



**UNIVERSIDADE DA INTEGRAÇÃO INTERNACIONAL DA LUSOFONIA AFRO-
BRASILEIRA**

**INSTITUTO DE ENGENHARIA E DESENVOLVIMENTO SUSTENTÁVEL
MESTRADO EM ENERGIA E AMBIENTE**

THAMARA KELLY DE SOUSA FERNANDES

**A INFLUÊNCIA CLIMÁTICA E A PREVISÃO EPIDEMIOLÓGICA DOS CASOS DE
DENGUE EM MUNICÍPIOS DO CEARÁ.**

**REDENÇÃO,
2025.**

THAMARA KELY DE SOUSA FERNANDES

**A INFLUÊNCIA CLIMÁTICA E A PREVISÃO EPIDEMIOLÓGICA DOS CASOS DE
DENGUE EM MUNICÍPIOS DO CEARÁ.**

Dissertação submetida como parte dos requisitos necessários para obtenção do grau de mestra em Energia e Ambiente da Universidade da Integração Internacional da Lusofonia Afro-Brasileira, UNILAB. Área de concentração: Recursos Hídricos.

Orientador: Prof. Dr. Luiz Martins de Araújo Júnior.

REDENÇÃO,

2025

Catálogo na Publicação
Universidade da Integração Internacional da Lusofonia Afro-Brasileira
Biblioteca Universitária

Fernandes, Thamara Kely de Sousa.

F363i

A influência climática e a previsão epidemiológica dos casos de dengue em municípios do Ceará / Thamara Kely de Sousa Fernandes. - Redenção, 2025.

96f: 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, 2025.

Orientador: Prof. Dr. Luiz Martins de Araújo Júnior.

Coorientador: Prof. Dr. Alexandre Cunha Costa.

1. Previsão epidemiológica. 2. Regressão linear. 3. Dengue.
I. Título

CE/UF/BSCA

CDD 614.42

THAMARA KELY DE SOUSA FERNANDES

**A INFLUÊNCIA CLIMÁTICA E A PREVISÃO EPIDEMIOLÓGICA DOS CASOS DE
DENGUE EM MUNICÍPIOS DO CEARÁ.**

Dissertação submetida como parte dos requisitos necessários para obtenção do grau de mestra em Energia e Ambiente da Universidade da Integração Internacional da Lusofonia Afro-Brasileira, UNILAB. Área de concentração: Recursos Hídricos.

Aprovada em: ____/____/____

BANCA EXAMINADORA

Prof. Dr. Luiz Martins de Araújo Júnior (Orientador)

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

Prof. Dr. Alexandre Cunha Costa (Co-Orientador)

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

Profa. Dra. Rafaella Pessoa Moreira

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

Prof. Dr. Cleiton da Silva Silveira

Universidade Federal do Ceará (UFC)

“Esperei com paciência no Senhor, e ele se inclinou
para mim, e ouviu o meu clamor.”

(Salmo 40: 1-2)

AGRADECIMENTOS

Primeiramente agradeço a Deus por me proporcionar esse momento tão importante e tão esperado, sem Ele nada disso estaria acontecendo. Foram dias de muitas orações, de muitas súplicas, não estava sendo fácil. Logo em seguida minha mãe, além mãe melhor amiga, companheira e que não me deixou desistir e me ajudou a lutar e a vencer cada dificuldade que surgia. Ela é exemplo de mulher, guerreira, dona de uma força infinita. In *memorian*, meu Pai, seja onde ele estiver, está como seus olhos cheios de lágrima de felicidade. O mérito de tudo isso que está acontecendo é somente dessas duas pessoas, eles são o que me faz levantar todos os dias e não desistir de ir atrás dos meus sonhos.

Deus em sua infinita bondade, colocou o Professor Luiz Júnior como meu orientador, me dando todo suporte, toda a ajuda, sendo paciente em cada dúvida. Ser Professor é além de um título e ele exemplo disso. Agradeço por não desistir de mim, agradeço por cada palavra, agradeço por me proporcionar estudar com um profissional tão competente.

Agradeço ao Professor Lucas da Silva da época da graduação até os dias de hoje, um grande mestre e que fez acreditar que esse momento aconteceria e que em nenhum momento eu deveria desistir, mas sim lutar.

Agradecer a FUNCAP, pela concessão da bolsa que pude me manter durante o período de mestrado. Ao Professor Alexandre Cunha, como meu coorientador, por toda paciência, disponibilização de dados, estudos e análises dos trabalhos desenvolvidos.

RESUMO

Este estudo epidemiológico é do tipo ecológico, de abordagem quantitativa e descritiva de série temporal. O presente trabalho tem o objetivo de investigar a influência do clima na variabilidade interanual do número de casos de dengue e prever situações epidemiológicas em áreas urbanas, de clima tropical semi-árido, no Ceará. Para isso, utilizou-se diversos modelos de regressão linear de mínimos quadrados ordinário baseados nas variáveis meteorológicas (precipitação e temperatura) com correlações mais significativas com a ocorrência de casos de dengue. As correlações amostrais foram calculadas para associações sem lag e com lag de 1 a 3 meses, a fim de verificar a influência da defasagem temporal entre os dados climáticos e os dados de dengue. Dos resultados extrai-se que a temperatura mínima com defasagem de 3 meses foi a variável que mais influenciou o número de casos de dengue, participando como variável preditora mais significativa em 6 dos 12 municípios analisados no estudo. Outro achado interessante é que o modelo calibrado para Fortaleza foi o que apresentou melhor qualidade entre os demais municípios, com um SRMSE de $\sim 0,799$. Juazeiro do Norte, Tianguá e Sobral foram os municípios em que nenhuma das variáveis preditoras possuíam correlação com significância estatística. Com isso, pode-se concluir que a relação entre variáveis climáticas e a incidência de dengue varia entre os municípios, não tendo um padrão bem definido de influência, podendo indicar que o clima sozinho não explica a variabilidade interanual do número de casos de dengue, outros fatores como urbanização, diminuição da vegetação e a expansão populacional podem modular/influenciar a incidência da dengue. Adicionalmente pode-se ainda concluir que modelos mais simples, baseados em variáveis significativas, apresentaram melhor desempenho. Em alguns casos, a previsão capturou bem as tendências sazonais da dengue, mas houve limitações como superestimação e subestimação em certos períodos.

Palavras-chave: Regressão Linear; Previsão Epidemiológica; Dengue.

ABSTRACT

This epidemiological study is ecological, with a quantitative and descriptive time series approach. The present work aims to investigate the influence of climate on the interannual variability of the number of dengue cases and epidemiological pre-situations in urban areas, with a semi-arid tropical climate, in Ceará. For this, several ordinary least squares linear regression models were used based on the detrimental variables (precipitation and temperature) with the most significant correlations with the occurrence of dengue cases. The sample correlations were calculated for associations without delay and with a delay of 1 to 3 months, in order to verify the influence of the time lag between the climate data and the dengue data. From the results it is extracted that the minimum temperature with a lag of 3 months was a variable that most influenced the number of dengue cases, participating as the most significant predictor variable in 5 of the 12 cities proven in the study. Another interesting finding is that the model calibrated for Fortaleza was the one that presented the best quality among the other municipalities, with a SRMSE of ~ 0.799 . Juazeiro do Norte, Tianguá and Sobral were the cities in which none of the predictor variables had statistically significant brightness. Therefore, we can conclude that the relationship between climate variations and the incidence of dengue varies among municipalities, with no well-defined pattern of influence, even indicating that climate alone does not explain the interannual variability in the number of dengue cases; other factors such as urbanization, increased vegetation and population expansion can modulate/influence the incidence of dengue. Additionally, it can also be concluded that simpler models, based on significant variables, presented better performance. In some cases, the forecast captured the seasonal trends of dengue well, but there were limitations such as overestimation and underestimation in certain periods.

Key words: Linear Regression; Epidemiological Forecast; Dengue.

LISTA DE FIGURAS

Figura 1: Fluxograma de delineamento.	26
Figura 2: Localização dos 12 município cearenses estudados.	28
Figura 3: Correlação Linear de Pearson considerando defasagens temporais de até 3 meses para Aracati	35
Figura 4: Ajuste dos resíduos - Quadrantes: 1º Normal Q-Q, 2º Plot dos resíduos, 3º autocorrelação, 4º autocorrelação parcial de Aracati.....	36
Figura 5: Valor do Critério de Informação de Akaike (AIC) para Aracati	37
Figura 6: Valor do Critério de Informação de Bayesiana (BIC) para Aracati.....	37
Figura 7: Variável de desempenho- RMSE para Aracati	38
Figura 8: Variável de desempenho- SRMSE para Aracati.....	38
Figura 9: Série temporal de validação para Aracati.	39
Figura 10: Correlação Linear de Pearson considerando defasagens temporais de até 3 meses para Canindé.....	40
Figura 11: Ajuste dos resíduos - Quadrantes: 1º Normal Q-Q, 2º Plot dos resíduos, 3º autocorrelação, 4º autocorrelação parcial de Canindé	40
Figura 12: Valor do Critério de Informação de Akaike (AIC) para Canindé.....	41
Figura 13: Valor do Critério de Informação de Bayesiana (BIC)para Canindé	41
Figura 14: Variável de desempenho- RMSE para Canindé.....	42
Figura 15: Variável de desempenho- SRMSE para Canindé.	42
Figura 16: Série temporal para validação para Canindé.....	43
Figura 17: Correlação Linear de Pearson considerando defasagens temporais de até 3 meses para Cratéus.	44
Figura 18: Ajuste dos resíduos - Quadrantes: 1º Normal Q-Q, 2º Plot dos resíduos, 3º autocorrelação, 4º autocorrelação parcial de Cratéus.	44
Figura 19: Valor do Critério de Informação de Akaike (AIC) para Cratéus	45
Figura 20: Valor do Critério de Informação de Bayesiana (BIC) para Cratéus.	45
Figura 21: Variável de desempenho - RMSE para Cratéus.....	46
Figura 22: Variável de desempenho- SRMSE para Cratéus.....	46
Figura 23: Série temporal para validação para Cratéus	47
Figura 24: Correlação Linear de Pearson considerando defasagens temporais de até 3 meses para Fortaleza	48
Figura 25: Ajuste dos resíduos - Quadrantes: 1º Normal Q-Q, 2º Plot dos resíduos, 3º autocorrelação, 4º autocorrelação parcial de Fortaleza.....	49
Figura 26: Valor do Critério de Informação de Akaike (AIC) para Fortaleza	49
Figura 27: Valor do Critério de Informação de Bayesiana (BIC) para Fortaleza.....	50
Figura 28: Variável de desempenho- RMSE para Fortaleza	50
Figura 29: Variável de desempenho- SRMSE para Fortaleza.....	51
Figura 30: Série temporal para validação para Fortaleza	51
Figura 31: Correlação Linear de Pearson considerando defasagens temporais de até 3 meses para Iguatu.	52
Figura 32: Ajuste dos resíduos - Quadrantes: 1º Normal Q-Q, 2º Plot dos resíduos, 3º autocorrelação, 4º autocorrelação parcial de Iguatu	53

Figura 33: Valor do Critério de Informação de Akaike (AIC) para Iguatu.....	54
Figura 34: Valor do Critério de Informação de Bayesiana (BIC) para Iguatu.....	54
Figura 35: Variável de desempenho- RMSE para Iguatu.....	55
Figura 36: Variável de desempenho- SRMSE para Iguatu.....	55
Figura 37: Série temporal para validação para Iguatu.....	56
Figura 38: Correlação Linear de Pearson considerando defasagens temporais de até 3 meses para Itapipoca	57
Figura 39: Ajuste dos resíduos - Quadrantes: 1º Normal Q-Q, 2º Plot dos resíduos, 3º autocorrelação, 4º autocorrelação parcial de Itapipoca.....	57
Figura 40: Valor do Critério de Informação de Akaike (AIC) para Itapipoca	58
Figura 41: Valor do Critério de Informação de Bayesiana (BIC) para Itapipoca.....	58
Figura 42: Variável de desempenho- RMSE para Itapipoca	59
Figura 43: Variável de desempenho- SRMSE para Itapipoca.....	59
Figura 44: Série temporal para validação para Itapipoca	60
Figura 45: Correlação Linear de Pearson considerando defasagens temporais de até 3 meses para Juazeiro do Norte.....	61
Figura 46: Correlação Linear de Pearson considerando defasagens temporais de até 3 meses para Morada Nova	62
Figura 47: Ajuste dos resíduos - Quadrantes: 1º Normal Q-Q, 2º Plot dos resíduos, 3º autocorrelação, 4º autocorrelação parcial de Morada Nova	62
Figura 48: Valor do Critério de Informação de Akaike (AIC) para Morada Nova	63
Figura 49: Valor do Critério de Informação de Bayesiana (BIC) para Morada Nova	63
Figura 50: Variável de desempenho- RMSE para Morada Nova.....	64
Figura 51: Variável de desempenho- SRMSE para Morada Nova.....	64
Figura 52: Série temporal para validação para Morada Nova.....	65
Figura 53: Correlação Linear de Pearson considerando defasagens temporais de até 3 meses para Quixadá.....	66
Figura 54: Ajuste dos resíduos - Quadrantes: 1º Normal Q-Q, 2º Plot dos resíduos, 3º autocorrelação, 4º autocorrelação parcial de Quixadá.....	66
Figura 55: Valor do Critério de Informação de Akaike (AIC) para Quixadá.....	67
Figura 56: Valor do Critério de Informação de Bayesiana (BIC) para Quixadá.....	68
Figura 57: Variável de desempenho- RMSE para Quixadá	68
Figura 58: Variável de desempenho- SRMSE para Quixadá	69
Figura 59: Série temporal para validação para Quixadá.....	69
Figura 60: Correlação Linear de Pearson considerando defasagens temporais de até 3 meses para Sobral.....	70
Figura 61: Ajuste dos resíduos - Quadrantes: 1º Normal Q-Q, 2º Plot dos resíduos, 3º autocorrelação, 4º autocorrelação parcial de Sobral.	71
Figura 62: Valor do Critério de Informação de Akaike (AIC) para Sobral.....	72
Figura 63: Valor do Critério de Informação de Bayesiana (BIC) para Sobral.	72
Figura 64: Variável de desempenho- RMSE para Sobral.	73
Figura 65: Variável de desempenho- SRMSE para Sobral	73
Figura 66: Série temporal para validação para Sobral.....	74
Figura 67: Correlação Linear de Pearson considerando defasagens temporais de até 3 meses para Tauá	75
Figura 68: Ajuste dos resíduos - Quadrantes: 1º Normal Q-Q, 2º Plot dos resíduos, 3º autocorrelação, 4º autocorrelação parcial de Tauá	75

Figura 69: Valor do Critério de Informação de Akaike (AIC) para Tauá	76
Figura 70: Valor do Critério de Informação de Bayesiana (BIC) para Tauá.....	76
Figura 71: Variável de desempenho- RMSE para Tauá	77
Figura 72: Variável de desempenho- RMSE para Tauá.....	77
Figura 73: Série temporal para validação para Tauá	78
Figura 74: Análise da Correlação Linear de Pearson para Tianguá	78

LISTA DE TABELAS

Quadro 1: MARCO DPSEEA (FORÇAS MOTRIZES, PRESSÃO, SITUAÇÃO, EXPOSIÇÃO, EFEITO, AÇÃO) **Erro! Indicador não definido.**

SUMÁRIO

1.	INTRODUÇÃO.....	14
1.1.	Objetivos.....	16
1.1.1.	Objetivo Geral	16
1.1.2.	Objetivos Específicos.....	16
2.	REVISÃO DA LITERATURA.....	17
2.1.	Dinâmica climática do nordeste brasileiro (NEB) e do Ceará	17
2.2.	Clima e saúde pública.....	19
2.3.	Arboviroses e vetores climáticos.....	21
2.4.	Previsão epidemiológica dos casos de dengue.....	23
3.	METODOLOGIA.....	26
3.1.	Tipo de Pesquisa.....	26
3.2.	Área de Estudo.....	27
3.3.	Modelo Epidemiológico da Dengue	29
3.4.	Software Rstudio.....	31
3.5.	Métricas de Avaliação	32
3.5.1.	AIC	32
3.5.2.	BIC.....	32
3.5.3.	RMSE	33
3.5.4.	SRMSE	33
4.	RESULTADOS	34
4.1.	Análise para Aracati.....	34
4.2.	Análise para Canindé	39
4.3.	Análise para Crateús	43
4.4.	Análise para Fortaleza.....	47
4.5.	Análise para Iguatu	51
4.6.	Análise para Itapipoca.....	56
4.7.	Análise para Juazeiro do Norte	60
4.8.	Análise para Morada Nova	61
4.9.	Análise para Quixadá	65
4.10.	Análise para Sobral	69
4.11.	Análise para Tauá.....	74
4.12.	Análise para Tianguá	78
5.	DISCUSSÃO	79
6.	CONCLUSÃO.....	81
	REFERÊNCIAS	83
	APÊNDICE	92

1. INTRODUÇÃO

O aumento da incidência do Zika vírus (ZIKV) e da Chikungunya (CHIKV) em áreas com alta presença do vírus da dengue (DENV) tornou-se um grande desafio para os serviços de saúde em diversos países. O crescimento dessas arboviroses¹, transmitidas principalmente pelo mosquito *Aedes aegypti* (do gênero *Aedes*), passou a ser uma questão de extrema relevância, especialmente em áreas urbanas, onde ocorre a maior proliferação do mosquito. Isso tem gerado um debate constante nas políticas de saúde pública (SIQUEIRA, 2022).

A dengue, atualmente, é definida como a arbovirose mais predominante do mundo. Anualmente, o número de casos de dengue clássica (DC) e da febre hemorrágica da dengue (FHD) vem aumentando (VIANA & IGNOTTI, 2013). A infecção pelo vírus da dengue resulta em diferentes quadros clínicos, desde assintomáticos até quadros sintomatológicos: Febre do Dengue (FD), quadros graves de Febre Hemorrágica do Dengue (FHD) e Síndrome do Choque do Dengue (SCD), dessa forma essas instabilidades de quadros podem evoluir para sintomas graves, em alguns casos resultando a morte. Diante disso, nas últimas décadas a doença se configurou como uma grande causa de morbidade e mortalidade no Brasil (MALECK, 2019).

O clima pode favorecer a disseminação de locais propícios para proliferação de vetores da Dengue. Elementos climáticos, como mudanças nos padrões de pluviometria e aumento de temperatura, podem acelerar as taxas de maturação e reprodução do mosquito, elevando a capacidade de transmissão do vírus (SAJIB et al., 2024). Nesse contexto, nos últimos anos, tem-se intensificado a busca de metodologias e estratégias que possam identificar e minimizar as causas e efeitos de doenças e suas relações com os fenômenos climáticos (SOUSA et al, 2018). Nessa perspectiva, Rahman et al. (2021) observaram que as variáveis climáticas exercem interferência direta no desenvolvimento, sobrevivência e hábitos alimentares do mosquito. Foi percebido que o ciclo de vida desse inseto sofre influência da temperatura, tendo propensão a ocorrer no intervalo térmico de 28 °C a 32 °C. Desvios nesses valores, seja em termos excessivamente baixos ou altos, podem ocasionar retardo no seu desenvolvimento ou aumentar sua mortalidade (HARRIS; CALDWELL; MORDECAI, 2019; MOREIRA et al., 2020).

Costa et al. (2022) investigaram a associação entre variabilidade hidroclimática interanual e sazonal e a incidência de dengue (2008-2018) em sete municípios de grande relevância socioeconômica no Ceará. A relação entre a incidência de dengue e variáveis

¹ Arboviroses são doenças causadas por arbovírus (Arthropod-borne virus), que por sua vez, são vírus transmitidos por artrópodes.

hidroclimáticas foi analisada por meio de regressão de mínimos quadrados generalizados (GLS). Os autores notaram que o início da quadra chuvosa, em fevereiro, também abre a temporada de dengue no estado do Ceará. Além disso, perceberam que no final da atuação da Zona de Convergência Intertropical (ZCIT) no Ceará, principal sistema indutor de chuvas no Estado, é o período de maior ocorrência de casos de dengue nos municípios de Fortaleza, Sobral e Barbalha. Quanto à modelagem da incidência de dengue, verificaram que as regressões GLS foram capazes de reproduzir o início, o desenvolvimento e o final da temporada de dengue, embora tenham encontrado subestimação dos picos e superestimação dos baixos índices de incidência.

Segundo Roy et al. (2024), elementos climáticos e sociodemográficos afetam a propagação da dengue. Embora precipitação, temperatura do ar e umidade relativa do ar possam influenciar o ciclo de vida dos mosquitos, a prevalência da dengue também está correlacionada com a urbanização, a diminuição da vegetação e a expansão populacional. Por isso, os índices de dengue tendem a ser maiores na zona urbana.

Conforme FERREIRA et al. (2023) e COSTA et al. (2022), o desenvolvimento de estudos de previsão epidemiológica dos casos de dengue também pode auxiliar na investigação dos efeitos do clima na saúde pública. As implicações na saúde variam de acordo com as escalas espaciais e de tempo, e depende de condições socioeconômicas e ambientais, com possibilidades de aumento da incidência de doenças ou modificação de sua abrangência geográfica. A avaliação de tendências e a quantificação da influência interanual na incidência da dengue é essencial na prevenção de surtos e no direcionamento de políticas públicas mais eficientes no combate à doença.

Nesse contexto, observa-se que os efeitos do clima nos casos de dengue são muito dependentes da localização e escala, o que dificulta a generalização dos resultados de pesquisa para regiões geográficas não estudadas. Além disso, pouco se sabe sobre os efeitos da variabilidade climática interanual na incidência de dengue em áreas urbanas de regiões tropicais secas (PAUL et al., 2021; BHATIA et al., 2022; COSTA et al., 2022; FERREIRA, 2023).

Investigações direcionadas a populações urbanizadas, localizadas em regiões climaticamente e sociodemograficamente favoráveis à incidência de dengue, são essenciais para identificar os elementos climáticos locais que influenciam a transmissão da doença. Com isso, é possível antecipar mudanças na magnitude e na sazonalidade dos surtos. A justificativa para esta pesquisa reside na necessidade de compreender como as variáveis hidroclimáticas impactam a dinâmica da transmissão da dengue, contribuindo para o desenvolvimento de modelos preditivos mais eficazes. A hipótese do trabalho é que as variações climáticas, como precipitação e temperatura, têm uma influência significativa na proliferação do mosquito *Aedes*

aegypti, e, portanto, na intensidade e periodicidade dos surtos de dengue nas áreas estudadas. Esse conhecimento pode fornecer subsídios cruciais para o planejamento de estratégias de controle mais eficientes, auxiliando os tomadores de decisão na implementação de medidas preventivas. (SIQUEIRA, 2018; BATISTA et al., 2021).

1.1. Objetivos

1.1.1. Objetivo Geral

Investigar a influência da precipitação e temperatura (máxima, média e mínima) na variabilidade interanual das incidências de casos de dengue e prever situações epidemiológicas em áreas urbanas, de clima tropical semi-árido, no Ceará.

1.1.2. Objetivos Específicos

- Analisar se variáveis climáticas, como precipitação e temperatura do ar, influenciam o número de casos de dengue;
- Criar um modelo de previsão epidemiológica com base nas variáveis que mais influenciam o crescimento de casos da doença;
- Validar o modelo de previsão epidemiológica dos casos de dengue.

2. REVISÃO DA LITERATURA

2.1. Dinâmica climática do nordeste brasileiro (NEB) e do Ceará

O clima do Nordeste Brasileiro (NEB) se distingue por amplas variações na distribuição da precipitação em escala espacial e temporal. No NEB, tanto os períodos prolongados de estiagem quanto os de alta pluviometria causam sérios problemas sociais e econômicos. A região está localizada na Zona Intertropical e seus sistemas meteorológicos mais atuantes em escala sazonal são Zona de Convergência Intertropical (ZCIT), Linhas de Instabilidade (LI), Vórtices Ciclônicos de Altos Níveis (VCAN), Distúrbios Ondulatórios de Leste (DOL) e Sistemas Frontais (SF). Outros fatores que afetam o clima da região são os fenômenos El Niño - Oscilação Sul (ENOS) e a Oscilação Decadal do Pacífico (ODP), que ocorrem em escala interanual e decadal, respectivamente (ARAÚJO JÚNIOR, 2018; FERREIRA & MELLO, 2005).

Na pré-estação chuvosa no NEB, que ocorre entre novembro e janeiro, os VCAN caracterizados por serem um sistema de baixa pressão em altos níveis da atmosfera, com circulação de ventos no sentido horário, comumente provocam chuvas significativas no Semiárido Brasileiro (REIS et al., 2021; FERREIRA et al., 2019). Os SF, como as Frentes Frias, que se formam no encontro entre uma massa de ar frio (mais densa) com uma massa de ar quente (menos densa), embora menos frequentes, podem atingir a região durante esse período, contribuindo para a formação de chuvas, especialmente nas áreas mais ao sul do Nordeste (FEDOROVA et al., 2016).

Durante a quadra chuvosa no NEB, de fevereiro a maio, o principal sistema indutor de chuvas no estado do Ceará é a ZCIT, que é uma zona de baixa pressão na região equatorial, formada pelo encontro dos ventos Alísios de Sudeste e de Nordeste em baixos níveis. Este realiza um deslocamento sazonal entre os hemisférios norte e sul, de modo que em anos normais², migra de uma posição mais ao norte, entre agosto e outubro, para uma posição mais ao sul, entre fevereiro e maio. Esse deslocamento está relacionado aos padrões de Temperatura da Superfície do Mar (TSM) sobre a bacia do oceano Atlântico Tropical e do Pacífico, dimensionando a pluviometria sobre o NEB (NOGUEIRA et al., 2024; OLÍMPIO & ZANELLA, 2015; FERREIRA & MELLO, 2005).

² Anos normais, são aqueles em que a pluviometria ficou em torno da média climatológica.

As Linhas de Instabilidade, formadas por nuvens do tipo cumulus de alta atividade convectiva, com bandas de nuvens em forma de linha, também tendem a atuar no NEB tanto durante o período da estação chuvosa, aumentando com a proximidade da ZCIT, principalmente em fevereiro e março, como durante o segundo semestre do ano, especialmente entre agosto e novembro (FERREIRA & MELLO, 2005).

Na pós-estação chuvosa no NEB, os DOL que são perturbações ondulatórias no campo dos ventos alísios, têm origem no Oceano Atlântico Tropical próximos à costa oeste da África e se propagam em direção ao oeste, tendo atuação mais pronunciada entre maio e julho, são responsáveis por chuvas intensas em estados litorâneos, como Ceará, Pernambuco, Alagoas, Sergipe e Bahia (SILVA et al, 2020; CAVALCANTE et al., 2020).

Anos secos ou chuvosos também estão relacionados à variabilidade climática interanual, que é significativamente influenciada por fenômenos como, El Niño-Oscilação Sul (ENOS) e o Gradiente Inter- Hemisférico da Temperatura da Superfície Mar (GRADM) do Atlântico no Brasil (LUCENA et al., 2010; WAINER et al., 2010; VASCONCELOS JÚNIOR et al., 2018).

O ENOS é dado como referência nas situações nos quais o oceano Pacífico Equatorial está mais quente (El Niño) ou mais frio (La Niña) do que a média normal histórica. As mudanças climáticas do oceano Pacífico Equatorial acarretam efeitos globais na temperatura e precipitação. O ENOS na fase positiva, estado mais quente, historicamente produz escassez hídrica no NEB e chuvas intensas no Sul/Sudeste do país. Já, o ENOS na fase negativa, estado mais frio, influencia a precipitação em grande parte da Região Norte e também em parte da Região Nordeste, com chuvas acima da média histórica para a atualidade, enquanto no Sul/Sudeste há uma tendência de redução da pluviometria (MEDEIROS & OLIVEIRA, 2021; ABREU et al., 2023)

O GRADM está relacionado a mudanças no regime de ventos alísios nos dois hemisférios do planeta devido ao gradiente de temperatura das águas do Atlântico Norte e do Atlântico Sul. No NEB, o GRADM influencia o deslocamento meridional da ZCIT tendendo a ocasionar escassez de chuvas na sua fase positiva (quando as águas do Atlântico Norte estão mais aquecidas que do Atlântico sul), enquanto que nos anos de precipitação intensa tal comportamento é oposto, sendo esta característica da fase negativa (LUCENA et al., 2011; CAVALCANTI, 2015; SILVA et al., 2021b).

O clima do NEB é significativamente influenciado pelas anomalias de temperatura da superfície do Oceano Pacífico tanto na escala interanual, já comentada acima, como na escala

decadal (SANTOS et al., 2023). A ODP, assim como o ENOS possui duas fases, quente e fria. As temperaturas das superfícies dos oceanos ficam mais aquecidas durante 20 a 30 anos e, em seguida, se resfriam durante outros 20 a 30 anos, totalizando um ciclo de 50 a 60 anos (Andreoli & Kayano, 2004; CAVALCANTI et al., 2009).

Estudos como o de Molion (2005), Andreoli e Kayano (2005) e Oliveira et al. (2017), mostraram que na fase negativa (ou fria) a ODP acarreta uma redução da frequência dos eventos de El Niño, e na fase positiva (ou quente) há uma tendência de aumento em número e intensidade de eventos de El Niño. Sendo, assim, a fase fria da ODP mais favorável a precipitação para o Nordeste Brasileiro.

2.2. Clima e saúde pública

As relações entre o clima e saúde humana são complexas, o aumento das temperaturas, a mudança de padrões climáticos e a degradação ambiental estão correlacionadas a doenças, como distúrbios respiratórios, problemas cardiovasculares e a disseminação de doenças transmitidas por vetores biológicos, afetando populações, especialmente as mais vulneráveis, em regiões socioeconômicas mais marginalizadas (Omeye, 2024).

Segundo Adamopoulos & Syrou (2024), a poluição do ar, aliada ao aumento de temperatura do planeta, tem intensificado doenças respiratórias e cardíacas. Estudos como os de Hasunuma et al. (2021), Hu et al. (2022) e Makrufardi et al. (2023) evidenciam a relação entre fatores ambientais e o aumento da prevalência e severidade da asma em crianças, por meio da tendência de crescimento de morbidade e mortalidade nesse público. Doenças cardiovasculares, como o Acidente Vascular Cerebral (AVC) e o Infarto Agudo do Miocárdio (IAM) podem ser influenciados pelo estresse térmico, predispondo potencialmente indivíduos vulneráveis a ruptura ou bloqueio dos vasos sanguíneos cerebrais ou cardíacos (MOREIRA et al., 2024). Silveira et al. (2021), Zhao et al. (2022) e Ohashi et al. (2023) notaram um aumento de internações e de mortalidade por AVC ou IAM associados a temperaturas extremas (muito elevadas e muito baixas)

Athirsha et al. (2024), em seu estudo de revisão, destacaram que a mudança climática em curso pode, alterar a sazonalidade de muitas doenças zoonóticas, acelerar os ciclos de vida dos vetores e criar condições favoráveis para patógenos, aumentando o risco de transmissão e levando a surtos mais frequentes e graves.

O clima não é o único aspecto que influencia geograficamente e que afeta as doenças suscetíveis aos elementos climáticos. As componentes não climáticas podem ter um efeito predominante, seja de maneira independente ou através de modificações do clima. Além disso, a compreensão das diversas causas que vão da mudança climática até os impactos na saúde, é importante na identificação das oportunidades de abordar os determinantes ambientais dos resultados deficientes de saúde (OPAS, 2014).

Os efeitos climáticos podem ter limitações de longo alcance para a saúde pública por meio de vulnerabilidades sociais inerentes que podem ampliar os impactos de vias de risco em cascata. Desenvolvimento de programas de controle podem ser incorporados ao uso da terra e determinantes socioeconômicos, buscando minimizar ou neutralizar indiretamente os impactos do aumento da variabilidade climática na transmissão ou exacerbação de doenças. Entender as fraquezas do sistema pode ajudar a promover a capacidade adaptativa e as medidas de intervenção (SEMENZA et al., 2022).

Pensando em estratégias para que os problemas de saúde fossem minimizados e em busca de compreender como o clima impacta na saúde pública, Kovats et al. (2005) desenvolveu um modelo hierárquico, denominado Marco DPSEEA (Forças Motrizes, Pressão, Situação, Exposição, Efeito, Ação), ver Quadro 1, afim de identificar os condicionantes ambientais ou de comportamento que afetam a saúde.

QUADRO 1: MARCO DPSEEA (FORÇAS MOTRIZES, PRESSÃO, SITUAÇÃO, EXPOSIÇÃO, EFEITO, AÇÃO)

FORÇAS MOTRIZES	MARCO DPSEEA	AÇÕES
	Políticas de Energia, agricultura e transporte; mudanças demográficas; mudanças no aproveitamento da terra; processo de urbanização.	Acordos internacionais (por exemplo, convenções das Nações Unidas como a CMNUCC, o CDB ou a CNUCLD)
	Emissões de gases de efeito estufa	Políticas nacionais de mitigação.

E S T A D O E X P O S I Ç Ã O E F E I T O	A mudança climática.	Políticas de adaptação e programas de gestão de riscos.
	Fenômenos meteorológico extremos (secas, inundações, ondas de calor); mudanças em ecossistemas; escassez de água; disponibilidade de alimentos; mudanças na distribuição de vetores.	Indicadores, acompanhamento, sistemas de vigilância, políticas de saúde pública, proteção ambiental.
	Doenças suscetíveis ao clima, entre elas cardiovasculares, respiratórias agudas e crônicas, diarreias agudas, mentais, transmitidas por vetores; má nutrição; lesões.	Diagnóstico e tratamento.

Fonte: Adaptado de OPAS (2014).

Então através das forças motrizes, entendeu-se, os principais fatores que geram os processos ambientais resultando em pressões sobre o ambiente. Dessa forma, o estado do meio ambiente é alterado com mudanças que podem ser mais complexas, de ampla abrangência e de diferentes escalas geográficas (OPAS, 2014).

Para que ocorra uma melhora atraente nos resultados entre a saúde e a dinâmica climática, programas e instituições de saúde pública têm buscado implementar, monitorar e avaliar serviços, programas e políticas inclusivos para proteger a saúde das pessoas dos riscos ambientais (OPAS, 2014).

2.3. Arboviroses e vetores climáticos

O arbovírus são transmitidos por artrópodes e são identificados não somente pela sua forma de veiculação, mas, principalmente, pelo fato de parte de seu ciclo de desenvolvimento ocorrer nos insetos. Os sintomas que podem aparecer em seres humanos podem variar desde de doença febril a um quadro moderado ou grave, apresentando erupções cutâneas, artralgia, síndrome neurológica e síndrome hemorrágica em alguns casos (CHAVES, 2021). O Brasil por sua larga extensão territorial, aproximadamente 8.510.000 km², está localizado em uma área de clima predominantemente tropical sendo um local adequado para a disseminação de insetos e vetores, consequentemente a proliferação de doenças.

O vírus do Nilo Ocidental (WNV) pode causar epidemias inclusive em áreas urbanas. É transmitido por mosquitos do gênero *Culex* e tem as aves como principais reservatórios. Alguns

vírus perderam a exigência de amplificação enzoótica³ e produzem epidemias urbanas tendo exclusivamente o homem como amplificador vertebrado. É o caso dos vírus da Dengue, Chikungunya e, mais recentemente, Zika.

A circulação de infecção por Dengue, Chikungunya e Zika no país dificulta o manejo dentro dos hospitais ou clínicas, devido a similaridade entre os sintomas. Implicações na transmissão de idosos, grávidas e crianças apresenta uma maior atenção. A interação de arboviroses (DENV sorotipos 1-4, CHIKV e ZIKV) poderia teoricamente resultar em viremias mais intensas ou outras alterações imunológicas que, por sua vez, agiriam como gatilho para doenças autoimunes, como a síndrome de Guillain-Barré (CHAVES, 2021). O Tempo e o clima são fatores importantes na determinação do comportamento do mosquito e na eficácia da transmissão do vírus da dengue. No entanto, a investigação sobre a relação entre as variáveis meteorológicas e a dengue limita-se principalmente aos valores médios de temperatura e estes ignoram o importante papel da variabilidade a curto prazo (LIU-HELMERSSON et al., 2014).

O desenvolvimento social e econômico faz com que o Dengue acompanhe o homem em seus empreendimentos, migrações e aglomerações no decorrer da história. E vários estudos veem mostrando os diversos caminhos que levam a transmissão. Mesmo sendo considerada uma doença urbana, casos frequentes estão sendo registrados em áreas rurais, abrindo ferramentas para que sejam desenvolvidos estudos para realizar análise da situação. O mosquito possui uma forte capacidade de adaptação (DONALÍSIO & GLASSER, 2002).

O referido autor ainda ressalta que o *Aedes aegypti* vetor marcadamente domiciliado, utiliza diversos tipos de criadouros, independentemente dos períodos de chuva, sugerindo que o pico de transmissão não está relacionado com a densidade do vetor, mas sim com o prolongamento da vida do mosquito em sua fase adulta nas condições de temperatura e umidade da estação chuvosa aumentando a probabilidade de as fêmeas infectadas completarem o período de replicação do vírus.

De acordo um estudo realizado no Estado de Goiás foi constatado a associação e pluviosidade e aumento dos casos de Dengue nos municípios de estudo. Havendo picos específicos nos 4 primeiros meses dos anos, dos quais são considerados os mais chuvosos. Sendo que a infestação do mosquito chegou a 97,5% de infestação em diversos municípios

³ Enzoótica é o equivalente não humano de endêmico e significa, em sentido amplo, "pertencente a" ou "nativo de", "característica de" ou "prevalente em" uma determinada geografia, raça, campo, área ou ambiente; nativo de uma área ou escopo.

goianos. Assim o autor também aponta a longevidade do *Aedes aegypti* durante o período chuvoso e o aumento de temperatura. Este último tem sido usado como um fator modelador para outros estados adotando a pluviosidade como um fator de pequenas interferências (SOUSA, 2010).

2.4. Previsão epidemiológica dos casos de dengue

De acordo um estudo realizado no Estado de Goiás foi constatado a associação e pluviosidade e aumento dos casos de Dengue nos municípios de estudo. Havendo picos específicos nos 4 primeiros meses dos anos, dos quais são considerados os mais chuvosos. Sendo que a infestação do mosquito chegou a 97,5% de infestação em diversos municípios goianos. Assim o autor também aponta a longevidade do *Aedes aegypti* durante o período chuvoso e o aumento de temperatura. Este último tem sido usado como um fator modelador para outros estados adotando a pluviosidade como um fator de pequenas interferências (SOUSA, 2010).

A criação de ferramentas para prever os casos de dengue é considerado algo complexo, mas diversos estudos e técnicas estão sendo elaborados, pois existem fatores que podem contribuir significativamente, ajudando as pesquisas na área de proliferação e aparecimento da doença. Técnicas de *Machine Learning* e de *Deep Learning*, vem influenciando nos estudos de análises de dados climáticos, como dados de temperatura, precipitação e umidade (BATISTA et al., 2021). A progressão da dengue, depende de condições ecológicas e sócio-ambientais que facilitam a dispersão do vetor.

Para os estudos de séries temporais, modelos matemáticos e estatísticos, mais especificamente as ferramentas de análises de séries temporais, têm sido amplamente utilizados para monitorar e prever a incidência de dengue e outras doenças infecciosas. Permitindo previsões do número de casos em períodos posterior a séries estudada. SARIMA (*Seasonal Autoregressive Integrate Moving Average*), destaca-se como um modelo útil em situações em que os dados das séries temporais exibem flutuações sazonais constantes (LIZZI et al., 2012).

Segundo Silva & Rosa (2018), um modelo matemático aplicado à sistemas dinâmicos epidemiológicos é a representação de um sistema, utilizando uma linguagem e ferramentas matemáticas, na busca de explicar o comportamento da doença, a sua propagação, os seus efeitos. Podendo ainda servir para prever os impactos da disseminação e das formas de controle de doenças. Dessa forma os modelos matemáticos aplicados a epidemiologia, podem ser úteis para fornecer estimativas sobre as formas mais eficazes de controle.

Costa et al. (2022) investigaram a associação entre a variabilidade hidroclimática e a incidência de dengue em uma grande área tropical seca. A influência entre as variáveis foi extraída por meio da regressão de mínimos quadrados generalizados (GLS). Os resultados mostraram que a variação interanual da dengue na região de estudo é modulada pela precipitação e temperatura. As regressões foram capazes de capturar o início, o desenvolvimento e o fim da temporada de dengue, apesar da subestimação dos picos e superestimação dos vales de incidência do vetor. Os autores ainda ressaltam que os desvios entre os dados previstos e observados não são um problema no caso de os modelos serem utilizados para avaliação do impacto de mudanças climáticas na incidência de dengue em escala municipal, visto que conseguiram representar bem a sazonalidade da incidência de dengue.

Batista et al. (2021) fazem uma revisão sistemática dos modelos de previsão de casos de dengue através de técnicas de *machine learning* e *deep learning*. A revisão diagnosticou que as técnicas de Random Forest (RF), Support Vector Regression (SVR) e Long Short-Term Memory (LSTM) são as mais utilizadas para prever os casos de dengue usando informações climáticas. O artigo ainda ressalta que a técnica de Root Mean Absolute Error (RMSE) é a preferida para mensurar o erro.

Em um estudo realizado no México, dados em escalas anuais relacionando dengue e temperaturas foram utilizados para analisar a dinâmica temporal e produzir previsões precisas da dengue. A dinâmica temporal dos dados foi obtida através de métodos de autocodificação, janelas de contagem e agrupamento de séries temporais colocados em cascata para capturar possíveis associações entre dengue e temperatura. Em seguida, foi utilizado o método de previsão do vizinho mais próximo (KNN) baseado em associação de tendência para prever o número de casos de dengue. Os resultados comprovaram a viabilidade da metodologia proposta, podendo esta concorrer com outros métodos de previsão de última geração (APPICE, 2020).

Mittelman e Soares (2017) usam dois tipos de arquitetura de redes neurais artificiais (RNAs) para prever o número de casos de dengue em Guarulhos - São Paulo. Dados de precipitação total, temperatura máxima média, temperatura mínima média e umidade relativa são utilizados para treinar redes de perceptron multicamadas (MLP) e redes autorregressivas com entradas exógenas (NARX). As redes MLP adotadas no estudo foram constituídas de cinco entradas, uma camada intermediária com “n” neurônios e um neurônio na camada de saída, já as redes NARX utilizou 12 entradas, em que se considerou os mesmos dados de entrada das redes MLP porém defasados até dois meses em relação a dengue, além de dois atrasos de

retroalimentação. O melhor desempenho foi obtida pela MLP com 10 neurônios na camada oculta, função de ativação logística e algoritmo de treinamento de regularização Bayesiana.

Diante do exposto, é evidente que o enfrentamento das arboviroses no Brasil exige uma abordagem integrada, que considere tanto os elementos climáticos quanto os socioambientais. A combinação de dados meteorológicos com técnicas avançadas de previsão, como os modelos matemáticos e métodos de aprendizado de máquina, apresenta-se como uma ferramenta promissora para antecipar surtos e orientar estratégias de prevenção. No entanto, a eficácia dessas iniciativas depende de investimentos contínuos em pesquisa, infraestrutura de saúde pública e educação sanitária da população. Somente com ações coordenadas entre governo, comunidade científica e sociedade civil será possível reduzir de forma significativa os impactos das doenças transmitidas por vetores, promovendo um ambiente mais seguro e saudável para todos.

3. METODOLOGIA

3.1. Tipo de Pesquisa

Trata-se de um estudo epidemiológico do tipo ecológico, de abordagem quantitativa e descritiva, de série temporal. Optou-se pelo estudo ecológico porque possibilita a comparação de um determinado objeto de estudo, no caso a dengue, com uma ou mais variáveis de interesse (LIMA-COSTA & BARRETO, 2003). Os dados coletados são correspondentes ao período 2008-2018 (11 anos) e incluem, os casos confirmados por dengue e dados meteorológicos para 12 município do estado do Ceará (Ver Figura 02). O estudo será realizado utilizando a correlação entre a dinâmica climática e a ocorrência de casos de dengue.

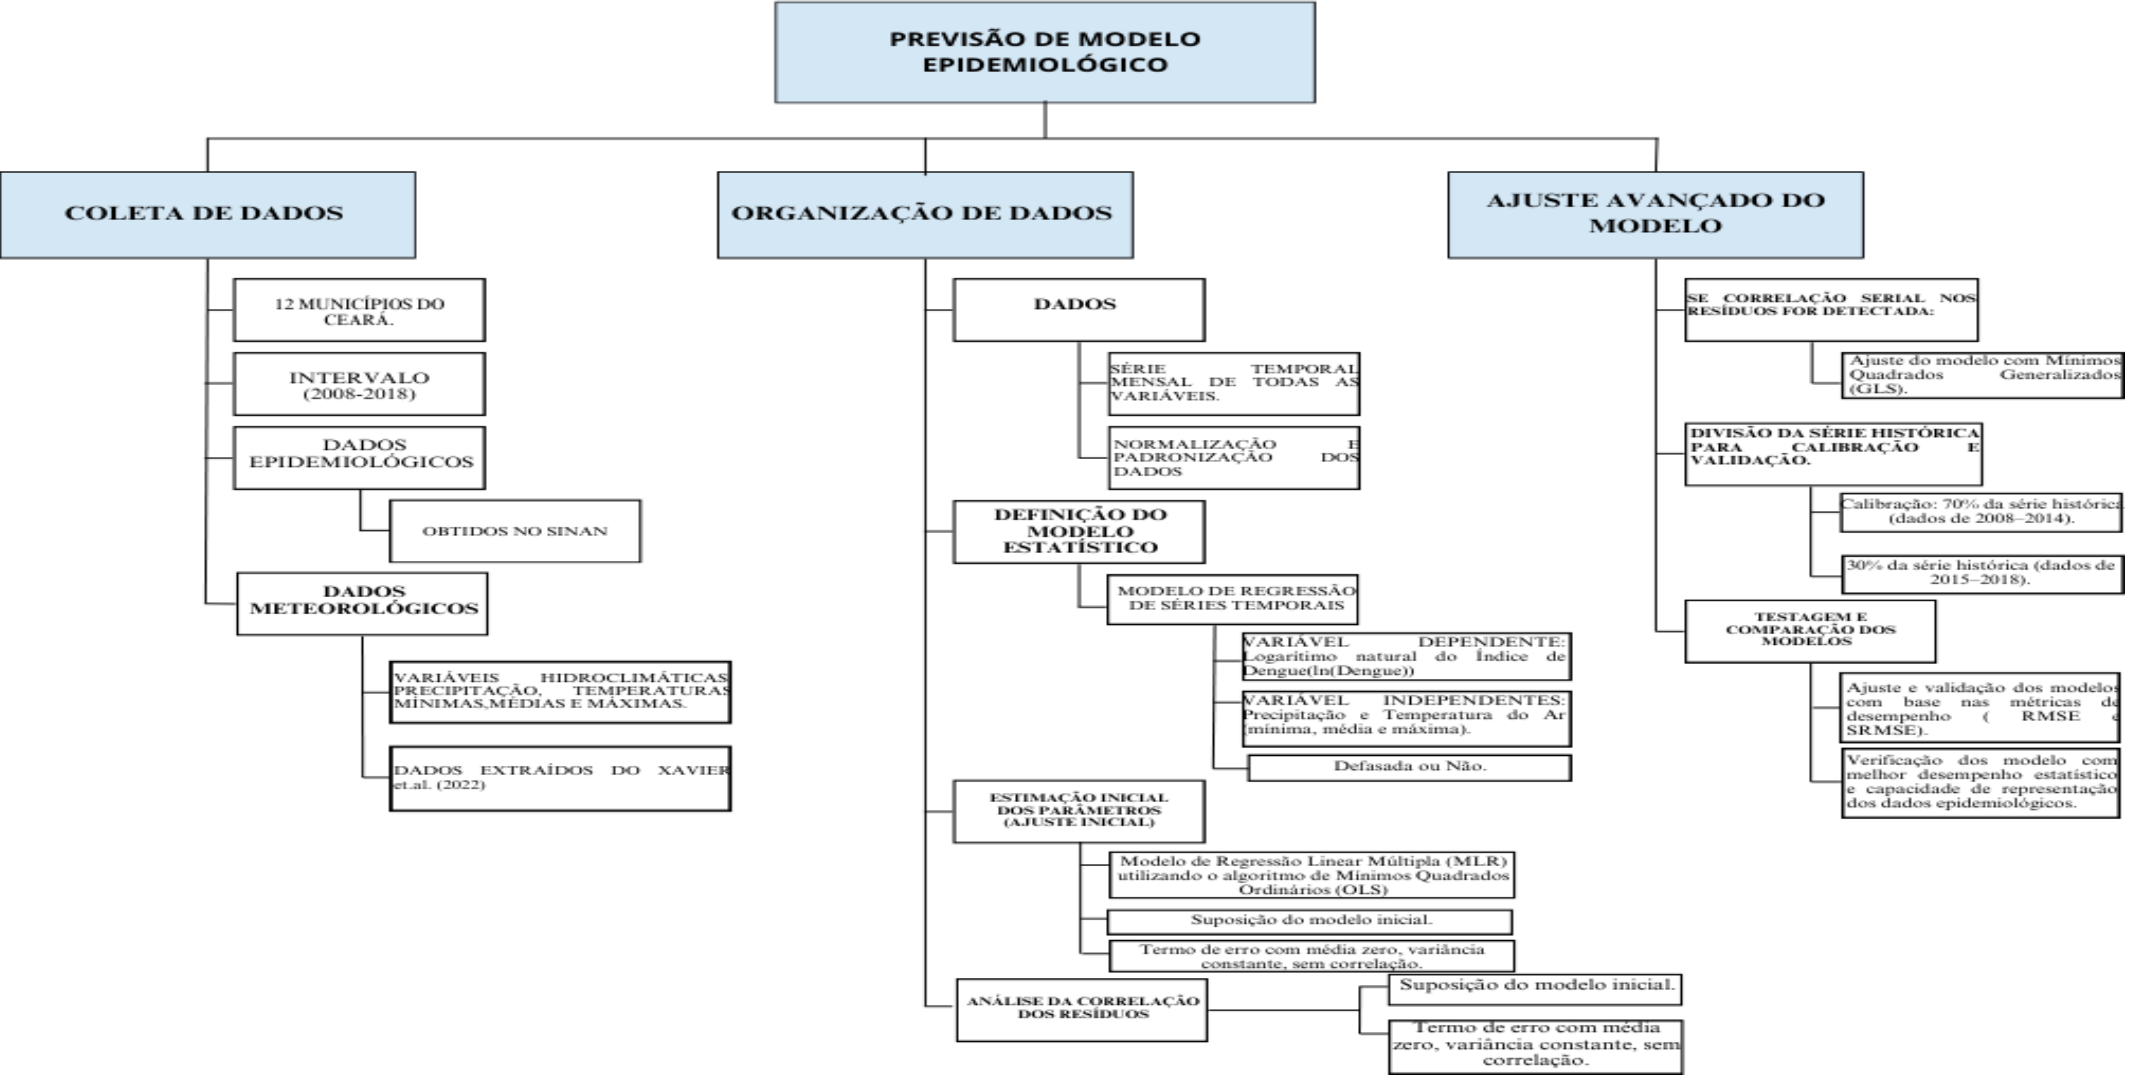
O fluxograma, mostrado na Figura 01, detalha as etapas do delineamento do estudo. Inicialmente, são obtidos os dados de dengue do Sistema de Informação de Agravos de Notificação (SINAN) e variáveis hidroclimáticas de Xavier et al. (2022), referentes a 12 municípios do Ceará no período de 2008 a 2018. Em seguida, os dados são organizados em uma série temporal mensal, com normalização e padronização, se necessário. Define-se o modelo estatístico com o \ln (Dengue) como variável dependente e variáveis explicativas como precipitação e temperaturas mínima, média e máxima, que podem ser defasadas até 3 meses em relação a Dengue. Os parâmetros do modelo de regressão linear múltipla (MLR) são inicialmente estimados pelo método dos Mínimos Quadrados Ordinários (OLS), assumindo erros não correlacionados. A série histórica é dividida em 70% para calibração (2008-2014) e 30% para validação (2015-2018). Após o ajuste, os modelos são testados e comparados com métricas de desempenho, selecionando o mais adequado. Por fim, os resultados são avaliados e interpretados para compreender a associação entre o Índice de Dengue e as variáveis hidroclimáticas. Mais informações sobre as etapas serão apresentadas nas seções a seguir.

3.2. Área de Estudo

O estado do Ceará é composto por 184 municípios, entre os quais destacam-se Aracati, Canindé, Crateús, Fortaleza, Iguatu, Itapipoca, Juazeiro do Norte, Morada Nova, Quixadá, Sobral, Tauá e Tianguá (Ver Figura 02). Esses municípios apresentam características socioeconômicas diversas que refletem a heterogeneidade do estado.

Fortaleza, a capital estadual, é o principal centro econômico e populacional do Ceará, concentrando grande parte das atividades industriais, comerciais e de serviços. Municípios como Sobral e Juazeiro do Norte também se destacam como polos regionais de desenvolvimento (Ver Tabela 1), possuindo economias diversificadas e infraestrutura significativa.

Figura 1: Fluxograma de delineamento.



De acordo com as estimativas populacionais mais recentes do Instituto Brasileiro de Geografia e Estatística (IBGE, 2023), o Ceará possui uma população de 8.794.957 de habitantes. A distribuição populacional é desigual, com maior concentração nas áreas metropolitanas e litorâneas, enquanto regiões do interior apresentam densidades demográficas menores. A maioria dos municípios possuem índice de desenvolvimento humano (IDH) entre 0,600 e 0,699, classificado como de categoria média. Logo abaixo apresentasse o IDH juntamente com outras dados socioeconômicos relevantes para cada um dos municípios em estudo (Ver Tabela 1).

O IDH é uma métrica que avalia o desenvolvimento de municípios, regiões, estados ou países em 3 dimensões básicas, saúde, educação e renda. Entre os municípios selecionados para o estudo, Fortaleza é o que possui o maior IDH, 0,754, evidenciando a qualidade de vida dos fortalezenses devido a uma maior qualidade da educação e maior renda dos seus habitantes em relação aos outros municípios.

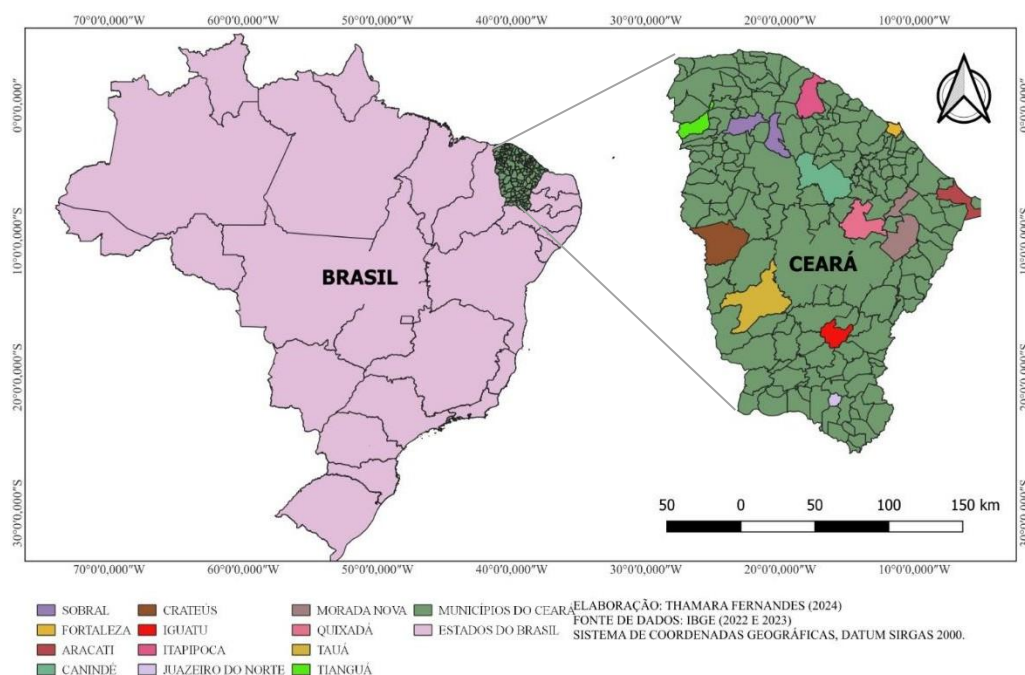
Tabela 1– Dados Socioeconômicos de 12 municípios cearenses.

MUNICÍPIO	ÁREA TERRITORIAL (Km ²)	Nº DE HABITANTES	ÍNDICE DE DESENVOLVIMENTO HUMANO MUNICIPAL- IDHM	ÁREA URBANIZADA (Km ²)	ESGOTAMENTO SANITÁRIO ADEQUADO (%)
ARACATI	1227,197	75.113	0,655	19,83	4,50
CANINDE	3032,390	74.174	0,612	10,20	23,2
CRATEÚS	2981,459	76.390	0,644	14,92	47,9
FORTALEZA	312353	2428708	0,754	253,69	74,0
IGUATU	992208	98064	0,677	19,46	27,4
ITAPIOCA	1600,358	131123	0,640	25,40	32,9
JUAZEIRO DO NORTE	258788	286120	0,694	51,44	47,20
MORADA NOVA	2763971	61443	0,610	11,69	9,10
QUIXADA	2020,586	84168	0,659	11,27	52,70
SOBRAL	2068,474	203023	0,714	31,17	75,60
TAUÁ	4010,618	61227	0,633	10,29	32,30
TIANGUÁ	909853	81506	0,657	18,88	39,40

Fonte: Instituto Brasileiro de Geografia e Estatística- IBGE, 2022.

A cobertura de esgotamento sanitário é um indicador crucial de infraestrutura e saúde pública, pois quando maior seu percentual, menores são as chances de contaminação do solo, da água e de propagação de doenças. Conforme Tabela 01, Fortaleza tem a maior cobertura, com 74% de esgotamento sanitário adequado, enquanto Aracati só tem um percentual de 4,5%. Segundo o ranking do saneamento do Instituto Trata Brasil de 2024 (ITB, 2024), entre as 100 cidades brasileiras com melhor nível de atendimento de esgotamento sanitário, Fortaleza está na 68ª posição.

Figura 2: Localização dos 12 município cearenses estudados.



Fonte: Autora, 2025.

Considerando componentes climáticas, o Ceará é marcado por altas temperaturas, baixos níveis de umidade e chuvas irregulares, devido seu ambiente semiárido. A temperatura média frequentemente excede 30 °C, especialmente durante a estação seca (Rodrigues et al., 2021). A quadra chuvosa, que ocorre de fevereiro a maio, é o período mais úmido do ano no Ceará. Durante esses meses, o estado recebe a maior parte de sua precipitação anual, sendo crucial para a agricultura e o abastecimento hídrico (NOGUEIRA et al., 2024; OLÍMPIO & ZANELLA, 2015). Em 2024, por exemplo, a quadra chuvosa registrou um acumulado de 764 mm, ficando acima da média histórica (CEARÁ, 2024). O principal sistema meteorológico responsável pelas chuvas no Ceará durante a quadra chuvosa é a ZCIT.

Em relação a presença de mosquito *Aedes aegypti*, no Ceará há registros desde o ano de 1851 com noticiada erradicação em 1950. Em 1986 houve a reintrodução dos casos de dengue nos municípios de Fortaleza, Aquiraz e Beberibe. Desde então, a doença permanece como um problema grave de saúde pública com epidemias cada vez mais frequentes. A partir de 1986, registrou-se ao menos 14 anos com epidemia de dengue no Ceará, com a circulação de quatro sorotipos da doença (DENV1 - 1986, DENV2 - 1994, DENV3 - 2002 e DENV4 - 2011). A partir de 2015, o Ceará passou a apresentar um cenário diferenciado de tripla epidemia, com a circulação autóctone de dois outros arbovírus Chikungunya e Zika (Cavalcanti et al., 2018).

3.3. Modelo Epidemiológico da Dengue

Nesta pesquisa analisaram-se as variáveis dependentes de casos confirmados de dengue, juntamente com variáveis independentes, como precipitação, temperatura máxima, temperatura média e temperatura mínima do ar. Na regressão linear simples tem-se uma variável independente X e uma variável dependente Y. Para um determinado valor de X, estima-se o valor médio de Y escrevendo essa relação numa perspectiva condicional $E(Y | X)$, ou apenas como $\mu(X)$. Como $\mu(X)$ varia com X, então é permitido dizer que Y tem uma regressão em X. A presença ou ausência de relação linear pode ser investigada sob dois pontos de vista:

- I. Quantificando a força dessa relação: **Correlação.**
- II. Explicitando a forma dessa relação: **Regressão.**

A regressão linear múltipla é uma técnica estatística que usa várias variáveis explicativas para prever o resultado de uma variável de resposta. A regressão múltipla é uma extensão da regressão linear simples que usa apenas uma variável explicativa. Em busca de analisar e avaliar a força da relação entre um resultado (variável dependente) e variáveis preditoras, bem como a importância de cada um dos preditores para a relação.

Os dados utilizados, extraídos dos bancos de dados de Xavier et al. (2022), são correspondentes ao período de 2008 a 2018 para as variáveis temperatura média (Tmed), temperatura máxima (Tmax), temperatura mínima (Tmin), precipitação acumulada (Prec) e número de casos confirmados de dengue, com um intervalo mensal. O estudo foi realizado utilizando a correlação de Pearson, com variáveis relacionadas a dinâmicas climáticas (precipitação e temperatura) com a ocorrência de casos de dengue.

O coeficiente de correlação de Pearson é uma medida de associação bivariada do grau de relacionamento entre duas variáveis. A correlação mensura a direção e o grau da relação linear entre duas variáveis quantitativas. Sua fórmula é apresentada abaixo:

$$r = \frac{1}{n-1} \sum \left(\frac{x_i - \bar{X}}{S_x} \right) \left(\frac{y_i - \bar{Y}}{S_y} \right) \quad (1)$$

Em relação as análises estatísticas, duas variáveis se associam quando elas guardam semelhanças nas distribuições. No caso da correlação de Pearson (r), a associação ocorre pela variância compartilhada entre duas variáveis. A relação linear desse coeficiente sugere que o aumento ou diminuição da variável X gera um impacto proporcional em Y , isto implica que a melhor forma de ilustrar o relacionamento entre duas variáveis é por meio uma linha reta, portanto a correlação de Pearson exige uma distribuição linear dessa variação (FIGUEIREDO FILHO & SILVA JÚNIOR, 2009).

As correlações amostrais foram calculadas para associações sem lag e com lag de 1 a 3 meses, em que lag é o período de tempo que separa as séries temporais, a fim de verificar a influência da defasagem temporal de no máximo 3 meses entre os dados climáticos e os dados de dengue.

A fim de compreender se as correlações obtidas são estatisticamente significativas é necessário, para tanto, partindo do objetivo, formular: H_0 e H_1 , estabelecer os graus de liberdade ($N-2$) e realizar o teste t-student para r_{xy} , em que:

$$t = \frac{r \sqrt{N-2}}{\sqrt{1-r^2}} \quad (2)$$

Para o teste de significância, que busca comprovar a relevância estatística da influência dos dados de climáticos nos casos de dengue, formulou-se as seguintes hipóteses:

$H_0: \rho=0$ (Não existe correlação)

$H_1: \rho \neq 0$ (Existe correlação)

Arbitrando-se nível crítico de significância para 5% (0,05), como a probabilidade de rejeitar a hipótese nula.

O conjunto de dados de observações mensais caracteriza uma série temporal onde foi usado a aplicação da Correlação de Pearson, uma vez que este modelo considera a correlação linear entre duas variáveis. (FAGUNDES et al., 2021). Para nosso caso será aplicado o uso de Correlação Cruzada (ACF) que permite identificação de correlações que ocorrem em qualquer período. Esse método é capaz de estimar estatisticamente a correlação entre duas séries temporais tendo o tempo incluído como uma variável. Dentro do contexto conseguimos identificar um atraso ou defasagem que chamamos de lag, podendo adquirir valores positivos ou negativos.

Após encontrar as variáveis independentes mais significativas estatisticamente, um modelo epidemiológico da dengue foi ajustado considerando o logaritmo natural do número de

casos de dengue (Y_t) como variável alvo e as variáveis climáticas selecionadas (x_{t1}, \dots, x_{tp}), como a precipitação (mm) e a temperatura do ar (mínima, média e máxima, °C), que podem estar defasadas em relação ao alvo ou não, como potenciais variáveis explicativas:

$$Y_t = \beta_0 + \beta_1 x_{t1} + \dots + \beta_p x_{tp} + E_t \quad (3)$$

Usando o algoritmo dos mínimos quadrados ordinários (OLS), os parâmetros β_1, \dots, β_p são estimados assumindo o termo de erro E_t com média zero, variância constante e nenhuma correlação. Aplicando OLS, o método passo a passo reverso produziu preditores com defasagem variando de 0 a 3.

O Apêndice mostra o código na linguagem R, comentado no subtópico abaixo, aplicado ao município de Fortaleza, informando todos os passos realizados para o desenvolvimento, aplicação e validação do modelo epidemiológico. Ressalta-se que a função “`gls`” que aparece no código se refere apenas a sintaxe da linguagem de programação, mas é a função OLS que está sendo aplicada, visto que quando as suposições clássicas são válidas, ou seja considera-se os erros independentes com distribuição normal, média zero e variância constante, a GLS se reduz a OLS conforme o teorema de Gauss-Markov (MAIA, 2017).

3.4. Software Rstudio

As análises estatísticas, bem como as análises gráficas, apresentadas neste trabalho foram realizadas por meio do ambiente de desenvolvimento integrado (do inglês, IDE) do RStudio®. O RStudio IDE constitui uma plataforma moderna que integra programação, geração de imagens e importação de dados em um único ambiente. O RStudio IDE opera através da linguagem de programação R, uma linguagem aberta, livre e com destaque na área de análise de dados e modelagem. Por operar através de bibliotecas de funções, muitas desenvolvidas e validadas pela comunidade de programadores de R, a linguagem R possui aplicações em diferentes áreas do conhecimento, desde a estatística clássica, psicologia, biologia até tópicos modernos como a big data. Além de contribuir para uma pesquisa com foco na reprodutibilidade dos resultados, o desenvolvimento de pesquisas quantitativas aliadas a uma linguagem de programação torna possível a implementação de soluções não disponíveis em softwares comerciais. (MASSA, 2017).

3.5. Métricas de Avaliação

As métricas de avaliação são utilizadas principalmente para averiguar a assertividade de modelos preditivos. Elas são capazes de retornar de maneira objetiva em um único valor o desempenho entre as previsões e os valores reais, sendo utilizadas como um parâmetro de comparação para os resultados obtidos com diferentes algoritmos aplicados em um mesmo conjunto de dados. A combinação dessas métricas em um sistema de avaliação é capaz de gerar

conclusões mais consistentes a respeito da usabilidade dos modelos. Neste capítulo serão apresentados as quatro métricas utilizadas para parametrizar e escolher o melhor modelo preditivo, sendo elas: AIC, BIC, RMSE, SMRSE.

3.5.1. AIC

O Critério de Informação de Akaike (AIC) é fundamentado na teoria da informação. Esta métrica mensura a qualidade de um modelo estatístico considerando sua simplicidade. Em outras palavras, o AIC estima a quantidade relativa de informação perdida por um determinado modelo. Quanto menor a perda de informação maior é a qualidade do modelo e menor é o valor AIC (TRAN, 2011; McELREATH, 2016). Matematicamente, o AIC tem a seguinte formulação:

$$AIC = -2\ln(L) + 2k \quad (4)$$

L = verossimilhança do modelo (mede o ajuste do modelo aos dados);

k = número de parâmetros estimados no modelo.

3.5.2. BIC

O Critério de Informação de Bayesiana (BIC) é similar ao AIC, mas penaliza mais fortemente modelos complexos, especialmente quando o tamanho da amostra (n) é grande. Semelhante ao AIC, quanto menor o valor BIC melhor é o modelo (TRAN, 2011; AGIAKLOGLOU & TSIMPANOS, 2022). A formulação do BIC é dada por:

$$BIC = -2\ln(L) + k \cdot \ln(n) \quad (5)$$

L = verossimilhança do modelo (mede o ajuste do modelo aos dados);

k = número de parâmetros estimados no modelo.

n = número de observações do modelo;

3.5.3. RMSE

A raiz do erro quadrático médio (RMSE, do inglês Root Mean Square Error) é uma métrica que estima a diferença média entre os valores previstos e os valores observados, em outras palavras, ela fornece a precisão da previsão em relação ao valor alvo. Uma característica interessante do RMSE é que ele estima o erro na unidade de medida da variável alvo, facilitando a interpretação do resultado. Valores elevados de RMSE, indicam o modelo não é de boa qualidade, enquanto valores baixos de RMSE, demonstram modelos de boa qualidade. Ressalta-se que valores altos ou baixos dependem do contexto da análise (CHAI et al., 2014; GANJI & KAJISA, 2019; HODSON, 2022). A definição matemática de RMSE é dada por:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - p_i)^2} \quad (6)$$

n = número de observações do modelo;

γ_i = valor real da observação i ;

p_i = valor previsto pelo modelo para a observação.

3.5.4. SRMSE

O erro quadrático médio padronizado (SRMSE) é definido como o RMSE dividido pelo desvio padrão da série observada (Perreti et al., 2013). A padronização do RMSE permite a comparação entre diferentes conjuntos de dados ou modelos, facilitando a interpretação e a comparação entre diferentes contextos. Se o SRMSE for maior que 1 (um) indica que o resultado da modelagem é menos precisa do que simplesmente assumir a média dos dados observados, se próximo de 0 (zero) implica em uma melhor correspondência entre o dado modelado e o observado.

4. RESULTADOS

O presente estudo investiga a influência da precipitação e temperaturas (máxima, média e mínima) na variabilidade inter anual das incidências de casos de dengue em 12 áreas urbanas, de clima tropical semi-árido. Considerando as correlações encontradas, para cada município descrito, entre as variáveis explanatórias e de resposta no intervalo definido entre 2008 e 2018. Considerando os diversos pré-testes realizados, estabeleceu-se como regra inicial de escolha das variáveis preditoras (temperaturas mínima, média, máxima, precipitações), aquelas cuja correlação apresentou valores maiores que 0,20 ou menores que -0,20. Em seguida, é feita uma análise de quais dessas variáveis explicativas têm significância estatística (ver Tabela 2) e verificado se os erros não estão autocorrelacionados. Com isso, procede-se com o treinamento/calibração e validação dos modelos., conforme explanado no capítulo metodológico (Seção 3).

4.1. Análise da Correlação Linear e dos Resíduos

As Figuras 3 a 14 retratam a Correlação Linear de Pearson considerando defasagens temporais de até 3 meses para os 12 municípios em estudo. Já as Figuras 15 a 24 mostram uma análise dos resíduos, por meio da plotagem os erros, por meio da comparação de distribuições de probabilidades Normais (Normal Q-Q plot), avaliação da autocorrelação total e parcial.

Considerando a defasagem máxima de 3 meses para todas as variáveis independentes, observa-se que, para o município de Aracati, a variável precipitação com defasagens de (t-1) e (t-2) encontra-se dentro do intervalo estabelecido pela regra inicial de seleção de variáveis. Quanto às temperaturas, apenas a temperatura mínima com defasagem (t-3) se enquadra, conforme ilustrado na Figura 3.

Na sequência, foi realizada a verificação do ajuste dos resíduos do modelo, com o objetivo de quantificar a discrepância em relação aos valores observados e avaliar a qualidade do ajuste (Figura 15). No quadrante 1, apresenta-se o gráfico de probabilidades “Normal Q-Q plot”, que compara dados independentes gerados aleatoriamente (eixo vertical) a uma distribuição normal teórica (eixo horizontal). A linearidade dos pontos sugere que os resíduos seguem uma distribuição normal.

No quadrante 2, o gráfico dos resíduos indica que os erros se distribuem aleatoriamente em torno de zero, variando entre -2 e 2, sem exibir tendência estatística, o que sugere que o modelo é adequado. O terceiro quadrante mostra a autocorrelação do erro, ou seja, a correlação do erro com ele mesmo considerando defasagens seriais. As linhas tracejadas horizontais indicam um intervalo de confiança de 95% para a significância das correlações, revelando que, para Aracati, apenas a série sem defasagem apresentou autocorrelação, indicando que o erro é

aleatório e não tende a se repetir ao longo da distribuição. O quarto quadrante apresenta a autocorrelação parcial do erro, que identifica a relação entre o resíduo e suas próprias defasagens, eliminando a influência das defasagens intermediárias. Assim como no quadrante anterior, as linhas tracejadas indicam um intervalo de confiança de 95%. A análise mostra que os resíduos não são autocorrelacionados, permitindo a utilização de modelos de regressão linear.

Em Canindé, município com 74.174 habitantes, as variáveis selecionadas dentro do intervalo definido foram: precipitação sem defasagem e com defasagem de 1 mês (t-1); temperatura máxima sem defasagem e com lag de 1 mês (t-1); temperatura mínima com defasagens (t-1, t-2 e t-3); e temperatura média sem lag e com defasagem (t-3), conforme apresentado na Figura 4.

A Figura 16 exibe o estudo detalhado dos resíduos do modelo aplicado. No quadrante 1, observa-se que o gráfico Q-Q tende a repousar sobre a linha $y = x$, indicando que o erro segue uma distribuição normal. No quadrante 2, verifica-se que os erros dos 132 pontos de previsão são aparentemente aleatórios e independentes, característica confirmada pelos quadrantes 3 e 4, os quais indicam ausência de correlação serial dos resíduos.

Para Crateús, a Figura 5 apresenta as correlações entre cada variável climática e a série de número de casos de dengue. As variáveis selecionadas, por estarem dentro do intervalo predefinido, foram: precipitação (t-1); temperatura máxima sem defasagem e com defasagem (t-1); temperatura mínima (t-3); e temperatura média sem defasagem e com defasagem (t-1).

Na etapa de ajuste dos resíduos, conforme o Quadrante 1 da Figura 17, os dados cobrem toda a extensão da reta, com maior concentração entre os intervalos de -1 e 1, indicando boa adequação dos erros à distribuição normal. Os quadrantes 2, 3 e 4 indicam que os erros são irregulares, mas não significativamente autocorrelacionados, o que valida o desenvolvimento do modelo de regressão por mínimos quadrados ordinários.

Em Fortaleza, capital metropolitana do estado do Ceará, a análise revelou que várias variáveis apresentaram correlações dentro do intervalo estabelecido: precipitação sem defasagem e com defasagens (t-1, t-2 e t-3); temperatura máxima sem defasagem e com defasagem (t-1); temperatura mínima (t-3); e temperatura média sem defasagem, conforme a Figura 6.

A análise do ajuste dos resíduos, ilustrada na Figura 18, mostra que no quadrante 1, o gráfico de probabilidade “Normal Q-Q plot” apresenta linearidade das séries, com leve desvio nos dados extremos, sem comprometer a suposição de normalidade dos erros. No quadrante 2, os resíduos variam entre -2 e 2, sem exibir tendência estatística, o que valida a adequação do modelo. Nos quadrantes 3 e 4, verifica-se que não há valores acima da linha pontilhada azul, indicando ausência de autocorrelação significativa, o que reforça a viabilidade do uso de modelos de regressão linear.

Para Iguatu, conforme a Figura 7, as variáveis selecionadas foram: precipitação com defasagens (t-1), (t-2) e (t-3); temperaturas máxima e média sem defasagem e com defasagens (t-1) e (t-2); e temperatura mínima sem defasagem, todas dentro do limite inicialmente definido.

Na Figura 19, a análise do ajuste residual evidencia que, no quadrante 1, há linearidade nos pontos do gráfico “Normal Q-Q plot”, indicando boa distribuição dos resíduos. No quadrante 2, os erros se distribuem aleatoriamente em torno de zero, variando entre -3 e 1, sugerindo a adequação do modelo. Nos quadrantes 3 e 4, observa-se que nenhuma variável ultrapassa o limite de confiança de 95%, o que confirma a inexistência de autocorrelação significativa nos resíduos.

Em Itapipoca, conforme a Figura 8, as variáveis pré-selecionadas foram precipitação, temperatura máxima e temperatura média, todas sem defasagem, além da temperatura mínima com defasagem em (t-3). A Figura 20 apresenta o estudo dos resíduos, indicando, no quadrante 1, que o gráfico se aproxima da linha que define a distribuição teórica, sugerindo normalidade dos erros. No quadrante 2, verifica-se que a previsão é aleatória e independente, sendo corroborada pelos quadrantes 3 e 4, que mostram ausência de autocorrelação significativa, com todos os valores abaixo do limite estabelecido pelo tracejado azul.

No município de Juazeiro do Norte, conforme indicado na Figura 9, os dados não apresentaram correlação dentro do critério inicial de seleção, inviabilizando a construção de um modelo de série temporal ajustado aos dados. Mesmo ao extrapolar os critérios e testar modelos com todas as variáveis explicativas (com ou sem defasagens), não foi possível encontrar um modelo de regressão satisfatório.

Em Morada Nova, as variáveis selecionadas dentro do intervalo inicial foram: precipitação com defasagens (t-1), (t-2) e (t-3); temperatura máxima sem defasagem e com defasagens (t-1), (t-2) e (t-3); temperatura mínima (t-3); e temperatura média sem defasagem e com defasagens (t-1) e (t-2), conforme apresentado na Figura 10.

Na Figura 21, a aplicação do modelo revela, no quadrante 1, que o ajuste do erro permitiu maior linearidade dos resíduos em relação à reta de distribuição normal. No quadrante 2, observa-se variação independente e aleatória dos resíduos, sem indícios de periodicidade, o que é confirmado pelos quadrantes 3 e 4, que mostram ausência de defasagens do resíduo estatisticamente significativas.

Em Quixadá, conforme a Figura 11, foram selecionadas as seguintes variáveis: precipitação com defasagens (t-1) e (t-2); temperatura máxima sem defasagem e com defasagem (t-1); temperatura mínima com defasagens (t-2) e (t-3); e temperatura média sem defasagem. A Figura 22, que avalia o ajuste dos resíduos, demonstra, nos quadrantes 1 e 2, que o erro se comporta como ruído branco com distribuição normal. Nos quadrantes 3 e 4, apenas a autocorrelação do erro sem defasagem fica fora do intervalo de confiança, enquanto a


autocorrelação parcial não apresenta defasagens acima dos limites, permitindo a aplicação de modelos de regressão linear.

Em Sobral, conforme a Figura 12, foram selecionadas: temperatura máxima com defasagens (t-2) e (t-3) e temperatura mínima sem defasagem. A Figura 23 evidencia, no quadrante 1, linearidade dos resíduos, indicando bom ajuste à distribuição normal. No quadrante 2, observa-se variação entre -2 e 2, com forte presença de picos ao longo da série. O quadrante 3 apresenta dois valores de autocorrelação acima do limite, mas estes ocorrem fora do período de defasagem considerado (até 3 meses). No quadrante 4, há correlações significativas para os lags 2, 5 e 11; contudo, estas são de baixa amplitude, consideradas insignificantes.

Em Tauá, as variáveis selecionadas foram: temperatura mínima com defasagens (t-1), (t-2) e (t-3); e temperatura média com defasagem (t-3), conforme a Figura 13. A análise dos resíduos, apresentada na Figura 24, confirma nos quadrantes 1 e 2 que o erro é aleatório e normalmente distribuído. Nos quadrantes 3 e 4, verifica-se que não há autocorrelação significativa, mantendo-se todas as lags dentro do intervalo de confiança de 95%.


Por fim, no município de Tianguá, conforme Figura 14, as variáveis explicativas não apresentaram correlação significativa com a dengue dentro do critério inicial, inviabilizando a construção de um modelo de série temporal. Assim como em Juazeiro do Norte, não foi possível desenvolver um modelo viável para este município.

Figura 3: Correlação Linear de Pearson considerando defasagens temporais de até 3 meses para Aracati.



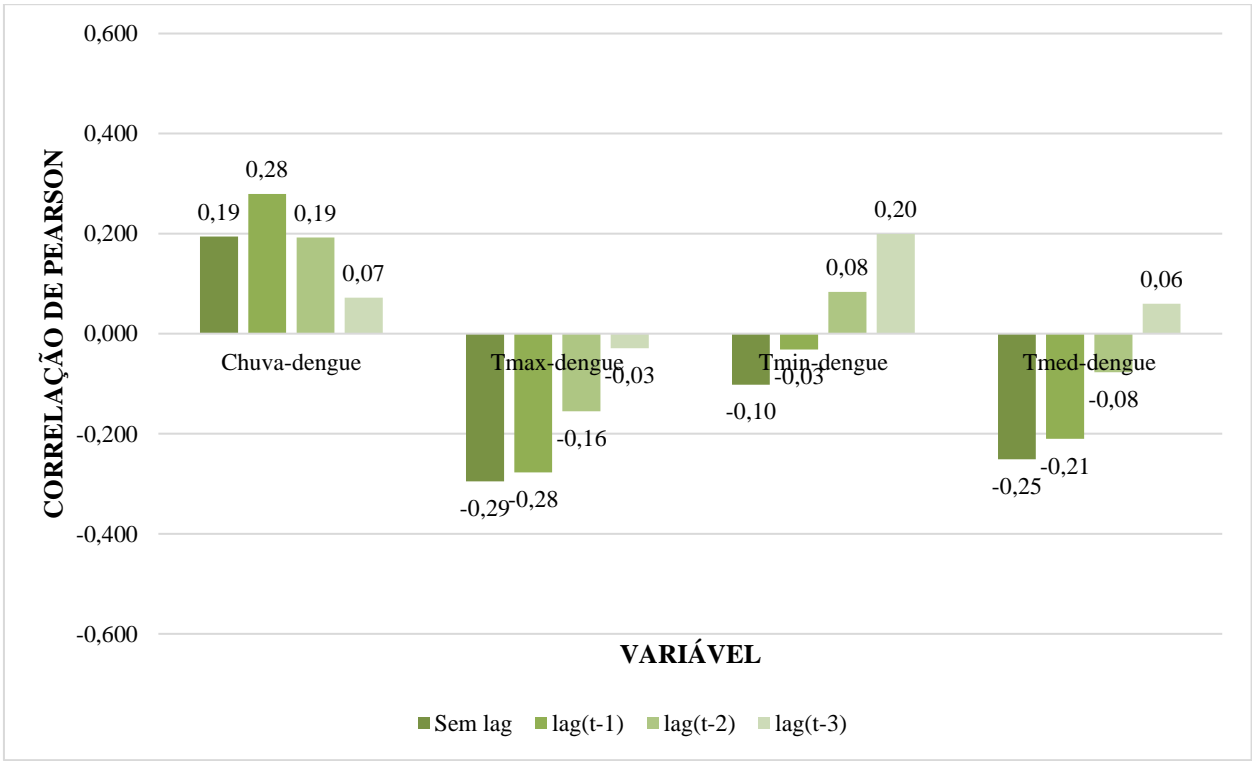
Fonte: Autor, 2024.

Figura 4: Correlação Linear de Pearson considerando defasagens temporais de até 3 meses para Canindé.




Fonte: Autor, 2024.

Figura 5: Correlação Linear de Pearson considerando defasagens temporais de até 3 meses para Crateús.




Fonte: Autor, 2024.

Figura 6: Correlação Linear de Pearson considerando defasagens temporais de até 3 meses para Fortaleza.



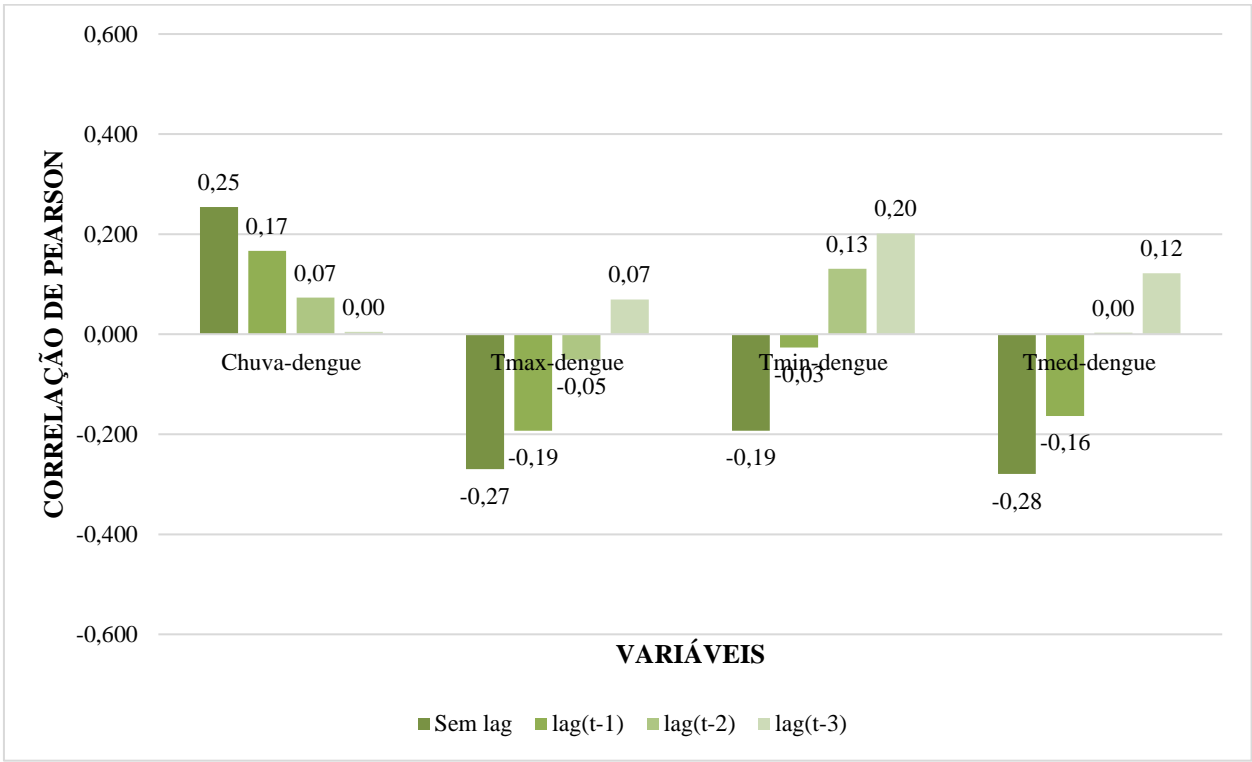
Fonte: Autor, 2024.

Figura 7: Correlação Linear de Pearson considerando defasagens temporais de até 3 meses para Iguatu.




Fonte: Autor, 2024.

Figura 8: Correlação Linear de Pearson considerando defasagens temporais de até 3 meses para Itapipoca.




Fonte: Autor, 2024.

Figura 9: Correlação Linear de Pearson considerando defasagens temporais de até 3 meses para Juazeiro do Norte.




Fonte: Autor, 2024.

Figura 10: Correlação Linear de Pearson considerando defasagens temporais de até 3 meses para Morada Nova.




Fonte: Autor, 2024.

Figura 11: Correlação Linear de Pearson considerando defasagens temporais de até 3 meses para Quixadá.




Fonte: Autor, 2024.

Figura 12: Correlação Linear de Pearson considerando defasagens temporais de até 3 meses para Sobral.



Fonte: Autor, 2024.

Figura 13: Correlação Linear de Pearson considerando defasagens temporais de até 3 meses para Tauá.



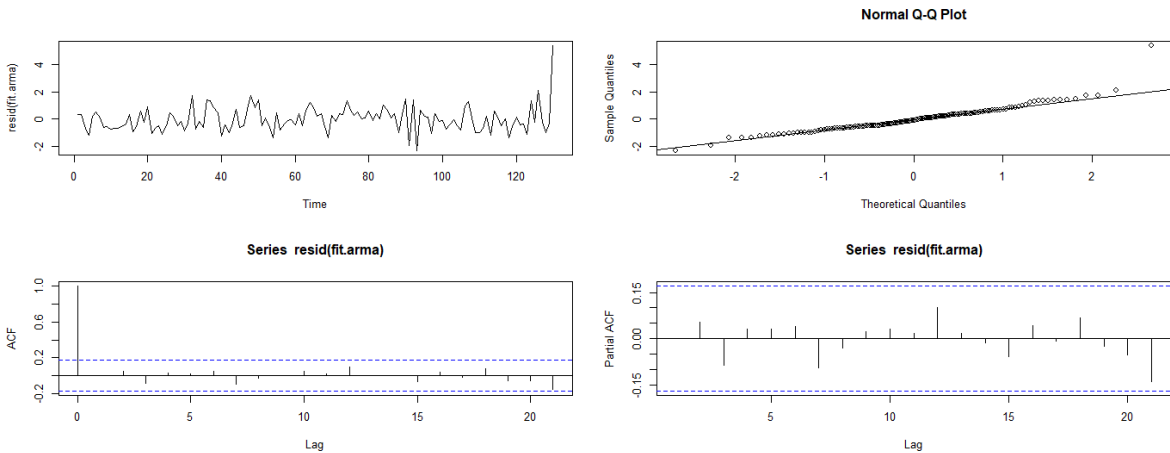
Fonte: Autor, 2024.

Figura 14: Correlação Linear de Pearson considerando defasagens temporais de até 3 meses para Tianguá.



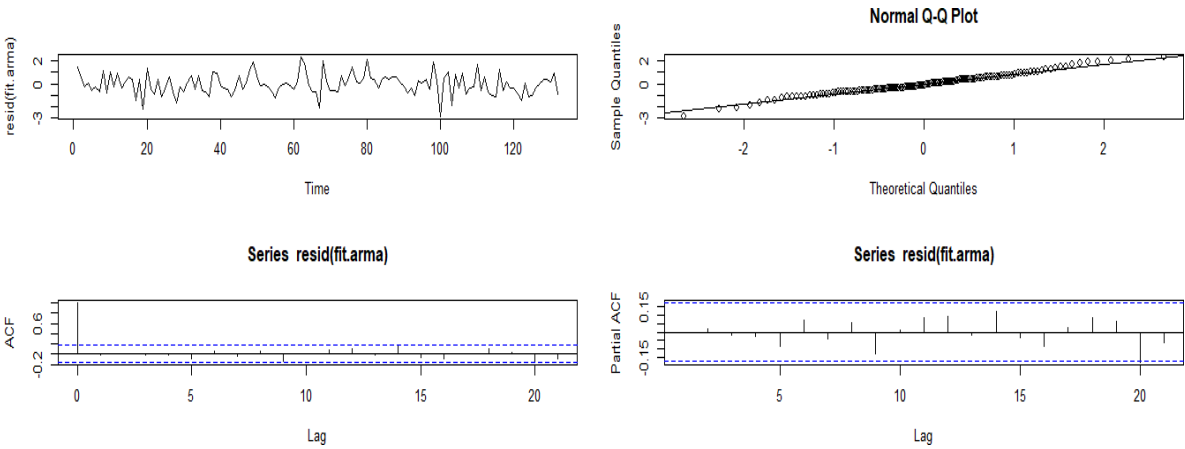
Fonte: Autor, 2024.

Figura 15: Ajuste dos resíduos - Quadrantes: 1º Normal Q-Q, 2º Plot dos resíduos, 3º autocorrelação, 4º autocorrelação parcial de Aracati.



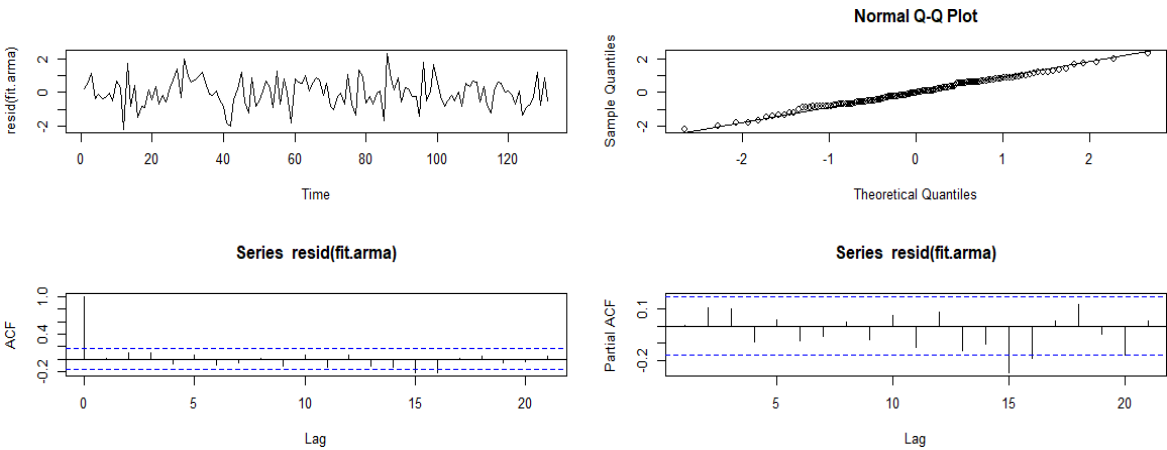
Fonte: Autor, 2024.

Figura 16: Ajuste dos resíduos - Quadrantes: 1º Normal Q-Q, 2º Plot dos resíduos, 3º autocorrelação, 4º autocorrelação parcial de Canindé.



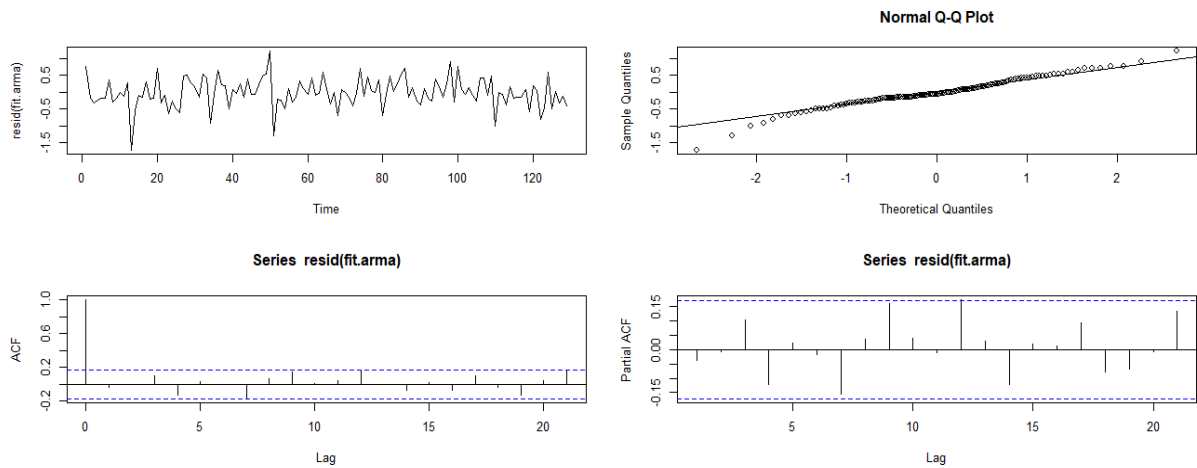
Fonte: Autor, 2024.

Figura 17: Ajuste dos resíduos - Quadrantes: 1º Normal Q-Q, 2º Plot dos resíduos, 3º autocorrelação, 4º autocorrelação parcial de Crateús.



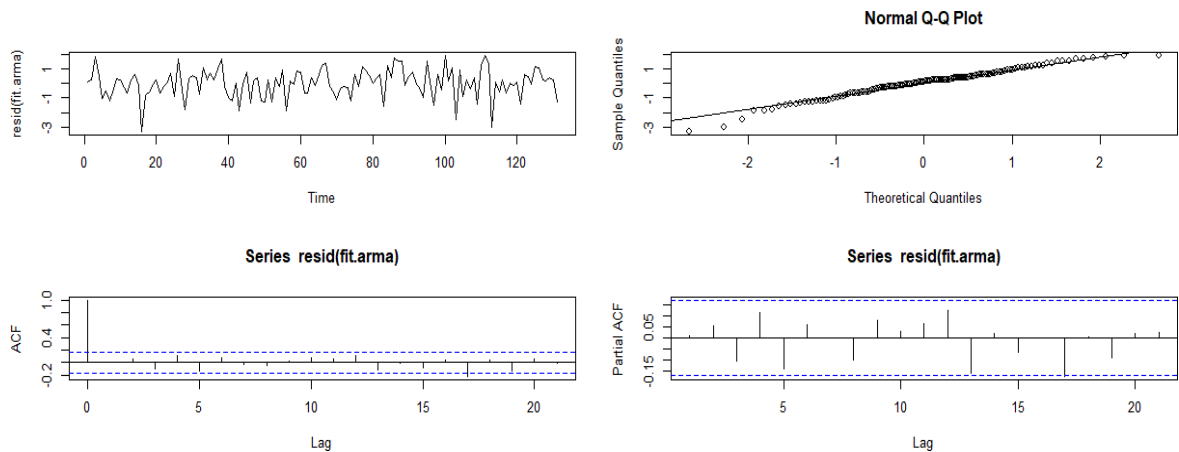
Fonte: Autor, 2024.

Figura 18: Ajuste dos resíduos - Quadrantes: 1º Normal Q-Q, 2º Plot dos resíduos, 3º autocorrelação, 4º autocorrelação parcial de Fortaleza.



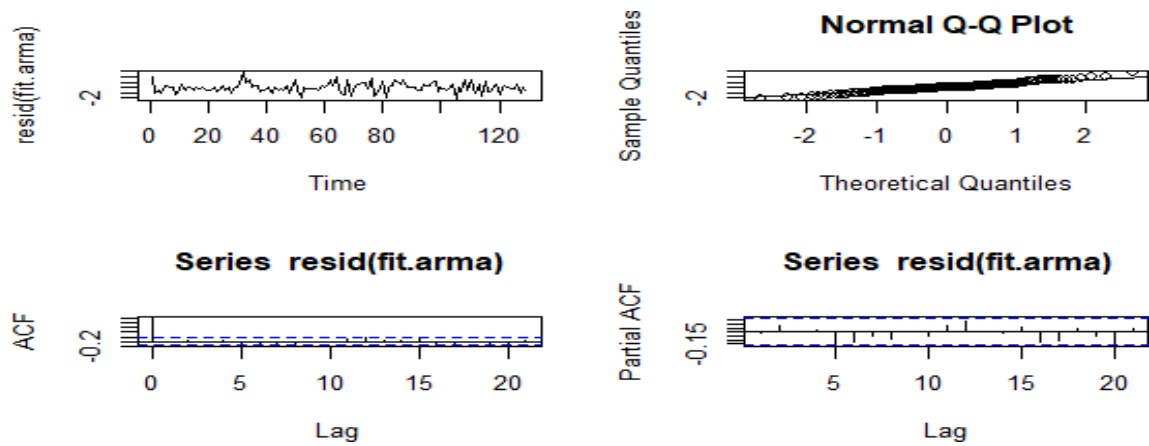
Fonte: Autor, 2024.

Figura 19: Ajuste dos resíduos - Quadrantes: 1º Normal Q-Q, 2º Plot dos resíduos, 3º autocorrelação, 4º autocorrelação parcial de Iguatu.



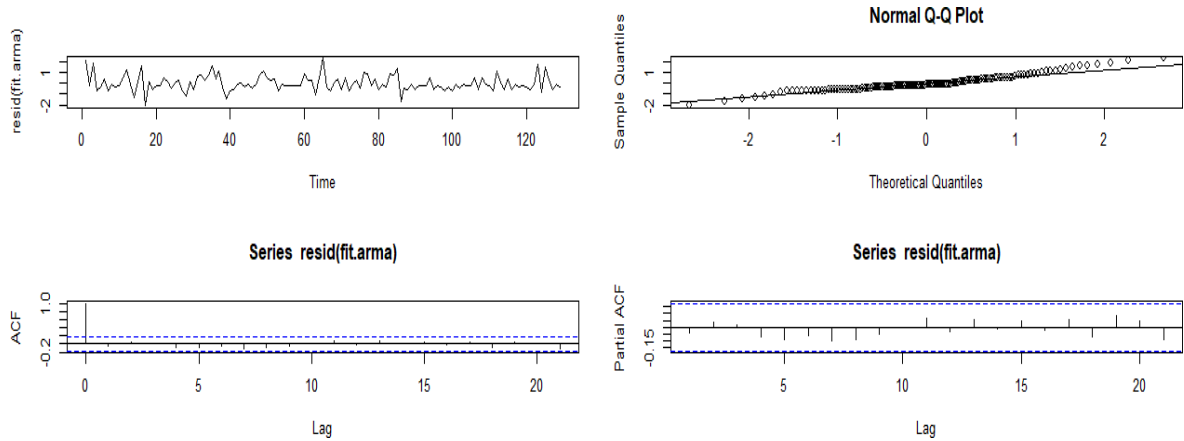
Fonte: Autor, 2024.

Figura 20: Ajuste dos resíduos - Quadrantes: 1º Normal Q-Q, 2º Plot dos resíduos, 3º autocorrelação, 4º autocorrelação parcial de Itapipoca.



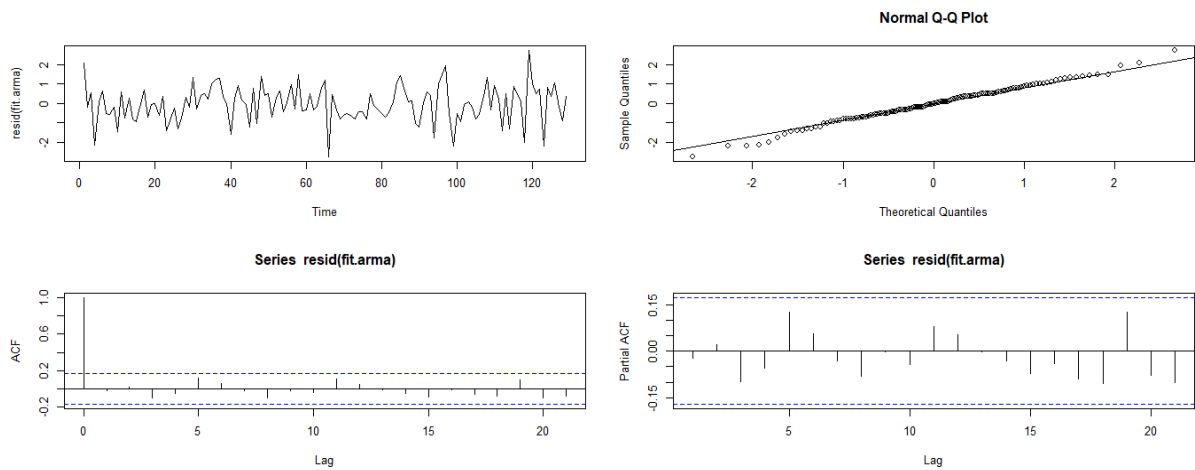
Fonte: Autor, 2024.

Figura 21: Ajuste dos resíduos - Quadrantes: 1º Normal Q-Q, 2º Plot dos resíduos, 3º autocorrelação, 4º autocorrelação parcial de Morada Nova.



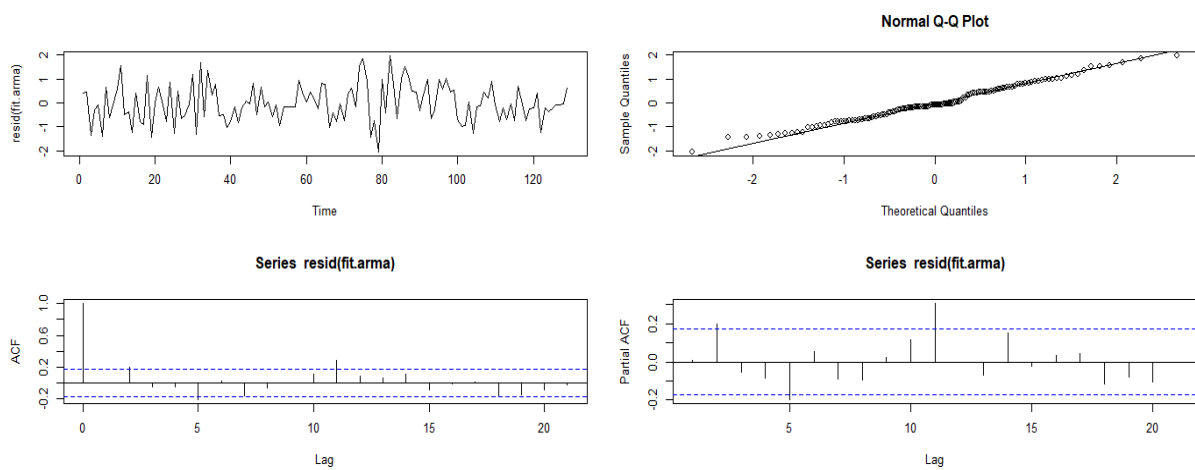
Fonte: Autor, 2024.

Figura 22: Ajuste dos resíduos - Quadrantes: 1º Normal Q-Q, 2º Plot dos resíduos, 3º autocorrelação, 4º autocorrelação parcial de Quixadá.



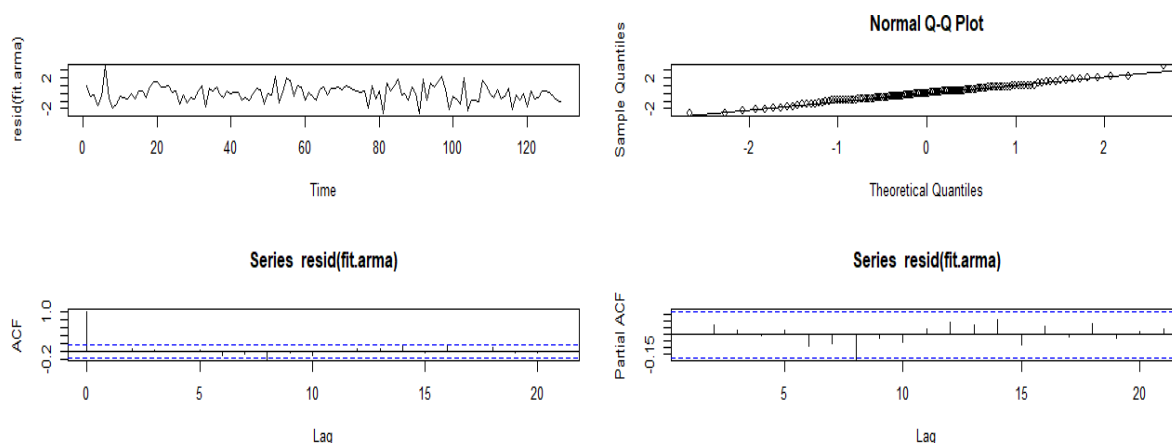
Fonte: Autor, 2024.

Figura 23: Ajuste dos resíduos - Quadrantes: 1º Normal Q-Q, 2º Plot dos resíduos, 3º autocorrelação, 4º autocorrelação parcial de Sobral.



Fonte: Autor, 2024.

Figura 24: Ajuste dos resíduos - Quadrantes: 1º Normal Q-Q, 2º Plot dos resíduos, 3º autocorrelação, 4º autocorrelação parcial de Tauá.



Fonte: Autor, 2024.

4.1.1. Variáveis mais significativas

A relação entre as variáveis ocorreu por meio do ajuste do modelo de regressão usando o método dos mínimos quadrados ordinários (GLS, do Inglês), em que a dengue é o principal alvo de estudo e as variáveis hidroclimáticas de maior significância podem possuir uma defasagem de até 3 meses em cada município.

Para Aracati apenas a temperatura mínima defasada de 3 meses ($t-3$), passou no teste de significância, de modo que a calibração foi realizada considerando apenas essa variável.

Em Canindé o treinamento dos dados foi realizado considerando a temperatura máxima e média sem lag, conforme definido pelo teste de significância da correlação realizado no modelo de aplicação.

Para Crateús, após o teste de significância apenas a temperatura média ($t-1$) foi excluída por não atingir o limite de confiabilidade. Com isso as variáveis precipitação ($t-1$), temperatura máxima sem defasagem, temperatura mínima ($t-3$), e temperatura média sem defasagem e com defasagem ($t-1$) foram utilizada como variáveis preditoras do modelo epidemiológico.

Em Fortaleza, considerando o intervalo de confiança de 95% para a significância das correlações, três variáveis foram selecionadas: precipitação com defasagens ($t-1$) e ($t-2$) e temperatura mínima ($t-3$), compondo assim o modelo de aplicação.

Para Iguatu, apenas a precipitação defasada em 1 mês ($t-1$) e temperatura mínima sem defasagem, passaram no teste de significância, considerando apenas essas variáveis para realização da calibração do modelo.

Em Itapipoca em seguida ao teste de significância, obteve-se temperatura mínima defasada em 3 meses ($t-3$), sendo considerada apenas esta para a calibração do modelo previsto.

Município	Intercept	Variável significativa de treinamento	Coefficiente
Aracati	-14,624	Temperatura mínima(t-3)	0,712
Canindé	10,630	Temperatura máxima	-1,222
		Temperatura média	1,103
Crateús	12,697	Temperatura máxima	-0,449
		Temperatura máxima(t-1)	-0,471
		Temperatura média	0,519
		Temperatura média(t-1)	0,227
		Precipitação(t-1)	-0,001
Fortaleza	-5,626	Temperatura mínima(t-3)	0,500
		Precipitação(t-1)	0,003
		Precipitação(t-2)	0,002
Iguatu	11,502	Temperatura mínima	-0,460
		Precipitação(t-1)	0,005
Itapipoca	-13,041	Temperatura mínima(t-3)	0,611
Juazeiro do Norte	Não possui variáveis estatisticamente significativas		
Morada Nova	0,441	Precipitação(t-3)	0,006
Quixadá	-14,521	Temperatura mínima(t-3)	0,710
Sobral	-8,923	Temperatura máxima(t-3)	-0,174
		Temperatura mínima(t-3)	0,739
Tauá	-10,713	Temperatura mínima(t-3)	0,623
Tianguá	Não possui variáveis estatisticamente significativas		

Tabela 2: Coeficientes das variáveis mais significativas para cada município.

Fonte: Autor, 2024.

Juazeiro do Norte não possui modelo de regressão viável dentro do contexto da pesquisa, mesmo após extrapolação da seleção inicial de variáveis explanatórias, em que foi considerada todas as variáveis explicativas (precipitação, temperatura máxima, temperatura mínima e temperatura média com ou sem defasagens) em estudo.

No município de Morada Nova, das 11 variáveis dentro do intervalo de seleção inicial, considerando as possibilidade de sem defasagem e com defasagem citadas na seção anterior, apenas a precipitação (t-3) foi considerada significativa.

Após o ajuste do modelo de regressão para Quixadá, as variáveis que tiveram o melhor resultado de significância após a realização dos testes foi a temperatura mínima (t-3), que será considerada para calibração do modelo.

Para Sobral, após a seleção das variáveis preditoras com os resultados dentro do intervalo permitido, não houve valor que atendesse ao nível de significância. Entranto, um modelo foi gerado considerando as variáveis previamente selecionadas.

Em Tauá, das 4 variáveis selecionadas conforme critérios iniciais, apenas a

temperatura mínima com defasagem (t-3) foi considerada significativa.

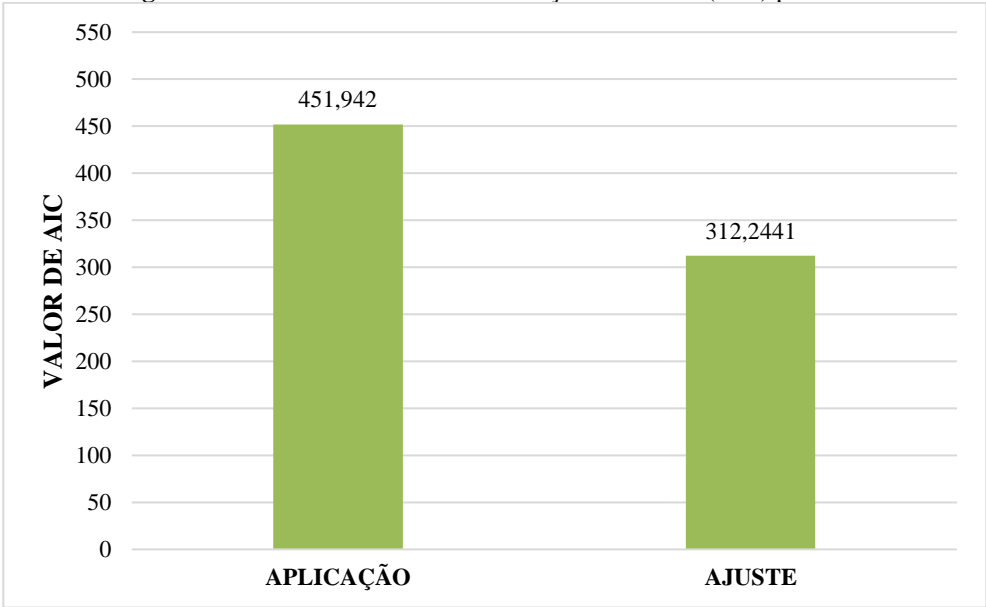
Tianguá não possui modelo de regressão viável dentro do contexto da pesquisa, assim como Juazeiro do Norte.

4.2. Análise de desempenho e validação

4.2.1. Aracati

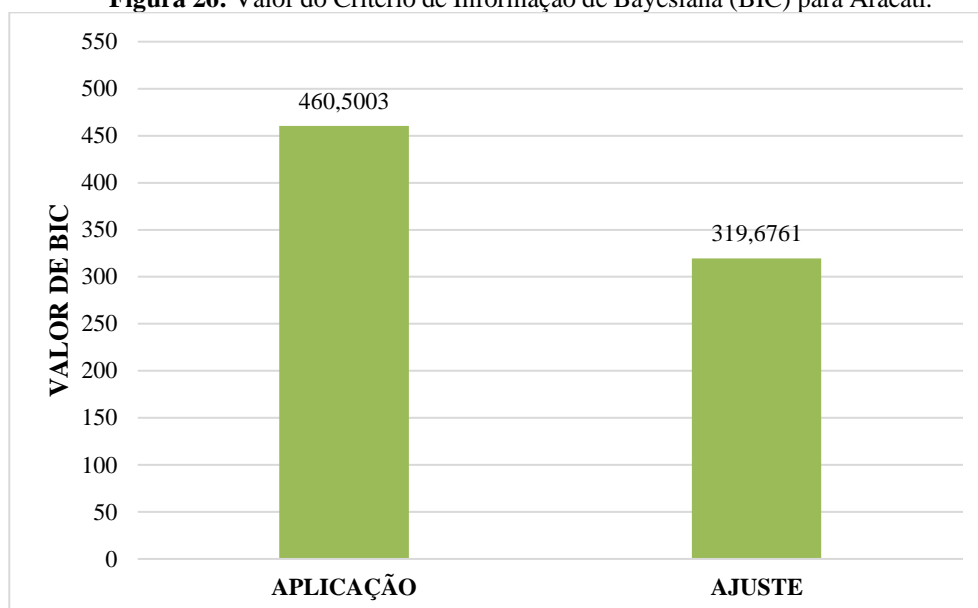
Uma comparação da aplicação e do ajuste/calibração pode ser observada por meio dos índices de desempenho AIC e BIC, nas Figuras 25 e 26, respectivamente. Comparativamente, nota-se que os valores de AIC e BIC foram melhores após o ajuste da função GLS, mostrando que apesar de ser um modelo relativamente mais simples que a aplicação, a qualidade é melhor, devido a uma menor perda de informação.

Figura 25: Valor do Critério de Informação de Akaike (AIC) para Aracati.



Fonte: Autor, 2024.


Figura 26: Valor do Critério de Informação de Bayesiana (BIC) para Aracati.



Fonte: Autor, 2024.

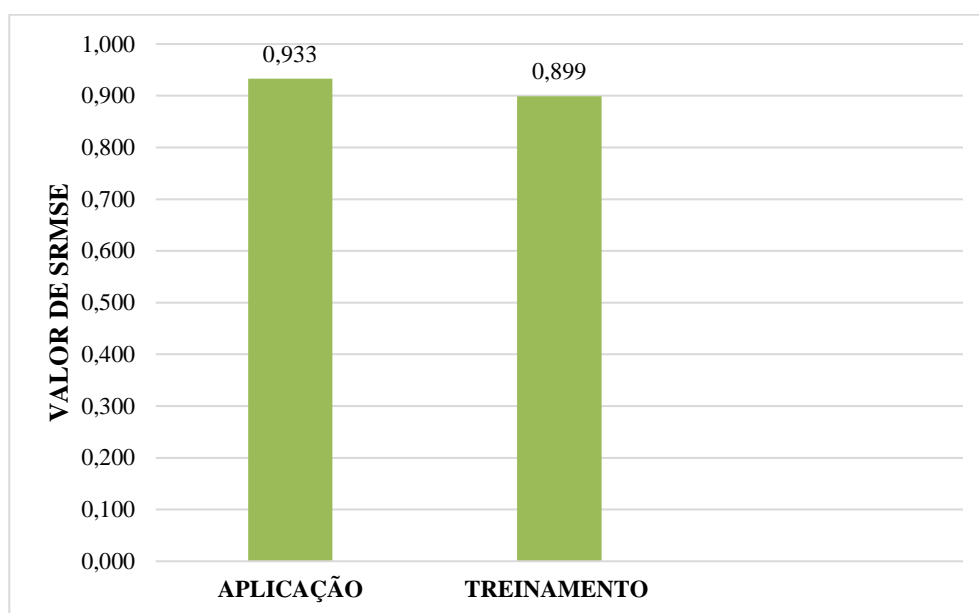
Outras variáveis de desempenho analisadas no estudo foram RMSE e SRMSE (ver Figuras 27 e 28). Considerando que quanto menor o valor do RMSE melhor a acurácia da previsão, a Figura 27 mostra uma mais uma vez a superioridade do ajuste em relação a aplicação, em que o modelo de calibração, apresenta valor RMSE de ~1,297. Em relação ao SRMSE, a Figura 8 apresenta um valor de 0,933 para o modelo de aplicação e 0,898 para o modelo de ajuste, o que significa que a saída do ajuste é ~10% melhor que a média dos dados observados de dengue.

Figura 27: Variável de desempenho- RMSE para Aracati.



Fonte: Autor, 2024.


Figura 28: Variável de desempenho- SRMSE para Aracati.



Fonte: Autor, 2024.

. Durante o período de validação, a avaliação da capacidade do modelo ajustado foi realizada graficamente, de maneira visual e descritiva, com foco no início, nos meses de pico e no fim da temporada da dengue, na ordem de magnitude e nos valores de pico da incidência da dengue. Dessa forma a Figura 29, mostra que a temporada de dengue em Aracati para o ano de 2016 foi bem capturada pelas regressões baseadas em OLS, porém o mesmo não ocorre para o segundo semestre de 2017 e para o ano de 2018. Ainda é possível notar que a previsão epidemiológica de dengue tende a superestimar os dados observados ao longo de toda a série, exceto para novembro de 2015, janeiro e fevereiro de 2017 e o segundo semestre de 2018, quando ocorre subestimação dos valores.

Figura 29: Série temporal de validação para Aracati.



Fonte: Autor, 2024.


Dessa forma a Figura 29, mostra que a temporada de dengue em Aracati para o ano de 2016 foi bem capturada pelas regressões baseadas em OLS, porém o mesmo não ocorre para o segundo semestre de 2017 e para o ano de 2018. Ainda é possível notar que a previsão epidemiológica de dengue tende a superestimar os dados observados ao longo de toda a série,

exceto para novembro de 2015, janeiro e fevereiro de 2017 e o segundo semestre de 2018, quando ocorre subestimação dos valores.

4.2.2. Canindé

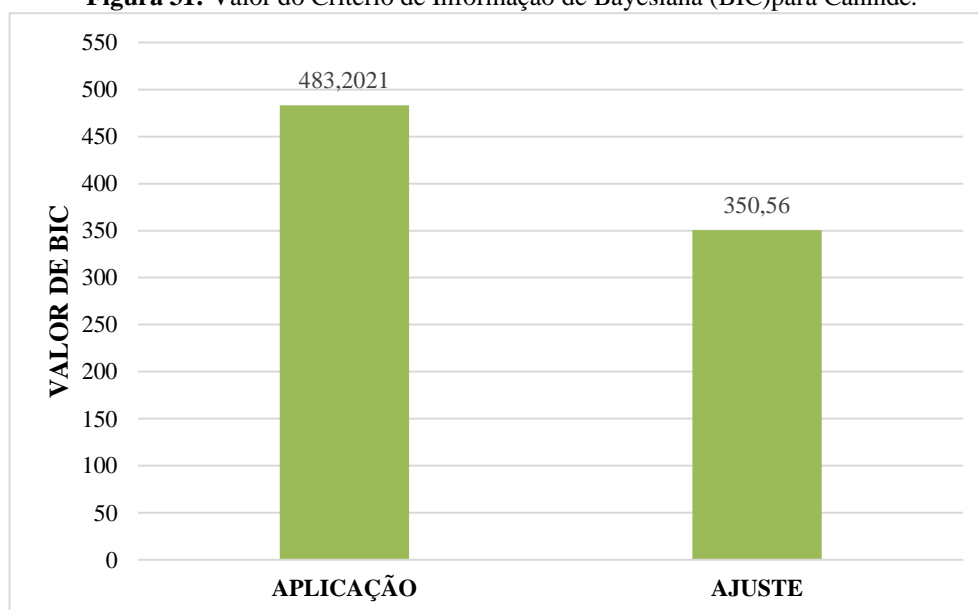
Com determinação dos valores de AIC e BIC, representados pelas figuras 30 e 31, respectivamente, é possível verificar que tais índices de desempenho foram piores para o modelo de aplicação (AIC 471,76 ; BIC 483,20), conforme o esperado, visto que o mesmo tende a ser mais complexo que o modelo de ajuste.

Figura 30: Valor do Critério de Informação de Akaike (AIC) para Canindé.



Fonte: Autor, 2024.

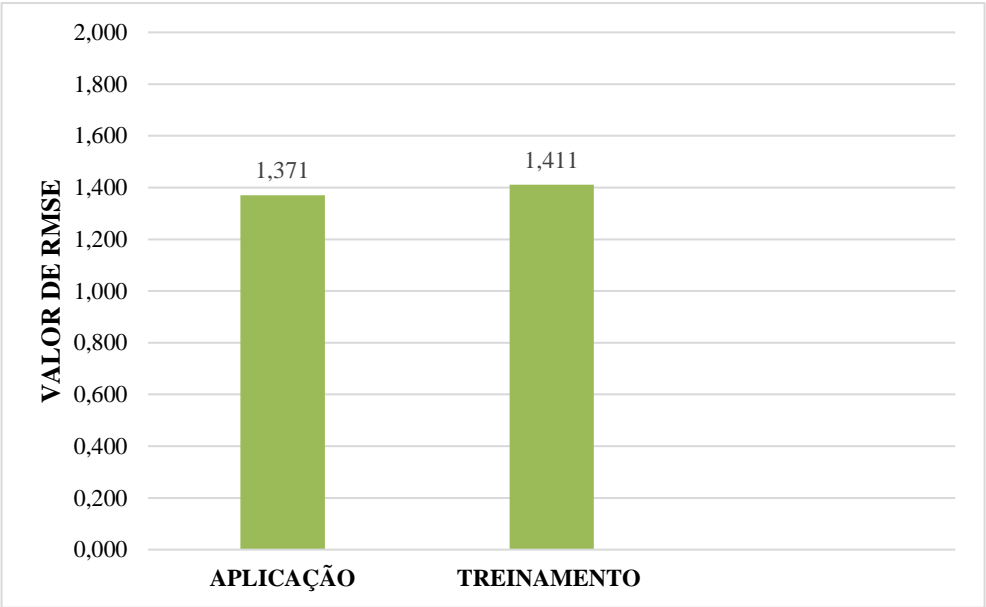
Figura 31: Valor do Critério de Informação de Bayesiana (BIC) para Canindé.



Fonte: Autor, 2024.


As Figuras 32 e 33 trazem informação sobre a capacidade preditiva dos modelos considerados. Para o RMSE, Figura 32, observa-se que seu valor para a aplicação é cerca de 0,04 menor do que para o ajuste, indicando um menor desvio médio das previsões obtidas pelo modelo de aplicação. Para o SRMSE, verifica-se que tanto o modelo de aplicação como o de treinamento preveem melhor que a média dos dados observados, em que a aplicação é ~21% mais precisa que a média, enquanto a modelo de treinamento é ~19% mais assertivo.

Figura 32: Variável de desempenho- RMSE para Canindé



Fonte: Autor, 2024.


Figura 33: Variável de desempenho- SRMSE para Canindé.



Fonte: Autor, 2024.

A Figura 34, que mostra a previsão do modelo de ajuste aplicada a série de validação, indica uma melhor performance para o período de out/2015 até o primeiro semestre de 2017, quando se inicia uma fase sem registro de casos de dengue, mas que não é percebida pelo


modelo. Entretanto, em geral, os resultados são satisfatórios no que diz respeito à previsão do modelo.



Fonte: Autor, 2024.


4.2.3. Crateús

Para os modelos de Crateús, aplicação e ajuste, os valores de AIC e BIC, apresentados nas Figuras 35 e 36, indicam um melhor aproveitamento da informação passada pelas variáveis preditoras e uma menor complexidade dos modelos de ajuste, refletindo uma melhor qualidade do modelo de treinamento.



Fonte: Autor, 2024.


Figura 36: Valor do Critério de Informação de Bayesiana (BIC) para Crateús.



Fonte: Autor, 2024.


As variáveis de desempenho, RMSE e SRMSE, apresentadas nas Figuras 37 e 38 para o município de Crateús, apresentam valores satisfatórios tanto para o modelo de aplicação como para o de ajuste, de modo que ambos tendem a ser melhores que simplesmente a adoção da média dos dados observados como previsão.

Figura 37: Variável de desempenho - RMSE para Crateús.



Fonte: Autor, 2024.


Figura 38: Variável de desempenho- SRMSE para Crateús.



Fonte: Autor, 2024.

O gráfico apresentado na Figura 39 é trabalhado em relação a sazonalidade, a estacionariedade e correlação entre os dados analisados. Observa-se que o modelo ajustado/previsão do modelo segue uma uniformidade na extensão da série temporal, acompanha a sazonalidade dos dados observados, havendo um melhor ajuste em períodos em que houve picos, especialmente em 2017. No entanto, pode ser visto que nos últimos meses da série temporal é demonstrado uma certa estabilidade móvel.

Figura 39: Série temporal para validação para Crateús




Fonte: Autor, 2024.

4.2.4. Fortaleza


Analisando o modelo de calibração dos resultados apresentados nas Figuras 40 e 41, respectivamente, podemos comparar os valores para AIC e BIC, que tiveram um resultado melhor após o ajuste da função GLS, ou seja, existe uma melhor qualidade do modelo após a determinação das variáveis mais significativas.

Figura 40: Valor do Critério de Informação de Akaike (AIC) para Fortaleza.



Fonte: Autor, 2024.


Figura 41: Valor do Critério de Informação de Bayesiana (BIC) para Fortaleza



Fonte: Autor, 2024.


Visualizando as Figuras 42 e 43, as variáveis de desempenho RMSE e SRMSE consecutivamente. A Figura 42 considera o valor de RMSE de $\sim 0,951$ para aplicação e $\sim 0,947$ para o modelo calibrado, mostrando um baixo valor de erro em ambos. Em relação ao SRMSE, a Figura 43, apresenta um valor de $\sim 0,782$ para o modelo de aplicação e $\sim 0,800$ para o modelo de ajuste, apesar do RMSE da aplicação ter sido maior. Isto provavelmente ocorre devido ao desvio padrão da série observada ser ligeiramente maior na entrada do modelo de aplicação, do que na entrada do modelo de calibração. Para esse município, o modelo de aplicação, teve o melhor resultado.

Figura 42: Variável de desempenho- RMSE para Fortaleza.



Fonte: Autor, 2024.


Figura 43: Variável de desempenho- SRMSE para Fortaleza.



Fonte: Autor, 2024.

Para análise comparativa da série temporal de validação, apresentada na Figura 44, o modelo ajustado teve as temporadas de dengue foram bem capturadas pelas regressões, conseguindo representar satisfatoriamente os meses de início, meio e fim da epidemia de dengue, sendo que entre o final de 2015 e o primeiro semestre de 2017 os dados observados foram subestimados e do segundo semestre de 2017 até o final da série de validação superestimados.

Figura 44: Série temporal para validação para Fortaleza.




Fonte: Autor, 2024.

4.2.5. Iguatu


Fazendo a comparação dos índices de AIC e BIC, observados nas Figuras 45 e 66, respectivamente, revelam que os melhores resultados ocorrem após o ajuste da função GLS. Na sequência das avaliações com as variáveis de desempenho RMSE e SRMSE (ver Figuras 47 e 48), o resultado a ser considerado deve ser o menor, havendo melhor avaliação. A Figura 47 mostra que o valor de aplicação chega a ser aproximadamente ~0,07 menor que o valor do ajuste. Para SRMSE, verifica-se que o modelo de aplicação tem melhor acurácia em relação ao treinamento, sendo o valor considerado melhor que a média dos dados observados, em que aplicação é mais precisa que a média cerca de ~13%.

Figura 45: Valor do Critério de Informação de Akaike (AIC) para Iguatu.




Fonte: Autor, 2024.

Figura 46: Valor do Critério de Informação de Bayesiana (BIC) para Iguatu.




Fonte: Autor, 2024.

Figura 47: Variável de desempenho- RMSE para Iguatu.



Fonte: Autor, 2024.


Figura 48: Variável de desempenho- SRMSE para Iguatu.



Fonte: Autor, 2024.

A Figura 49 apresenta a previsão gerada pelo modelo ajustado, aplicada ao conjunto de validação. De modo geral, observa-se uma subestimação sistemática dos valores observados ao longo de diferentes períodos do ano, com exceção dos meses de março e abril de 2017, bem como de parte do primeiro semestre de 2018, especificamente maio, junho e julho, além de todo o segundo semestre deste mesmo ano. Apesar dessa tendência à subestimação, o modelo demonstra capacidade de reproduzir adequadamente a dinâmica temporal do fenômeno, acompanhando os padrões de elevação e redução observados nos dados empíricos.

Figura 49: Série temporal para validação para Iguatu.




Fonte: Autor, 2024.

4.2.6. Itaipipoca


Para acompanhamento do modelo de ajuste, apresentou-se nas Figuras 50 e 51 os valores encontrados para AIC e BIC, havendo um melhor desempenho para ambos os modelos de ajustes, que seguem com os valores: 365,170 e 372,602, respectivamente.

Figura 50: Valor do Critério de Informação de Akaike (AIC) para Itapipoca.



Fonte: Autor, 2024.


Figura 51: Valor do Critério de Informação de Bayesiana (BIC) para Itapipoca.



Fonte: Autor, 2024.


Os gráficos das Figuras 52 e 53 representam as variáveis de desempenho, aplicados para avaliar a precisão e qualidade do modelo. Para o RMSE, em específico na Figura 52, observa-se que seu valor para aplicação é cerca de ~0,15 menor que o ajuste, o mesmo apresenta melhor desvio médio. Para o SRMSE, Figura 53, os dados de aplicação e ajuste estão bem próximos, com a margem de assertividade para aplicação de ~9,33% e ~9,37% para o ajuste em relação à média observada.

Figura 52: Variável de desempenho- RMSE para Itapipoca



Fonte: Autor, 2024.


Figura 53: Variável de desempenho- SRMSE para Itapipoca



Fonte: Autor, 2024.

Na Figura 54 é possível observar que para validação o modelo não capturou de maneira adequada a temporada epidemiológica da dengue em Iguatu, exceto para os meses de abril a junho de 2018. Isso pode estar associado a prevalescência de fatores não climáticos, como imunidade da população a diferentes sorotipos (DENV-1, DENV-2, DENV-3 e DENV-4) no comportamento da dengue no município.

Figura 54: Série temporal para validação para Itapipoca.




Fonte: Autor, 2024.

4.2.7. Juazeiro do Norte

Para Juazeiro do Norte, extrapolou-se os resultados para além do critério inicial de seleção de variáveis explanatórias, e tentou-se gerar um modelo considerando todas as variáveis explicativas (precipitação, temperatura máxima, temperatura mínima e temperatura média com ou sem defasagens) e mesmo assim não foi possível encontrar um modelo de regressão satisfatório, conforme pode ser observado na Figura 55..

Figura 55: Série temporal para validação para Juazeiro do Norte.




Fonte: Autor, 2024.

4.2.8. Morada Nova


Em análise dos resultados de AIC e BIC, podemos ver nas Figuras 56 e 57 que os índices para o ajuste, tiveram o melhor desempenho (AIC - 253,5251 ; BIC - 260,9571), respectivamente, mostrando mais uma vez que modelos menos complexos podem ser melhores que modelos com uma ampla gama de variáveis explicativas.

Figura 56: Valor do Critério de Informação de Akaike (AIC) para Morada Nova



Fonte: Autor, 2024.


Figura 57: Valor do Critério de Informação de Bayesiana (BIC) para Morada Nova.



Fonte: Autor, 2024.


Os gráficos das Figuras 58 e 59, revelam informações sobre as variáveis de desempenho para os modelos considerados. Para o RMSE, Figura 58, observa-se que seu valor para o ajuste é maior que a aplicação ~0,08, indicando um maior desvio médios das previsões obtidas. Para o SRMSE, Figura 59, verifica-se que o modelo de ajuste é ~19% mais preciso que o modelo de aplicação, com aproximadamente ~10% melhor que a média dos dados observados.

Figura 58: Variável de desempenho- RMSE para Morada Nova.



Fonte: Autor, 2024.


Figura 59: Variável de desempenho- SRMSE para Morada Nova.



Fonte: Autor, 2024.

A Figura 60, mostra a previsão do modelo de ajuste para a série de validação, indicando uma performance melhor a partir de fev/2017 até o início do segundo semestre de 2018, quando ocorre uma baixa dos casos de dengue. No entanto, os resultados apresentam um resultado satisfatório.

Figura 60: Série temporal para validação para Morada Nova.




Fonte: Autor, 2024.

4.2.9. Quixadá

Analisando os resultados das Figuras 61 e 62, respectivamente, em que comparamos e apresentamos os valores para AIC e BIC, nota-se valores menores após o ajuste da função GLS, havendo uma melhor qualidade na apresentação do modelo.


Observando as variáveis de desempenho RMSE e SRMSE através das Figuras 63 e 64, consecutivamente. A Figura 63, apresenta o valor de ~1,417 para RMSE, considerando um melhor resultado para o ajuste do modelo. Seguindo para o gráfico seguinte, Figura 64, tem-se que o melhor resultado foi novamente para o ajuste, sendo este o modelo que possui a melhor acurácia dos resultados. Sendo considerado ~11% melhor que a média dos dados observados.

Figura 61: Valor do Critério de Informação de Akaike (AIC) para Quixadá.




Fonte: Autor, 2024.

Figura 62: Valor do Critério de Informação de Bayesiana (BIC) para Quixadá.




Fonte: Autor, 2024.

Figura 63: Variável de desempenho- RMSE para Quixadá.



Fonte: Autor, 2024.


Figura 64: Variável de desempenho- SRMSE para Quixadá



Fonte: Autor, 2024.

Na Figura 65, pode-se notar que a previsão acompanha a fase dos dados observados, com leves flutuações nas regiões de picos e vales, com tendência à subestimação das observações, especialmente em períodos de temperaturas mais amenas, que ocorrem no período da quadra chuvosa.

Figura 65: Série temporal para validação para Quixadá.



Fonte: Autor, 2024.


4.2.10. Sobral

Em específico para Sobral, o modelo foi realizado sem o resultado de uma variável significativa, após a seleção das variáveis com os resultados dentro do intervalo permitido, não houve valor que atendesse ao nível de significância. Mesmo assim, o modelo foi gerado considerando as mesmas variáveis definidas pelo intervalo inicialmente. Os valores para AIC e BIC são apresentados pelas Figuras 66 e 67, respectivamente, onde para os valores de AIC teve um resultado menor para o ajuste, sendo ~157 a diferença entre a aplicação e o ajuste. Para o valor de BIC há uma semelhança, o valor é considerado com melhor resultado para o ajuste.

As variáveis de desempenho RMSE E SRMSE, podem ser visualizadas pelas Figuras 68


e 69, respectivamente. O gráfico da Figura 68 apresenta o valor de RMSE com diferença de 0,116 de redução para o ajuste, sendo considerado melhor resultado para o modelo. Para o SRMSE, Figura 69, os resultados apontam que o ajuste é ~7,4% melhor que a média observada, sendo este o modelo selecionado.

Figura 66: Valor do Critério de Informação de Akaike (AIC) para Sobral.




Fonte: Autor, 2024.

Figura 67: Valor do Critério de Informação de Bayesiana (BIC) para Sobral.




Fonte: Autor, 2024.

Figura 68: Variável de desempenho- RMSE para Sobral.



Fonte: Autor, 2024.


Figura 69: Variável de desempenho- SRMSE para Sobral.



Fonte: Autor, 2024.

A Figura 70 mostra uma boa modelagem, de forma que o modelo de previsão segue inicialmente com valores menores em relação aos dados reais, desde de out/2015 até o final do segundo semestre de 2016, quando a previsão passa a superestimar os dados reais.

Figura 70: Série temporal para validação para Sobral.




Fonte: Autor, 2024.

4.2.11. Tauá

Acompanhando o modelo de ajuste, temos os valores de AIC e BIC, representados pelos gráficos das Figuras 71 e 72. Em ambos os modelos, aplicam-se os melhores resultados para o ajuste da função GLS. Os valores de AIC tiveram uma redução de aproximadamente ~167,465 em relação ao modelo de aplicação, sendo este o mais favorecido. O mesmo ocorreu para análise de BIC, com uma redução de ~168,566, confirmando que o melhor resultado ocorreu para o ajuste.


Os índices de desempenho, RMSE e SRMSE (Figuras 73 e 74), buscando avaliar a precisão e qualidade do modelo, apresentam um melhor resultado para o modelo de ajuste, com a valor de SRMSE ~0,9, o que indica que o modelo é ~10% melhor que a média dos dados observado.

Figura 71: Valor do Critério de Informação de Akaike (AIC) para Tauá.




Fonte: Autor, 2024.

Figura 72: Valor do Critério de Informação de Bayesiana (BIC) para Tauá.




Fonte: Autor, 2024.

Figura 73: Variável de desempenho- RMSE para Tauá.



Fonte: Autor, 2024.


Figura 74: Variável de desempenho- SRMSE para Tauá.



Fonte: Autor, 2024.

A Figura 75 apresenta uma superestimação de dados logo no início da séries, out/2015, seguindo com uma modesta linearidade referente ao primeiro semestre de 2016. Todo o restante da série é modelado por essa superestimação dos dados.

Figura 75: Série temporal para validação para Tauá.



Fonte: Autor, 2024.

5. DISCUSSÃO

O presente estudo investigou a influência de variáveis climáticas, como precipitação e temperaturas (máxima, média e mínima), na variabilidade interanual das incidências de casos de dengue em 12 áreas urbanas, de clima tropical semi-árido. A maioria dos municípios estudadas apresentou relações estatisticamente significativas entre a incidência da doença e variáveis climáticas. Essas relações podem ser explicadas pela influência da variabilidade climática através de regressões lineares, conforme discutido em Costa et al. (2022) e Borges et al. (2024), que analisaram a inter-relação entre precipitação, temperatura e casos confirmados de dengue em municípios do Nordeste Brasileiro.

A análise dos municípios investigados revela importantes variações na relação entre as

variáveis hidroclimáticas (precipitação e temperaturas) e a incidência de dengue em regiões de clima tropical semiárido. As diferenças observadas refletem tanto os contexto climáticos locais quanto fatores urbanos, ambientais e socioeconômico que modulam a dinâmica da doença.

Dos resultados, pode-se extrair que a temperatura mínima com defasagem de 3 meses foi a variável que mais influenciou o número de casos de dengue, ela foi tida como a variável preditora mais significativa ou entre as mais significativas, em Aracati, Fortaleza, Itapipoca, Quixadá e Tauá. Ainda foi possível verificar que a variável temperatura, seja ela máxima, média ou mínima esteve contemplada em todos os modelos de calibração que foram viáveis. Isso mostra que a temperatura é variável que mais impacta no número de casos de dengue, conforme evidenciado por diversos estudos em várias partes do mundo (Jesus et al., 2024; Feng et al., 2024; Costa et al., 2022; Ouattara et al., 2022; Lowe et al., 2022), especialmente nos casos temperatura mais amenas, conforme discutido em ABDULLAH et al. (2022), Gómez et al. (2022) e NURAINI et al. (2021).

Em relação à precipitação, os resultados mostraram que ela só teve representatividade em 3 dos 12 municípios em estudo, Fortaleza, Iguatu e Morada Nova. Estudos como o de Sophia et al. (2025) e Benitez et al. (2021), mostram que a relação entre chuvas e dengue é complexa, chuvas intensas podem diminuir a incidência de dengue e períodos de estiagem podem propiciar grandes surtos da doença, especialmente em áreas onde há armazenamento temporário de água, conforme pode ser visto em Borges et al. (2024) e Costa et al. (2022).

Outro achado importante do estudo é que o modelo calibrado, por meio de regressão linear por mínimos quadrados ordinários, para Fortaleza foi o que apresentou melhor qualidade entre os demais municípios estudados, com um SRMSE de ~0,799, indicando que o modelo é ~20% melhor que se a adotar a média das observações de dengue no período analisado. Este resultado contraria, em parte, o do estudo realizado por Costa et al. (2022), que avaliou a influência da variabilidade hidroclimática na incidência de dengue em uma grande área tropical seca, utilizando uma metodologia de regressão similar a adotada nesta dissertação, em que não foi possível encontrar a reta de ajuste as variáveis preditoras para Fortaleza.

A robustez estatística dos modelos varia entre os municípios, mas a aplicação dos modelos GLS mostrou-se adequada para lidar com autocorrelação e heterocedasticidade, frequentes em séries temporais epidemiológicas. A viabilidade preditiva é maior onde há forte associação entre variáveis hidroclimáticas e o padrão endêmico de dengue, sendo limitada em áreas onde outros fatores (socioeconômicos, de gestão urbana ou ambientais) parecem ter papel predominante.

Ressalta-se que no presente estudo também houve localidades em que as variáveis

explicativas não possuíam correlação com significância estatística, Juazeiro do Norte, Tianguá e Sobral, não sendo possível o desenvolvimento de um modelo de regressão linear de qualidade minimamente satisfatória.

Os resultados obtidos reforçam a relevância das variáveis hidroclimáticas como fatores explicativos da incidência de dengue em regiões de clima tropical semiárido, embora com variações significativas entre os municípios. A precipitação acumulada e a temperatura mínima média foram, em geral, os principais preditores nos modelos aplicados.

A análise comparativa evidencia que a eficácia dos modelos GLS depende do contexto local, ressaltando a importância de abordagens que integrem múltiplas dimensões – ambientais, sociais, econômicas e de infraestrutura – para a compreensão e enfrentamento da dengue. Municípios com padrões distintos de urbanização e disponibilidade de serviços públicos podem demandar estratégias de monitoramento e controle específicas, adaptadas às suas realidades climáticas e socioambientais.

Em síntese, os achados deste estudo contribuem para o aprimoramento de políticas públicas voltadas à vigilância e prevenção da dengue, ao indicar como o comportamento da doença está intrinsecamente relacionado às condições climáticas locais e como modelos estatísticos podem oferecer suporte à antecipação de surtos, especialmente em contextos vulneráveis.

6. CONCLUSÃO

Em geral, as regressões de séries temporais baseadas nas funções dos mínimos quadrados ordinários foram capazes de reproduzir o desenvolvimento das séries temporais, com a previsão sazonal de casos de dengue. A proposta do estudo foi investigar a influência do clima na variabilidade interanual dos casos de dengue, com o objetivo de prever situações epidemiológicas em áreas urbanas

Nota-se através do presente estudo que as variações climáticas, de precipitação e temperatura, e a incidência de casos de dengue podem variar de um município para o outro, ou seja, não há um padrão bem definido de influência, de modo que apenas uma variável consegue explicar essa variação. Contudo, o desenvolvimento da simulação tem sido bem estruturado, no entanto, em todos os municípios, com exceção de Juazeiro do Norte e Tianguá, houve subestimação dos dados reais. Havendo uma maior discrepância em determinados períodos entre os valores reais.

A presente dissertação teve como objetivo principal analisar a influência de variáveis hidroclimáticas — notadamente a precipitação acumulada e as temperaturas média, mínima e máxima — sobre a incidência de casos de dengue em treze municípios cearenses inseridos em

contexto de clima tropical semiárido, no período compreendido entre 2008 e 2018. A partir da aplicação de modelos de regressão linear generalizada (GLS), buscou-se investigar em que medida os elementos climáticos contribuíram para a variabilidade temporal da doença, destacando os diferentes padrões observados entre os municípios selecionados.

Os resultados obtidos evidenciaram que a relação entre as variáveis hidroclimáticas e a ocorrência da dengue é espacialmente heterogênea. Em municípios como Fortaleza, Sobral e Juazeiro do Norte, observou-se um ajuste mais expressivo dos modelos, com destaque para a precipitação acumulada e a temperatura mínima como variáveis significativamente associadas à incidência de casos. Por outro lado, localidades como Tauá, Crateús e Canindé apresentaram desempenhos mais discretos, sugerindo que, nesses contextos, fatores não-climáticos — como condições socioambientais, infraestrutura urbana, acesso a serviços de saúde, mobilidade populacional e efetividade das ações de vigilância — podem ter maior peso explicativo.

O município de Fortaleza destaca-se com a presença de resultados considerados bons para as variáveis de desempenho. Cada município conseguiu apresentar sua capacidade preditiva, analisando a melhor performance dos períodos de validação, alguns com superestimação dos dados. Nos municípios em que foram obtidas variáveis significativas, houve um melhor ajuste dos erros à reta de distribuição normal. Outro resultado importante é análise foram os valores de AIC e BIC, que tiveram seu desenvolvimento melhor nos modelos de ajuste em ambos os modelos.

No entanto, deve-se notar que o modelo possui algumas limitações, fatores ecológicos como a abundância de mosquitos, cobertura de solos e proximidades em corpos d'água não foram considerados para o desenvolvimento da pesquisa. Construir um modelo amplamente transferível, considerando também fatores socioeconômicos e ecológicos do ambiente, é necessário maiores pesquisas. Contudo, o modelo apresentou resultados bem dimensionados para aplicação em futuras pesquisas e desenvolvimentos em novas variáveis.

A heterogeneidade dos achados reafirma a complexidade dos processos envolvidos na determinação da dengue, especialmente em áreas semiáridas, onde os eventos pluviométricos são irregulares e as condições socioambientais tendem a acentuar a vulnerabilidade da população. Apesar disso, os modelos desenvolvidos demonstraram ser ferramentas úteis para a compreensão dos efeitos climáticos sobre a dinâmica da doença, com potencial para subsidiar estratégias de vigilância epidemiológica e planejamento de ações preventivas em saúde pública.

A utilização dos modelos GLS representou um diferencial metodológico relevante, uma vez que permitiu tratar adequadamente a autocorrelação temporal intrínseca às séries analisadas. Essa abordagem se mostrou eficaz na modelagem da variabilidade interanual dos casos de

dengue, contribuindo para a construção de um arcabouço analítico mais robusto e alinhado às necessidades da pesquisa epidemiológica aplicada.

Em termos práticos, os achados deste estudo indicam que o monitoramento de variáveis hidroclimáticas pode auxiliar na antecipação de períodos críticos de transmissão da dengue, sobretudo em municípios onde essas variáveis demonstraram maior capacidade preditiva. Assim, reforça-se a importância da integração entre dados climáticos e sistemas de informação em saúde como parte de políticas públicas que visem à mitigação de riscos associados a arboviroses em contextos semiáridos.

Por fim, destaca-se que, diante do atual cenário de mudanças climáticas globais e de expansão das áreas de risco para doenças transmitidas por vetores, torna-se imperativo o aprofundamento de investigações que articulem as dimensões ambientais, climáticas e sociais na explicação da dinâmica das arboviroses. A construção de respostas eficazes e territorialmente adaptadas passa, necessariamente, pela produção de conhecimento científico que reconheça a complexidade dos territórios e promova o fortalecimento de ações integradas em saúde e meio ambiente.

Os resultados desta pesquisa podem ajudar a criar políticas de saúde para evitar surtos de dengue nos municípios estudados. Isso pode ajudar a criar sistemas de alerta baseados em modelos de predição de dengue, estimativas de risco para doenças transmitidas por mosquitos e mapas de risco baseados na população e na variação da doença.

REFERÊNCIAS

- ABDULLAH, N. A. M. H. ET AL. THE ASSOCIATION BETWEEN DENGUE CASE AND CLIMATE: A SYSTEMATIC REVIEW AND META-ANALYSIS. *ONE HEALTH*, v. 15, p. 100452, 31 OUT. 2022.
- ABREU, M. C.; FRAGA, M. S.; LYRA, G.; OLIVEIRA JÚNIOR, J.; VILLAR-HERNÁNDEZ, B. J.; SOUZA, A.; ZERI, M. Long-term trend analysis in annual, seasonal and monthly rainfall in East Northeast of Brazil and the influence of modes of climate variability. **International Journal of Climatology**, 2023. DOI: 43. 10.1002/joc.8274.
- ADAMOPOULOS, I.; SYROU, N. Climate Change Risks Impacts on Public Health Correlated with Air Pollution, African Dust in South Europe. **Preprints 2024**, 2024101234. <https://doi.org/10.20944/preprints202410.1234.v1>
- AGIAKLOGLOU, C.; TSIMPANOS, A. Evaluating the performance of AIC and BIC for selecting spatial econometric models. *Journal of Spatial Econometrics*, 4(1), 2022. DOI: <https://doi.org/10.1007/s43071-022-00030-x>
- ALBUQUERQUE, E.L.S. & SOUZA, M.J.N. Bacias hidrográficas costeiras: importância e cenário degradacional no setor leste metropolitano de Fortaleza/Ceará. *Revista GeoUECE - Programa de Pós-Graduação em Geografia da UECE Fortaleza/CE*, v. 4, nº 6, p. 151-176, jan./jun. 2015. Disponível em: <http://seer.uece.br/geouece>
- ALMEIDA, L. S.; COTA, A. L. S.; RODRIGUES, D. F. Saneamento, Arboviroses e Determinantes Ambientais: impactos na saúde urbana. **Ciência & Saúde Coletiva**, 25(10), 3857–3868, 2020. <https://doi.org/10.1590/1413-812320202510.30712018>
- ANDREOLI, R. V.; KAYANO, M. T. Multi-scale variability of the sea surface temperature in the Tropical Atlantic. **Journal of Geophysical Research**, 109, C05009, 2004. DOI: 10.1029/2003JC002220.
- ANDREOLI, R.V.; KAYANO, M. T. Enso-Related Rainfall Anomalies in South America and Associated Circulation Features During Warm and Cold Pacific Decadal Oscillation Regimes, **Internacional Journal Climatology**, 25, p. 2017–2030, 2005.
- APPICE, A., GEL, Y., ILIEV, I., LYUBCHICH, V., MALERBA, D. **A Multi-Stage Machine Learning Approach to Predict Dengue Incidence: A Case Study in Mexico**. *IEEE Access*, 8, 52713-52725, 2020.
- ARAÚJO JÚNIOR, L. M. **Desenvolvimento de um sistema de informação e alerta precoce da seca e elaboração de estratégias de planejamento proativo de adaptação às secas urbanas**. Tese (doutorado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Civil: Recursos Hídricos, Fortaleza, 2018.
- ATHIRSHA, A.; ANITHA, M.; SUNDAR, J. S.; KALPANA, S.; VALARMATHI, S.; SRINIVAS, G. Unleashing the relationship between climate change and infectious diseases. **International Journal of Community Medicine and Public Health**, 11(11), 4569–4576, 2024. DOI: 10.18203/2394-6040.ijcmph20243325
- BATISTA, E.D.A.; ARAÚJO, W.C.; BATISTA, L.I.A. Previsão de casos de dengue através de Machine Learnig e Deep Learning: uma revisão sistemática. **Research, Society and Development**, v. 10, n.10, e 33101119 347, 2021(CC BY 4.0) | ISSN 2525-3409 | DOI: <https://dx.doi.org/10.33448/rsd-v10i11.19247>

BENITEZ, E. M. et al. Understanding the role of temporal variation of environmental variables in predicting *Aedes aegypti* oviposition activity in a temperate region of Argentina. **Acta Tropica**, v. 216, p. 105744, abr. 2021.

BHATIA, S.; BANSAL, D.; PATIL, S.; PANDYA, S.; ILYAS, Q. M.; IMRAN, S. A retrospective study of climate change affecting dengue: evidences, challenges and future directions. **Front Public Health**, 10:884645, 2022. <https://doi.org/10.3389/fpubh.2022.884645>.

CAVALCANTE, L. C. V.; FEDOROVA, N.; LEVIT, V. Influência dos Distúrbios Tropicais na Formação de Fenômenos Adversos de Atmosfera Estável no Nordeste Brasileiro. **Revista Brasileira De Meteorologia**, 35(spe), 735–743, 2020. DOI: 10.1590/0102-77863550002

CAVALCANTI, I. F. A. The influence of extratropical Atlantic Ocean region on wet and dry years in North-Northeastern Brazil. **Frontiers in Environmental Science**, v. 3, 2015. ISSN 2296-665X | DOI: 10.3389/fenvs.2015.00034.

CAVALCANTI, I. F. A.; FERREIRA, N. J.; SILVA, M. G. A. J.; DIAS, M. A. F. S. **Tempo e Clima no Brasil**. 1. ed. São Paulo: Oficina de Textos, 2009.

CAVALCANTI, L. P. G.; BARRETO, F. K. A.; OLIVEIRA, R. M. A. B.; CANUTO, I. F. P.; LIMA, A. A. B.; LIMA, J. W. O.; ESCÓSSIA, K. N. F.; MARTINS, V. E. P.; ALENCAR, C. H.; PERDIGÃO, A. C. B.; LIMA, D. M.; RAMALHO, I. L. C.; ARAÚJO, F. M. C. Trinta anos de dengue no Ceará: história, contribuições para ciência e desafios no cenário atual com tripla circulação de arbovírus. **Journal of Health & Biological Sciences**, Fortaleza, v. 6, n. 1, p. 65-82, 2018.

CEARÁ – Governo do Estado do Ceará. Com precipitações irregulares e mais concentradas no norte, quadra chuvosa termina acima da média. Notícia disponível em: <https://www.ceara.gov.br/2024/06/10/com-precipitacoes-irregulares-e-mais-concentradas-no-norte-quadra-chuvosa-termina-acima-da-media/> | Acessado em: 24/01/2025

CHAI, T.; DRAXLER, R. R. Root mean square error (RMSE) or mean absolute error (MAE)? – Arguments against avoiding RMSE in the literature. **Geoscientific Model Development**, 7(3), 1247–1250, 2014. DOI: <https://doi.org/10.5194/GMD-7-1247-2014>

CHAVES, T. L. D., de FREITAS, J. G., GUEDES, D. N., NETO, G. C., ROCHA, T. J. M., & CAVALCANTI dos S. M. G. **Casos de arboviroses e correlação com os indicadores de infestação vetorial, fatores climáticos e determinantes sociais de saúde**. **Revista Principia**, n. 54, p. 71-82, 2021. ISSN 2447-9187 | DOI: <http://dx.doi.org/10.18265/1517-0306a2021v1n54p71-82>

COSTA, A. C.; GOMES, T. F.; MOREIRA, R. P.; CAVALCANTE, T. F.; MAMEDE, G. L. Influence of hydroclimatic variability on dengue incidence in a tropical dryland área. **Acta Tropica**, Volume 235, 2022,106657, 2022. ISSN 0001-706X | DOI: <https://doi.org/10.1016/j.actatropica.2022.106657>.

CUNHA, L. V.; OLIVEIRA, R.; NUNES, V. B. Impactos das alterações climáticas sobre os recursos hídricos de Portugal. **La directiva marco del agua: realidades y futuros:(comunicaciones)**. Lisboa, Portugal, p. 520-527, 2002.

DOMINGOS, C. S. **Geoprocessamento na Escolha de Sistemas Ambientais para Aterros Sanitários na Região Metropolitana** D. 2007. Dissertação (Mestrado Acadêmico ou Profissional em 2007) - Universidade Estadual do Ceará, , 2007. Disponível em:

<<http://siduece.uece.br/siduece/trabalhoAcademicoPublico.jsf?id=41980>> Acesso em: 26 de abril de 2024

DONALÍSIO, M. R.; GLASSER, C. M. Vigilância entomológica e controle de vetores do dengue. **Revista Brasileira De Epidemiologia**, 5(3), 259–279, 2002. DOI: <https://doi.org/10.1590/S1415-790X2002000300005>

FAGUNDES, J. A. G.; OLIVEIRA, M. H. S.; FAGUNDES, V. **A linguagem R na análise de dados: Um estudo de caso dos transportes públicos do Rio de Janeiro RJ durante a pandemia da Covid-19**. Minicursos da ERSI-RJ 2021 - VII Escola Regional de Sistemas de Informação do Rio de Janeiro, 2021. DOI: 10.5753/sbc.7872.6.

FEDOROVA, N.; LEVIT, V.; CRUZ, C. D. On Frontal Zone Analysis in the Tropical Region of the Northeast Brazil. **Pure and Applied Geophysics**, 173(4):1403-1421, 2016. DOI: 10.1007/S00024-015-1166-Y

FENG, F.; MA, Y.; QIN, P.; ZHAO, Y.; LIU, Z.; WANG, W.; CHENG, B. Temperature-Driven Dengue Transmission in a Changing Climate: Patterns, Trends, and Future Projections. *Geohealth*, 8(10), 2024. <https://doi.org/10.1029/2024gh001059>

FERREIRA, A. G.; MELLO, N. G. S. Principais sistemas atmosféricos atuantes sobre a região Nordeste do Brasil e a influência dos oceanos Pacífico e Atlântico no clima da região. **Revista Brasileira de Climatologia**, v. 1, n. 1, 2005.

FERREIRA, G. O. **Análise de casos de dengue e sua relação com a precipitação e temperatura nos municípios Cearenses**. Trabalho de Conclusão de Curso, Mestrado em Energia e Ambiente, UNILAB, 2023.

FERREIRA, G. W. S.; REBOITA, M. S.; ROCHA, R. P. Vórtices Ciclônicos de Altos Níveis nas Cercanias do Nordeste do Brasil: Climatologia e Análise da Vorticidade Potencial Isentrópica. **Anuário do Instituto de Geociências**, 42(3):568-585, 2019. DOI: 10.11137/2019_3_568_585

FIGUEIREDO FILHO, D. B.; SILVA JÚNIOR, J. A. DESVENDANDO OS MISTÉRIOS DO COEFICIENTE DE CORRELAÇÃO DE PEARSON (R). *REVISTA POLÍTICA HOJE*, VOL. 18, N.1, 2009.

GANJI, H.; KAJISA, T. Error propagation approach for estimating root mean square error of the reference evapotranspiration when estimated with alternative data. **Journal of Agricultural Engineering**, 50(3), 120–126, 2019. DOI: 10.4081/JAE.2019.909

GÓMEZ, R. E. G. et al. Association between Climate Factors and Dengue Fever in Asuncion, Paraguay: A Generalized Additive Model. *International Journal of Environmental Research and Public Health*, v. 19, n. 19, p. 12192, 26 set. 2022.

GONÇALVES, T. E.; GONÇALVES, D. S. L.; CAETANO, F. A. O. TRANSFORMAÇÕES NO MEIO URBANO A PARTIR DOS SHOPPING CENTERS: UMA ABORDAGEM GEOGRÁFICA DA EDUCAÇÃO AMBIENTAL EM FORTALEZA-CE. *Caminhos De Geografia*, v. 16, n. 54, 2015.

HARRIS, M.; CALDWELL, J. M.; MORDECAI, E. A. Climate drives spatial variation in Zika epidemics in Latin America. **Proceedings Royal Biological Sciences**, 286 (1909), 20191578, 2019 <https://doi.org/10.1098/rspb.2019.1578>.

HASUNUMA, H.; TAKEUCHI, A.; ONO, R.; AMIMOTO, Y.; HWANG, Y. H.; UNO, I., SHIMIZU, A.; NISHIWAKI, Y.; HASHIZUME, M.; ASKEW, D. J.; ODAJIMA, H. Effect of Asian dust on respiratory symptoms among children with and without asthma, and their

sensitivity. **The Science of the Total Environment**, 753, 141585, 2021. DOI: <https://doi.org/10.1016/j.scitotenv.2020.141585>

HODSON, T. ROOT-MEAN-SQUARE ERROR (RMSE) OR MEAN ABSOLUTE ERROR (MAE): WHEN TO USE THEM OR NOT. **Geoscientific Model Development**, 15, 5481-5487, 2022. DOI:10.5194/GMD-15-5481-2022.

HU, Y.; CHENG, J.; LIU, S.; TAN, J.; YAN, C.; YU, G.; YIN, Y.; TONG, S. Evaluation of climate change adaptation measures for childhood asthma: A systematic review of epidemiological evidence. **The Science of the Total Environment**, 839, 156291, 2022. DOI: <https://doi.org/10.1016/j.scitotenv.2022.156291>

IAS, INSTITUTO DE ÁGUA E SANEAMENTO, 2021. Municípios e Saneamento beta. Disponível em: <https://www.aguaesaneamento.org.br/municipios-e-saneamento/ce/fortaleza>. Acesso em 19 de Abril de 2024.

IBGE – INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. Cidades@ - Ceará. Disponível em: <https://www.ibge.gov.br/cidades-e-estados/ce.html>. Acesso em: 20 set. 2023.

IBGE – INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA, 2023. Censo demográfico 2022 : características dos domicílios : resultados do universo. Disponível em: https://biblioteca.ibge.gov.br/visualizacao/periodicos/3106/cd_2022_domicilios.pdf. Acesso em: 26 abril. 2024.

ITB - Instituto Trata Brasil, 2024. RANKING DO SANEAMENTO DO INSTITUTO TRATA BRASIL DE 2024 (SNIS 2022). Disponível em: <https://tratabrasil.org.br/wp-content/uploads/2024/04/Relatorio-Completo-Ranking-do-Saneamento-de-2024-TRATA-BRASIL-GO-ASSOCIADOS.pdf>. Acesso em: 26 abril. 2024.

JESUS, P.A. P, EDUARDO, O. C., EDUARDO, P. M. D., & GUADALUPE, R. Á. K. (2024). RELATIONSHIP BETWEEN CLIMATE FACTORS, TEMPERATURE, AND HUMIDITY, AND THE INCIDENCE OF DENGUE CASES IN MEXICO. **INTERNATIONAL JOURNAL OF ADVANCED MULTIDISCIPLINARY RESEARCH AND STUDIES**, 4(3), 1341–1344. [HTTPS://DOI.ORG/10.62225/2583049X.2024.4.3.2943](https://doi.org/10.62225/2583049X.2024.4.3.2943)

KOVATS, R. S.; CAMPBELL-LENDRUM, D.; MATTHIES, F. CLIMATE CHANGE AND HUMAN HEALTH: ESTIMATING AVOIDABLE DEATHS AND DISEASE. **RISK ANALYSIS: AN OFFICIAL PUBLICATION OF THE SOCIETY FOR RISK ANALYSIS**, 25(6), 1409–1418, 2005. DOI: [HTTPS://DOI.ORG/10.1111/J.1539-6924.2005.00688.X](https://doi.org/10.1111/J.1539-6924.2005.00688.X)

LIMA, E. A.; FIRMINO, J. L. N.; GOMES FILHO, M. F. A relação da previsão da precipitação pluviométrica e casos de dengue nos estados de Alagoas e Paraíba nordeste do Brasil. **Revista Brasileira De Meteorologia**, 23(3), 264–269, 2008. DOI: <https://doi.org/10.1590/S0102-77862008000300001>

LIMA-COSTA, M. F.; BARRETO, S. M. Tipos de estudos epidemiológicos: conceitos básicos e aplicações na área do envelhecimento. **Epidemiologia e Serviços de Saúde**, v. 12, n. 4, dez. 2003.

LOWE, R. et al. Combined effects of hydrometeorological hazards and urbanisation on dengue risk in Brazil: a spatiotemporal modelling study. **The Lancet Planetary Health**, v. 5, n. 4, p. e209–e219, abr. 2021.

LUCENA, D. B., SERVAIN, J., GOMES FILHO, M. F. Evolução do impacto de eventos climáticos extremos nos oceanos pacífico e atlântico sobre a estação chuvosa no nordeste do Brasil. In **Clima do Atlântico Tropical e Impactos Sobre o Nordeste (CATIN)**. Org. Servain, J., Campos, J. N. B., Martins, E. S. P. R., Reis Junior, D. R., 1ed., FUNCEME/IRD, Fortaleza - CE, v. 1, p. 176-197, 2010.

LUCENA, D.; SERVAIN, J.; GOMES FILHO, M. Rainfall Response in Northeast Brazil from Ocean Climate Variability during the Second Half of the Twentieth Century. **Journal of Climate**, 24(23), pp. 6174-6184, 2011.

MAIA, A. G. Econometria: conceitos e aplicações. Edição padrão, 2017. Disponível em: <https://www.google.com.br/books/edition/Econometria/qTKDDwAAQBAJ?hl=pt-BR&gbpv=1&pg=PT2&printsec=frontcover>. Acessado em 28/04/2025.

MAKRUFARDI, F.; MANULLANG, A.; RUSMAWATININGTYAS, D.; CHUNG, K. F.; LIN, S. C.; CHUANG, H. C. Extreme weather and asthma: a systematic review and meta-analysis. **European respiratory review: an official journal of the European Respiratory Society**, 32(168), 230019, 2023. DOI: <https://doi.org/10.1183/16000617.0019-2023>

MALECK, M.; BARBOSA, V. F. J.; DA CRUZ, I. L. S.; GONÇALVES, S. J. C.; ORSINI, M.; FERREIRA, A. G. Arboviroses: Estudo Longitudinal de Casos de Dengue: Arboviruses: Longitudinal Study of Dengue cases. **Revista de Saúde**, 10(2), 31–36, 2019. <https://doi.org/10.21727/rs.v10i2.1977>

MANZIONE, R. L. **Águas Subterrâneas: Conceitos e aplicações sob uma visão multidisciplinar**. São Paulo, Paco Editorial, 388p, 2015.

MASSA, A.R.C.G. **Analizador virtual para a determinação do teor dos contaminantes MAPD em um reator trickle bed**. Dissertação de mestrado em Energia Ambiente. Universidade Federal da Bahia. Salvador, 2017.

McELREATH, R. Overfitting, Regularization and Information Criteria. In: **Statistical Rethinking: A Bayesian Course with Examples in R and Stan**. [S.l.]: CRC Press. p. 189, 2016. ISBN 978-1-4822-5344-3.

MEDEIROS, F. J.; DE OLIVEIRA, C. P. Dynamical aspects of the recent strong El Niño events and its climate impacts in Northeast Brazil. **Pure and Applied Geophysics**, v. 178, n. 6, p. 2315-2332, 2021.

MINISTÉRIO DA SAÚDE- **Boletim Epidemiológico: Monitoramento dos casos de arboviroses urbanas causados por vírus transmitidos pelo mosquito Aedes (dengue, chikungunya e zika)**. Editado pela Secretária de Vigilância em Saúde. Disponível em <https://www.gov.br/saude/pt-br/centrais-de-conteudo/publicacoes/boletins/epidemiologicos>. Acesso em: 09 de agosto de 2022.

MITTELMANN, M.; SOARES, D. G. Previsão de Casos de Dengue no Município de Guarulhos com Redes Neurais Artificiais Multicamadas e Recorrentes. **Revista de Informática Aplicada**, Volume 13, Número 2, 2017.

MOLION, L. C. B. Aquecimento Global, El Niños, Manchas Solares, Vulcões e Oscilação Decadal do Pacífico. **Revista Climanalise**, 2005.

MOREIRA, R.P., COSTA, A.C., GOMES, T.F., DE OLIVEIRA FERREIRA, G. Climate and climate-sensitive diseases in semi-arid regions: a systematic review. *International Journal of Public Health*, 65 (9), 1749–1761, 2020. <https://doi.org/10.1007/s00038-020-01464-6>.

MOREIRA, R. P.; SILVA, C. B. C.; SOUSA, T. C.; LEITÃO, F. L. B. F.; MORAIS, H. C. C.; OLIVEIRA, A. S. S.; DUARTE-CLÍMENTS, G.; GÓMEZ, M. B. S.; CAVALCANTE, T. F.; COSTA, A. C. The Influence of Climate, Atmospheric Pollution, and Natural Disasters on

Cardiovascular Diseases and Diabetes Mellitus in Drylands: A Scoping Review. **Public Health Reviews**, v. 45, p. 1, 2024.

NATAL, D. Bioecologia do *Aedes aegypti*. **Biológico**, v. 64, n. 2, p. 205-207, 2002.

NOGUEIRA, N. C. O.; MACHADO, P. H. G.; REBOITA, M. S.; REIS, A. L. Assessment of the Intertropical Convergence Zone over the Atlantic Ocean through an Algorithm Based on Precipitation. **Journal of Atmospheric Science Research**, 7(1): 59–73, 2024. DOI: <https://doi.org/10.30564/jasr.v7i1.6188>.

NURAINI, N. et al. Climate-based dengue model in Semarang, Indonesia: Predictions and descriptive analysis. *Infectious Disease Modelling*, v. 6, p. 598–611, 2021.

OHASHI, Y.; IHARA, T.; OKA, K.; TAKANE, Y.; KIKEGAWA, Y. Machine learning analysis and risk prediction of weather-sensitive mortality related to cardiovascular disease during summer in Tokyo, Japan. **Scientific Reports**, v. 13, Article number: 17020, 2023. DOI: <https://doi.org/10.1038/s41598-023-44181-9>

OLÍMPIO, J. L. S.; ZANELLA, M. E. **Distribuição espaço-temporal dos desastres naturais associados à dinâmica climática no estado do Ceará**. Revista do Departamento de Geografia, 30, 110-131, 2015.

Oliveira, C. P. Dynamical Aspects of the Recent Strong El Niño Events and Its Climate Impacts in Northeast Brazil. **Pure and Applied Geophysics**, 178, 2021. DOI: 10.1007/s00024-021-02758-3.

OLIVEIRA, P. T.; SANTOS E SILVA, C. M.; LIMA, K. C. Climatology and trend analysis of extreme precipitation in subregions of Northeast Brazil. **Theoretical and Applied Climatology**, 130, 77–90, 2017. DOI: <https://doi.org/10.1007/s00704-016-1865-z>

OMEYE, F. I. The Impact of Climate Change on Public Health. **NEWPORT INTERNATIONAL JOURNAL OF RESEARCH IN MEDICAL SCIENCES (NIJMS)**, Volume 5, Issue 3, 2024. DOI: 10.59298/nijrms/2024/5.3.3437

ORGANIZAÇÃO PAN-AMERICANA DA SAÚDE. **Proteger a saúde frente à mudança climática: avaliação da vulnerabilidade e adaptação**. Brasília, DF: OPAS, 2014. ISBN 978-92-75-71698-4 | (<https://iris.paho.org/handle/10665.2/9999>).

OUATTARA, C. A. et al. Climate factors and dengue fever in Burkina Faso from 2017 to 2019. *Journal of Public Health in Africa*, v. 13, n. 1, 24 maio 2022.

PAUL, K. K.; MACADAM, I.; GREEN, D.; REGAN, D. G.; GRAY, R. T. Dengue transmission risk in a changing climate: Bangladesh is likely to experience a longer dengue fever season in the future. *Environmental Research Letters*, Volume 16, Number 11, 2021. <https://doi.org/10.1088/1748-9326/ac2b60>

PAULA PEREIRA, Gustavo; GRANDO, Karina Deboni; MACHADO, Matheus. **ANÁLISE DE REGRESSÃO LINEAR COM O AUXÍLIO DO RSTUDIO**.

PETERSEN, Lyle R. et al. Zika vírus. **New England Journal of Medicine**, v. 374, n. 16, pág.1552-1563, 2016.

PEREIRA, M. D. B. **Dinâmica climática e as chuvas na região da Zona da Mata**, Nordeste do Brasil. INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (2007). O relatório de clima. Disponível em<

http://clima1.cptec.inpe.br/~rclima1/pdf_notatecnica/Nota_Tecnica.pdf> Acesso em: 09 de agosto de 2022.

PERRETTI, C. T.; MUNCH, S. B.; SUGIHARA, G. Model-free forecasting outperforms the correct mechanistic model for simulated and experimental data. **Proceedings of the National Academy of Sciences (PNAS)**, 110 (13), 5253-5257, 2013. DOI: <https://doi.org/10.1073/pnas.1216076110>.

RAHMAN, M. S.; OVERGAARD, H. J.; PIENTONG, C.; MAYXAY, M.; EKALAKSANANAN, T.; AROMSEREE, S.; PHANTHANAWIBOON, S.; ZAFAR, S.; SHIPIN, O.; PAUL, R. E.; PHOMMACHANH, S.; PONGVONGSA, T.; VANNAVONG, N.; HAQUE, U. Knowledge, attitudes, and practices on climate change and dengue in Lao People's Democratic Republic and Thailand. **Environmental Research**, 193, 110509, 2021. <https://doi.org/10.1016/j.envres.2020.110509>.

REIS, J. S.; WEBER, G. A.; MENDES, D. Climatology of the dynamic and thermodynamic features of upper tropospheric cyclonic vortices in Northeast Brazil. **Climate Dynamics**, 57(11):1-19, 2021. DOI: 10.1007/S00382-021-05873-Y.

RIBEIRO, A. F.; MARQUES, G. R. A. M.; VOLTOLINI, J. C.; CONDINO, M. L. F. Associação entre incidência de dengue e variáveis climáticas. **Revista De Saúde Pública**, 40(4), 671–676, 2006. <https://doi.org/10.1590/S0034-89102006000500017>

RODRIGUES, I. S.; COSTA, C. A. G.; RAABE, A.; MEDEIROS, P. H. A.; ARAÚJO, J. C. Evaporation in Brazilian dryland reservoirs: Spatial variability and impact of riparian vegetation. **The Science of the Total Environment**, 797, 149059, 2021. DOI: <https://doi.org/10.1016/s42269-024-01188-0>

ROY, S.; BISWAS, A.; SHAWON, M. T. A.; AKTER, S.; RAHMAN, M. M. Land use and meteorological influences on dengue, transmission dynamics in Dhaka city, Bangladesh. **Bulletin of the National Research Centre**, 48(32), 2024. DOI: <https://doi.org/10.1186/J.SCITOTENV.2021.149059>.

SAJIB, A. H.; AKTER, S.; SAHA, G.; HOSSAIN, Z. Demographic-Environmental Effect on Denge Outbreaks in 11 Countries, Plos One, vol. 29, september 11, 2024. DOI:10.1371/Journal.pone0305854.

SANTOS, A. M. DOS, GALVÍNCIO, J. D., MOURA, M. S. B. Cambio climático y el flujo en la cuenca del rio Goiana – Pernambuco - Brasil. **Investigaciones Geográficas**, (81), 2013. DOI: <https://doi.org/10.14350/rig.26692>.

SANTOS, D. C.; SANTOS, C. A. G.; BRASIL NETO, R. M.; SILVA, R. M.; CARLOS, A. C. S. Precipitation variability using GPCC data and its relationship with atmospheric teleconnections in Northeast Brazil. **Climate Dynamics**, 61, 5035–5048, 2023. DOI: <https://doi.org/10.1007/s00382-023-06838-z>

SANTOS, D. C.; SANTOS, C. A. G.; BRASIL NETO, R. M.; SILVA, R. M.; CARLOS, A. C. S. Precipitation variability using GPCC data and its relationship with atmospheric teleconnections in Northeast Brazil. **Climate Dynamics**, 61, 5035–5048, 2023. DOI: <https://doi.org/10.1007/s00382-023-06838-z>

SEMENZA, J. C.; ROCKLÖV, J.; EBI, K. L. Climate Change and Cascading Risks from Infectious Disease. **Infectious Diseases and Therapy**, 11 , 1371–1390, 2022. <https://doi.org/10.1007/s40121-022-00647-3>

SILVA, A. S.; SILVA, E. M.; LEAL JUNIOR, J. B. V.; SALES, D. C.; MOURA, I. J. M.; ALVES, J. M. B. Distúrbios Ondulatórios de Leste no Nordeste Brasileiro: Um Estudo de Caso Utilizando Modelagem Numérica de Mesoescala. **Revista Brasileira de Meteorologia**, 36(3), 637–649, 2020. DOI: 10.1590/0102-77863630033

SILVA, D. T. F. do N. **A importância de ações de educação socioambiental na escola como mecanismo de combate a proliferação dos vetores de arboviroses**. 2018. Trabalho Acadêmico de Conclusão de Curso. (Graduação)- Ciências Biológicas, Universidade Federal da Paraíba, João Pessoa. 2018.

SILVA, I. R. M.; ROSA, J. Modelagem matemática aplicada à sistemas dinâmicos epidemiológicos: O modelo sir. **Revista Científica Interdisciplinar INTERLOGOS**, 3(1), 33-41, 2018.

SILVA M. A. da, et al. Do Global Ao Local: Desafios Para Redução De Riscos à Saúde Relacionados Com Mudanças Climáticas, Desastre e Emergências Em Saúde Pública, **Saúde Em Debate**, vol. 44, no. spe2, pp. 48–68, 2021a.

SILVA, M. V.; PANDORFI, A. M. R. F. J. H.; OLIVEIRA-JÚNIOR, J. F.; DIVINCULA, J. S.; GIONGO, P. R.; SILVA, T. G. F.; ALMEIDA, G. L. P.; MOURA, G. B. A.; LOPES, P. M. O. Spatial modeling of rainfall patterns and groundwater on the coast of northeastern Brazil. **Urban Climate**, Volume 38, 2021b. ISSN 2212-0955 | DOI: <https://doi.org/10.1016/j.uclim.2021.100911>.

SILVEIRA, I. H.; CORTES, T. R.; OLIVEIRA, B. F. A.; JUNGER, W. L. Projections of excess cardiovascular mortality related to temperature under different climate change scenarios and regionalized climate model simulations in Brazilian cities. **Environmental Research**, 197, 110995, 2021. DOI: <https://doi.org/10.1016/j.envres.2021.110995>

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** [online], v. 33, n. 2, pp. 380-389, 2018. DOI: <https://doi.org/10.1590/0102-7786332010>.

SIQUEIRA, A. S. P.; Praça, H. L. F.; Santos, J. P. C.; ALBUQUERQUE, H. G.; PEREIRA, L. H. V.; CESAR, T. S.; GUSMÃO, E. V. V.; PEREIRA, A. A. T.; PIMENTA JUNIOR, F. G.; NOBRE, A. A.; ALVES, M. B.; BARCELLOS, C.; CARVALHO, M. S.; SABROZA, P. C.; HONÓRIO, N. A. ArboAlvo: método de estratificação da receptividade territorial às arboviroses urbanas. **REVISTA DE SAÚDE PÚBLICA (ONLINE)**, v. 56, p. 1-14, 2022.

Sophia, Y., Roxy, M.K., Murtugudde, R. et al. Dengue dynamics, predictions, and future increase under changing monsoon climate in India. **Scientific Reports**, 15, 1637, 2025. <https://doi.org/10.1038/s41598-025-85437-w>

SOUSA, T. C. M.; AMÂNCIO, F.; HACON, S. S.; BARCELLOS, C. Doenças sensíveis ao clima no Brasil e no mundo: revisão sistemática [Climate-sensitive diseases in Brazil and the world: systematic review] [Enfermedades sensibles al clima en Brasil y el mundo: revisión sistemática]. **Revista Panamericana de Salud Publica = Pan American Journal of Public Health**, 42, e85, 2018. DOI: <https://doi.org/10.26633/RPSP.2018.85>

SOUZA, S. S. S.; SILVA, I. G.; SILVA, H. H. G. **Associação entre incidência de dengue, pluviosidade e densidade larvária de Aedes aegypti, no Estado de Goiás**. **Revista da Sociedade Brasileira de Medicina Tropical**, 43(2): 152-155, mar-abr, 2010.

SOUZA, Maria Salete de. **MEIO AMBIENTE URBANO E SANEAMENTO BÁSICO. Mercator**, Fortaleza, v. 1º de janeiro. 2009. ISSN 1984-2201. Disponível em: < <http://www.mercator.ufc.br/mercator/article/view/194> >. Data de acesso: 14 jan. 2024. doi: <https://doi.org/10.4215/rm.v1i1.194>.

TEIXEIRA, M. da G.; BARRETO, M. L.; GUERRA, Z. Epidemiologia e medidas de prevenção da dengue. **Informe epidemiológico do SUS**, v. 8, n. 4, pág. 5-33, 1999.

TRAN, M.-N. A Criterion for Optimal Predictive Model Selection. **Communications in Statistics-Theory and Methods**, 40(5), 893–906, 2011. DOI: <https://doi.org/10.1080/03610920903486798>

VASCONCELOS JUNIOR, F. C.; JONES, C.; GANDU, A. W. **Interannual and Intraseasonal variations of the Onset and Demise of the Pre-Wet Season and The Wet Season in the Northern Northeast Brazil**. Revista Brasileira de Meteorologia, Rio de Janeiro, v. 33, n. 3, p. 472-484, 2018.

VIANA, D.V., IGNOTTI, E. (2013). **A ocorrência da dengue e variações meteorológicas no Brasil: revisão sistemática**. Revista Brasileira de Epidemiologia, 16(2), 240–256. <https://doi.org/10.1590/S1415-790X2013000200002>

XAVIER, A. C.; Scanlon, B. R.; King, C. W.; Alves, A. I. New improved Brazilian daily weather gridded data (1961–2020). **International Journal of Climatology**, v. 42, n. 16, p. 8390–8404, 2022.

WAINER, I., SERVAIN, J., CLAUZET, G. Is the decadal variability in the tropical atlantica precursor to the NAO. In **Clima do Atlântico Tropical e Impactos Sobre o Nordeste (CATIN)**. Org. Sevain, J., Campos, J. N. B., Martins, E. S. P. R., Reis Junior, D. R., 1ed., FUNCEME/IRD, Fortaleza - CE, v. 1, p. 17-34, 2010.

WERMELINGER, E.D., **Interdisciplinaridade na estratégia de controle dos vetores urbanos das arboviroses: uma dimensão necessária para o Brasil**. Cadernos de saúde pública, 38(1), pp. Cadernos de saúde pública, 2022, Vol.38 (1).

YOKOO, S. C. **Clima e saúde: estudo sobre a influência do tempo atmosférico no número de notificações de dengue no município de Campo Mourão-PR**. In. **Encontro de Produção Científica e Tecnológica**, 5., 2010, Campo Mourão. **Anais eletrônicos...** Campo Mourão: FECILCAM, 2010. Disponível em: Acesso em: 09 agosto 2022.

ZHAO, J.; ZHANG, Y.; NI, Y.; HE, J.; WANG, J.; LI, X.; GUO, Y.; LI, C.; ZHANG, W.; CUI, Z. Effect of ambient temperature and other environmental factors on stroke emergency department visits in Beijing: A distributed lag non-linear model. **Frontiers in Public Health**, 10, 1034534, 2022. DOI: <https://doi.org/10.3389/fpubh.2022.1034534>

APÊNDICE

```
rm(list=ls()) #Limpar memoria
library(readxl)
```

#Entrada de Dados

```
dados <- read_excel("C:/Users/Luiz/Documents/Unilab/PGEA_mestrado_unilab/Orientandos/Thamara/dados_fortaleza.xlsx")
View(dados)
tsd<-ts(dados$Dengue,start=c(2008,1),freq=12)
#tsE<-ts(dados$`EMI`,start=c(2008,1),freq=12)
#tsnino12<-ts(dados$nino12,start=c(2008,1),freq=12)
#tsnino3<-ts(dados$nino3,start=c(2008,1),freq=12)
#tsnino34<-ts(dados$nino34,start=c(2008,1),freq=12)
#tsnino4<-ts(dados$nino4,start=c(2008,1),freq=12)
#tsatn<-ts(dados$atn,start=c(2008,1),freq=12)
#tsats<-ts(dados$ats,start=c(2008,1),freq=12)
#tsatlgrad<-ts(dados$atlgrad,start=c(2008,1),freq=12)
#tsatl3<-ts(dados$atl3,start=c(2008,1),freq=12)
tsp<-ts(dados$`Chuva (mm)`,start=c(2008,1),freq=12)
tsTmed<-ts(dados$Tmed,start=c(2008,1),freq=12)
tsTmin<-ts(dados$Tmin,start=c(2008,1),freq=12)
tsTmax<-ts(dados$Tmax,start=c(2008,1),freq=12)
```

#Visualizando as series temporais

```
#plot(ts.union(tsd,tsp,tsTmed,tsTmin,tsTmax)) # SEM LOG
plot(ts.union(log(tsd),tsp,tsTmed,tsTmin,tsTmax)) #COM LOG
```

#REALIZAR A CORRELAÇÃO CRUZADA

#COM LOG

```
acf(ts.union(log(tsd),tsp),na.action=na.pass,ylim=c(-1,1))
acf(ts.union(log(tsd),tsTmed),na.action=na.pass,ylim=c(-1,1))
acf(ts.union(log(tsd),tsTmin),na.action=na.pass,ylim=c(-1,1))
acf(ts.union(log(tsd),tsTmax),na.action=na.pass,ylim=c(-1,1))
```

Criando variáveis defasadas

#PRECIPITAÇÃO

```
length(tsp)
tsp1<-ts()
tsp2<-ts()
```

```

tsp3<-ts()
for (i in 1:length(tsp)) {
  if(i<length(tsp)& i==1){tsp1[[1]]<-NA}
  if(i<=length(tsp) & i>1){tsp1[[i]]<-tsp[[i-1]]}
  else{tsp1[[i]]<-NA}
}

for (i in 1:length(tsp)) {
  for(j in 1:2){
    tsp2[[j]]<-NA
  }
  if(i<=length(tsp) & i>2){tsp2[[i]]<-tsp[[i-2]]}
  else{tsp2[[i]]<-NA}
}

for (i in 1:length(tsp)) {
  for(j in 1:3){
    tsp3[[j]]<-NA
  }
  if(i<=length(tsp) & i>3 ){tsp3[[i]]<-tsp[[i-3]]}
  else{tsp3[[i]]<-NA}
}

tsp1<-ts(tsp1,start=c(2008,1),freq=12)
tsp2<-ts(tsp2,start=c(2008,1),freq=12)
tsp3<-ts(tsp3,start=c(2008,1),freq=12)

```

#TEMPERATURA MÉDIA

```

length(tsTmed)
tsTmed1<-ts()
tsTmed2<-ts()
tsTmed3<-ts()

for (i in 1:length(tsTmed)) {
  for(j in 1:1){
    tsTmed1[[j]]<-NA
  }
  if(i<=length(tsTmed) & i>1 ){tsTmed1[[i]]<-tsTmed[[i-1]]}
  else{tsTmed1[[i]]<-NA}
}

for (i in 1:length(tsTmed)) {

```

```

for(j in 1:2){
  tsTmed2[[j]]<-NA
}
if(i<=length(tsTmed) & i>2 ){tsTmed2[[i]]<-tsTmed[[i-2]]}
else{tsTmed2[[i]]<-NA}
}

for (i in 1:length(tsTmed)) {
  for(j in 1:3){
    tsTmed3[[j]]<-NA
  }
  if(i<=length(tsTmed) & i>3 ){tsTmed3[[i]]<-tsTmed[[i-3]]}
  else{tsTmed3[[i]]<-NA}
}

tsTmed1<-ts(tsTmed1,start=c(2008,1),freq=12)
tsTmed2<-ts(tsTmed2,start=c(2008,1),freq=12)
tsTmed3<-ts(tsTmed3,start=c(2008,1),freq=12)

```

#TEMPERATURA MÍNIMA

```

length(tsTmin)
tsTmin1<-ts()
tsTmin2<-ts()
tsTmin3<-ts()

for (i in 1:length(tsTmin)) {
  for(j in 1:1){
    tsTmin1[[j]]<-NA
  }
  if(i<=length(tsTmin) & i>1 ){tsTmin1[[i]]<-tsTmin[[i-1]]}
  else{tsTmin1[[i]]<-NA}
}

for (i in 1:length(tsTmin)) {
  for(j in 1:2){
    tsTmin2[[j]]<-NA
  }
  if(i<=length(tsTmin) & i>2 ){tsTmin2[[i]]<-tsTmin[[i-2]]}
  else{tsTmin2[[i]]<-NA}
}

for (i in 1:length(tsTmin)) {

```

```

for(j in 1:3){
  tsTmin3[[j]]<-NA
}
if(i<=length(tsTmin) & i>3 ){tsTmin3[[i]]<-tsTmin[[i-3]]}
else{tsTmin3[[i]]<-NA}
}

```

```

tsTmin1<-ts(tsTmin1,start=c(2008,1),freq=12)
tsTmin2<-ts(tsTmin2,start=c(2008,1),freq=12)
tsTmin3<-ts(tsTmin3,start=c(2008,1),freq=12)

```

#TEMPERATURA MÁXIMA

```

length(tsTmax)
tsTmax1<-ts()
tsTmax2<-ts()
tsTmax3<-ts()

```

```

for (i in 1:length(tsTmax)) {
  if(i<length(tsTmax)& i==1){tsTmax1[[1]]<-NA}
  if(i<=length(tsTmax) & i>1){tsTmax1[[i]]<-tsTmax[[i-1]]}
  else{tsTmax1[[i]]<-NA}
}

```

```

for (i in 1:length(tsTmax)) {
  for(j in 1:2){
    tsTmax2[[j]]<-NA
  }
  if(i<=length(tsTmax) & i>2 ){tsTmax2[[i]]<-tsTmax[[i-2]]}
  else{tsTmax2[[i]]<-NA}
}

```

```

for (i in 1:length(tsTmax)) {
  for(j in 1:3){
    tsTmax3[[j]]<-NA
  }
  if(i<=length(tsTmax) & i>3 ){tsTmax3[[i]]<-tsTmax[[i-3]]}
  else{tsTmax3[[i]]<-NA}
}

```

```

tsTmax1<-ts(tsTmax1,start=c(2008,1),freq=12)
tsTmax2<-ts(tsTmax2,start=c(2008,1),freq=12)
tsTmax3<-ts(tsTmax3,start=c(2008,1),freq=12)

```

#Análise dos mais significativos

```
#fit.lm<-lm(log(tsd) ~
tsTmax+tsTmax1+tsTmax2+tsTmax3+tsTmin+tsTmin1+tsTmin2+tsTmin3+tsT
med+tsTmed1+tsTmed2+tsTmed3+tsp+tsp1+tsp2+tsp3)
fit.lm<-lm(log(tsd) ~
tsTmax+tsTmax1+tsTmin3+tsTmed+tsp+tsp1+tsp2+tsp3) #modelo teste
com variaveis de correlação acima de 0.2
summary(fit.lm)
fit.lm<-lm(log(tsd) ~ tsTmin3+tsp1+tsp2)#Ajuste das mais
significativas
summary(fit.lm)
```

```
par(mfrow=c(2,2))
plot(resid(fit.lm))
qqnorm(resid(fit.lm))
qqline(resid(fit.lm))
acf(resid(fit.lm))
pacf(resid(fit.lm))
```

```
fit.arma<-arima(resid(fit.lm),order=c(1,0,1)
)
plot(resid(fit.arma))
qqnorm(resid(fit.arma))
qqline(resid(fit.arma))
acf(resid(fit.arma))
pacf(resid(fit.arma))
```

#Aplicação da a função GLS

```
library(nlme)
model<-formula(log(tsd) ~ tsTmin3 + tsp1 + tsp2 )
df_dados<-data.frame(tsTmin3,tsp1,tsp2)
fit.gls<-glsl(model,data=df_dados,na.action=na.omit) #AJUSTE DOS
COEFICIENTES DA OLS
summary(fit.gls)
```

```
#Variáveis de desempenho do teste
rmse<-sqrt(mean(residuals(fit.gls)^2))
rmse
sdo<-sd(log(tsd),na.rm=TRUE)
srmse<-rmse/sdo
srmse
```

```

#Teste da previsão
prev<-predict(fit.gls,newdata=df_dados,na.action=na.omit)
#TENTATIVA 3, SEM CORRELAÇÃO#
prev
prev.ts<-ts(prev,start=c(2008,4),freq=12)
prev.ts
plot(log(tsd))
lines(prev.ts,col="red")
#Calibração e Validação do Modelo
library(nlme)

#Figura de demonstração dos períodos
par(mfrow=c(1,1))
logtsd<-log(tsd)
plot(logtsd)
treinamento<-ts(logtsd[1:93],start=c(2008,1),freq=12)      #      Até
setembro 2015
lines(treinamento,col="red")
validacao<-ts(logtsd[93:132],start=c(2015,9),freq=12)
lines(validacao,col="green")
#Treinamento do modelo

tsTmin3_treino<-ts(tsTmin3[1:93],start=c(2008,1),freq=12)
tsp1_treino<-ts(tsp1[1:93],start=c(2008,1),freq=12)
tsp2_treino<-ts(tsp2[1:93],start=c(2008,1),freq=12)

model_treinamento<-formula(treinamento ~ tsTmin3_treino +
tsp1_treino + tsp2_treino )
df_treino<-data.frame(tsTmin3_treino,tsp1_treino,tsp2_treino)
fit.gls_treino<-
glS(model_treinamento,data=df_treino,na.action=na.omit)      #AJUSTE
DOS COEFICIENTES DA OLS
summary(fit.gls_treino)

#Variáveis de desempenho do treinamento
rmse_treino<-sqrt(mean(residuals(fit.gls_treino)^2))
rmse_treino
sdo_treino<-sd(treinamento,na.rm=TRUE)
#sdo_treino
srmse_treino<-rmse_treino/sdo_treino
srmse_treino
#Previsão com dados do treinamento.
prev_treino<-
predict(fit.gls_treino,newdata=df_treino,na.action=na.omit)
#TENTATIVA 3, SEM CORRELAÇÃO#

```

```

prev_treino
prev_treino.ts<-ts(prev_treino,start=c(2008,4),freq=12)      #
start=c(2008,6) se treinamento ~ tsTmin_treino + tsE_treino +
tsTmax5_treino + tsatlgrad5_treino
prev_treino.ts                                              #
start=c(2008,7) se treinamento ~ tsTmin_treino + tsTmax5_treino +
tsp6_treino

plot(treinamento)
lines(prev_treino.ts,col="blue")

```

#Validação do modelo

```

validacao<-ts(logtsd[94:132],start=c(2015,10),freq=12)

tsTmin3_validacao<-ts(tsTmin3[94:132],start=c(2015,10),freq=12)
tsp1_validacao<-ts(tsp1[94:132],start=c(2015,10),freq=12)
tsp2_validacao<-ts(tsp2[94:132],start=c(2015,10),freq=12)
df_validacao<-
data.frame(tsTmin3_validacao,tsp1_validacao,tsp2_validacao)
colnames(df_validacao)                                     <-
c("tsTmin3_treino","tsp1_treino","tsp2_treino")

prev_validacao<-
predict(fit.gls_treino,newdata=df_validacao,na.action=na.omit)
#TENTATIVA 3, SEM CORRELAÇÃO#
prev_validacao
prev_validacao.ts<-ts(prev_validacao,start=c(2015,10),freq=12)
prev_validacao.ts

plot(validacao)
lines(prev_validacao.ts,col="blue")

```