidemia de dengue no Estado do Rio de Janeiro, com 368.460 casos notificados. O município do Rio de Janeiro registrou 41% dos casos notificados durante este período (Rodrigues, 2016).

A dispersão viral se deu em todo território nacional, devido à efetiva colonização do mosquito *Aedes Aegypti*. A dengue em suas formas clássicas e graves (síndrome do choque da dengue e febre hemorrágica) está amplamente difundida, com ocorrência em todos os 27 Estados da Federação, alcançando um total de 3.794 municípios, nos quais três sorotipos do vírus circulam simultaneamente em 24 Estados. (Nascimento, 2015).

No século atual, o Brasil alcançou a posição de líder mundial em número total de casos reportados de dengue, com mais de três milhões de casos registrados entre 2000 e 2005 (78% do total de casos nas Américas e 61% dos casos reportados no mundo). Em 2007-2008, ocorreu uma nova epidemia no Rio de Janeiro, devido ao retorno do sorotipo DENV-2, com aumento significativo no número de casos em indivíduos com menos de 15 anos de idade e alta taxa de mortalidade na forma hemorrágica da doença (Oliveira, 2020).

A co-circulação dos quatro sorotipos do vírus dengue no Brasil aumenta o risco de epidemias de febre hemorrágica de dengue, especialmente em grandes cidades que já enfrentaram surtos de dois sorotipos (Neto, 2019). A sobrevivência e reprodução do mosquito *Aedes Aegypti* no ambiente é determinante para a persistência e propagação da doença. Dessa forma, a estratégia mais viável é o combate aos criadouros desse mosquito, visto que ainda não há uma vacina disponível para prevenir a infecção pelo vírus (Nascimento, 2015).

Diante do cenário apresentado, é fundamental enfatizar a necessidade de implementar ações efetivas para a redução dos casos de dengue e a realização de investigações detalhadas dos óbitos. Essas ações são essenciais para subsidiar o monitoramento e a assistência adequada aos casos graves, visando evitar novos óbitos relacionados à doença (Silva et al., 2019). É importante adotar medidas de prevenção, controle do vetor e educação em saúde, em conjunto com uma abordagem integrada e coordenada entre as autoridades de saúde, profissionais de saúde e comunidade (Santos et al., 2019). Ações de promoção da saúde, capacitação dos profissionais de saúde, melhoria do sistema de informação e vigilância epidemiológica são estratégias fundamentais para enfrentar o desafio da dengue e minimizar seu impacto na população (Viana, 2016).

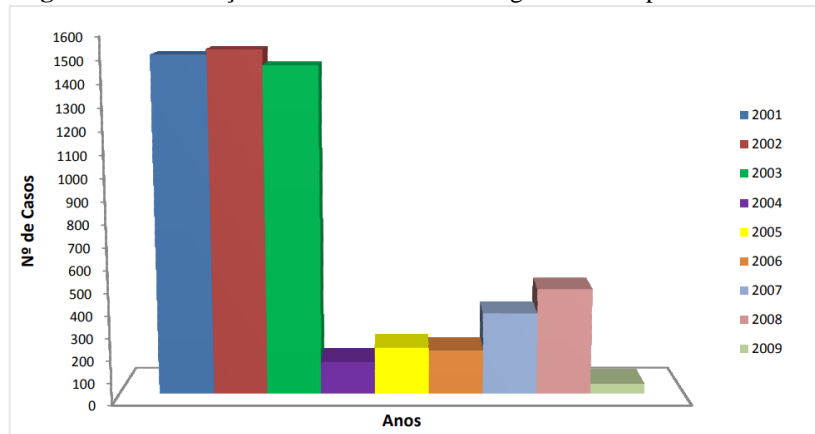
3.5 Casos Dengue na Cidade de Campina Grande-PB

Entre os anos de 1995 e 1997, foram registrados apenas seis casos da doença na Paraíba, distribuídos em diferentes municípios e meses. Em Campina Grande, foi registrado apenas um caso durante esse período, especificamente em novembro de 1996 (Rocco e Borges, 2001). Desde então, houve um aumento significativo no número de casos, com 138 casos registrados na cidade em 1998. Observou-se um maior número de casos nos meses de abril (25 casos) e maio (21 casos), coincidindo com o período de chuvas. Além disso, foram registrados casos isolados em regiões vizinhas nos meses de abril (12 casos), maio (12 casos), junho (15 casos) e julho (16 casos), novamente correspondendo aos meses de aumento nos índices pluviométricos. Essa associação sugere uma possível relação entre o início das chuvas e o aumento no número de casos. No ano de 2000, foram registrados 645 casos, sendo 259 casos notificados na região de Campina Grande, com os maiores índices observados nos meses de março (34 casos), abril (63 casos) e maio (28 casos) (Rocco e Borges, 2001).

O número de casos de dengue notificados pela Secretaria Municipal de Saúde da cidade, e posteriormente encaminhados para a Secretaria Estadual de Saúde, totalizou 5.954 durante o período de janeiro de 2001 a dezembro de 2009. A maioria dos casos foi considerada autóctone,

ou seja, adquiridos localmente. Foi observado que os anos de 2001 a 2003 apresentaram o maior número de casos da doença que pode ser observado na Figura 1.

Figura 1: Distribuição anual dos casos de dengue em Campina Grande-PB.



Fonte: Lima, 2018.


No ano de 2013, a cidade enfrentou uma das maiores epidemia de dengue já documentadas, com um registro de 1205 casos (Figura 2) (Silva, 2020). Esses dados sugerem que Campina Grande está em um contexto em que os índices de infestação do vetor estão em níveis que caracterizam um risco médio a alto, de acordo com os parâmetros de controle estabelecidos pelo Ministério da Saúde. No ano anterior à epidemia, 2012, foi registrado o menor número de casos de dengue na cidade, com apenas 63 casos. Esse ano se destacou no gráfico como o de menor incidência.

Após 2012, os anos que apresentam os menores índices de casos de dengue são 2019, com 149 casos registrados, 2017, com 164 casos, e 2021, com 100 registros (Figura 2). No entanto, é importante mencionar que esses anos são exceções, conforme explicado pelo Ministério da Saúde em seu Boletim Epidemiológico, volume 52, número 3 de janeiro de 2021. Nos últimos três anos do gráfico, há o risco de atraso ou ausência no registro de dados, bem como subnotificação, o que pode levar a uma subestimação dos casos reais. Portanto, é possível que os índices sejam mais elevados do que os apresentados no sistema do Ministério da Saúde nesses anos (Mendonça, 2022).

Os anos de 2014, 2015 e 2016 apresentam uma tendência crescente de casos, com 234, 264 e 379 casos, respectivamente (Figura 2). No ano de 2017, houve uma queda considerável para 164 casos, representando uma redução de quase 50% em relação ao ano anterior. No entanto, em 2018, o país enfrentou outra epidemia da doença, repetindo o padrão observado nos anos de 2012 e 2013, em que o ano anterior apresentou uma redução nos casos e o subsequente registrou um aumento drástico. Embora não tenha atingido o mesmo nível de 2013, o ano de

2018 é relevante por também abrir espaço para casos de Zika e Chikungunya, doenças que também são transmitidas pelo *Aedes Aegypti* (Silva, 2020).

Figura 2: Casos de Dengue em Campina Grande - PB para o período de 2011 a 2021.



Fonte: Ministério da Saúde/SVS - Sistema de Informação de Agravos de Notificação - Sinan Net. Organizado por: Silva, 2022.

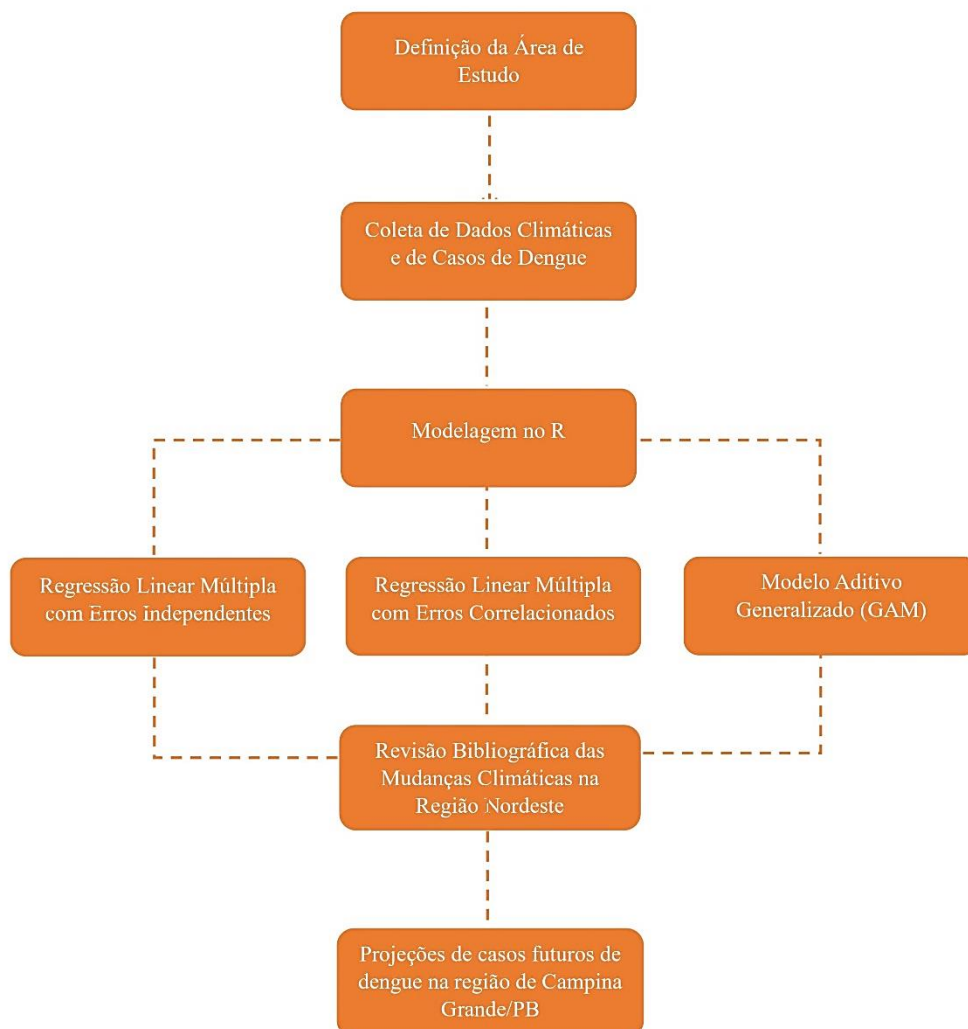
Rodrigues et al. (2018) também retrata que foram notificados um total de mais ou menos 1259 casos de dengue para os anos de 2015 e 2016 no município de Campina Grande. O perfil epidemiológico da doença no município aponta para uma maior incidência de casos em indivíduos na faixa etária de 20 a 39 anos, bem como uma predominância de casos no sexo feminino em 2015, enquanto em 2016 houve uma similaridade na transmissão entre os sexos.

Assim, depois da entrada do vetor biológico em meadas da década de 1990, a incidência da dengue apresentou elevada variabilidade interanual em Campina Grande, com anos de pouco incidência intercaladas com epidemias, que pode estar indicando o efeito dos diferentes sorotipos da dengue na população local e condições sociais e hidroclimáticas locais.

4. METODOLOGIA

A metodologia a ser empregada segue três fases fundamentais (conforme ilustrado na Figura 3). A fase inicial compreende a seleção da área de investigação e a obtenção dos dados referentes às variáveis climáticas e casos de dengue na localidade de Campina Grande, no Estado da Paraíba. A segunda etapa engloba a execução da modelagem estatística no ambiente de programação “R”, as quais consistiram em regressão linear múltipla com erros independentes, regressão linear múltipla com erros correlacionados e modelos aditivos generalizados. Por fim o terceiro e último bloco da metodologia envolve, de forma simplificada, a estimativa da projeção dos casos futuros de dengue na área de estudo.

Figura 3: Fluxograma de atividades realizadas no trabalho.

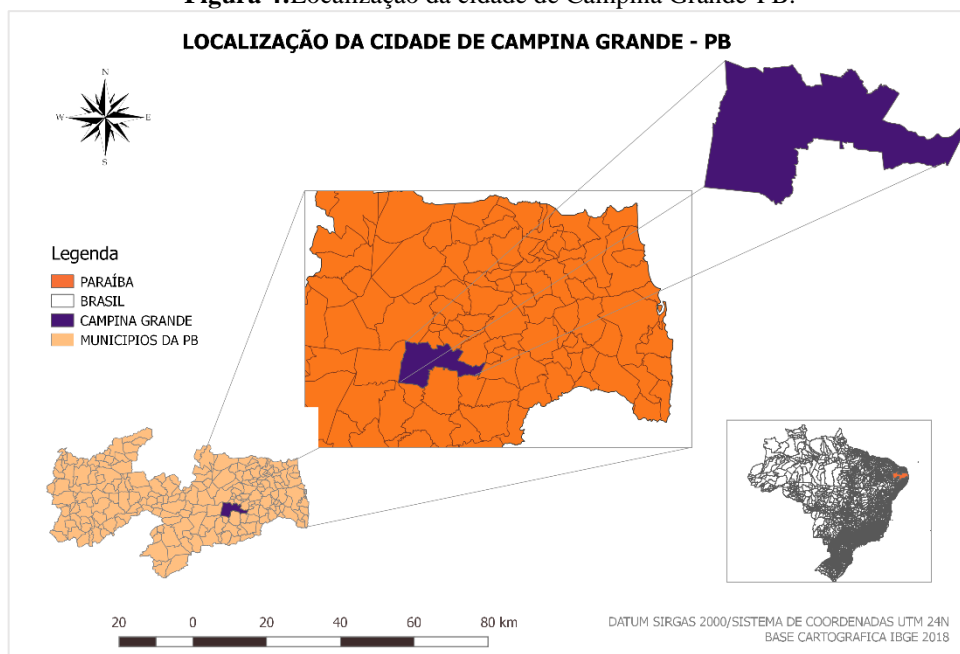


Fonte: Autor, 2023.

4.1 Caracterização da Área de Estudo

O município de Campina Grande, localizada na Zona Centro-Oriental do Estado da Paraíba, no Nordeste do Brasil (Figura 4), ocupa uma posição estratégica na mesorregião do Agreste Paraibano e na microrregião de Campina Grande. Em termos de coordenadas geográficas, Campina Grande está localizado aproximadamente a 7°13'00" de latitude Sul e 35°53' de longitude Oeste (INMET, 2018). A cidade desempenha um papel de centro submetropolitano, exercendo influência política e econômica não apenas nos municípios vizinhos, mas em toda a região (Rodrigues, 2017; Cabral, 2022).

Figura 4:Localização da cidade de Campina Grande-PB.



Fonte: Autor, 2023.

Com uma população de aproximadamente 413.830 habitantes, de acordo com os dados do Instituto Brasileiro de Geografia e Estatística (IBGE) de 2023, Campina Grande se destaca como o segundo maior município em termos populacionais no Estado da Paraíba. A cidade possui uma infraestrutura desenvolvida, abrangendo setores como comércio, serviços, instituições de ensino e uma economia diversificada. A região do Agreste Paraibano, onde Campina Grande está inserida, apresenta uma atividade agrícola relevante, destacando-se na produção de frutas, grãos e aviculturas (Rodrigues, 2017; Cabral, 2022).

Além disso, Campina Grande é reconhecida por sediar periodicamente o evento "Maior São João do Mundo", uma tradicional festa junina que atrai muitos turistas de diversas partes do país. Essa é considerada uma das maiores festas populares do Brasil, com apresentações

musicais, quadrilhas, culinária típica e outras manifestações culturais (Rodrigues, 2017; Cabral, 2022).

O município está inserido no bioma Caatinga, próxima à Serra da Borborema, sendo marcada por colinas e um relevo montanhoso. A caatinga é conhecida por suas condições climáticas semiáridas, com chuvas escassas e irregulares. No caso de Campina Grande, o clima é classificado como semiárido tropical previsto pelo Instituto Nacional de Meteorologia (INMET, 2018). As chuvas na região são concentradas em um período de aproximadamente quatro meses, geralmente entre fevereiro e maio, conhecida como a estação chuvosa. O restante do ano tende a ser seco. A temperatura média anual na área de estudo é em torno de 25°C, (Cabral et al., 2013).

4.2 Período da Coleta de Dados

Neste estudo, foram utilizados dados provenientes do Sistema de Informação de Agravos de Notificação (SINAN), do Ministério da Saúde do Brasil, referentes ao período de 2007 a 2020, que dizem respeito aos casos de dengue registrados no município de Campina Grande. Os dados climatológicos utilizados, incluindo precipitação, temperatura máxima, temperatura média e temperatura mínima, foram adquiridos do site oficial do Instituto Nacional de Meteorologia (INMET), que corresponde à estação meteorológica em funcionamento no município.

4.3 Operacionalização da Coleta de Dados

Os dados referentes aos casos de dengue foram coletados a partir do registro do início dos sintomas (dia/mês/ano) e do município de residência dos pacientes, que são disponíveis no SINAN. Todos os dados foram compilados em um formulário eletrônico no Microsoft Excel 2019, com as seguintes variáveis mensais: número de casos de dengue, precipitação, temperatura máxima, temperatura média e temperatura mínima.

4.4 Análise dos Dados

Para investigar a evolução dos casos mensais de dengue em relação às variáveis climáticas, foram utilizados inicialmente gráficos das series temporais das variáveis envolvidas. Depois, foram realizados os cálculos da correlação linear de Pearson entre os casos de dengue e as variáveis climáticas. A linguagem de programação R foi adotada como ferramenta para a análise dos dados do estudo assim como o MS Excel.

4.4.1 Coeficiente de Correlação Linear de Pearson

O coeficiente de correlação linear, também chamado de coeficiente de Pearson, é uma medida que avalia o grau de dependência linear entre duas variáveis aleatórias (Naghetini e Pinto, 2007). Quando a relação linear entre as variáveis é mais forte, os pontos tendem a ficar mais próximos de uma linha de regressão. Esse coeficiente assume valores entre -1 e 1, podendo ser expresso pela Equação 1

$$\rho_{X,Y} = \frac{\sigma_{x,y}}{\sigma_x \sigma_y} \quad (1)$$

Para calcular o coeficiente de correlação linear, é necessário calcular a covariância entre duas variáveis. A covariância é uma medida estatística que quantifica o grau de interdependência ou inter-relação numérica entre duas variáveis aleatórias, ou seja, o quanto elas se alteram juntas. Pode ser interpretado como o momento de primeira ordem de duas variáveis aleatórias, centrado em suas respectivas médias, expresso pela Equação 2.

$$\sigma_{x,y} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{n-1} \quad (2)$$

onde $\sigma_{x,y}$ é a covariância amostral entre as variáveis X e Y ; \bar{x} e \bar{y} são as médias aritméticas de cada uma das variáveis; n é o tamanho da amostra; x_i e y_i são as observações simultâneas das variáveis. Os desvios-padrão das expressões são calculados pelas Equações 3 e 4.

$$\sigma_x = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1}} \quad (3)$$

$$\sigma_y = \sqrt{\frac{\sum_{i=1}^n (y_i - \bar{y})^2}{n-1}} \quad (4)$$

4.5 Modelos Empíricos

De forma geral, um modelo de previsão empírico é composto por uma equação de recorrência, na qual os valores previstos são obtidos a partir de séries históricas das variáveis envolvidas no processo. Não há preocupação em representar o conhecimento do fenômeno por meio de leis físicas, e os parâmetros são obtidos por meio de ajustes baseados na série histórica das variáveis. Os modelos empíricos podem utilizar dados anteriores e atuais da própria variável e de outras variáveis exógenas para realizar previsão em um determinado período (Amorim, 2022).

As previsões empíricas são fundamentadas em séries temporais quando a variável de interesse apresenta variações ao longo do tempo. O objetivo da previsão de séries temporais é estimar como a sequência de observações irá se comportar no futuro. Em seguida, são

apresentados os modelos empíricos de séries temporais utilizados neste estudo e seus principais elementos.

4.5.1 Regressão Linear

A regressão linear é uma técnica estatística que busca estimar o valor esperado de uma variável Y com base nos valores das variáveis X, assumindo a existência de uma relação funcional entre Y e X. Quando a relação entre a resposta e as variáveis é uma função linear dos parâmetros, a regressão é chamada de linear. No entanto, quando essa relação não é linear, é denominada de regressão não-linear (Naghetini e Pinto, 2007).

Quando há apenas uma variável independente que se relaciona com uma variável dependente, trata-se de um modelo linear simples (Jung e Chang, 2011). Esse modelo fornece um valor médio de uma das variáveis em função da outra, e os pontos observados apresentam uma variação ao redor da linha que representa a função de regressão. A linha de regressão pode ser presumida por meio da Equação 5.

$$Y_i = \alpha + \beta \cdot X_i + e_i \quad (5)$$

Onde Y_i é a variável dependente (ou seja, o valor que se deseja conhecer), X_i é a variável independente (que representa a variável explicativa), α é uma constante que representa o intercepto com o eixo vertical, β é uma constante que representa o coeficiente angular da reta e e_i representam os erros ou resíduos da regressão (Moreno et al., 2010). Os parâmetros são estimados com base nos dados utilizados para realizar a regressão. Os parâmetros α e β dos modelos lineares podem ser estimados utilizando as Equações 6 e 7.

$$\beta = \frac{\sqrt{\frac{\sum_{i=1}^n x_i \cdot y_i - n \cdot \bar{y} \cdot \bar{x}}{\sum_{i=1}^n x_i^2 - n \cdot \bar{x}^2}}}{\sqrt{\sum_{i=1}^n x_i^2 - n \cdot \bar{x}^2}} \quad (6)$$

$$\alpha = \bar{y} - \beta \cdot \bar{x} \quad (7)$$

A regressão linear múltipla (RLM) é usada para estudar o comportamento de uma variável dependente em função de duas ou mais variáveis independentes. Se a variável apresentar um comportamento linear em relação às variáveis, é possível adotar um modelo geral aplicando a Equação 8 (Torres et al., 2011).

$$Y_i = \alpha + \beta_1 \cdot X_{1,i} + \beta_2 \cdot X_{2,i} + \dots + \beta_n \cdot X_{n,i} + e_i \quad (8)$$

Os modelos de regressão linear são ferramentas importantes utilizadas em diferentes tarefas como projetar variáveis hidrológicas em longo prazo (Moreno et al., 2010), analisar os

efeitos das mudanças climáticas nas concentrações de nitrato em grandes rios (Zweimuller et al., 2008), identificar relações entre chuva e vazão sazonais (Torres et al., 2011) e avaliar a tendência de escoamento futuro sob diferentes cenários de mudanças climáticas (Jung e Chang, 2011), por exemplo.

4.5.2 Modelo Aditivo Generalizado

Os Modelos Aditivos Generalizados (Generalized Additive Models - GAM), introduzidos por Hastie e Tibshirani (1990), são uma extensão dos modelos lineares generalizados. O GAM possui um preditor linear que inclui a soma de funções de suavização não paramétricas das covariáveis. Isso permite que os próprios dados guiem a relação entre as covariáveis e o preditor, que frequentemente ocorre de forma não linear. O GAM é expresso por meio da Equação 9:

$$\eta = g(\mu_i) = X_i^* \theta + f_1(x_{1i}) + f_2(x_{2i}) + f_3(x_{3i}) + \dots \quad (9)$$

Onde $\mu_i \equiv E(Y_i)$ sendo que $Y_i \sim$ alguma distribuição da família exponencial. Y_i é a variável resposta, X_i^* é uma coluna da matriz do modelo para os componentes paramétricos, θ é o vetor de parâmetros, e f_j são funções suaves das covariáveis x_k (Rigby et al., 2017).

As funções de suavização mais comumente utilizadas, são p-splines, splines cúbicas, loess e redes neurais. As *splines* são curvas definidas matematicamente por meio de dois ou mais pontos de controle, e é dessa maneira que os dados estabelecem a relação entre $\eta = g(\mu_i)$ e as variáveis explicativas, sendo esse o conceito fundamental para empregar uma função de suavização (Eilers, 2015).

A complexidade dos modelos semiparamétricos com o GAM reside no fato de não serem facilmente descritos em uma forma matemática explícita. No entanto, eles podem ser visualmente representados de forma gráfica, fornecendo informações valiosas sobre a adequação do ajuste e dos resíduos.

4.5.3 Resíduos

Os resíduos em um modelo são obtidos subtraindo-se os valores observados dos valores ajustados. Espera-se que esses resíduos sejam independentes e identicamente distribuídos, embora o GAM também permita lidar adequadamente com resíduos assimétricos. Uma forma simples e rápida de verificar essa condição é analisar o gráfico de dispersão dos resíduos em relação à variável prevista. Se for observado um padrão não aleatório dos resíduos de um

modelo linear, isso pode indicar uma relação não linear nos dados, sugerindo que um modelo linear pode não ser adequado para fazer previsões com esses dados (Hyndman e Athanasopoulos, 2013). Outra forma é calcular a função de autocorrelação e a função de autocorrelação parcial. Caso a correlação serial seja relevante, processos ARMA poderão ser ajustados aos resíduos. Os resíduos também são úteis para identificar viés, caso a média dos resíduos seja diferente de zero (Chang, 2011).

4.5.4 Colinearidade e multicolinearidade

Embora os termos “colinearidade” e “multicolinearidade” sejam frequentemente usados como sinônimos, alguns autores fazem uma distinção entre eles. A colinearidade refere-se à existência de uma relação linear entre duas variáveis explicativas, enquanto a multicolinearidade refere-se à existência de uma relação linear entre uma variável explicativa e as demais variáveis (Sem, 2022). Algumas características que podem indicar problemas de colinearidade ou multicolinearidade como:

- β_i com sinal oposto ao esperado;
- Mudanças muito proeminentes em β_i , quando realiza-se adições ou exclusões de variáveis ou observações.
- β_i não apresentando significância estatística para variável X_i teoricamente importante.

4.5.5 Teste de significância da regressão linear múltipla

Na regressão linear simples, o teste F é usado para avaliar a significância global do modelo, ou seja, se a variável independente é estatisticamente significativa na explicação da variável dependente (Biasi et al., 2017). Nesse caso, o teste F compara a variação explicada pelo modelo com a variação não explicada (Maciel, 2019).

Na regressão linear múltipla, o teste F é utilizado para avaliar a significância conjunta de um conjunto de variáveis independentes (Castor, 2020). O teste F compara a variação explicada pelo modelo completo (com todas as variáveis independentes) com a variação não explicada, e é usado para determinar se o conjunto de variáveis independentes, como um todo, tem um efeito significativo na variável dependente (Sell, 2005).

A estatística F convencional, proposta por Snedecor, é utilizada para testar a conversão estatística de um conjunto de parâmetros em um modelo de regressão linear múltipla, quando o modelo é ajustado aos dados por meio dos mínimos quadrados (Sell, 2005).

Define-se o seguinte teste de hipóteses:

$$H_0: \beta_0 = \beta_1 = \beta_2 \dots = \beta_k = 0 \quad (10)$$

As hipóteses a testar assumem o seguinte aspecto:

$$H_0: \beta = 0 \quad H_1: \beta \neq 0 \quad (11)$$

A variabilidade total dos valores da variável dependente Y, representada pela soma dos quadrados dos desvios de Y em relação à sua média Y (SQT), pode ser decomposta em dois componentes aditivos: uma explicada pelo modelo de regressão (SQR) e outra atribuída aos resíduos (SQE) (Oliveira, 2020).

Dessa forma, levando em consideração as quantidades;

Notação matricial

$$SQE = \sum_{i=1}^n (y_1 - \hat{y}_i)^2 \quad SQE = (y - X\hat{\beta})^T \cdot (y - X\hat{\beta}) = e^T e \quad (12)$$

$$SQR = \sum_{i=1}^n (\hat{y}_1 - \bar{y}_i)^2 \quad SQR = (X\hat{\beta} - \bar{y})^T \cdot (X\hat{\beta} - \bar{y}), \quad (13)$$

$$SQT = \sum_{i=1}^n (y_1 - \bar{y}_i)^2 \quad SQT = (y - \bar{y})^T \cdot (y - \bar{y}), \quad (14)$$

estabelece-se a seguinte relação:

$$SQT = SQR + SQE, \text{ ou seja,}$$

$$\sum_{i=1}^n (y_1 - \hat{y}_i)^2 = \sum_{i=1}^n (\hat{y}_1 - \bar{y}_i)^2 + \sum_{i=1}^n (y_1 - \hat{y}_i)^2 \quad (15)$$

A proporção da variância total em Y explicada pelo modelo de regressão e a proporção atribuída aos resíduos podem ser adquiridas dividindo-se os valores de SQR e SQE pelos seus graus de liberdade, respectivamente (Castor, 2020). Esses resíduos são conhecidos como quadrados médios da regressão (QMR) e quadrados médios dos resíduos (QME), respectivamente.

Portanto, temos que:

$$QMR = \frac{SQR}{K} \quad (16)$$

Para avaliar a evolução do modelo de regressão aos dados populacionais, é comum comparar a proporção da variância explicada pelo modelo de regressão com a proporção da

variância atribuída aos resíduos (Villa, 2016). Se a primeira proporção for significativamente maior do que a segunda, pode-se concluir que o modelo é estatisticamente significativo. Essa comparação é feita utilizando a distribuição estatística da razão entre essas duas variâncias (Américo, 2017).

Considerando a independência e a homocedasticidade dos erros aleatórios, e sob a hipótese nula inicial, pode-se afirmar que:

$$\frac{SQR}{K} \sim \sigma^2 X^2_k \quad \text{e} \quad \frac{SQE}{K} \sim \sigma^2 X^2_{n-k-1} \quad (17)$$

Devido à independência entre as duas quantidades, a estatística de teste, que corresponde à razão entre as duas quantidades anteriores, segue uma distribuição F com k e n-k-1 graus de liberdade, ou seja,

$$F = \frac{SQR/K}{SQE/(n-k-1)} \sim F_{n-k-1} \quad (18)$$

A estatística de teste F, sob a hipótese nula H_0 , segue uma distribuição F_{n-k-1} . A um nível de significância α , rejeita-se H_0 se $F > F^{-1}_{n-k-1}(1 - \alpha)$ (Villa, 2016).

Sob a veracidade da hipótese alternativo $H_1: \beta_1 \neq 0$, a estatística de teste F segue uma distribuição com k e $n - k - 1$ em graus de liberdade e parâmetros de não centralidade dado por:

$$\delta = \frac{\beta^T X^T X \beta}{\alpha^2} \quad (19)$$

A aplicação do teste F ao modelo completo de regressão linear permite tomar uma decisão em relação ao conjunto de todos os parâmetros presentes no modelo (Sell, 2005). Assim, ao rejeitar a hipótese nula, indica-se que pelo menos um dos parâmetros β_j é significativamente diferente de zero, embora isso não implique que todos os parâmetros o sejam (Oliveira, 2020).

Para verificar a significância de um subconjunto de parâmetros no modelo de regressão linear, é necessário analisar um submodelo do modelo de regressão linear múltiplo, no qual os preditores correspondentes a esses parâmetros são excluídos (Maciel, 2019). O objetivo desse procedimento é determinar se as variáveis que foram removidas do modelo reduzido são ou não significativas para o ajuste global (Biasi, et al., 2017).

4.6 Métricas de Avaliação do Ajuste do Modelo

A seguir, são apresentadas as principais métricas utilizadas para avaliar o desempenho dos modelos empíricos aplicados nesta pesquisa.

4.6.1 Coeficiente de determinação

Dentre as métricas empregadas nesta pesquisa, a primeira a ser calculada foi o coeficiente de determinação (R^2). Uma maneira eficiente de quantificar a relação entre duas variáveis aleatórias é por meio do coeficiente de correlação (Team, 2016). O coeficiente de determinação, por sua vez, corresponde ao quadrado dessa correlação, representando a proporção da variabilidade nas observações que pode ser explicada pelos valores previstos pelo modelo.

Explicado como:

$$R^2 = \text{corr}^2\{y_i, \hat{\mu}\} \quad (20)$$

ou simplesmente

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{\mu}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}, \quad (21)$$

onde y_i são observações independentes e μ_i os correspondentes valores calculados pelo modelo

Em modelos multivariados, pode-se afirmar que o coeficiente de determinação é uma medida que indica a proporção da variabilidade total dos dados (soma dos quadrados dos desvios de cada valor observado y em relação à média de y) que pode ser explicada pelas covariáveis x_1, \dots, x_n , incluídas no modelo empírico (Team, 2016). Um valor de R^2 próximo de 1 indica um aumento na capacidade de previsão do modelo, mesmo levando em conta a possível perda de graus de liberdade e a perda de informação (Trevor, 2008).

4.6.2 Coeficiente de determinação ajustado

Essa medida ajusta o coeficiente de determinação de acordo com o aumento do número de variáveis explicativas, (Malaquias, 2014).

Matematicamente ao adicionar uma variável explicativa ao modelo, aumenta-se a dimensão do espaço no qual ocorre a estimação (Malaquias, 2014). Assim, a estimação no

espaço de dimensão $p+1$ é uma minimização restrita no espaço de dimensão p , e sabe-se por cálculo que os mínimos restritos são maiores do que os mínimos absolutos. Portanto, o coeficiente de determinação obtido no modelo de ordem p é ligeiramente menor do que obtido no modelo de ordem $p+1$ (León, 2011).

Essa propriedade nos indica que, ao adicionar um número infinito de covariáveis ao modelo, mesmo que não sejam relevantes para o problema em questão, é possível melhorar artificialmente o coeficiente de determinação. Por essa razão, é recomendado o uso do o coeficiente de determinação ajustado (León, 2011):

$$R^2_{adj} = 1 - (1 - R^2) \frac{n-1}{n-p-1} \quad (22)$$

Onde R^2_{adj} é o R ao quadrado ajustado ou coeficiente de determinação ajustado, R^2 é o R ao quadrado ou coeficiente de determinação, n é o número de observações na amostra e p número de variáveis independentes.

4.6.3 Raiz do erro quadrático médio

Em seguida, calculou-se a métrica conhecida como a raiz do erro médio ou do inglês Root Mean Squared Error (RMSE) (Equação 23) (Trevor, 2008). Quando o RMSE é dividido pelo desvio-padrão da variável dependente, temos então um valor padronizado de RMSE ou SRMSE. Quanto mais próximo SRMSE de zero, melhor será o ajuste do modelo. Se SRMSE for maior que um, significa que o modelo não é melhor que o valor esperado como preditor da variável dependente.

$$RMSE = \left(\frac{1}{n} \sum_{i=1}^n (y_i - p_i)^2 \right)^{\frac{1}{2}} \quad (23)$$

Onde n é o número de amostras, y_i é o valor observado para a amostra i e p_i é o valor previsto pelo modelo para a amostra i

4.7 Modelagem linear dos Casos de Dengue em Função de Séries Temporais

Primeiramente, foram conduzidas análises de regressão de séries temporais mensais utilizando Modelos Lineares Generalizados (MLG). Esses modelos incorporam variáveis como precipitação (P), temperatura mínima do ar (Tmin) e temperatura máxima do ar (Tmax) para explicar a variação da incidência de dengue (ID), bem como componentes autorregressivas (AR) e de média móvel (MA) para o erro ou resíduo correlacionado. Depois, foram aplicadas as métricas de desempenho dos modelos ajustados (ver acima)

No modelo de regressão de séries temporais, em que o logaritmo de ID (Y_t) é a variável alvo e as variáveis hidroclimáticas (x_{t1}, \dots, x_{tp}), como precipitação (desfasada) (mm) e

temperatura do ar (mínima, média e máxima), são as variáveis explicativas para o município como mostra a Equação (24).

$$Y_t = \beta_0 + \beta_1 x_{t1} + \dots + \beta_n x_{tn} + E \quad (24)$$

Usando o algoritmo dos mínimos quadrados ordinários (OLS), os parâmetros $(\beta_0, \beta_1, \dots, \beta_n)$, podem ser estimados assumindo o termo de erro “E” com média zero, variância constante e sem correlação. No entanto, se os erros estiverem correlacionados, existem melhores estimadores para os parâmetros da regressão linear múltipla (MLR) acima, como a abordagem de mínimos quadrados generalizados (GLS).

Portanto, primeiro ajusta-se o MLR pelo OLS, assumindo que os erros não são correlacionados. Em seguida, aplicam-se as funções de autocorrelação e autocorrelação parcial para avaliar se há correlação serial nos erros. Se os erros forem correlacionados, aplica-se o GLS para ajustar o MLR e um modelo autorregressivo de média móvel (ARMA) para os erros correlacionados.

No caso da aplicação do método dos mínimos quadrados generalizados, utiliza-se o critério de informação conhecido como AIC (*Akaike Information Criterion*) para selecionar o modelo ARMA que apresenta a melhor qualidade e simplicidade. Nesse sentido, busca-se encontrar o modelo ARMA mais simples que se ajuste adequadamente à correlação serial nos erros.

Ele combina componentes autorregressivos (AR) e de média móvel (MA). Começa-se com um modelo autorregressivo de primeira ordem AR (1), um modelo de média móvel de primeira ordem MA (1) e um modelo de média móvel autorregressivo de primeira ordem ARMA (1,1). Em seguida, aumenta-se a complexidade do modelo, por exemplo, ARMA (3,1), avaliando o AIC dos modelos. O modelo com menor AIC será escolhido. Por último, utilizando os preditores selecionados da modelagem linear generalizada, aplica-se o modelo aditivo generalizado.

4.8 Projeções da Incidência de Dengue a Partir das Mudanças Climáticas na Região Nordeste

Primeiramente, foi realizado uma revisão de literatura sobre a modelagem das mudanças climáticas na região Nordeste do Brasil. Neste contexto, foram analisadas projeções futuras referentes às variações na temperatura do ar, cobrindo o período que se estende até o final do século XXI. Durante essa revisão, foram levantados resultados de diversos modelos aplicados

para a região Nordeste, a exemplo do CanESM2, RAMS6.0, RAMS-CAM e CMIP5, conforme discutido por vários autores (Marengo et al., 2011; Silveira et al., 2013; Costa et al., 2015; Guimarães, 2015; Silveira et al., 2015) (ver detalhes no Anexo II).

Nesse contexto, verificou-se que os resultados mais consistentes emergiram do emprego do modelo CMIP5 em combinação com os cenários de emissões RCP4.5 e RCP8.5. Os autores sustentam que tais cenários se mostram mais congruentes com as projeções da realidade em relação às futuras mudanças climáticas. Portanto, optou-se por adotar as projeções dos modelos correspondentes aos cenários RCP4.5 e RCP8.5 para o presente estudo.

Ao final da investigação acerca da projeção das mudanças climáticas na região Nordeste, procedeu-se uma projeção relativa aos futuros casos de dengue em Campina Grande, assumindo a) a projeção climática dos cenários RCP4.5 e RCP8.5 e b) uma regressão linear simplificada entre casos de dengue e clima presente (representada pela temperatura máxima):

$$\ln D = I + \alpha T_{\text{máx}} \quad (25)$$

Onde $\ln D$ é logaritmo da dengue, I e α são constantes ajustadas da regressão linear.

Depois, foi realizada a diminuição entre o logaritmo da incidência de dengue observada no presente e o logaritmo da incidência de dengue nos cenários de projeção (valores médios) é uma aproximação da mudança da média projetada no cenário de mudança climática (DCen.) em relação à média observada no período de referência (DOBS):

$$\begin{aligned} \overline{\ln D}_{Cen.} - \overline{\ln D}_{OBS.} &\cong \frac{D_{Cen.} - D_{OBS.}}{D_{OBS.}} \\ I + \alpha \bar{T}_{\text{máx}}_{Cen.} - I - \alpha \bar{T}_{\text{máx}}_{OBS.} & \quad (26) \\ \alpha (\bar{T}_{\text{máx}}_{Cen.} - \bar{T}_{\text{máx}}_{OBS.}) & \end{aligned}$$

5. RESULTADOS E DISCUSSÃO

5.1 Correlação entre as Variáveis

Realizou-se uma análise de correlação com o intuito de determinar o intervalo de tempo mais apropriado que uma variável climática explica linearmente a variável alvo que é o número de casos de dengue. As variáveis preditoras escolhidas, considerando um possível tempo de atraso para o pico da proliferação do mosquito da dengue (de 0 a três meses), foram aquelas que o coeficiente de correlação apresentou o maior valor absoluto com a ocorrência de dengue. As mesmas variáveis utilizadas foram precipitação, temperatura mínima, média e máxima.

Na Tabela 1, são apresentados os resultados da análise de correlação entre as variáveis. Observou-se que a correlação mais significativa entre a dengue e a precipitação ocorreu com um atraso de um mês. A correlação entre dengue e precipitação foi positiva. Esse resultado está em conformidade com o fato de que a proliferação do mosquito da dengue geralmente começa aproximadamente um mês após o início das chuvas. Por outro lado, a correlação mais significativa entre a dengue e as temperaturas máxima ocorreu no mês atual. A correlação entre dengue e temperaturas máxima e média foi negativa. Por último, a correlação mais significativa entre a dengue e a temperatura mínima foi com três meses de atraso. A correlação entre dengue e temperatura mínima foi positiva.

Esses resultados em relação à temperatura estão em conformidade com o que já foi documentado na literatura, em que temperaturas muito elevadas (máxima e média) são prejudiciais ao desenvolvimento do mosquito (Torres, 1998; Kramer, 2023). Por um outro lado, a correlação positiva entre dengue e temperatura mínima pode estar indicado que as temperaturas mais frias não estão limitando o desenvolvimento do mosquito como documentado em outros estudos (Hales et al., 2002).

Tabela 1: Coeficiente de correlação para variáveis do estudo.


Tempo de atraso (mês)	Precipitação	Temperatura Máxima	Temperatura Média	Temperatura Mínima
0	0,22	-0,39	-0,29	-0,21
1	0,31	-0,26	-0,12	-0,02
2	0,26	-0,07	0,07	0,17
3	0,13	0,15	0,25	0,31

Fonte: Autor, 2023.

Em Campina Grande observou-se o maior número de casos de dengue nos anos de 2014 e 2018, registrando aproximadamente duzentos casos (Figura 5). No que se refere aos dados de precipitação, notou-se que o período de maior precipitação ocorreu entre 2008 e o início de 2012. Entretanto, esses picos não coincidem com o período de maior incidência de casos de dengue, indicando que precipitação muito elevada também pode ser prejudicial ao desenvolvimento do mosquito, como demonstrado em outros estudos (Arcari, 2007). Essa discrepância pode ser atribuída às variações significativas nos padrões de chuva na região nordeste, bem como aos anos de seca que afetaram a Paraíba depois de 2012.

No tocante às temperaturas máximas, os anos de 2010 e 2020 se destacaram como os anos com as temperaturas mais elevadas. Nesses anos, as temperaturas ultrapassaram os 35°C, que é um limite de temperatura que pode desfavorecer a proliferação do mosquito transmissor (Kramer, 2023; Torres, 1998). Isso ocorre porque em temperaturas muito elevadas, o mosquito não sobrevive, enquanto em temperaturas moderadas, tanto a máxima 32°C, quanto a média de 22°C, as condições tornam-se mais propícias para o aumento da população do mosquito, juntamente com um aumento na incidência de picadas, visto que a temperatura também influencia esse comportamento do mosquito. Esses padrões climáticos coincidiram com os anos de 2014 e 2018, em que as temperaturas variaram entre 22 e 30°C (Figura 5).

Figura 5: Series temporais mensais dos casos de Dengue, precipitação (P) (mm), temperatura média (Tmed) (°C) e temperatura máxima (Tmax) (°C).



Fonte: Autor, 2023.


5.2 Regressão Linear

Escolhidas as variáveis preditoras potenciais (ver seção anterior), foi ajustado um modelo de regressão linear múltipla. Entretanto, apenas a temperatura máxima no mês atual (variável dependente) e o coeficiente de interseção foram estatisticamente significativos. Vale notar que o algoritmo de ajuste adotado no R evita a multicolinearidade na modelagem. Além disso, o ajuste foi melhor para o logaritmo dos casos de dengue, pois essa transformação uniformizou a variância da série temporal dos casos de dengue (ver Figura 5). Todos os passos desta e demais modelagens no R podem ser encontrados no Anexo I.

Os erros do modelo ajustado apresentaram uma distribuição próxima da distribuição normal (ver QQ-plot na Figura 6), mas pode-se observar que esses resíduos exibem uma maior dispersão em suas extremidades, o que pode gerar incertezas na predição com o modelo ajustado. Estudando a estrutura de correlação dos erros, foi encontrado que essa correlação foi relevante, como demonstrado na função de autocorrelação (Figura 7) e na função de autocorrelação parcial (Figura 8). Assim, foi ajustado também um modelo ARMA para a série de erros.


Depois de uma série de tentativas de ajuste de um processo ARMA à série de erros, um simples modelo autorregressivo de primeira ordem [AR(1)] foi o que apresentou o menor índice de AIC (=164,5). Em resumo, o melhor modelo de regressão linear da dengue em função da variabilidade climática em Campina Grande é um modelo que possui como variável dependente a temperatura máxima e uma distribuição de erros seguindo um modelo autorregressivo de primeira ordem. O seu SRMSE foi de 0,90, o que significa que o modelo é 10% melhor que o valor esperado da variável dependente (logaritmo dos casos de dengue) como preditor.

Figura 6: QQ - plot dos erros do modelo linear ajustado.




Fonte: Autor, 2023.

Figura 7: Função de autocorrelação dos erros do modelo linear ajustado.



Fonte: Autor, 2023.

Figura 8: Função de autocorrelação parcial dos erros do modelo linear ajustado.



Fonte: Autor, 2023.

5.3 Modelo Aditivo Generalizado

Ajustando um modelo aditivo generalizado para as mesmas variáveis do modelo de regressão linear anterior, não foi encontrado uma melhoria no ajuste com o SRMSE ainda igual à 0,90 (Tabela 2). Entretanto, considerando uma possível associação não-linear relevante entre as variáveis climáticas candidatas à preditores e a variável alvo (logaritmo dos casos de dengue), a precipitação com um mês de atraso se demonstrou significativa. Além disso, houve uma melhoria significativa da modelagem, com o SRMSE igual à 0,85 (Tabela 2). Assim, os

resultados confirmam o que foi encontrado em outros, a temperatura do ar possui uma associação diretamente proporcional com a proliferação do mosquito da dengue, enquanto a precipitação não possui uma associação linear (Arcari, 2007; Colón-González et al., 2013; Wang et al., 2014; Struchiner et al., 2015; Li et al., 2017).

Tabela 2: Cálculos das métricas de avaliação do ajuste do modelo aditivo generalizado.

Intercept	R ²	R ² - Ajustado	F-Statistic	SRMSE	Preditores
					Tmax(t)
3,54	0,21	0,20	12,76	0,90	
1,01	0,27	0,30	12,76	0,85	P (t-1), Tmax(t)

Fonte: Autor, 2023.

5.4 Estimativa da Mudanças da Incidência de Dengue para o Final deste Século

Na Tabela 3, são apresentadas medidas estatísticas das variáveis preditoras utilizadas nos modelos ajustados. A média da temperatura máxima foi de aproximadamente 29°C pra o período de referência.

Tabela 3: Cálculo das médias e desvio-padrão. das variáveis preditoras: precipitação (P) (mm), temperatura média (Tmed) (°C) e temperatura máxima (Tmax) (°C).

Dados	P	T.max.	T.méd.
Média	61,41	29,06	21,78
Desvio Padrão	65,02	1,99	6,16

Fonte: Autor, 2023.

Além disso, a constante da Equação (26) foi igual à -0,272. Aplicando a Equação (26) e considerando os dados observados e os dados dos cenários RCP4.5 e RCP8.5, com incrementos de temperatura do ar previstos de 1,8°C e 4,1°C, respectivamente, para a Região Nordeste, foram calculadas as estimativas da incidência de Dengue para o final deste Século. Resumindo:

1) Cenário *RCP4.5*:

$$\Delta \bar{T}_{\text{máx}} = 1,8^{\circ}\text{C}$$

$$-0,272 * 1,8 = - 0,4896$$

$$- 0,4896 * 100 = - 48,96\%$$

$$- 0,4896 * 100 \cong - 50\%$$

2) Cenário *RCP8.5*:

$$\Delta \bar{T}_{\text{máx}} = 4,1^{\circ}\text{C}$$

$$-0,272 * 4,1 = - 1,1152$$

$$- 1,1152 * 100 \cong 100\%$$

Assim, estimou-se uma projeção da redução de aproximadamente 50% nos casos de dengue em Campina Grande para o primeiro cenário, *RCP4.5*, que prevê um aumento de temperatura de $1,8^{\circ}\text{C}$. Já para o segundo cenário, *RCP8.5*, que prevê um aumento de temperatura de $4,1^{\circ}\text{C}$, estimou-se uma redução de aproximadamente 100% nos casos de dengue na região (Tabela 4).

Tabela 4: Projeção dos casos de dengue em Campina Grande-PB.

Cenário	$\Delta \bar{T}_{\text{máx}}$	Projeções	%	$\cong\%$
<i>RCP4.5</i>	$1,8^{\circ}\text{C}$	-0,4896	49	50
<i>RCP8.5</i>	$4,1^{\circ}\text{C}$	-1,1152	112	100

Fonte: Autor, 2023.

Essas estimativas refletem a possível influência das mudanças climáticas na redução da incidência de dengue na região de Campina Grande-PB, considerando diferentes cenários de aumento de temperatura futura. Diante do aumento previsto da temperatura na Região Nordeste, na ordem de $1,8^{\circ}\text{C}$, é plausível inferir uma redução de aproximadamente 50% no número de casos de dengue, devido a uma provável redução na taxa de proliferação do mosquito ocasionadas pelas altas temperaturas. Quando confrontados com um cenário de aumento de temperatura mais acentuado de $4,1^{\circ}\text{C}$, verifica-se uma diminuição aproximada de 100% nos

casos de dengue, sugerindo uma inibição completa da propagação dessa doença. É pertinente ressaltar que os resultados, mesmo gerados por uma metodologia simplificada, demonstram coerência com os achados de estudos anteriores abordados neste trabalho, fortalecendo a presente estimativa do impacto das mudanças climáticas na incidência de dengue.

6. CONCLUSÃO

Embora os resultados tenham fornecido informações valiosas, é importante reconhecer que o modelo utilizado apresenta limitações, principalmente relacionadas à suposição de linearidade nas relações entre as variáveis preditoras e a incidência de dengue em cenários futuros do clima. Além disso, não foi considerada uma possível variação local do clima no município estudado em relação à tendência geral na Região Nordeste. Essa generalização pode não capturar nuances climáticas locais que são relevantes para a proliferação do mosquito e a incidência de dengue em nível municipal.

Em relação à suposição de que as variáveis climáticas, como temperatura máxima do ar e precipitação, tenham um efeito linear sobre a proliferação do mosquito *Aedes aegypti* e, consequentemente, sobre a incidência de dengue, na realidade, essas relações podem ser não lineares e complexas. Por exemplo, é possível que exista uma faixa de temperaturas ideais para a reprodução do mosquito, além da qual a temperatura excessivamente alta ou baixa possa limitar sua sobrevivência. Da mesma forma, a relação entre a precipitação e a incidência de dengue pode variar ao longo do tempo e ser afetada por outros fatores, como a disponibilidade de criadouros para o mosquito.

Apesar dessas limitações, os resultados deste estudo oferecem *insights* importantes sobre a relação entre a variabilidade climática e a incidência de dengue em Campina Grande. A correlação positiva entre dengue e precipitação, com um atraso de um mês, destaca a importância das chuvas como um fator que impulsiona a proliferação do mosquito. Por outro lado, as temperaturas máxima e média do mês atual mostraram uma correlação negativa com a dengue, sugerindo que temperaturas mais altas podem limitar a sobrevivência do mosquito. Isso é consistente com a literatura científica que aponta para a sensibilidade do ciclo de vida do mosquito transmissor da dengue à temperatura, mas pode estar sendo contrabalanceado pela correlação positiva entre dengue e temperatura mínima.

O melhor modelo de regressão linear da dengue foi aquele que possuiu como variável dependente a temperatura máxima no mês atual e uma distribuição de erros seguindo um modelo autorregressivo de primeira ordem. O seu SRMSE foi de 0,90, o que significa que o modelo é 10% melhor que o valor esperado da variável dependente (logaritmo dos casos de dengue) como preditor. O ajuste do modelo aditivo generalizado mostrou um melhor desempenho com um SRMSE igual a 0,85, com a adição da precipitação com um mês de antecedência como variável independente, mostrando a influência da precipitação no número de casos de dengue de forma não-linear.

Em resumo, este estudo contribui para o entendimento das complexas interações entre o clima e a incidência de dengue em uma região da Paraíba. Pesquisas futuras, especialmente aquelas direcionadas ao microclima local, são cruciais para aprimorar nosso conhecimento e a precisão das projeções sobre a incidência de dengue na região.

REFERÊNCIA

- A Lee S. et. Al., **Effect of climate change, connectivity, and socioeconomic factors on the expansion of the dengue virus transmission zone in 21st century Brazil: an ecological modelling study**. Disponível em: <
[https://www.thelancet.com/journals/lanplh/article/PIIS2542-5196\(21\)00098-X/fulltext](https://www.thelancet.com/journals/lanplh/article/PIIS2542-5196(21)00098-X/fulltext)> abril, 2023.
- Abreu, A. M., et al. **A interface entre saúde, mudanças climáticas e uso do solo no Brasil: uma análise da evolução da produção científica internacional entre 1990 e 2019**. Saúde soc, 29 (2), e 180866. 2020.
- Akaike, H. **A New Look At The Statistical Model Identification**. IEEE Transaction on Automatic Contrl, 1974. AC-19, 715-723.
- Alkhalidy, I. **Modelling the association of dengue fever cases with temperature and relative humidity in Jeddah, Saudi Arabia: A generalised linear model with break-point analysis**. Acta Tropica, 168, 9e15. 2017.
- Almeida, H. A., Cabral Júnior, J. B., 2014. **Variabilidades Sazonais e Interdecadais da Chuva nas Microrregiões Geográficas do Estado da Paraíba**. Revista Brasileira de Geografia Física 07, n. 5, 846-858.
- Alves L. **Amazon fires coincide with increased respiratory illnesses in indigenous populations**. Lancet Respir Med. 2020;8(11): e84.
- Américo, B. L., e Lacruz, A. J. **Contexto e desempenho escolar: análise das notas na Prova Brasil das escolas capixabas por meio de regressão linear múltipla**. Revista De Administração Pública, 51(5), 854–878, 2017. Disponível em: <https://doi.org/10.1590/0034-7612160483>. Acesso em: 28 maio. 2023.
- AMORIM, Marcos Renato Basilio. **Estudo comparativo da regressão linear múltipla e redes neurais artificiais na modelagem do processo de adsorção**. 2022. 136F. Dissertação (Programa de Pós-Graduação em Ciência e Tecnologia Ambiental - PPGCTA) - Universidade Estadual da Paraíba, Campina Grande, 2022
- Arrhenius, S., 1896: **On the influence of carbonic acid in the air upon the temperature on the ground**, Philos. Mag., 41, 237–276
- Ashish Sen, Muni Srivastava. **Regression Analysis: Theory, Methods, and Applications**. Springer New York, NY, 1990. Disponível em: <https://doi.org/10.1007/978-1-4612-4470-7>. Acesso em: 21 de abril de 2023.
- Barcellos C, Hacon S de S. **Um grau e meio. E daí?** Cad Saude Publica. 2016; 32(3): 00212315.
- Barcellos C, Lowe R. **Expansion of the dengue transmission area in Brazil: the role of climate and cities**. Trop Med Int Health 2014; 19: 159–68.
- Bejon P, Lusingu J, Olotu A, et al. **Efficacy of RTS, S/AS01E vaccine against malaria in children 5 to 17 months of age**. N Engl J Med. 2008;359(24):2521–32.

Bhatt S, Gething PW, Brady OJ, et al. **A distribuição global e a carga da dengue**. *Natureza*. 2013;496(7446):504–7.

Biasi, L. H. et al. **Atualização do modelo de regressão linear múltipla para avaliação de imóveis tipo apartamento na cidade de Criciúma – SC**. UNESCO, 2017. Disponível em: <http://repositorio.unesc.net/handle/1/5918>. Acesso em: 29 maio. 2023.

BOX, G. E. P. et al. **Time Series Analysis: Forecasting and Control**. Hoboken, New Jersey: Wiley, 5° ed., 2015.

BRASIL, C. I. M. C. Plano Nacional de Adaptação à Mudança do Clima -PNABrasil. Ministério do Meio Ambiente, Brasília, DF, Brasil, 201.

BRASIL, C. I. M. C. Plano Nacional sobre Mudança do Clima–PNMC--Brasil. Ministério do Meio Ambiente, Brasília, DF, Brasil, v. 129, 2008.

Brasil. Ministério da Saúde. Lei 13.685, de 25 de julho de 2018 [Internet]. Ministério da Saúde. 2018. Disponível em: http://www.planalto.gov.br/ccivil_03/_ato2015-2018/2018/lei/L13685.htm.

Brasil. Ministério da Saúde. Portaria no 1.793, de 11 de agosto de 2009 [Internet]. Ministério da Saúde. 2009 [cited 2021 Feb 9]. Disponível em: http://bvsms.saude.gov.br/bvs/saudelegis/gm/2009/prt1793_11_08_2009.html

Brito SSB, Cunha APMA, Cunningham CC, Alvalá RC, Marengo JA, Carvalho MA. **Frequency, duration and severity of drought in the Semiarid Northeast Brazil region**. *Int J Climatol* 2018.

Cabral Júnior, J. B., Lucena, R. L., Almeida, H. A. **Avaliação da evapotranspiração de referência diária, estimada pelo método tanque classe A, para Campina Grande, PB**. *Revista Brasileira de Geografia, Física* vol. 11, n.06 (2018) 1971-1984. 2018.

CABRAL, J. V. et. al., **Epidemiological behavior of dengue in a northeastern state from 2014 to 2017**. *Research, Society and Development, [S. l.]*, v. 11, n. 13, p. e390111334981, 2022. DOI: 10.33448/rsd-v11i13.34981. Disponível em: <https://rsdjournal.org/index.php/rsd/article/view/34981>. Acesso em: 27 nov. 2023.

Cabral Júnior, J.B., Almeida, H.A., Silva, C.M.S., 2013. **Análise Comparativa da Temperatura Média do Ar em Campina Grande, PB, obtida pelo Método dos Extremos e pelo Método Padrão**. *Revista Brasileira de Geografia Física*, 6, p. 888-902.

Callendar, G.S., 1938: **The artificial production of carbon dioxide and its influence on temperature**. *Q. J. R. Meteorol. Soc.*, 64, 223–237

Caminade C. et. al., **Impact of climate change on global malaria distribution**. *PNAS*. Vol. 111, n° 9, march 4, 2014.

Carvajal TM, Viacrusis KM, Hernandez LF, Ho HT, Amalin DM, Watanabe K. **Machine learning methods reveal the temporal pattern of dengue incidence using meteorological factors in metropolitan Manila, Philippines**. *BMC Infect Dis*. 2018.

Castor, M. R. S. **Bootstrap não paramétrico aplicado ao modelo de regressão linear múltipla com uso da planilha do excel**. Dissertação apresentada ao curso de Especialização em Estatística na Universidade Federal de Minas Gerais, 27 Mai. 2020 Disponível em: <http://hdl.handle.net/1843/33971>. Acesso em: 24 maio. 2023.

Chalghaf B. et. al., **Ecological niche modeling predicting the potential distribution of Leishmania vectors in the Mediterranean basin: impact of climate change**. Parasites e Vectors, 2018.

CHOU, S.C.; LYRA, A.; MOURAO, C.; DEREZYNSKI, C.; PILOTTO, I.; GOMES, J.; BUSTAMANTE, J.; TAVARES, P.; SILVA, A.; RODRIGUES, D.; CAMPOS, D.; CHAGAS, D.; SUEIRO, G.; SIQUEITA, G.; MARENGO, J. Assessment of Climate Change over South America under RCP 4.5 and 8.5 **Downscaling Scenarios**. American Journal of Climate Change, v. 3, n. 5, p. 512-527, 2014.

Correia, T. C., Flausino, V. de O., Figueiredo, L. L., Ferreira, T. V. dos S., Rabelo, T. V., Coelho, T. D. F., Abreu, A. C. C. e, e Prince, K. A. **Prevalência de dengue clássica e dengue hemorrágica no Brasil, entre 2011 e 2015**. Revista Eletrônica Acervo Saúde, (22), e753, 2019.

Costa, A. C. Influence of hydroclimatic variability on dengue incidence in a tropical dryland rea, Acta Tropica, Volume 235, 2022, 106657, ISSN 0001-706X, Acesso em: <https://doi.org/10.1016/j.actatropica.2022.106657>.

DAWSON, C.W.; WILBY, R.L. **The Statistical DownScaling Model (SDSM): Insights from one decade of application**. International Journal of Climatology, v. 33, n. 7, p. 1707-1719, 2013.

DEPRADINE, Colin; LOVELL, Ernest. **Climatological variables and the incidence of Dengue fever in Barbados**. International Journal of Environmental Health Research, 2004, vol. 14, nº 6, p. 429 – 441. Diseases, 9(7), Article e0003901.

Duarte, J. L. et al., **Variabilidade climática e interações por doenças diarreicas infecciosas em um município da Amazônia Ocidental Brasileira**. Ciênc. Saúde Coletiva. 24 (8), 2959-2970, 2019.

DUNN, P. K.; SMYTH, G. K. **Resíduos de quantis randomizados**. Journal of Computational and Graphical Statistics, JSTOR, v. 5, n. 3, p. 236, set 1996. Disponível em: <<https://www.jstor.org/stable/1390802?origin=crossref>>. Acesso em: mai. 2023.

Ebi KL, Hasegawa T, Hayes K et al. **Health risks of warming of 1.5 °C, 2 °C, and higher, above pre-industrial temperatures**. Environmental Research Letters, 2018. Disponível em: <https://iopscience.iop.org/article/10.1088/1748-9326/aac4bd/meta> Acesso em: 07 agos. 2023.

Ebi, K. L., e Nealon, J. **Dengue in a changing climate**. Environmental Research, 151, 115e123. 2016.

EILERS, P. H.; MARX, B. D.; DURBÁN, M. **Twenty years of p-splines**. SORT: statistics and operations research transactions, v. 39, n. 2, p. 149-186, 2015.

ESTATCAMP. **Software Action - Consultoria em estatística e qualidade**. Versão 40 2.8. Estatcamp, São Carlos, São Paulo, Brasil, 2014.

Fakhruddin, M., et al. **Assessing the interplay between dengue incidence and weather in Jakarta via a clustering integrated multiple regression model.** *Ecological Complexity*, 39, 100768. 2019.

FECCHIO, A.; et l. **Climate variation influences host specificity in avian malaria parasites.** *Ecology Letters*, [s. l.], v. 22, n. 3, p. 547–557, 2019. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1111/ele.13215>. Acesso em: 17 mai. 2023.

FERREIRA, A. C.; CHIARAVALLLOTI NETO, F.; MONDINI, A. **Dengue in Araraquara, state of São Paulo: epidemiology, climate and aedes aegypti infestation.** *Revista de Saúde Pública*, v. 52, p. 18, 26, 2018.

Ferreira, T. V. (2014). **Estimação Inteligente da Poluição de Isolamentos elétricos Baseada nos VECSE do Ruído Ultrassônico**. Tese de Doutorado - Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Campina Grande - UFCG.

Field, C.B., V.R. Barros, D.J. Dokken, K.J. Mach, M.D. Mastrandrea, T.E. Bilir, M. Chatterjee, K.L. Ebi, Y.O. Estrada, R.C. Genova, B. Girma, E.S. Kissel, A.N. Levy, S. MacCracken, P.R. Mastrandrea, and L.L. White (eds.)). **Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA**, pp. 535-612, 2014.

FLORENCIO, L. A. **Engenharia de avaliações com base em modelos GAMLSS.** Tese (Doutorado) — Universidade Federal de Pernambuco, 2010.

FOWLER, H.J.; BLENKINSOP, S.; TEBALDI, C. **Linking climate change modeling to impacts studies: Recent advances in downscaling techniques for hydrological modeling.** *International Journal of Climatology*, v. 27, n.12, p. 1547-1578, 2007.

Freitas, B. S., Lima, L. S., Gomes, A. C. S., Peres, L. V., e Silva, A.S. **Análise da associação entre variáveis meteorológicas e as internações por dengue no município de Rio Branco/AC.** *Revista de Geociências do Nordeste*, 7(2), 162-171, 2021

GOMES, A. C. S.; CONSTANTINO, S. M. H.; LUCIO, P. S. **Dynamic Regression Model for Evaluating the Association Between Atmospheric Conditions and Deaths due to respiratory diseases in São Paulo.** *Brazil.Revista Brasileira de Meteorologia*,v. 33, n. 1, 1-10, 2018.

Gomes A. C., Freire T. **Doenças sensíveis ao clima e sua relação com a hidroclimatologia do semiárido.** 2021. Tese de Doutorado.

GOMES, Juliana Vieira. **Métodos de Estimação do Desvio-Padrão Para a Padronização de Variáveis na Análise de Componentes Principais.** 2018. 48 f. Dissertação (Mestrado em Estatística Aplicada e Biometria) - Universidade Federal de Viçosa, Viçosa. Julho de 19,2023.

GUZMAN, M. G.; HARRIS, E. **Dengue.** *The Lancet*, v. 385, n. 9966, 4453-465, 2015.

Gomez H., Dantes and J.R. Willoquet. **Dengue in the americas: challenges for prevention and control.** *Cadernos de Saúde Pública*, 25:19–31, 2009.

Hahn MB, Gangnon RE, Barcellos C, Asner GP, Patz JA. **Influence of deforestation, logging, and fire on malaria in the Brazilian Amazon.** *PLOS ONE*. 2014;9(1): e85725.

Hales S. et. al., **Potential effect of population and climate changes on global distribution of dengue fever: an empirical model**. The Lancet, Vol 360, September 14, 2002.

Hasan, S., Jamdar, S., Alalowi, M., e Beaiji, S. Al A. Al. (2016). **Dengue virus: a global human threat**. Journal of International Society of Preventive and Community Dentistry, 6(1), 1-6.

HASTIE, T.; TIBSHIRANI, R. **Generalized additive models**. [S.l.]: Wiley Online Library, 1990

HUQ, Saleemul; GRUBB, Michael. **Scientific assessment of the interrelationships of mitigation and adaptation**. Scoping paper for IPCC Fourth Assessment Report, 2003.

HYNDMAN, R. J.; ATHANASOPOULOS, G. **Forecasting: principles and practice**. IGES, Center for Ocean-Land-Atmosphere Studies. Disponível em:<
<http://www.iges.org/cola.html>> Acesso em 21 de abril de 2023.

INMET - Instituto Nacional de Meteorologia. Disponível em:
<http://www.inmet.gov.br/portal/index.php?r=clima/normasclimatologicas>. Acesso em 15/09/2018.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE -) SIDRA - Sistema de Recuperação Automática do IBGE. 2014.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE -) SIDRA - Sistema de Recuperação Automática do IBGE. 2014.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. IBGE Cidades.

INSTITUTO ETHOS. **O que as empresas podem fazer pela inclusão das pessoas com deficiência**. Instituto Ethos, Empresas e Responsabilidade Social, 2016.

IPCC – **Intergovernmental Panel in Climate Change. Managing the Risks of Extreme Events and Disasters to Advance Climate Change Adaptation. Special Report of Working Groups I and II of the Intergovernmental Panel on Climate Change**. Edited by C. B. Field et al. Cambridge/New York, Cambridge University Press/IPCC, 2012.

IPCC. **Climate Change: Impacts, Adaptation and Vulnerability**. Working Group II. TAR: Summary for Policymakers, 2001.

IPCC. **Working Group, I Contribution to the IPCC Fifth Assessment Report (AR5)**, Climate Change 2013: The Physical Science Basis. Geneva: Intergovernmental Panel on Climate Change, 2013.

IPCC. (2014). **Mudanças Climáticas 2014: Relatório Síntese. Contribuição dos Grupos de Trabalho I, II e III para o Quinto Relatório de Avaliação do Painel Intergovernamental sobre Mudanças Climáticas**. Genebra, Suíça: IPCC.

ISLAM, M. N.; SIVAKUMAR, B. (2002). **Characterization and prediction of runoff dynamics: a nonlinear dynamical view**. Adv. Water Resour. 25, 179–190.

Islam, M. Z., et al. **Correlates of climate variability and dengue fever in two metropolitan cities in Bangladesh.** *Cureus*, 10(10), e3398. 2018.

JAYAWARDENA, A. W.; LAI, F. (1994). **Analysis and prediction of chaos in rainfall and streamflow time series.** *J. Hydrol. (Amst)* 153, 23–52.

JUNG, I-W; CHANG, H. **Assessment of future runoff trends under multiple climate change scenarios in the Willamette River Basin, Oregon, USA.** *HYDROLOGICAL PROCESSES*. 25, 258– 277

Kramer, I. M., Pfenninger, M., Feldmeyer, B., Dhimal, M., Gautam, I., Shreshta, P., Baral, S., Phuyal, P., Hartke, J., e Magdeburg, A. (2023). **Genomic profiling of climate adaptation in *Aedes aegypti* along an altitudinal gradient in Nepal indicates non-gradual expansion of the disease vector.** *Molecular Ecology*, (32), 350-368.

Krug T. et. Al., **O Brasil e as Mudanças Climáticas.** INPE, março, 2019. Disponível em: < <http://www.inpe.br/noticias/arquivos/pdf/brasil-e-as-mudancas-climaticas.pdf>>. Acesso em: 27, novembro de 2023.

L. Liang, L. Hualiang, T. Linwei, Y. Weizhong, S. Jimin, and L. Qiyong. **Time series analysis of dengue fever and weather in Guangzhou, China.** *BMC Public Health*, 9, 2009.

León, D. A. D. **Análise Fatorial Confirmatória Através dos Softwares R e Mplus.** LUMI, Porto Alegre, BR-RS, 2011-09-03T06:01:50Z

Lima-Camara, T. N. **Emerging arboviruses and public health challenges in Brazil.** *Revista de Saúde Pública*. 50, 1-7. 2016.

LIRA, B., LOPES, L., CHAVES, J., SANTANA, L., e FERNANDES, L. **Identificação de Homogeneidade, Tendência e Magnitude da Precipitação em Belém (Pará) entre 1968 e 2018.** *Anuário do Instituto de Geociências*, v. 43, n.4, 426-439, 2020.

Liu-Helmersson et. al., **Estimating past, present, and future trends in the global distribution and abundance of the arbovirus vector *Aedes Aegypti* under climate change scenarios.** *Frontiers*, June 12, 2019.

LOPES, R. A. **Monitoramento dos casos de dengue e a relação com a desigualdade socioespacial no Distrito Federal. Brasília, 2015.** 61f. Monografia (Bacharelado em Saúde Coletiva). Universidade de Brasília, Brasília-DF, 2015.

Lowe R, Bailey TC, Stephenson DB, et al. **The development of an early warning system for climate-sensitive disease risk with a focus on dengue epidemics in Southeast Brazil.** *Stat Med*. 2013;32(5):864-883. doi:10.1002/sim.5549.

Lowe R, Barcellos C, Coelho CA, et al. **Dengue outlook for the World Cup in Brazil: an early warning model framework driven by real-time seasonal climate forecasts.** *Lancet Infect Dis* 2014; 14: 619–26.

Lowe R. et al., **Combined effects of hydrometeorological hazards and urbanisation on dengue risk in Brazil: a spatiotemporal modelling study.** *Lancet Planet Health*, 2021.

Lung, C.Y. P.C. Wu, H.R. Guo, S.C. Lin, and H.J. Su. **Weather as an effective predictor for occurrence of dengue fever in Taiwan.** *Acta Tropica*, 103(1):50–57, 2007.

Lyra AA, Chou SC, Sampaio GO. **Sensitivity of the Amazon biome to high resolution climate change projections.** Acta Amazonica. 2016; 46 (2): 175 – 188.

M'Bra RK, Kone B, Soro DP, et al. **Impact of climate variability on the transmission risk of malaria in northern Côte d'Ivoire.** PLoS ONE. 2018;13(6):e0182304.

Maciel, L. F. V. et al.: **Regressão linear múltipla na modelagem de resultados na National Basketball Association (NBA).** 2019.

Mais de 50% dos bairros de Campina Grande apresentam alto índice de infestação do Aedes aegypti. globo.com, 2023. Disponível em: <<https://g1.globo.com/pb/paraiba/noticia/2023/01/17/mais-de-50percent-dos-bairros-de-campina-grande-apresentam-alto-indice-de-infestacao-do-aedes-aegypti.ghtml>>. Acesso em: 04, abril de 2023.

Malaquias, R. F. et.al. **Fundos de Investimentos, Bancos Administradores e Empréstimos Concedidos A Empresas Abertas: Uma Análise No Cenário Brasileiro** Contabilidade Vista e Revista, vol. 25, núm. 3, septiembre-diciembre, 2014, pp. 121-142.

Marengo A., **Mudanças climáticas e seus efeitos sobre a Biodiversidade: Caracterização do clima atual e definição das alterações climáticas para o Território Brasileiro ao longo do Século XXI.** Series Biodiversidade No. 26, MMA, 2007.

Marengo J., **O futuro clima do Brasil.** REVISTA USP; São Paulo, n. 103; p. 25-32, 2014.

Mayer L., Pachauri RK, **Intergovernmental Panel on Climate Change.** Climate change 2014: synthesis report. Genebra: Intergovernmental Panel on Climate Change; 2015.

Mello, Y. O. **Análise Estatística e Geoestatística da Precipitação Média para o Município de Joinville (SC).** Rev bras meteorologic, Apri; 2016.

Midekisa A, Beyene B, Mihretie A, Bayabil E, Wimberly MC. **Seasonal associations of climatic drivers and malaria in the highlands of Ethiopia.** Parasit Vectors. 2015;8(1):1–1.

MORENO, J. I. L.; LATRON, J.; LEHMANN, A. **Effects of sample and grid size on the accuracy and stability of regression-based snow interpolation methods.** HYDROLOGICAL PROCESSES. 24, 1914– 1928

NAGHETTINI, M.; PINTO, É. J. DE A. **Hidrologia estatística.** Belo Horizonte: CPRM. 552 p. 2007.

Nascimento, L. B., Oliveira, P., S., Magalhães, D. P., França, D. D. S., Magalhães, A. L. Á., Silva, J. B., Silva, F. P. A., e Lima, D. M. (2015). **Caracterização dos casos suspeitos de dengue internados na capital do estado de Goiás em 2013: período de grande epidemia.** Epidemiologia e Serviços de Saúde, 24(3), 475-484.

NETO, T. S. C., RAMIREZ, M. T. P., GALINDO, V. R., HERCULANO, L. F. S., CAMPELLO, M. V. M. **Levantamento de potenciais criadouros de Aedes aegypti no Campus do Itaperi da Universidade Estadual do Ceará.** Medicina Veterinária (UFRPE), v. 13, n. 1, 43-48, 2019.

OJIMA, R.; MARANDOLA JR, E. **Mudanças climáticas e as cidades: novos e antigos debates na busca da sustentabilidade urbana e social. Coleção População e Sustentabilidade.** São Paulo: Edgard Blucher Ltda., 2013. E-book.

Oliveira, D. L., Silva, Y. S., Naves, J. S., Melo Jr., G., Gonçalves, P. H. D., Silva, B. C. R., Furriel, G. P., e Silva, J. R. (2020). **Custo das internações por dengue no estado de Goiás, no período de 2016 a 2018.** Brazilian Journal of Development, 6(5). 30695-30697.

Oliveira, L. de Tonin, P. C., e Vicenzi, S. L. (2020). **Comportamento dos custos totais de produção no segmento da avicultura de postura no estado do Paraná: estudo baseado na análise de regressão linear múltipla.** Revista Produção Online, 20(1), 28–46. Disponível em: <https://doi.org/10.14488/1676-1901.v20i1.3242>. Acesso em: 28 maio. 2023.

OLIVEIRA, R. D. F.; ALVES, J. W. S. **Cadernos de educação ambiental: mudanças climáticas globais no Estado de São Paulo.** Governo do Estado de São Paulo 31 Coordenadoria de Planejamento Ambiental, São Paulo: Secretaria do Meio Ambiente, 2011.

Oliveira, R. M., Oliveira, L. R. M. (2019). **Epidemiologia da dengue: análise em diversas regiões do Brasil.** EsSEX: Revista Científica, 2(2), 32-44.

Ong, Y. Y., e Tan, G. E. **Climate variability and dengue in Singapore, Fiji, and Hongkong: Small bite, big threat.** Proceedings of Singapore Healthcare, 28(3), 145e146. 2019

P. Arcari, N. Tapper, and S. Pfueller. **Regional variability in relationships between climate and dengue/dhf in Indonesia.** Singapore Journal of Tropical Geography, 28(3):251–272, 2007.

PAHO. **Impact of Hurricane Mitch on Central America.** Epidemiol Bull. 1998; 19:1–14.

PBMC – PAINEL BRASILEIRO DE MUDANÇAS CLIMÁTICAS. **Impactos, vulnerabilidades e adaptação às mudanças climáticas.** In: ASSAD, E. D.; MAGALHÃES, A. R. (Eds). Contribuição do Grupo de Trabalho 2 do Painel Brasileiro de Mudanças Climáticas ao Primeiro Relatório da Avaliação Nacional sobre Mudanças Climáticas. Rio de Janeiro: Coppe/UFRJ, 2014. 414 p.

Pontes RJ. et al., **Vector densities that potentiate dengue outbreaks in a Brazilian city.** Am J Trop Med Hyg 2000; 62: 378–83.

Putra, P. S., e Nuraini, N. **Modeling of dengue occurrences early warning involving temperature and rainfall factors.** Asian Pacific Journal of Tropical. 2017.

RAO et al. **Linear Models and Generalizations: Least Squares and Alternatives.** Springer Berlin, Heidelberg, 2008. Disponível em: <https://doi.org/10.1007/978-3-540-74227-2>. Acesso em: 21 de abril de 2023.

REVI, A., D.E. Satterthwaite, F. Aragón-Durand, J. Corfee-Morlot, R.B.R. Kiunsi, M. Pelling, D.C. Roberts, and W. Solecki: **Urban areas. In: Climate Change 2014: Impacts, Adaptation, and Vulnerability.** Part A: Global and Sectoral Aspects. Contribution of Working Group II to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change.

RIGBY, R.; STASINOPOULOS, M.; HELLER, G.; BASTIANI, F. **Distributions for Modelling Location, Scale, and Shape: Using GAMLSS in R**. [S.l.: s.n.], 2017.

Rocklöv J, Tozan Y, Ramadana A, Sewe MO, Sudre B, Garrido J, et al. **Using big data to monitor the introduction and spread of chikungunya, Europe, 2017**. Emerg Infect Dis. 2019 Jun. <https://doi.org/10.3201/eid2506.180138>.

Rodrigues L. R. N. et al. **Perfil Epidemiológico da Dengue em Campina Grande - PB, 2015 a 2016**. CONBRACIS, 2017.

Rodrigues, N. C. P., Lino, V. T. S., Daumas, R. P., Andrade, M. K. N., O'dwyer, G., Moneteiro, D. L. M., Gerardi, A., Fernandes, G. H. B. V., Ramos, J. A. S., Ferreira, C. E. G., e Leite, I. C. (2016). **Temporal and spatial evolution of dengue incidence in Brazil, 2001-2012**. Plos One, 11(11), 1-12.

Santiago, E. A. S., e Landa, G. G. (2022). **Perfil epidemiológico de casos de dengue no município de Bom Jesus do Itabapoana-RJ nos anos de 2014 a 2020**. Pensar Acadêmico, 20(2), 334-345.

Santos, A. T. S.; Silva, C. M. S., 2013. **Seasonality, interannual variability, and linear tendency of wind speeds in the Northeast Brazil from 1986 to 2011**. The Scientific World Journal, 2013, p. 1-11.

Santos, L. K. F., Pessôa, V. M. L., Santos, T. S., Bragagnollo, G. R., Machado, G. P., Munõz, S. I. S., Bragagnollo, S. R., Guimarães, M. N., e Carvalho, L. W. T., (2019). **Perfil epidemiológico da dengue em um estado do nordeste brasileiro, 2011 a 2015**. Revista Eletrônica Acervo Saúde, 11(10), e423. <https://doi.org/10.25248/reas.e423.2019>

SCHULTZ, D. P.; SCHULTZ, S. E. **História da psicologia moderna**. São Paulo: Cultrix. ed. 16. 439 p. 1992.

SELL, I. **Utilização da regressão linear como ferramenta de decisão na gestão de custos**. In: CONGRESSO BRASILEIRO DE CUSTOS, 12., 2005. Florianópolis. [Anais...] Florianópolis: 2005.

Semenza JC, Sudre B, Miniota J, et al. **Dispersão internacional da dengue por meio de viagens aéreas: risco de importação para a Europa, 2014**.

Seah A, Aik J, Ng LC, Tam CC. **The effects of maximum ambient temperature and heatwaves on dengue infections in the tropical city-state of Singapore - A time series analysis**. Sci Total Environ. 2021;775:145117. doi:10.1016/j.scitotenv.2021.145117.

Sharmin, S., et al. **Interaction of mean temperature and daily fluctuation influences dengue incidence in Dhaka, Bangladesh**. PLoS Neglected Tropical. 2019.

SILVA, A. M.; SILVA, R. M.; ALMEIDA, C. A. P.; CHAVES, J. J. S. **Modelagem geostatística dos casos de dengue e da variação termopluiométrica em João Pessoa**. Brasil.Sociedade e Natureza,v. 27, n. 1, 157-169, 2015.

Silva, I. K. M., Medeiros, E. R., Silva, B. C. O., Paiva, M. D. B., Barreto, V. P., e Feijão, A. R., (2020). **Série histórica dos casos de dengue no estado do Rio Grande do Norte, Brasil**. Revista Uruguaya de Enfermería, 2020; 15(2): 1-13.

Silva, M. A., e Silva, R. S. (2017). **Perfil epidemiológico da dengue no Brasil: revisão integrativa**. [Trabalho de Conclusão de Curso]. Centro Universitário Tiradentes, Recife, Brasil.

Silva, M. E. T. **A evolução da dengue no estado de Santa Catarina, Brasil, entre 2014 e 2019**. [Trabalho de Conclusão de Curso]. Universidade Federal de Santa Catarina, 2020.

Silva, R. E. da., Silva, A. C. A. da., Araújo, D. D., Alves, N. S., Oliveira, A. A. de., Santos, I. L., Mendes, M. S. S., e Ramos, J. C. F. (2021). **Análise da realização dos exames laboratoriais no diagnóstico da Dengue no Piauí**. Research, Society and Development, 10(12), e531101220776. <https://doi.org/10.33448/rsd-v10i12.20776>. Disponível em: <<https://rsdjournal.org/index.php/rsd/article/view/20776>> Acesso em: 21 de abril de 2023.

Silva, T. M., e Ramalho, A. M. C. (2020). **A metáfora do espetáculo vertical: um olhar para a cidade de Campina Grande-PB**. urbe. Revista Brasileira de Gestão Urbana, 12, e20190222. <https://doi.org/10.1590/2175-3369.012.e20190222>.

Siqueira JB. et al., **Dengue and dengue hemorrhagic fever, Brazil, 1981–2002**. Emerg Infect Dis 2005; 11: 48–53.

SIQUEIRA, I. S.; QUEIROZ J. C. B.; AMIN, M. M.; CÂMARA, R. K. C. **A Relação da Incidência de Casos de Dengue com a Precipitação na Área Urbana de Belém-PA, 2007 a 2011, Através de Modelos Multivariados de Séries Temporais**. Revista brasileira de Meteorologia, v. 33, n. 2, 380-389, 2018.

SIVAKUMAR, B. (2004). **Chaos theory in geophysics: past, present and future**. Chaos, Solitons and Fractals 19 (2004) 441–462.

Sophie A. et. al., **The impact of climate suitability urbanisation, and connectivity on the expansion of dengue in 21st century Brazil**. ResearchGate, September, 2021.

SOUSA, J. W. **Características climáticas do município de Rio Branco, Acre, período de 1990-2019**. Scientia Naturalis, v. 2, n. 2, 723-740, 2020.

Sousa, T. C. M., et al. **Doenças sensíveis ao clima no Brasil e no mundo: revisão sistemática**. Revista Panamericana de Salud Pública. 42, 1-10, 2018

Stanaway JD, Shepard DS, Undurraga EA, et al. **A carga global da dengue: uma análise do Estudo da Carga Global de Doenças 2013**. Lancet Infect Dis. 2016;16(6):712–23.

Sudre B, Rossi M, Van Bortel W, et al. **Mapping environmental suitability for malaria transmission, Greece**. Emerg Infect Dis. 2013;19(5):784.

Team, T. R. **R: A Language and Environment for Statistical Computing**. R Foundating for Statistical Computing, 2016.

Teixeira, M. G., Siqueira Junior, J. B., Ferreira, J. L. C., Bricks, L., e Join, G., (2013). **Epidemiological trends of dengue disease in Brazil (2000-2010): A systematic literature search and analysis**. Literature Search and Analysis. PLoS Negl Trop Dis 7(12): e2520. <https://doi.org/10.1371/journal.pntd.0002520>

Tesla B, Demakovsky LR, Mordecai EA, et al. **Temperature drives Zika virus transmission: evidence from empirical and mathematical models.** Proc Biol Sci. 2018;285(1884):20180795. Published 2018 Aug 15. doi:10.1098/rspb.2018.0795.

Tjaden NB, Suk JE, Fischer D, Thomas SM, Beierkuhnlein C, Semenza JC. **Modelling the effects of global climate change on chikungunya transmission in the 21st century.** Sci Rep. 2017;7(1):1–1.

TORRES, I. B. La; AMATYA, D. M.; SUN, G.; CALLAHAN, T. J. (2011). **Seasonal rainfall–runoff relationships in a lowland forested watershed in the southeastern USA.** HYDROLOGICAL PROCESSES. 25, 2032– 2045

TORRES, E. M. **Dengue e dengue hemorrágico.** Buenos Aires/Argentina: Editora. Nacional da Universidade de Quilmes, 1998, p. 24-58.

TREUT, H., R. Somerville, U. Cubasch, Y. Ding, C. Mauritzen, A. Mokssit, T. Peterson and M. Prather, 2007: Historical Overview of Climate Change. In: Climate Change 2007: **The Physical Science Basis.** Contribution of Working Group I to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change [Solomon, S., D. Qin, M. Manning, Z. Chen, M. Marquis, K.B. Averyt, M. Tignor and H.L. Miller (eds.)]. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA.

Trevor, H. R. T. **The elements of Statistical Learning-Data Mining, Inference and Prediction.** Stanford: Springer, 2008.

VASCONCELOS, P.F.C.; LIMA, J.W.O.; DA ROSA, A.P.A.T.; TIMBÓ, M.J.; DA ROSA, E.S.T.; LIMA, H.R.. **Epidemia de dengue em Fortaleza, Ceará: inquérito soro-epidemiológico aleatório.** Rev Saúde Pública, 32:447-54. 1998.

Viana, B. E. **Limitações e desafios do controle da dengue no Brasil: uma revisão.** [Trabalho de Conclusão de Curso]. Instituto Adolfo Lutz, São Paulo, Brasil, 2020.

Viana, J. A. **Análise da correlação entre arboviroses epidêmicas no Brasil (dengue, chikungunya e zika) e a síndrome de Guillain-Barré: revisão sistemática de literatura.** <https://repositorio.ufba.br/handle/ri/21315>, 2016.

Villa, T. E. d.: **Predição do custo de milho por meio de modelos de regressão linear múltipla.** 2016.

WILBY, R.L.; DAWSON, C.W. **The Statistical DownScaling Model (SDSM): Insights from one decade of application.** International Journal of Climatology, v. 33, n. 7, p. 1707-1719, 2013.

WILBY, R.L.; FOWLER, H.J. **Regional climate downscaling. In Modelling the Impact of Climate Change on Water Resources** Fung CF, Lopez A, New M (eds). Wiley-Blackwell Publishing: Chichester, 2010.

World Health Organization. **World Health Organization Report on Global Surveillance of Epidemic-prone Infectious Diseases 2007.** World Health Organization, Geneva, 2007.

Yactayo S, Staples JE, Millot V, Cibrelus L, Ramon-Pardo P. **Epidemiology of Chikungunya in the Americas.** J Infect Dis. 2016;214(suppl_5): S441–5.

Yang, H. M., et al. **Follow up estimation of Aedes aegypti entomological parameters and mathematical modeling.** Biosystems, 103, 360e371. 2011.

ZWEIMÜLLER, I.; ZESSNER, M.; HEIN, T. **Effects of climate change on nitrate loads in a large river: the Austrian Danube as example.** HYDROLOGICAL PROCESSES. 22, 1022– 1036.

ANEXO I

Comandos utilizados em R

Distribuição das variáveis preditoras

```
> data<-read.table("C:/Users/Jéssica
Silva/Desktop/Importante/Faculdade/Alternate/Mestrado/UNILAB/Orientador/Campina-
PB/DadosLog.txt",TRUE)

> ts.data<-ts.union(Ldeng=ts(data$Ldeng,start=c(2007,2),freq=12),P=ts(data$P,start=
c(2007,1),freq=12),Tmed=ts(data$Tmed,start=c(2007,2),freq=12),
Tmax=ts(data$Tmax,start=c(2007,2),freq=12))

> plot(ts.data)

> library(mgcv)

Carregando pacotes exigidos: nlme

This is mgcv 1.8-42. For overview type 'help("mgcv-package")'.
```

Modelo de regressão linear múltipla

```
> fit.ols<-lm(Ldeng~P+Tmed+Tmax,data=ts.data ,na.action=na.exclude)

> summary(fit.ols)

Call:
lm(formula = Ldeng ~ P + Tmed + Tmax, data = ts.data, na.action = na.exclude)

Residuals:
    Min     1Q  Median     3Q    Max
-1.50726 -0.47076  0.05166  0.43474  1.26929

Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept)  3.5361496  0.9661050   3.660 0.000355 ***
P             0.0002013  0.0011109   0.181 0.856496
Tmed         0.2270910  0.1283416   1.769 0.078969 .
Tmax        -0.2718373  0.0933092  -2.913 0.004156 **
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Calculo dos residuos

Residual standard error: 0.5941 on 142 degrees of freedom

(22 observations deleted due to missingness)
```

Multiple R-squared: 0.2124, Adjusted R-squared: 0.1957

F-statistic: 12.76 on 3 and 142 DF, p-value: 1.969e-07

Erro encontrado no modelo

```
> qqnorm(fit.ols)
```

Error in match.arg(type):

'arg' should be one of “working”, “response”, “deviance”, “pearson”, “partial”

```
> qqline(fit.ols)
```

Error in sort.int (x, na.last = na.last, decreasing = decreasing, ...) :

'x' deve ser atômico

```
> qqnorm(resid(fit.ols))
```

```
> qqline(resid(fit.ols))
```

```
> acf(resid(fit.ols))
```

Error in na.fail.default(as.ts(x)) : valores em falta em objeto

```
> acf(resid(fit.ols))
```

Error in na.fail.default(as.ts(x)) : valores em falta em objeto

Análise de resíduos

```
> acf(resid(fit.ols),na.action = na.pass)
```

```
> pacf(resid(fit.ols), na.action = na.pass)
```

```
> library(nlme)
```

```
> cor<-corARMA(p=1)
```

```
> model<-formula (Ldeng ~Tmax)
```

```
> fit.gls<-glms(model, data=ts.data,correlation=cor,na.action=na.omit)
```

```
> summary (fit.gls)
```

Generalized least squares fit by REML

Model: model

Data: ts.data

	AIC	BIC	logLik
	164.5442	176.9679	-78.27208

Correlation Structure: AR (1)

Formula: ~1

Parameter estimate(s):

Phi

0.7749507

Coefficients:

	Value	Std.Error	t-value	p-value
(Intercept)	3.895302	0.6859478	5.678715	0
Tmax	-0.100029	0.0231298	-4.324701	0

Correlation:

(Intr)

Tmax -0.983

Standardized residuals:

Min	Q1	Med	Q3	Max
-2.106786347	-0.789220801	-0.002476864	0.823491713	1.986597184

Residual standard error: 0.599267

Degrees of freedom: 167 total; 165 residual

```
> cor<-cor ARMA(p=2)
```

```
> model<-formula(Ldeng ~Tmax)
```

```
> fit.gls<-glsl(model, data=ts.data,correlation=cor,na.action=na.omit)
```

```
> summary(fit.gls)
```

Modelo mínimos cuadrados generalizados

Generalized least squares fit by REML

Model: model

Data: ts.data

AIC	BIC	logLik
166.5285	182.0583	-78.26427

Correlation Structure: ARMA(2,0)

Formula: ~1

Parameter estimate(s):

Phi1	Phi2
0.767231826	0.009883275

Coefficients:

	Value	Std.Error	t-value	p-value
(Intercept)	3.912395	0.6825064	5.732393	0
Tmax	-0.100616	0.0230007	-4.374478	0

Correlation:

(Intr)

Tmax -0.982

Standardized residuals:

Min	Q1	Med	Q3	Max
-2.10973874	-0.78960180	-0.00379258	0.82144568	1.98501762

Residual standard error: 0.5992108

Degrees of freedom: 167 total; 165 residual

```
> sd(ts.data[,1],na.rm=TRUE)
```

```
[1] 0.6558298
```

```
> rmse<-sqrt(mean(residuals(fit.gls)^2))
```

```
> sdo<-sd(ts.data[,1],na.rm=TRUE)
```

```
> srmse<-rmse/sdo
```

```
> srmse
```

```
[1] 0.8973855
```

```
> sdo
```

```
[1] 0.6558298
```

```
> fit.gam<-gam(Ldeng ~ s(P)+s(Tmed)+s(Tmax),data=ts.data,na.action=na.omit)
```

```
> summary(fit.gam)
```

Family: gaussian

Link function: identity

Aplicação das variáveis

Formula:

$Ldeng \sim s(P) + s(Tmed) + s(Tmax)$

Parametric coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	0.99958	0.04753	21.03	<2e-16 ***

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

Approximate significance of smooth terms:

	edf	Ref.df	F	p-value
s(P)	5.474	6.578	1.670	0.110
s(Tmed)	1.000	1.000	0.089	0.766
s(Tmax)	1.000	1.000	1.175	0.280

R-sq.(adj) = 0.249 Deviance explained = 28.7%

GCV = 0.35011 Scale est. = 0.32979 n = 146

```
> fit.gam<-gam(Ldeng ~ s(P)+s(Tmax),data=ts.data,na.action=na.omit)
```

```
> summary(fit.gam)
```

Family: gaussian

Link function: identity

Retirada de variáveis ao modelo completo

Formula:

$Ldeng \sim s(P) + s(Tmax)$

Parametric coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	1.00657	0.04526	22.24	<2e-16 ***

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

Approximate significance of smooth terms:

	edf	Ref.df	F	p-value
s(P)	5.259	6.332	2.428	0.024010 *
s(Tmax)	1.000	1.000	14.716	0.000184 ***

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

R-sq.(adj) = 0.267 Deviance explained = 29.6%

GCV = 0.33721 Scale est. = 0.32162 n = 157

```
> rmse<-sqrt(mean(residuals(fit.gam)^2))
```

```
> sdo<-sd(ts.data[,1],na.rm=TRUE)
```

```
> srmse<-rmse/sdo
```

```
> srmse
```

```
[1] 0.8445061
```

```
> sdo
```

```
[1] 0.6558298
```

```
> plot(ts.data).
```

ANEXO II

PARA O NORDESTE:

Simulações do Clima Presente

Título do artigo	Modelos	Cenários NEB	1985 a 2005	Temperatura anual	Confiança(%) / resultados
Projeções De Mudanças Climáticas Sobre O Nordeste Brasileiro Dos Modelos Do Cmpip5 E Do Cordex. Guimarães, 2015	MCGs	CMIP5	A média de temperatura para o clima presente	25,8°C	90
Guimarães, 2015	CanESM2	-	-	-	Melhor modelo para cálculo de precipitação futura
Guimarães, 2015	TAS e PR	-	-	-	50
Guimarães, 2015	RAMS-CAM	Aplicadas ao CRU	Mostram aumento no IA	-	Não tem boa representação para locais com clima muito seco.
Guimarães, 2015	RAMS-SAM	Aplicadas ao CRU	Mostram aumento no IA/futuro	-	Resulta no desaparecimento de zonas áridas
Guimarães, 2015	CSIRO-Mk3-6-0		Projetam mais mudança no IA	-	Mostram o surgimento de uma área hiperárida entre os Sertões
Projeções De Mudanças Na Precipitação E Temperatura No Nordeste Brasileiro Utilizando A Técnica De Downscaling Dinâmico	RAMS6.0	RCP8.5 A simulação foi comparada com os dados do CRU	Superior ao hadgem2-ES	-	Representação da fase do ciclo anual de precipitação e temperatura Redução do viés seco na estação seca sobre o NNEB

Costa Et Al., 2015					
Avaliação De Desempenho Dos Modelos Do Cmp5 Quanto À Representação Dos Padrões De Variação Da Precipitação No Século Xx Sobre A Região Nordeste Do Brasil, Amazônia E Bacia Do Prata E Análise Das Projeções Para O Cenário Rcp8.5	CMIP5	RCP8.5	Os modelos globais do CMIP5 analisados apresentam correlações elevadas em relação à climatologia observada no período de 1901 a 1999.	-	Futuro da precipitação nas várias regiões da América.
Silveira Et Al., 2013					

Fonte: Autor, 2023.

Simulações do Clima Futuro:

Título do artigo	Cenários NEB	Ano de 2006-2099	Temperatura anual	A temp. ficar mais quente, do que no último ano do experimento historical (até 2005)
Projeções De Mudanças Climáticas Sobre O Nordeste Brasileiro Dos Modelos Do Cmp5 E Do Cordex. Guimarães, 2015	RCP4.5	-	26,8°C	1,8°C
Projeções De Mudanças Climáticas Sobre O Nordeste Brasileiro Dos Modelos Do Cmp5 E Do Cordex. Guimarães, 2015	RCP8.5	Como fisicamente esperado, o RCP8.5 mostra mais aquecimento sobre o NEB que o RCP4.5.	29,1°C	4,1°C
Variabilidade E Mudanças Climáticas No Semiárido Brasileiro.	Modelo (HadAM3P) Cenário:	As temperaturas aumentariam de 2 a 4 °c e as chuvas teriam uma redução de	-	2 e 4°C

Marengo Et Al., 2011	A2- pessimista	15 a 20% (2-4 mm dia-1) no semiárido, até o final do século XXI.		
Variabilidade E Mudanças Climáticas No Semiárido Brasileiro. Marengo Et Al., 2011	Modelo (HadAM3P) Cenário: B2-otimista	No cenário otimista o aquecimento seria entre 1 a 3 °C e a chuva ficaria entre 10 a 15% (1-2 mm dia-1) menor que no presente a nível anual.	-	1 e 3°C
Avaliação De Desempenho Dos Modelos Do Cmp5 Quanto À Representação Dos Padrões De Variação Da Precipitação No Século Xx Sobre A Região Nordeste Do Brasil, Amazônia E Bacia Do Prata E Análise Das Projeções Para O Cenário Rcp8.5. Silveira Et Al., 2013	CMIP5	RCP8.5	-	Com reduções de precipitação de até 20,5%,33,6 e 39,5% para os períodos de 2010 a 2039, 2040 a 2069 e 2070 a 2099, respectivamente.

Fonte: Autor, 2023.