

PROGRAMA DE PÓS-GRADUAÇÃO STRICTO SENSU EM  
POLÍTICAS PÚBLICAS EM SAÚDE  
ESCOLA FIOCRUZ DE GOVERNO  
FUNDAÇÃO OSWALDO CRUZ

Rachel Helen Borges da Silva Bitar

MODELOS PREDITIVOS DE CENÁRIOS DE TRANSMISSÃO DA  
DENGUE: uma revisão de escopo

Brasília  
2022

Rachel Helen Borges da Silva Bitar

MODELOS PREDITIVOS DE CENÁRIOS DE TRANSMISSÃO DA  
DENGUE: uma revisão de escopo.

Trabalho de Dissertação apresentado à Escola  
Fiocruz de Governo como requisito parcial para  
obtenção do título de mestre em Políticas  
Públicas em Saúde, linha de pesquisa Saúde e  
Justiça Social.

Orientador: Prof. Dr. Walter Massa Ramalho  
Coorientadora: Profa. Dra. Helen da Costa  
Gurgel

Brasília/DF  
2022

Título do trabalho em inglês: Models for predicting dengue transmission scenarios: a scoping review.

B624m Bitar, Rachel Helen Borges da Silva.  
Modelos preditivos de cenários de transmissão da dengue: uma revisão de escopo / Rachel Helen Borges da Silva Bitar. -- 2022.  
125 f. : il. color.

Orientador: Walter Massa Ramalho.  
Coorientadora: Helen da Costa Gurgel.  
Dissertação (Mestrado Profissional em Políticas Públicas em Saúde),  
Brasília, 2022.  
Bibliografia: f. 81-88.

1. Dengue. 2. Transmissão de Doença Infecciosa. 3. Aprendizado de Máquina. 4. Previsão. I. Título.

CDD 614

Elaborada pelo Sistema de Geração Automática de Ficha Catalográfica da Rede de Bibliotecas da Fiocruz com os dados fornecidos pelo(a) autor(a).

Bibliotecário responsável pela elaboração da ficha catalográfica: Livia Rodrigues Batista - CRB-1/3443  
Biblioteca Fiocruz Brasília

Rachel Helen Borges da Silva Bitar

**MODELOS PREDITIVOS DE CENÁRIOS DE TRANSMISSÃO DA  
DENGUE: uma revisão de escopo.**

Trabalho de Dissertação apresentado à Escola  
Fiocruz de Governo como requisito parcial para  
obtenção do título de mestre em Políticas  
Públicas em Saúde, linha de pesquisa Saúde e  
Justiça Social.

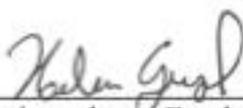
Aprovado em: 25/11/2022.

**BANCA EXAMINADORA**



---

Dr. Walter Massa Ramalho - Orientador - Fundação Oswaldo Cruz - Fiocruz Brasília



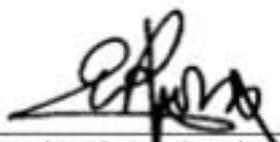
---

Dra. Helen da Costa Gurgel – Coorientadora - Fundação Oswaldo Cruz - Fiocruz Brasília

Documento assinado digitalmente  
**gov.br** EVERTON NUNES DA SILVA  
Data: 04/01/2023 13:31:57-0300  
Verifique em <https://verificador.jfi.br>

---

Dr. Everton Nunes da Silva. Fundação Oswaldo Cruz - Fiocruz Brasília



---

Dr. Emmanuel Roux. IRD - Institut de Recherche pour le Développement - França

---

Dr. Jorge Otávio Maia Barreto (suplente). Fundação Oswaldo Cruz - Fiocruz Brasília

*Dedico este trabalho a todos os trabalhadores do SUS,  
para que tenham coragem na busca de mais  
conhecimento científico.*

## **AGRADECIMENTOS**

À Deus, minha grande fortaleza.

Aos meus queridos e amados pais, Ester e Horácio, que me ensinaram a sempre buscar pelos meus sonhos e por me incentivarem a nunca parar de estudar.

Ao meu querido e amado esposo, Paulo Bitar Júnior, pelo incansável apoio, compreensão e paciência, durante este percurso.

Aos meus familiares e amigos, que foram compreensivos com as minhas ausências e sempre me fortaleceram nos momentos difíceis.

À geógrafa Krishna Freire, que colaborou na execução deste trabalho.

Aos meus orientadores, aos quais tenho enorme respeito e, gratidão por não desistirem de mim.

*“Se pudéssemos primeiro saber onde estamos e para onde estamos indo, poderíamos julgar melhor o que fazer e como fazer.” (Abraham Lincoln)*

## RESUMO

Este estudo mapeia os modelos utilizados para prever cenários de dengue, descritos na literatura científica mundial entre 1968 e 2021, pesquisados nas bases de dados Pubmed, Embase e portal BVS. Descreve técnicas de modelagens e parâmetros que utilizaram obrigatoriamente dados de incidência da doença e ao menos dois fatores ligados à sua transmissão em seres humanos, ao tempo que exclui os artigos que utilizaram dados exclusivamente entomológicos ou climáticos. Analisa as informações de 24 artigos incluídos na revisão. Verifica os indicadores bibliométricos dos artigos incluídos, por meio do fator de impacto das revistas. Identifica os tipos de modelagens mais utilizados, em que se destacam *machine learning* (ML), estatística, matemática e redes neurais. Consolida 75 tipos variáveis preditoras e suas frequências, categorizadas em 7 grupos. Detecta o nível de aplicação dos modelos no território, sendo os mais usados: município ou cidade, estado e província. Demonstra nos resultados que as técnicas de modelagens ganharam maior capacidade preditiva com o uso de ML, com antecipação de surto em até 3 meses e maior acurácia em até 4 semanas. Entretanto, existe grande variedade de modelos e usos de dados climáticos e entomológicos, além do que há tendência cada vez mais forte na incorporação nos modelos, de fatores sensíveis à transmissão da dengue, de ordem socioeconômica e demográfica, contexto territorial e de saúde. Conclui que a dinâmica complexa de transmissão da dengue exige modificações contínuas nas análises preditivas, para que sejam capazes de refletirem os movimentos humanos que desencadeiam a presença e proliferação dos seus vetores em áreas climaticamente favoráveis.

Palavras-Chave: Dengue. Modelos Matemáticos. Modelos Estatísticos. Aprendizado de Máquina. Previsão.

## ABSTRACT

This study maps the models used to predict dengue scenarios, described in the world scientific literature between 1968 and 2021, searched in Pubmed, Embase and the BVS portal databases. It describes modeling techniques and parameters that used mandatory disease incidence data and at least two factors linked to its transmission in humans. Excludes articles that used exclusively entomological or climatic data. Analyzes the information from 24 articles included in the review. Verifies the bibliometrics indicators of the included articles, using the impact factor of the journals. Identifies the types of modeling most used, in which machine learning (ML), statistics, mathematics, and neural networks stand out. Consolidates 75 predictor variable types and their frequencies, categorized into 7 groups. Detects the level of application of the models in the territory, being the most used: county or city, state, and province. It shows in the results that modeling techniques have gained greater predictive capacity with the use of ML, with outbreak anticipation up to 3 months and greater accuracy up to 4 weeks. However, there is a great variety of models and uses of climatic and entomological data, and there is a growing trend to incorporate into the models factors sensitive to dengue transmission, of socioeconomic and demographic order, territorial and health context. It concludes that the complex dynamics of dengue transmission requires continuous modifications in predictive analyses, so that they can reflect the human movements that trigger the presence and proliferation of its vectors in climatically favorable areas.

Keywords: Dengue. Mathematical Models. Statistical Models. Machine Learning. Forecasting

## RESUMEN

Este estudio mapea los modelos utilizados para predecir escenarios de dengue, descritos en la literatura científica mundial, buscada en las bases de datos Pubmed, Embase y el portal BVS. Describe las técnicas de modelización y los parámetros que utilizan necesariamente datos sobre la incidencia de la enfermedad y al menos dos factores relacionados con su transmisión en el ser humano. Excluye los artículos que utilizan exclusivamente datos entomológicos o climáticos. Analiza la información de 24 artículos incluidos en la revisión. Verifica los indicadores bibliométricos de los artículos incluidos, utilizando el factor de impacto de las revistas. Identifica los tipos de modelización más utilizados, en los que destacan el aprendizaje automático (ML), la estadística, las matemáticas y las redes neuronales. Consolida 75 tipos de variables predictoras y sus frecuencias, clasificadas en 7 grupos. Detecta el nivel de aplicación de los modelos en el territorio, siendo los más utilizados: municipio o ciudad, estado y provincia. Concluye que las técnicas de modelización ganaron mayor capacidad de predicción con el uso del ML, con anticipación del brote en hasta 3 meses y mayor precisión en hasta 4 semanas. Observa una variedad en el uso de los datos climáticos y entomológicos. Además, se tiende a incorporar en los modelos otros factores sensibles a la transmisión del dengue, de orden socioeconómico y demográfico, de contexto territorial y de salud. Se concluye que la dinámica compleja de la transmisión del dengue requiere modificaciones continuas en los análisis predictivos, para que sean capaces de reflejar los movimientos humanos que desencadenan la presencia y proliferación de sus vectores en áreas climáticamente favorables.

Palabras clave: Dengue. Modelos matemáticos. Modelos estadísticos. Aprendizaje automático. Predicción del escenario.

## LISTA DE FIGURAS

<b>Figura 1</b> Representação conceitual dos tipos de modelagens.....	34
<b>Figura 2</b> Diagrama de fluxo PRISMA.....	46
<b>Figura 3</b> Mapa de localização dos países alvo dos estudos por continentes. ....	50
<b>Figura 4</b> Áreas temáticas dos artigos incluídos publicados nas Revistas Plos e Nature. ....	52
<b>Figura 5</b> Palavras-chave dos artigos incluídos nas revistas científicas. ....	52
<b>Figura 6</b> Frequência do parâmetro: tipos de modelagens. ....	55
<b>Figura 8</b> Frequência do parâmetro: programas ( <i>softwares</i> ) para modelagens.....	57
<b>Figura 9</b> Frequência percentual do parâmetro: escala espacial dos dados. ....	58
<b>Figura 10</b> Frequência percentual do parâmetro: unidade temporal de previsão.....	58
<b>Figura 11</b> Frequência percentual do parâmetro: período de previsão antecipada. ....	59
<b>Figura 12</b> Frequência percentual do parâmetro: período de experimento.....	59
<b>Figura 13</b> Frequência percentual das variáveis preditoras por grupo.....	60
<b>Figura 15</b> Frequência percentual do parâmetro: variável – entomológica (top 12). ....	62
<b>Figura 16</b> Frequência percentual do parâmetro: variável - climática e ambiental (top 18)....	63
<b>Figura 17</b> Frequência percentual do parâmetro: variável - contexto territorial (top 10). ....	64
<b>Figura 18</b> Frequência percentual do parâmetro: variável - fator calendário.....	64
<b>Figura 19</b> Frequência percentual do parâmetro: variável - demográfica / socioeconômica. ....	65
<b>Figura 20</b> Frequência percentual do parâmetro: variável - contexto saúde.....	66

## LISTA DE QUADROS

<b>Quadro 1</b> Parâmetros para extração dos dados.....	42
---	----

## LISTA DE TABELAS

<b>Tabela 1</b> Mapeamento de indicadores bibliométricos dos artigos incluídos: fator de impacto dos periódicos, países das pesquisas, palavras-chave, fonte de financiamento e conflitos de interesses.....	48
<b>Tabela 4</b> Resumo dos parâmetros mais frequentes, por grupo mapeado.....	68
<b>Tabela 5</b> Número de variáveis preditoras e grupos de variáveis por artigo incluído. ....	69
<b>Tabela 2</b> Mapeamento das técnicas de modelagens e parâmetros intimamente associados nos modelo. ....	95
<b>Tabela 3</b> Mapeamento das variáveis, tipos de modelagens e escala espacial dos dados, nos artigos incluídos.....	100
<b>Tabela 6</b> Frequência do parâmetro: tipos de modelagens.....	107
<b>Tabela 7</b> Frequência do parâmetro: programas (softwares) para modelagens. ....	107
<b>Tabela 8</b> Frequência do parâmetro: variável – incidência.....	107
<b>Tabela 9</b> Frequência do parâmetro: variável – entomológicas.....	108
<b>Tabela 10</b> Frequência do parâmetro: variável - climáticas e ambientais.....	109
<b>Tabela 11</b> Frequência do parâmetro: variável - fator calendário.....	110
<b>Tabela 12</b> Frequência do parâmetro: variável - contexto territorial. ....	110
<b>Tabela 13</b> Frequência do parâmetro: variável - demográfico / socioeconômico.....	111
<b>Tabela 14</b> Frequência do parâmetro: variável - contexto saúde. ....	111
<b>Tabela 15</b> Frequência do parâmetro: variáveis preditoras por grupo. ....	111
<b>Tabela 16</b> Frequência do parâmetro: escala espacial dos dados.....	112
<b>Tabela 17</b> Frequência do parâmetro: localização. ....	112
<b>Tabela 18</b> Frequência do parâmetro: unidade temporal de previsão.....	113
<b>Tabela 19</b> Frequência do parâmetro: período de previsão antecipada.....	113
<b>Tabela 20</b> Frequência do parâmetro: período de experimento. ....	114

## LISTA DE SIGLAS E ABREVIATURAS

ANN "*Artificial neural network*" Rede neural artificial

AR "*Autoregressive model*" Modelo autorregressivo

ARIMA "*Autoregressive integrated moving average model*" Modelo auto-regressivo integrado de médias móveis

B-TSM "*Bayesian time series model*" Modelo de série temporal bayesiano

BFAST "*Breaks For Additive Seasonal Trend*" Quebras para o algoritmo aditivo de sazonalidade e tendência

BYM "*Besag-York-Mollie model*" Modelo Besag-York-Mollie

CAR "*Conditional autoregressive model*" Modelo auto-regressivo condicional

CART "*Classification and Regression Trees*" Árvores de decisão - classificação e regressão

CMORMH "*Climate prediction center Morphing method from NOAA*" Método de Morphing do centro de previsão climática da NOAA

CPC "*Climate prediction center from NOAA*" Centro de previsões climáticas da NOAA

DLNM "*Distributed lag non-linear models*" Modelos não lineares de atraso distribuído

EOS "*Earth observing system*" Sistema de observação terrestre da nasa

EVI "*Enhanced vegetation index*" Índice de vegetação aprimorada

FARM "*Fuzzy Association Rule Mining*" Associação Fuzzy Regra de Mineração

GAM "*Generalized additive model*" Modelo aditivo generalizado

GBM "*Gradient boosted regression tree algorithm*" Algoritmo de árvore de regressão impulsionada por gradiente

GINI INDEX "*Gini index or coefficient*" Índice de Gini - indicador da desigualdade econômica (mede a distribuição de renda ou a distribuição de riqueza entre uma população)

GLM "*Generalized linear bayesian models*" Modelos lineares generalizados bayesianos

GLMM "*Generalized linear bayesian mixed models*" Modelos lineares generalizados bayesianos mistos

GLMNET "*Lasso and elastic-net regularized generalized linear models*" Modelos lineares generalizados regularizados LASSO e elastic-net

GMRF "*Gaussian Markov random field*" Campo aleatório gaussiano Markov

IAMAT "*International association for medical assistance to travelers*" Associação internacional de assistência médica aos viajantes

IBGE Instituto brasileiro de geografia e estatística

INLA "*Integrated nested Laplace approximation methods*" Modelo Bayesiano espacial hierárquico utilizando algoritmo integrado de aproximação de Laplace

KNN "*K-Nearest Neighbor*" K - vizinhos mais próximos

LASSO "*Least absolute shrinkage and selection operator based models*" Modelo baseado no mínimo de encolhimento absoluto e operador de seleção

LP DAAC "*Land processes distributed active archive center from NASA*" Processos do solo - centro de arquivo ativo distribuído da NASA

LRM "*Linear regression models*" Modelos de regressão linear

LSTM "*Rede neural Long Short-Term Memory*" Rede neural memória de curto prazo

ML "*Machine learning*" Aprendizado de máquina

MLP "*Multilayer perceptron*" Perceptron de multiplas camadas

MLR "*Multinomial logistic regression*" Regressão logística multinomial

MOD11C2.006 "*MODIS - terra land surface temperature 8-day image products*" MODIS - temperatura da superfície da terra - produtos de imagem de 8 dias

MOD13C1.006 "*MODIS - terra vegetation indices 16-day image products*" MODIS - índices de vegetação da terra - produtos de imagem de 16 dias

MODIS "*Moderate resolution imaging spectroradiometer*" Espectroradiômetro de imagem de resolução moderada

MPR "*Multivariate Poisson regression*" Regressão multivariada de Poisson

NBM "*Negative binomial regression model*" Modelo de regressão binomial negativo

NASA "*National aeronautics and space administration*" Agência espacial norte-americana

NDVI "*Normalized difference vegetation index*" Índice de vegetação da diferença normalizada

NN "*Neural Network*" Rede Neural

NN-SIRS "*Neural network informed by a susceptible-infectious-recovered-susceptible (SIRS) compartmental model*" Rede neural formada por um modelo de compartimento susceptível-infectado-recuperado-susceptível (SIRS)

NN-TSM "*Neural network time series model*" Modelo de séries temporais de redes neurais

NOAA "*National oceanic and atmospheric administration*" Administração oceânica e atmosférica nacional

PLS "*Partial least squares*" Mínimos quadrados parciais

RF "*Random forests*" Florestas aleatórias

ROC "*Receiver operating characteristics*" Características de funcionamento do receptor

SARIMA "*Seasonal autoregressive integrated moving average model*" Modelo auto-regressivo integrado de médias móveis sazonais

SEIRS "*Susceptible-exposed-infectious-recovered compartmental model*" Modelo compartmental suscetível-exposto-infectado-recuperado

SIR "*Susceptible-infectious-recovered compartmental model*" Modelo compartmental suscetível--infectado-recuperado

SVM "*Support vector machine*" Máquina de vetor de suporte

TAN "*Tree Augmented Naïve Bayes*" Árvore aumentada do Naive Bayes (construção de classificadores)

## LISTA DE SÍMBOLO

® Marca registrada

## SUMÁRIO

<b>1 INTRODUÇÃO .....</b>	<b>20</b>
<b>2 REVISÃO BIBLIOGRÁFICA .....</b>	<b>24</b>
2.1 A ESCOLHA DO MÉTODO DE REVISÃO.....	24
2.2 DENGUE NO CONTEXTO DE SAÚDE PÚBLICA .....	25
2.3 MODELAGEM PREDITIVA E CONSTRUÇÃO DE CENÁRIOS EPIDEMIOLÓGICOS .....	30
<b>3 METODOLOGIA.....</b>	<b>37</b>
3.1 TIPO DE REVISÃO: .....	37
3.2 ETAPAS DA REVISÃO: .....	37
3.2.1 Busca das fontes de informação .....	38
3.2.2 Seleção dos estudos .....	39
3.2.3 Extração dos dados .....	41
3.2.4 Síntese dos resultados .....	43
3.2.5 Redação e publicação dos resultados.....	44
<b>4 RESULTADOS .....</b>	<b>45</b>
4.1 ANÁLISE DOS INDICADORES BIBLIOMÉTRICOS .....	47
4.2 MODELAGEM PREDITIVA EM DENGUE .....	53
<b>5 DISCUSSÃO .....</b>	<b>71</b>
<b>6 CONCLUSÃO.....</b>	<b>78</b>
<b>REFERÊNCIAS.....</b>	<b>80</b>
<b>APENDICE A – ESTRATÉGIAS APLICADAS NAS BASES DE DADOS .....</b>	<b>88</b>

<b>APÊNDICE B – GUIA DE REDAÇÃO PRISMA.....</b>	<b>92</b>
<b>APÊNDICE C – PALAVRAS-CHAVE E ÁREAS TEMÁTICAS .....</b>	<b>94</b>
<b>APENDICE D - RECORTE DAS TÉCNICAS DE MODELAGENS, NÚMERO DE VARIÁVEIS E FATORES ASSOCIADOS À PREDIÇÃO .....</b>	<b>95</b>
<b>APÊNDICE E - FREQUÊNCIAS DOS PARÂMETROS.....</b>	<b>107</b>
<b>APÊNDICE F - DESCRIÇÃO AGRUPADA POR SEMELHANÇA DOS MÉTODOS DE MODELAGENS MAPEADOS .....</b>	<b>115</b>
<b>APÊNDICE G - FONTES DOS DADOS DOS ARTIGOS INCLUÍDOS .....</b>	<b>117</b>
<b>APENDICE H – OBJETIVOS DOS ARTIGOS INCLUÍDOS .....</b>	<b>122</b>

## 1 INTRODUÇÃO

A dengue é uma arbovirose, doença transmitida por mosquitos, fêmeas, do gênero *Aedes* (*Ae. albopictus* e *Ae. aegypti*, seus principais vetores). Além da dengue esses mosquitos também são vetores dos vírus chikungunya, febre amarela, e zika (1–3).

Epidemias compatíveis com a dengue são registradas no mundo desde o século III a.C. A dengue atingiu ao longo dos séculos diversos países de clima tropical e subtropical em diferentes continentes - China, França (Antilhas), Egito, Líbia, Indonésia, EUA, Espanha, Índia, Síria, Taiwan e os que pertencem à África oriental. Em 1983 a Organização Mundial da Saúde (OMS) adotou o termo dengue, durante o *Council for International Organizations of Medical Sciences* (4,5).

Estima-se que cerca de 2,5 bilhões de pessoas que vivem em países tropicais e subtropicais estão expostas ao risco de se infectarem por dengue.

De acordo com a OMS, no bloco mundial, engloba-se para o perfil de transmissão da dengue as seguintes regiões e/ou continentes: África, Américas, Mediterrâneo oriental, Europa, Pacífico ocidental, sudeste da Ásia (6). Ao longo das últimas décadas a dengue causou epidemias recorrentes, sobrecarregando sistemas de saúde públicos (5,7,8).

Um estudo recente, sobre a distribuição global e carga de adoecimento, estimou 390 milhões de casos por ano de infecções por dengue ao redor do mundo, dos quais 96 milhões são assintomáticos (1).

Provavelmente a combinação da forte urbanização desordenada das cidades, com o baixo saneamento básico, aumento do desmatamento de florestas, alto consumo de produtos industrializados plásticos, com descarte indevido, favoreceu a urbanização permanente do vetor (do gênero *Aedes*), ocasionando sua propagação e a disseminação da dengue para várias regiões (4,7,9).

A dinâmica de transmissão da dengue parece estar diretamente relacionada a macro fatores (ambientais, socioeconômicos, políticos e sociais), bem como aqueles intrínsecos, que influenciam diretamente na sobrevivência do mosquito vetor, como os climáticos e entomológicos (4,5,7,9).

Devido a isso, as razões que promovem os surtos e epidemias de dengue demonstram ser complexas e requerem monitoramento personalizado para diferentes áreas (10). Neste contexto, as técnicas de modelagens preditivas vêm ganhando notoriedade, ao permitirem realizar análises simples ou complexas, em cenários realísticos, com bom grau de confiabilidade, sobretudo a curto prazo (11).

Desde a década de 80 observa-se o uso de modelagens estatísticas e matemáticas ensaiando oportunidades neste campo preditivo para a dengue (5). De toda sorte, a intensificação dos ciclos epidêmicos nos últimos anos e as dificuldades para o controle efetivo enfrentados por vários países aguçaram o desenvolvimento para novos métodos de modelagens, aos quais foram potencializados ao agregarem técnicas de inteligência artificial, como *machine learning* (ML), mineração de dados e redes neurais artificiais (RNA)(12–14) .

Por outro lado os fatores envolvidos ou determinantes na dinâmica de transmissão da dengue são pontos sensíveis para identificar e prever novos surtos, bem como direcionar as políticas e práticas de manejo para redução dos casos (14,15).

Por conta disso são possíveis diferentes formas de modelagens, que variam tanto nos detalhes biológicos e ecológicos incorporados, quanto na formulação dos modelos ao permitirem modelagens complexas e robustas, associando, por exemplo, regressões lineares e logísticas, com modelos matemáticos compartimentais, mais componentes de árvores de decisão (*Random forests*), dentre outros (16,17).

Diante disso, vários modelos foram propostos e descritos em formato de artigos, com o intuito de prever cenários de dengue e de estabelecer medidas de controle estratégicas, como a redução do número de casos da doença.

Assim, têm-se o seguinte problema de pesquisa: a complexa dinâmica de transmissão da dengue oportuniza inúmeras formas de modelagens capazes de avaliar e prever o seu risco de transmissão.

No entanto, não está claro que tipo de informação está disponível na literatura científica para compreender quais são as técnicas de modelagens que estão sendo usadas, variáveis utilizadas (dados de entrada), nível de aplicação no território, período de previsão antecipada, que sejam capazes de fornecer um catálogo de oportunidades para implementação ou aperfeiçoamento de análises preditivas para os serviços públicos de vigilância da dengue.

Diante deste paradigma, foi realizada uma revisão de escopo ou *scoping review* (ScR) para mapear sistematicamente evidências disponíveis na literatura científica nesta área, bem como identificar eventuais lacunas de conhecimento existentes.

Para tanto formulou-se a seguinte pergunta de pesquisa: quais modelos de análises preditivas de cenários epidemiológicos de dengue e seus respectivos parâmetros estão disponíveis na literatura científica?

Para resposta à essa questão tem-se como objetivo geral deste estudo, mapear os modelos utilizados para prever cenários de dengue, descritos na literatura científica mundial.

Para responder a essa questão tem-se como objetivo geral deste estudo, mapear os modelos utilizados para prever cenários de dengue, descritos na literatura científica mundial.

Os objetivos específicos são:

- I. Especificar os tipos de modelagens utilizadas - matemática, estatística, inteligência artificial (ML, *deep learning*, RNA) e verificar os métodos empregados;

- II. Listar as principais variáveis incorporadas nas análises e suas frequências;
- III. Identificar o nível de aplicação dos modelos no território;
- IV. Analisar os indicadores bibliométricos dos artigos incluídos.

## 2 REVISÃO BIBLIOGRÁFICA

### 2.1 A ESCOLHA DO MÉTODO DE REVISÃO

Em se tratando de síntese de evidências, definida como “a revisão do que é conhecido a partir de pesquisas existentes usando métodos sistemáticos e explícitos para esclarecer a base de evidências” (18), tornaram-se fundamentais para traduzir o conhecimento científico e disponibilizar as melhores evidências, que possam subsidiar a tomada de decisão (19).

Existem várias metodologias para a síntese de evidências, que podem ser empregadas em dezenas de tipos de revisão. A literatura descreve 14 tipos de revisão mais empregadas, como revisão sistemática, ScR, revisão guarda-chuva, revisão para visão geral ou *overview*, revisão de métodos mistos, revisão de mapeamento, revisão da literatura, revisão crítica, dentre outras (20).

Para cada tipo de revisão empregado existem metodologias associadas com o intuito de buscar, avaliar, sintetizar e analisar, as informações que se desejam obter (20).

É possível diferenciar a aplicabilidade de cada uma, pela natureza da síntese de evidência ser alcançada, por exemplo, ScR são de natureza exploratória e descritiva, enquanto as revisões sistemáticas, explicativa e analítica (com ou sem meta-análises) (19–21).

Neste contexto, a ScR adota abordagem metodológica para avaliar preliminarmente o escopo da literatura de pesquisa, compreender a extensão do conhecimento num campo emergente, bem como identificar, mapear, relatar e discutir as características e/ou conceitos nesse campo (19–21). As ScR podem ser empregadas nas seguintes situações:

- Conhecer os tipos de informações disponíveis num determinado campo.
- Detectar e analisar possíveis lacunas do conhecimento.

- Explorar conceitos/definições chave disponíveis na literatura.
- Analisar a forma como as pesquisas são conduzidas sobre um determinado tópico ou campo.
- Identificar características ou elementos-chave relacionados com um conceito.
- Direcionar uma revisão sistemática.

Por conta disso, as ScR assumem uma pergunta de pesquisa com enfoque mais amplo. No entanto, a condução da pesquisa acontece de forma sistemática, com etapas padronizadas e pré-definidas, que devem seguir rigor metodológico na sua execução e redação dos resultados (19–21).

Devido sua abordagem de pesquisa fornecer uma visão abrangente sobre determinada questão, a análise dos achados ocorre de forma descritiva. Isto permite ao pesquisador decidir qual a melhor forma de apresentar a informação extraída (19–21).

## 2.2 DENGUE NO CONTEXTO DE SAÚDE PÚBLICA

Estima-se que mais da metade da população mundial está em risco de infecção por dengue (1,3). Tornou-se um grande problema de saúde pública ao longo dos anos, devido ocasionar epidemias recorrentes, com maior relevância em áreas tropicais e subtropicais, sendo, as Américas e a Ásia, as zonas de maior risco.

Os registros históricos de surtos de dengue, desde o século XVII até os mais recentes e frequentes no século XXI, mostram que a doença é de difícil controle e que o vetor é de fácil domesticação. Sua proliferação vem sendo associada à urbanização não planejada e acelerada (2,5,9,22).

O vírus dengue é do tipo RNA de cadeia simples, pertence ao gênero flavivírus, da família Flaviviridae. Pode ser diferenciado em 4 sorotipos (DENV-1, DENV-2, DENV-3 e DENV-4).

4), aos quais são atribuídas imunidades independentes. Para imunidade completa seria necessário contrair a infecção isoladamente, para cada um dos sorotipos. Ou seja, uma vez o ser humano infectado por um sorotipo e recuperado, a imunidade pode ser permanente (2,3).

A circulação desses sorotipos costuma ser alternada e está atrelada à presença de suscetíveis na população, no entanto, é possível a circulação viral concomitante de todos os sorotipos em um território. Ainda que as epidemias sejam marcadas por um sorotipo de forma mais intensa (2-4).

Em 2013, houve mais um achado em construção de evidência, o isolamento do possível sorotipo DENV-5, cuja circulação sugere estar restrita em ambiente silvestre, diferente dos demais sorotipos, que vem causando doença no homem (23). Tal informação pode ser relevante no futuro, se confirmada, caso ocorra o esgotamento de suscetíveis aos demais sorotipos, com potencial para o acometimento da população humana.

A ocorrência de casos clínicos que evoluem com sinais de alarme e, posteriormente, maior gravidade, pode ser associada a qualquer um dos tipos virais, quer seja numa primoinfecção ou em infecção secundária. Algumas pesquisas associaram maior probabilidade de gravidade nos infectados numa segunda infecção, e/ou quando houve circulação do DENV-2, sobretudo na população mais jovem, crianças e adolescentes (1,2,9,24,25).

Os ciclos de transmissão e propagação da dengue dependem, condicionalmente, de fatores que envolvem características e comportamentos, do vetor (mosquitos *Aedes*) e do homem, no território, interligados as condições climáticas e ambientais.

Resumidamente, o ciclo epidêmico da dengue depende de três etapas que acontecem: 1. no mosquito; 2. nos ovos no ambiente e; 3. no indivíduo.

Inicia-se com a infecção das fêmeas do mosquito *Aedes* durante o repasto sanguíneo em indivíduos contaminados. Após o período de incubação extrínseca no mosquito,

que dura entre 7 e 10 dias, os mosquitos fêmeas infectantes passam a transmitir o vírus em novos repastos sanguíneos por todo o seu tempo de vida.

A fêmea, ao se reproduzir com um mosquito macho, deposita seus ovos contaminados no ambiente. Havendo condições de desenvolvimento (principalmente, umidade elevada e altas temperaturas), os ovos evoluem para as fases de larva, pupa e alado, período que dura de 7 a 10 dias, podendo ser menor em condições ideais (4,25).

Somente os indivíduos suscetíveis (que não foram infectados antes por um dos sorotipos virais) se tornam infectados em um novo repasto sanguíneo, com capacidade para desenvolver a doença. O período de incubação intrínseca no homem varia de 4 a 6 dias, podendo chegar a 15 dias. Quando, então, podem manifestar sinais e sintomas da doença, que duram em média 7 dias. Desde o 1º dia de sintomas até o 7º dia, ocorre circulação e replicação viral no organismo, conhecido como período infeccioso (3–5).

Os ciclos epidemiológicos da dengue apresentam periodicidade que variam de 2 - 3 anos. Entretanto, foram reportados nos últimos anos flutuações nessa dinâmica. Variações sazonais e mudanças no ambiente afetam a dinâmica dos ciclos (3).

No Brasil, dados oficiais do Ministério da Saúde (MS), sobre o monitoramento de arboviroses mostram que os casos prováveis de dengue estão em alta. Houve aumento de 189% de casos, até a semana epidemiológica 35 de 2022, quando comparado ao mesmo período de 2021, também considerado um ano epidêmico (26).

Há evidência que a pandemia Covid-19 aumentou a carga para ambas as doenças, nas regiões que já eram endêmicas para a dengue (27). Observou-se possível reatividade cruzada entre anticorpos SARS-CoV-2 e DENV, que dificultaram o diagnóstico, bem como provável aumento na gravidade dos casos clínicos (28).

Dados do repositório sobre saúde urbana da OMS, atualizado em 2022, demonstram que mais de 55% da população mundial vive em áreas urbanas, com expectativa de aumento

para 68% até 2050. Dentre os residentes urbanos, cerca de 40% estão em áreas com baixos serviços para o gerenciamento de saneamento apropriado e acesso contínuo à água potável (29).

Provavelmente, a rápida urbanização não planejada nestas áreas desencadeou este cenário negativo na saúde social e ambiental, podendo trazer maior impacto para os mais pobres e vulneráveis (2,9,24).

Além disso, o adensamento populacional em regiões ambientalmente degradadas, carentes de saneamento e de gestão de resíduos, denota moradias insalubres. Condições que elevam os riscos para transmissão de doenças infecciosas como COVID-19, tuberculose, dengue e diarreia (1,24).

O mau gerenciamento de resíduos sólidos acarreta lixo acumulado em áreas urbanizadas, abertas e de forma inadequada, propiciando reservatórios oportunos à proliferação vetores urbanos (*Ae. Aegypti* e *Ae. Albopictus*), devido ao depósito de ovos em recipientes contendo água parada (1–3,24). Desta forma, elevasse as chances para doenças vetoriais virais como a dengue, zika, Chikungunya.

Atualmente não há vacinas altamente eficazes e tratamentos específicos para a dengue (30). Tampouco os amplos esforços para o controle de vetores não impediram sua larga transmissão e disseminação global (1,2,25).

Pelo exposto, para conhecer e compreender sua cadeia de transmissão é necessário analisar os fatores ecológicos e biogeográficos que afetam o comportamento do vetor e do vírus no ambiente e no homem, com o intuito de prevenir e controlar os surtos e epidemias de dengue (1,22,24).

A literatura científica (1,2,7,9,24,25,31,32) destaca larga influência de amplos fatores associados à transmissão da dengue: climáticos (precipitação, temperatura, umidade, densidade do ar, altitude, velocidade do vento etc.); ambientais (índices de vegetação ou cobertura do solo); entomológicos (relacionados ao comportamento do vetor no ambiente e da

transmissão do vírus no vetor); detecção da doença na população (incidências); imunológicos (relacionados a aquisição de imunidade humana); socioeconômicos e demográficos; territoriais (saneamento, acesso à água potável e eletricidade, coleta de lixo, estabilidade política etc.)

Por conta disso, a depender do território envolvido, esses diferentes fatores podem se relacionar e gerar cenários de transmissão – condicionado a presença do vetor, concatenado aos movimentos humanos intra e interurbanos. Isso tem potencial para gerar variabilidade nos ciclos epidêmicos, como vem sendo registrado nos últimos anos (22,24,33,34)

Para além disso, um estudo sobre o impacto econômico da ocorrência de três arboviroses (dengue, zika e Chikungunya) no Brasil, em 2016, revelou um impacto negativo de, no mínimo, 2% no Produto Interno Bruto (PIB)<sup>1</sup>. Sendo que os gastos públicos, estimados em cerca de R\$ 2,3 milhões de reais, foram destinados apenas para atender ações emergenciais, com foco no controle da epidemia (35).

(1) manejo e combate ao vetor (repasse de recursos federais, e aquisição de pesticidas; (2) custos médicos envolvidos no diagnóstico e tratamento das doenças no SUS; (3) custos indiretos, desencadeados pelo absenteísmo no trabalho, tanto em entes públicos quanto privados, ocasionando perda de produtividade.

Desse total, R\$431 milhões (19%) se referem aos custos indiretos total, relacionado à perda de produtividade com base no PIB *per capita* nacional, por afastamentos decorrentes dessas arboviroses em 2016.

Observa-se que há uma discrepância no valor financeiro empregado nas ações emergenciais concentradas no controle da epidemia, em relação ao provável dano que epidemia de dengue pode causar ao afetar a cadeia produtiva do país.

---

<sup>1</sup> De acordo com o Instituto brasileiro de geografia e estatística – IBGE, o PIB do Brasil atingiu em 2016 a marca de R\$ 6,3 trilhões de reais. Um resultado 3,3% menor do que o registrado no ano de 2015. A queda afetou principalmente 3 setores econômicos: agropecuária, indústria e serviços (36).

Pelo exposto, é notório o desafio em controlar a dengue, pelo seu crescimento demonstrado nas últimas três décadas, principalmente em áreas com baixo e médio índice sociodemográfico, impulsionada pelo rápido crescimento populacional e acelerada urbanização, requer mais ações de prevenção e controle, que podem ser obtidas pelos modelos preditivos como ferramentas auxiliares a enfrentar esse grande desafio (37).

## 2.3 MODELAGEM PREDITIVA E CONSTRUÇÃO DE CENÁRIOS EPIDEMIOLÓGICOS

A previsão de cenários é importante e necessária em várias situações, independente do horizonte de tempo de antecedência requerido (curto ou longo). Corrobora para um planejamento eficaz e eficiente em diversos setores, de áreas como: economia, telecomunicações, eletricidade, oportunidades de mercado, clima e ambiente, agropecuária, transporte, saúde etc. (38).

Numa conjuntura histórica, a modelagem de epidemias possibilita um melhor entendimento de como as epidemias ocorrem e a busca por medidas eficientes de prevenção ou erradicação da doença. Teve seu advento no final do século XIX e início do século XX, com o uso de modelos matemáticos aplicados na epidemiologia das doenças transmissíveis por vetores, em estudos desenvolvidos por Ronald Ross (39).

Filho de oficiais britânicos, nascido no norte da Índia, formou-se em medicina, atuou como cirurgião em hospitais de guerra, no entanto foi no campo da medicina tropical que desenvolveu suas habilidades nos estudos com doenças vetoriais, como a malária e a filariose (39)

Entretanto, existem condições que afetam a previsibilidade de um evento ocorrer. Para tanto, é necessário compreender alguns fatores primordiais que podem interferir na previsão: 1. Disponibilidade dos dados pretéritos no presente, com alguma qualidade de uso; 2.

Se foram compreendidas todas ou grande parte das causas relacionadas ao evento de interesse;

3. Se o cenário atual se assemelha ao passado, de modo que possa capturar padrões e relacionamentos genuínos; 4. Como as previsões são uteis para o que se deseja prever (38).

Desta maneira, a partir da (s) variável (is) de interesse é possível identificar padrões não aleatórios, a exemplo de uma série temporal. Ou seja, se existe uma relação de causa e efeito relacionada com o tempo, que influenciou um determinado resultado no passado e esta mesma relação pode fazer o mesmo no futuro. Desta forma, a observação do passado permite fazer previsões para o futuro, orientando a tomada de decisões (40).

Os tipos de dados determinam qual método de predição poderá ser usado. Assim, fazer uma análise de dados preliminar é um fundamental para observar padrões, situações incomuns, mudanças ao longo do tempo, relações entre as variáveis, que devem, o quanto possível, serem incorporados aos métodos de previsão (38).

Um fator que realça esta condição é que modelos de previsão bem concebidos conseguem capturar como as coisas estão mudando e, a maneira como as mudanças ocorrem, projetará o futuro (38).

O processo de modelagem preditiva utiliza abordagens como previsões de séries temporais, que envolve: organização dos dados, visualização dos dados, definição do modelo, treinamento do modelo, avaliação de desempenho do modelo para finalmente execução da previsão (38).

A modelagem preditiva dengue, embasada por exemplo em dados de incidência da doença, utiliza comumente modelos que retratam séries temporais (12,14). Isto se justifica pelo tipo de dado utilizado, como as séries de casos notificados de dengue ao longo de um período de tempo, num território específico, que podem refletir ou assumir uma relação com uma série espaço-temporal prevista por modelagem (14,41).

Mais recentemente, a incidência de casos da dengue também possui a ser mapeada por meio de dados apoiados em pesquisas da internet associadas à dengue, como tendências do Google e Baidu Search<sup>1</sup> e tweets (14,41).

Falar sobre modelagem preditiva é um desafio neste estudo. Pois, aparentemente, não há uma padronização para se referir aos tipos e métodos de modelagens preditivas em epidemiologia.

Assim, para fins didáticos, assume-se que os tipos de modelagens podem ser tradicionais (por meio da modelagem estatística, matemática) e de inteligência artificial, que utilizam um conjunto de técnicas de programação (ML, *deep learning*, aprimoradas por RNA, e em algumas situações, a mineração de dados).

A modelagem matemática e a estatística alavancaram este processo ao fornecerem modelos apropriados para estas análises, capazes de resolver problemas, neste caso prever o futuro.

De uma forma simples a modelagem matemática utiliza equações matemáticas determinísticas. Entretanto, há uma tendência de integração entre os modelos, de forma que os matemáticos assumam intervalos de confiança e incertezas, através por exemplo de cadeias de Markov (39,42)

A modelagem estatística utiliza o raciocínio probabilístico, baseado em suposições, para formar relacionamentos entre as variáveis, que é traduzido em equações matemáticas (43).

No entanto, trazem como limitações: 1. dificuldade para incorporar variações em sistemas não lineares; 2. dificuldade para interação entre fenômenos que acontecem em larga escala de tempo, espaço e complexidade organizacional, 3. dificuldade para estabelecer relações entre padrão e processo (44).

Métodos avançados de predição de cenários incorporam processos de inteligência artificial, capazes de agregar grande capacidade raciocínio lógico, analisando extenso volume de dados, num curto espaço de tempo (45).

A exemplo disso tem-se os modelos do tipo ML e o *deep learning* (aprendizado profundo). Desenvolvem processos de aprendizado automático, a partir de padrões de informação. Permitem fazer inferências sem instruções explícitas e têm capacidade gerir grande número de variáveis (principalmente o deep learning). Por estas razões, consegue fazer relações entre as variáveis (44). Uma condição que oferece flexibilidade, sendo desejável na predição de doenças, como a dengue, que têm diversos fatores associados à transmissão.

As RNAs aprimoram *ML e deep learning*, por meio de uma arquitetura de rede de neurônios organizada em camadas. Na camada inferior estão os preditores (variáveis de entrada), na superior as previsões (saída), e pode ter uma camada intermediária “os neurônios ocultos” (esta torna o processo não linear) (38,44).

Outro tipo de modelo bastante utilizado é a mineração de dados, um processo para descobrir informações de um grande conjunto de dados, por meio de padrões e tendências advindos de relacionamentos complexos ou grande volume de dados, que não podem ser acionados pela exploração tradicional de dados (44). Utiliza para esta finalidade análise matemática e estatística, IA e ML.

Para tentar resumir como os tipos de modelagens que podem ser empregados no contexto da predições de cenários epidemiológicos, foi esquematizada uma representação conceitual, conforme a Figura 1.



A seleção dos métodos de modelagens depende de uma análise preliminar dos dados e observação de alguns padrões: 1. tendência ou comportamento de longo prazo na série; 2. ciclos ou flutuações da variável superiores a um ano; 3. sazonalidade ou flutuações inferiores a um ano, compatível com as estações do ano; e 4. variações irregulares ou flutuações inexplicáveis (38,40).

Estes padrões podem ser explorados nos modelos de forma isolada ou combinada, revelando muitas possibilidades de abordagens (métodos de modelagens).

O ponto principal é descobrir quais componentes estão atuando em um conjunto de variáveis e decidir qual a melhor equação que relaciona os componentes aos modelos (40).

São exemplos de métodos de modelagens empregados nas análises preditivas para a dengue: modelos compartimentais autorregressivos de médias móveis, como o ARIMA e o SARIMA (agrega um componente sazonalidade), descrevem melhor a autocorrelação nos dados; modelos de regressão (como: linear, não linear, árvore de regressão impulsionada por gradiente, binomial negativa); modelos aditivos generalizados (GAMs), operador de seleção e contração menos absoluta (LASSO), bem como os mais modernos algoritmos de aprendizado, como máquinas de vetores de suporte (SVM) (8,33,35)

A modelagem em dengue pode enfrentar desafios, que envolvem amplas condições inerentes as seguintes variações: climáticas e ambientais; entomológicas (habitat e reprodução do vetor); de contexto territorial (saneamento, acesso água encanada e potável, acesso à eletricidade, coleta de lixo regular, estabilidade política entre outros); sobre aspectos demográficos e socioeconômicos (densidade e estimativas populacionais, índices de pobreza, índices de desenvolvimento humano, cobertura educacional etc.) (1,15,46)

Diante disso, identificar todos esses fatores e decidir quais são relevantes e devem ser objeto de análise, para a predição de cenários, não é uma tarefa simplória. Previsões precisas

e antecipadas de epidemias de dengue permitem que sistemas públicos de saúde possam desenvolver estratégias oportunas para impedir um cenário sem controle (1,15,47)

### 3 METODOLOGIA

#### 3.1 TIPO DE REVISÃO:

Trata-se de um estudo para síntese de evidências com o método ScR, a partir de estudos descritos na literatura científica, que utilizaram modelos na previsão de cenários de transmissão da dengue.

A ScR é um delineamento de pesquisa capaz de mapear a evidência existente e identificar possíveis lacunas do conhecimento sobre determinada questão. Não visa analisar a qualidade metodológica dos estudos incluídos (21).

Esse tipo de revisão aplica-se quando há diversos estudos sobre um determinado tema ou questão, que remete um possível desconhecimento do universo de informação disponível. Isto requer identificação e compreensão da evidência existente, realce das possíveis lacunas no conhecimento, que possam direcionar outras pesquisas, como a revisão sistemática (21).

#### 3.2 ETAPAS DA REVISÃO:

O planejamento e execução desta revisão observou 5 etapas fundamentais: 1. Busca das fontes de informação, 2. Seleção dos artigos, 3. Extração dos dados, 4. Síntese dos resultados e 5. Redação e publicação dos resultados, conforme descrito a seguir.

O protocolo de pesquisa poderá ser obtido por requisição ao autor. Posteriormente, estará disponível na plataforma *Open Science Framework*®.

As etapas foram desenvolvidas por uma equipe com 3 (três) membros: o autor planejou, definiu e executou as estratégias de buscas dos artigos nas bases de dados; 2 (dois)

pesquisadores (o autor e outro colaborador) foram responsáveis pela seleção dos artigos de forma pareada e independente; 1 (um) pesquisador (autor) foi responsável pela extração dos dados, síntese e redação dos resultados, e 1 (um) pesquisador especialista, responsável em dirimir as dúvidas, principalmente quanto a seleção, extração dos dados e síntese dos resultados.

### 3.2.1 Busca das fontes de informação

Para identificar os artigos relevantes foram pesquisados todos os artigos científicos publicados até 29 de dezembro de 2021, nas seguintes bases de dados científicas: PubMed, EMBASE e BVS – LILACS. Por serem as bases de maior relevância científica, pois reúnem os periódicos de elevada avaliação científica no mundo e na América Latina.

A estratégia de busca ampla foi construída utilizando descrições específicas para as diferentes bases de dados selecionadas. Seguiu-se a lógica para incluir os termos referentes aos tipos de modelagens (estatística, matemática, inteligência artificial, *machine learning*, *deep learning*, redes neurais artificiais), associados aos termos predição (*forecasting*) e dengue. Os termos específicos de busca foram obtidos por descritor de assunto, utilizando seguintes vocabulários controlados:

- 1 MeSH (Medical Subject Headings), para as bases de dados do PubMed;
- 2 Emtree, para a base de dados do Embase;
- 3 DeCs (descritores em ciências da saúde), para a base de dados do Lilacs/BVS.

A estratégia principal foi construída no PubMed. A partir dos termos indexados e sintaxes, fez-se a tradução para as demais bases de dados eletrônicas, conforme as especificidades contidas nos seus buscadores.

Todas as estratégias finais de buscas estão disponíveis no Apêndice A.

Para garantir a amplitude e sensibilidade na estratégia de busca dos estudos e, ainda, para evitar possível viés de linguagem, não foram aplicados os filtros para restrição no período e nos idiomas, por ser mais honesto garantir a inclusão de todos os estudos disponíveis (48).

Para mitigar dificuldades na leitura e compreensão de textos em idiomas não dominantes pelos autores, poderiam ser utilizadas ferramentas de tradução como o Google Tradutor®, o Reverso Context® ou DeepL®. Além destas, poderia obter ajuda com algum pesquisador próximo fluente no idioma requerido.

Na impossibilidade de leitura e extração dos dados de algum estudo devido ao idioma, seria informada a sua exclusão e justificativa.

Todas as referências obtidas nas mencionadas bases de dados, foram importadas para a ferramenta Zotero®, para fins de tratamento das duplicidades.

Diante do número considerável de publicações (mais de 4 mil) esta revisão não foi complementada por outras abordagens, para identificar material relevante adicional com os autores, também não foi previsto o escaneamento das listas de referências dos artigos incluídos.

### 3.2.2 Seleção dos estudos

As referências foram importadas para a plataforma eletrônica *Ray.yan*®, para leitura dos títulos e resumos, de forma pareada e independente, para seleção das referências elegíveis, conforme os critérios de elegibilidade descritos anteriormente.

Dois revisores (o autor e um colaborador) trabalharam em pares analisando de forma cega as mesmas publicações, para selecionar os artigos relevantes por meio da leitura de títulos, resumos e quando necessário o texto completo.

Antes de iniciar foi realizada a calibração da triagem entre os revisores com os primeiros 100 artigos, para ajustes das terminologias utilizadas para categorizar os artigos, sobretudo os excluídos.

Um pesquisador especialista dirimiu as dúvidas e divergências no final desta etapa de seleção.

### 3.2.2.1 *Definição dos critérios de elegibilidade*

Foram incluídos estudos publicados em revistas científicas, no formato de artigo científico, que utilizaram qualquer tipo de modelagem preditiva (matemática, estatística, *machine learning*, *deep learning*, redes neurais artificiais ou outro tipo de inteligência artificial) de cenários epidemiológicos de dengue. As modelagens deveriam incluir pelo menos três tipos de variáveis, categoricamente diferentes ligados à transmissão da dengue em seres humanos, sendo uma delas, obrigatoriamente, a incidência de casos.

Foram excluídos os estudos que apresentavam as seguintes características:

- Aplicados a outros tipos de sistemas de vigilância, que não seja epidemiológica em saúde;
- Utilizaram modelos destinados a outras arboviroses e outras doenças;
- Aplicaram modelagens, exclusivamente, com dados entomológicos ou climáticos, pois isoladamente não alcançam totalmente o ciclo de transmissão da doença;
- Destinados ao tratamento ou prevenção da dengue, quer sejam com medicamentos ou vacinas;
- Abordaram questões imunológicas envolvendo células de defesa (como: anticorpos e antígenos);

- Avaliaram a gravidade e ou quadro clínico da dengue no homem;
- Experimentais e observacionais analíticos, pois fogem do escopo desta pesquisa.

Para fins de contabilização e classificação dos artigos excluídos utilizou-se as seguintes etiquetas, para sinalizar os artigos por temas aversos: imunobiológicos, entomológicos, gravidade/quadro clínico, climáticos, vacina, outras arboviroses e outras razões.

### 3.2.3 Extração dos dados

Foi desenvolvida uma planilha para determinar quais variáveis deveriam ser extraídas. Para tanto foram estabelecidos e validados pelo autor 23 parâmetros pré-selecionados para análise (Quadro 1).

Os dados foram extraídos manualmente e unicamente pelo autor com revisão de dúvidas por um pesquisador especialista.

As informações obtidas passaram por processo de organização em planilha do Office Excel®, visando posterior análise e sumarização dos dados.

No que concerne ao parâmetro fator de impacto dos artigos, utilizou-se um indicador bibliométrico internacional, introduzido pela editora Thomson Reuters, disponível na plataforma *Journal Citation Reports*.

Para tanto, escolheu-se o indicador JIF médio (do inglês, *JIF percentile*) ou percentil médio do fator de impacto, que representa a média da soma da classificação do percentual do fator de impacto do periódico, para cada categoria. A conversão em percentil proporciona uma comparação transversal mais intuitiva entre os periódicos (49).

**Quadro 1** Parâmetros para extração dos dados

1	ID	
2	TÍTULO	
3	AUTOR	
4	ANO	
6	PAÍS DA INSTITUIÇÃO DO 1º AUTOR	
5	REVISTA OU PERIÓDICO	
6	PAIS DA INSTITUIÇÃO DO 1º AUTOR	
7	FATOR DE IMPACTO JCR (Journal Citation Reports)	Categoria Percentil médio do fator de Impacto (JIF médio)
8	PALAVRAS-CHAVE	
9	FONTE DE FINANCIAMENTO (financeiro, intelectual, político, nenhum, outro, não informado)	
10	CONFLITO DE INTERESSES (sim ou não)	
11	POPULAÇÃO ALVO (PAÍS/REGIÃO)	
12	PERÍODO DOS DADOS DO ESTUDO	
13	OBJETIVOS DOS ESTUDOS	
14	CENÁRIO TEÓRICO OU REALISTICO	
15	TIPOS DE MODELAGENS	
16	MÉTODOS DE MODELAGENS	
17	PROGRAMAS – pacotes e/ou bibliotecas	
18	FONTE DOS DADOS	
19	UNIDADE TEMPORAL DE PREVISÃO (semanal, mensal, trimestral, anual)	
20	PERÍODO DE PREVISÃO ANTECIPADA	
21	DISTRIBUIÇÃO ESPACIAL DOS DADOS (vila, bairro, distrito, município, província, estado, país, região)	
22	VARIÁVEIS PREDITORAS UTILIZADAS (agrupadas em 7 grupos)	Tipos de Incidências Entomológicas Climáticas ou ambientais Fator Calendário Contexto territorial Demográfico / Socioeconômico Contexto saúde
23	APLICÁVEL À SAÚDE PÚBLICA (sim ou não)	

Fonte: elaborado pelo autor.

Esse indicador apresenta característica estatística diferente do fator de impacto bruto (JIF), consegue melhorar o valor relativo, diminuir o coeficiente de variação e produzir distribuição mais próxima da distribuição normal. Sua leitura é simples, os valores variam de 0 a 100, quanto maior melhor. Entretanto, não deve ser utilizado para medir a diferença relativa entre os periódicos, pois utiliza transformação não paramétrica dos dados (49,50).

Não foi utilizado o indicador brasileiro Qualis-Periódicos, mantido pela Agência governamental CAPES (Coordenação de Aperfeiçoamento e Pessoal de Nível Superior), disponível na plataforma Sucupira, pois a aplicação é exclusiva para avaliar a produção científica dos programas de pós-graduação no âmbito da CAPES.

Além disso, os dados disponíveis, até setembro de 2022, trazem classificações defasadas, consolidadas no triênio 2010-2012 e quadriênio 2013-2016.

### 3.2.4 Síntese dos resultados

Foi realizada de forma descritiva, apoiada pela apresentação de quadros, tabelas e figuras, que resumem as informações mapeadas.

As tabelas e gráficos foram estruturados conforme suas semelhanças, contextos e cenários aplicados, com especial destaque aos tipos de modelagens, variáveis utilizadas, tempo de predição e aplicabilidade em diferentes cenários e territórios.

Para fins de organização das informações obtidas e melhor visão do mapeamento obtido pelos 23 parâmetros pré-determinados (Quadro 1), optou-se por dividir os resultados em duas partes.

A primeira parte, foi destinada à análise de indicadores bibliométricos dos artigos incluídos, para responder ao objetivo específico IV (com o intuito de tentar identificar a qualidade da comunicação científica, e possíveis associações temáticas). Foram analisados os

seguintes parâmetros: fator de impacto dos periódicos, países de concentração das pesquisas, palavras-chave, fonte de financiamento e conflitos de interesse.

No que se concerne à segunda parte dos resultados, voltada especificamente à modelagem preditiva em dengue, o foco foi responder aos demais objetivos específicos desta ScR – sobretudo, identificar as técnicas (tipos, métodos e programas) de modelagens, variáveis utilizadas, escala espacial dos dados, localização, unidade temporal de previsão, período de previsão antecipada, período de experimento e possibilidade de aplicar em saúde pública, na predição de cenários epidemiológicos para a dengue.

### 3.2.5 Redação e publicação dos resultados

Utilizou-se o guia para redação PRISMA (PRISMA ScR – do inglês, “*Preferred Reporting Items for Systematic reviews and Meta-Analyses extension for Scoping Reviews*” - Itens preferenciais para revisões sistemáticas e extensão de metanálises para revisões de escopo), versão 2020, com alterações específicas para revisão de escopo, conforme recomendação contida no manual da JBI (21,51,52). O cumprimento das fases deste guia está apresentado no Apêndice B.

Com o intuito de resumir etapas desta ScR, busca e seleção dos estudos, foi elaborado o diagrama de fluxo PRISMA (Figura 2) (53).

Houve financiamento parcial, além das custeadas pelo próprio autor, do Laboratório Misto Internacional, LMI Sentinela (UnB - Fiocruz - IRD), Brasília-DF, Brasil, Rio de Janeiro-RJ, Brasil e Montpellier, França [<http://www.lmi-sentinela.unb.br>].

Esta ScR não foi submetida ao comitê de ética e pesquisa. Os dados obtidos são secundários, disponíveis em plataformas de pesquisa científica abertas e de forma pública.

## 4 RESULTADOS

Foram levantados ao todo 4.768 estudos, nas 3 bases de dados, publicados a partir do ano 1968 até 29 de dezembro 2021. Destes, 55 removidos por duplicidade e 14 por outras razões (artigos retratados em suas revistas, e resumos de outros formatos (vídeos, livros ou capítulos de livros).

Na etapa de seleção, foram analisados 4.699 artigos, onde foram excluídos 4.675 artigos - classificados em 7 razões ou temáticas, em: imunobiológicos (1.097); entomológicos (959); gravidade/quadro clínico (487); climáticos (445); vacina (368); outras arboviroses (259) e outras razões (1.060)<sup>1</sup>.

Finalmente, restaram 24 artigos que foram incluídos para extração dos dados.

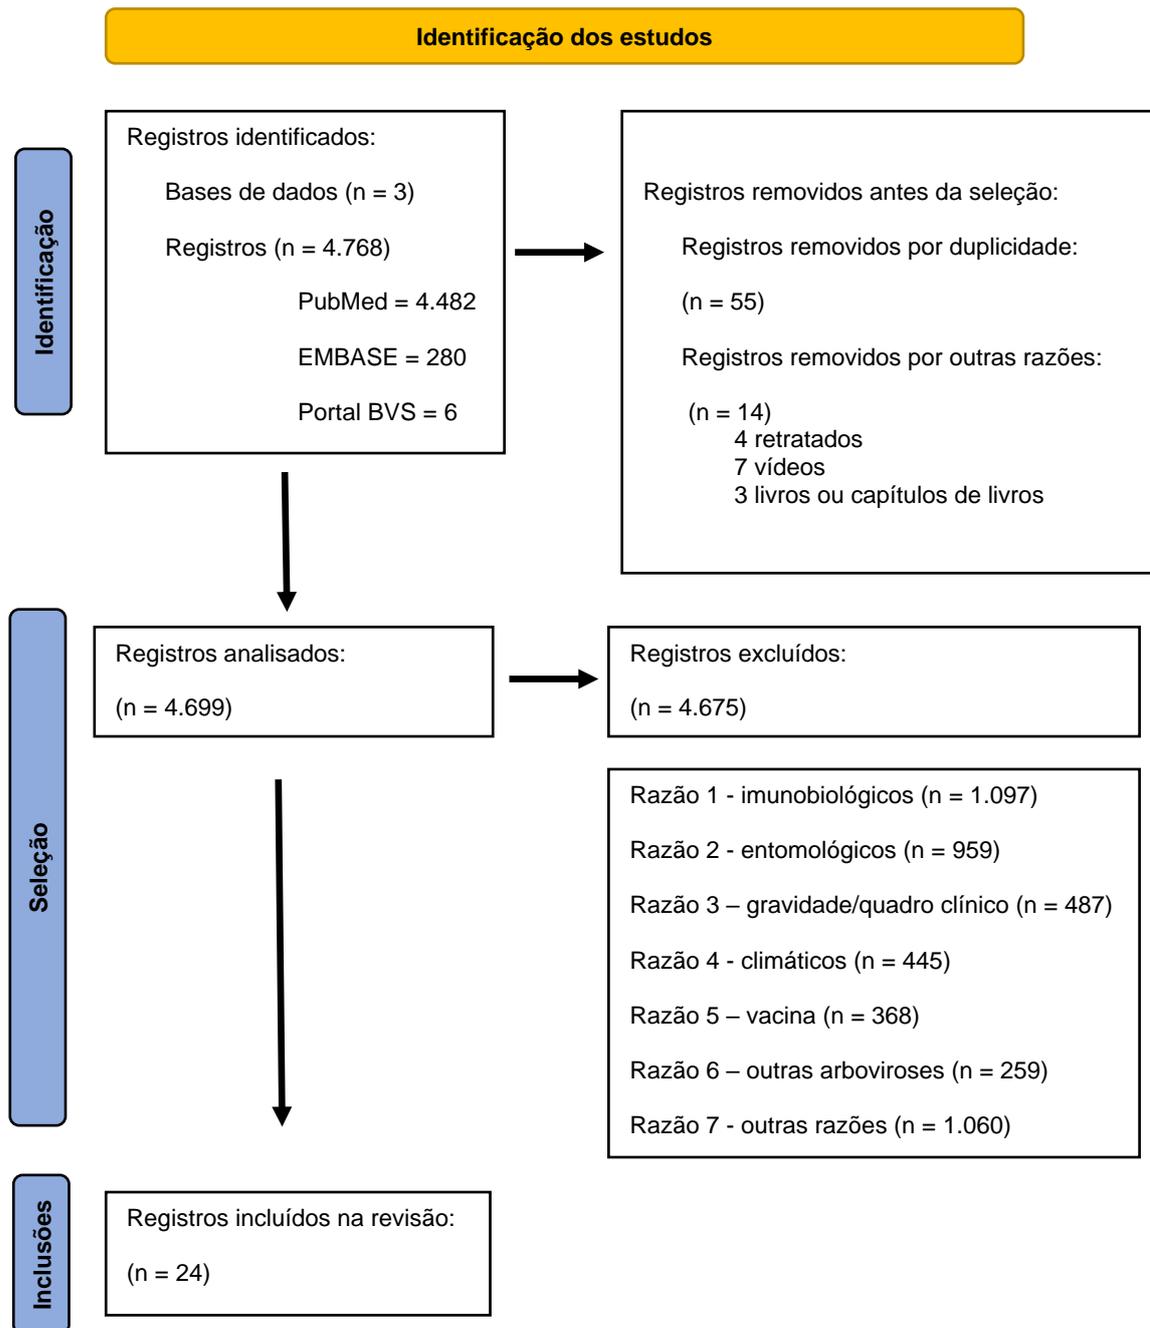
Os termos ou descritores selecionados e a estratégia de busca aplicada nesta ScR, para cada base de dados – Pubmed, Embase, BVS, estão descritos no Apêndice A.

O diagrama de fluxo Prisma a seguir ilustra como aconteceu a identificação dos estudos em cada etapa do processo.

Destaca-se que todos os vinte e quatro artigos incluídos foram publicados em inglês, portanto não houve dificuldades para a extração dos dados. O mapeamento inicial capturou artigos publicados em revistas científicas, desde 1968 até 21 de dezembro de 2021. Entretanto, os artigos incluídos são publicações mais recentes, de 2008 a 2021.

---

<sup>1</sup> Assuntos diversos como: aspectos socioeconômicos, demográficos, tratamento terapêuticos em indivíduos, outras doenças diferente de arboviroses (COVID-19, HIV, hipertensão pulmonar idiopática, infecções bacterianas, influenza), biologia molecular, uso apenas de dados de incidência, assuntos análogos e restritos a técnicas de modelagens de forma geral, entre outros.



**Figura 2** Diagrama de fluxo PRISMA.

## 4.1 ANÁLISE DOS INDICADORES BIBLIOMÉTRICOS

A Tabela 1 apresenta o mapeamento de indicadores bibliométricos dos artigos incluídos, nos seguintes aspectos: fator de impacto dos periódicos, países de concentração das pesquisas, palavras-chave, fonte de financiamento e conflitos de interesses.

Perante o fator de impacto dos periódicos, 23 artigos obtiveram pontuação no indicador JIF médio. Os percentis variaram de 41,67 a 95,16, com média de 78,92. Em um artigo o dado não estava disponível no momento do acesso (26/03/2022).

Com relação aos países alvo das pesquisas observa-se uma concentração no continente asiático, sobretudo na região sudeste: Tailândia (n = 4), Sri Lanka (n = 3), Vietnã (n = 2), Singapura (n = 2), Indonésia (n = 1), Filipinas (n = 1), Malásia (n = 1), Taiwan (n = 1) e China (n = 1). Seguido do continente americano: México (n = 1), Colômbia (n = 1), Peru (n = 1), Brasil (n = 2) e Porto Rico (n = 1) – Figura 3.

No continente Europeu uma pesquisa envolveu 21 países que reportaram casos confirmados de dengue, oriundos de pessoas residentes, com história de viagem conhecida para locais com transmissão endêmica de dengue. Na Oceania, houve pesquisa na Austrália (n = 1).

Observou-se que em 37,5% (n = 9) dos estudos, o país da instituição do 1º autor foi diferente do país onde ocorreu o estudo (destaques em vermelho na Tabela 1). Instituições sediadas nos Estados Unidos (n = 3) fizeram pesquisas nos seguintes países: Tailândia, Filipinas e Peru.

As demais instituições sediadas, Austrália, Espanha, Canadá, Japão, Quênia e Reino Unido, realizaram suas pesquisas, respectivamente, nos seguintes países: Indonésia, Brasil, Colômbia e Vietnã.

**Tabela 1** Mapeamento de indicadores bibliométricos dos artigos incluídos: fator de impacto dos periódicos, países das pesquisas, palavras-chave, fonte de financiamento e conflitos de interesses.

Seq.	Primeiro autor (ano)	Periódico	Fator de impacto JCR		País instituição do 1º autor	País alvo do estudo	Palavras-chave	Fonte de financiamento	Conflito de interesses (S ou N)
			Categoria	JIF médio					
1	Rachel Lowe (2016)	eLife	Biologia	95,16	Espanha	Brasil	Climate, Dengue, Early Warning System, Epidemiology, Evaluation, Global Health, Infectious Disease, Microbiology, Model, None, Probabilistic	Financeiro	N
2	Yuan Shi (2016)	Environmental Health Perspectives	Saúde Pública, ambiental e ocupacional & Ciências ambientais	94,94	Singapura	Singapura	nd*	Financeiro	N
3	Chathurangi Edussuriya (2021)	PLoS Neglected Tropical Diseases	Medicina tropical	94,31	Sri Lanka	Sri Lanka	# Dengue fever, Optimization, Population density, Wolves, Sri Lanka, Epidemiology, Machine learning, Humidity	Nenhum	N
4	Felipe J. Colón-González (2021)	PLoS Medicine	Medicina, geral e interna	94,31	Reino Unido	Vietnã	# Dengue Fever, Seasons, Forecasting, Vietnam, Public and Occupational Health, Decision Making, Humidity, Mosquitoes	Financeiro, Intelectual	N
5	Naizhuo Zhao (2020)	PLoS neglected tropical diseases	Medicina tropical	94,31	Canadá	Colômbia	# Dengue, Forecasting, Artificial neural networks, Colombia, Machine learning, Rain, Neurons, Public and Occupational Health	Financeiro	N
6	Pi Guo (2017)	PLoS neglected tropical diseases	Medicina tropical	94,31	China	China	# Dengue Fever, Epidemiology, Forecasting, China, Internet Algorithms, Linear Regression Analysis, Humidity	Financeiro	N
7	Anna L. Buczak (2014)	PLoS neglected tropical diseases	Medicina tropical	94,31	Estados Unidos	Filipinas	# Dengue Fever, Epidemiology, Forecasting, Philippines, Data Mining, Geographic Information Systems, Rain, Public and Occupational Health	Financeiro	N
8	Yirong Chen (2018)	BMC Medicine	Medicina, geral e interna	92,51	Singapura	Singapura	Spatio-temporal Prediction, Dengue forecast, LASSO, Control and Prevention	Financeiro	N
9	Michael A. Johansson (2019)	Proceedings of the National Academy of Sciences of the United States of America	Ciências multidisciplinares	89,58	Porto Rico***	Porto Rico; Peru	Forecast, Dengue, Epidemic, Peru, Puerto Rico	Intelectual	N
10	Stephen A. Lauer (2018)	Proceedings of the National Academy of Sciences of the United States of America	Ciências multidisciplinares	89,58	Estados Unidos	Tailândia	Dengue, Forecasting, Infectious Disease, Statistic	Não informado	N
11	Cecilia A. Marques-Toledo	Parasites & Vectors	Medicina tropical e parasitologia	84,70	Brasil	Brasil	Dengue, Non-endemic, Risk Model, Transmission	Financeiro	N
12	Gayana P. Withanage (2018)	Parasites & Vectors	Medicina tropical e parasitologia	84,70	Sri Lanka	Sri Lanka	Dengue, District of Gampaha, Prediction Model, Time Series Regression	Financeiro, Intelectual	N
13	Ta-Chien Chan (2015)	International Journal of Health Geographics	Saúde Pública, ambiental e ocupacional & Ciências ambientais	77,14	Taiwan	Taiwan	Logistic Regression, Dengue, Dynamic Threshold, Decision Support	Financeiro	N

Continuação - tabela 1

Seq.	Primeiro autor (ano)	Periódico	Fator de impacto JCR		País instituição do 1º autor	País alvo do estudo	Palavras-chave	Fonte de financiamento	Conflito de interesses (S ou N)
			Categoria	JIF medio					
14	Nurul Azam Mohd Salim (2021)	Scientific Reports	Ciências multidisciplinares	77,08	Malásia	Malasia	Ecology, Risk Factors	Financeiro	N
15	Donald Salami (2020)	Scientific Reports	Ciências multidisciplinares	77,08	Portugal	Europa **	## Infectious Diseases, Machine Learning, Public Health	Financeiro, Intelectual	N
16	Jessica Liebig (2021)	Epidemics	Doenças infecciosas	70,43	Australia	Australia	Dengue, Early Warning System, Forecasting Disease Spread, Human Mobility	Financeiro	N
17	Bernard Bett (2019)	PLoS One	Ciências multidisciplinares	64,58	Quênia	Vietnã	# Dengue fever, Epidemiology, Medical risk factors, Vietnam, Dengue Virus, Rain, Forecasting, Mosquitoes	Financeiro	N
18	Gilberto Sánchez-González (2018)	PLoS One	Ciências multidisciplinares	64,58	Mexico	Mexico	# Dengue fever, Mosquitoes, Eggs, Dengue virus, Rain, Death Rates, Epidemiology, Mexico	Nenhum	N
19	Kraisak Kesorn (2015)	PLoS One	Ciências multidisciplinares	64,58	Tailândia	Tailândia	# Dengue Fever, Epidemiology, Forecasting, Morbidity, Larvae, Mosquitoes, Kernel functions Epidemiology, Support Vector Machines	Financeiro	N
20	Halmar Halide (2008)	International Journal of Environmental Health Research	Saúde Pública, ambiental e ocupacional & Ciências ambientais	62,36	Australia	Indonésia	DHF Epidemics, Prediction Skill, Statistical Model	Intelectual	nd*
21	Padet Siriyasatien (2016)	BMC Bioinformatics	Biologia matemática e computacional	56,92	Tailândia	Tailândia	Dengue hemorrhagic fever, Forecasting model, Prediction model, Multivariate Poisson Regression, Climate Factor Analysis	Financeiro	N
22	K.K.W.H. Erandi (2021)	Theoretical Biology and Medical Modelling	Matemática e Biologia computacional	56,03	Sri Lanka	Sri Lanka	Dengue, IR model, Seasonal Pattern, Fourier Analysis	Financeiro	N
23	Anna L. Buczak (2012)	BMC Medical Informatics and Decision Making	Informática médica	41,67	Estados Unidos	Perú	Dengue Fever, Prediction, Association Rule Mining, Fuzzy Logic, Predictor Variables	Financeiro, Intelectual	N
24	Raghvendra Jain (2019)	BMC Infectious Diseases	Doenças infecciosas	nd*	Japão	Tailândia	Dengue Forecasting, Data-driven Epidemiology, Disease Surveillance, Generalized Additive Models (GAMs)	Nenhum	N

Fonte: Fonte: elaborado pelo autor

Legenda :

JCR: Journal Citation Reports; JIF medio: percentil médio do fator de impacto

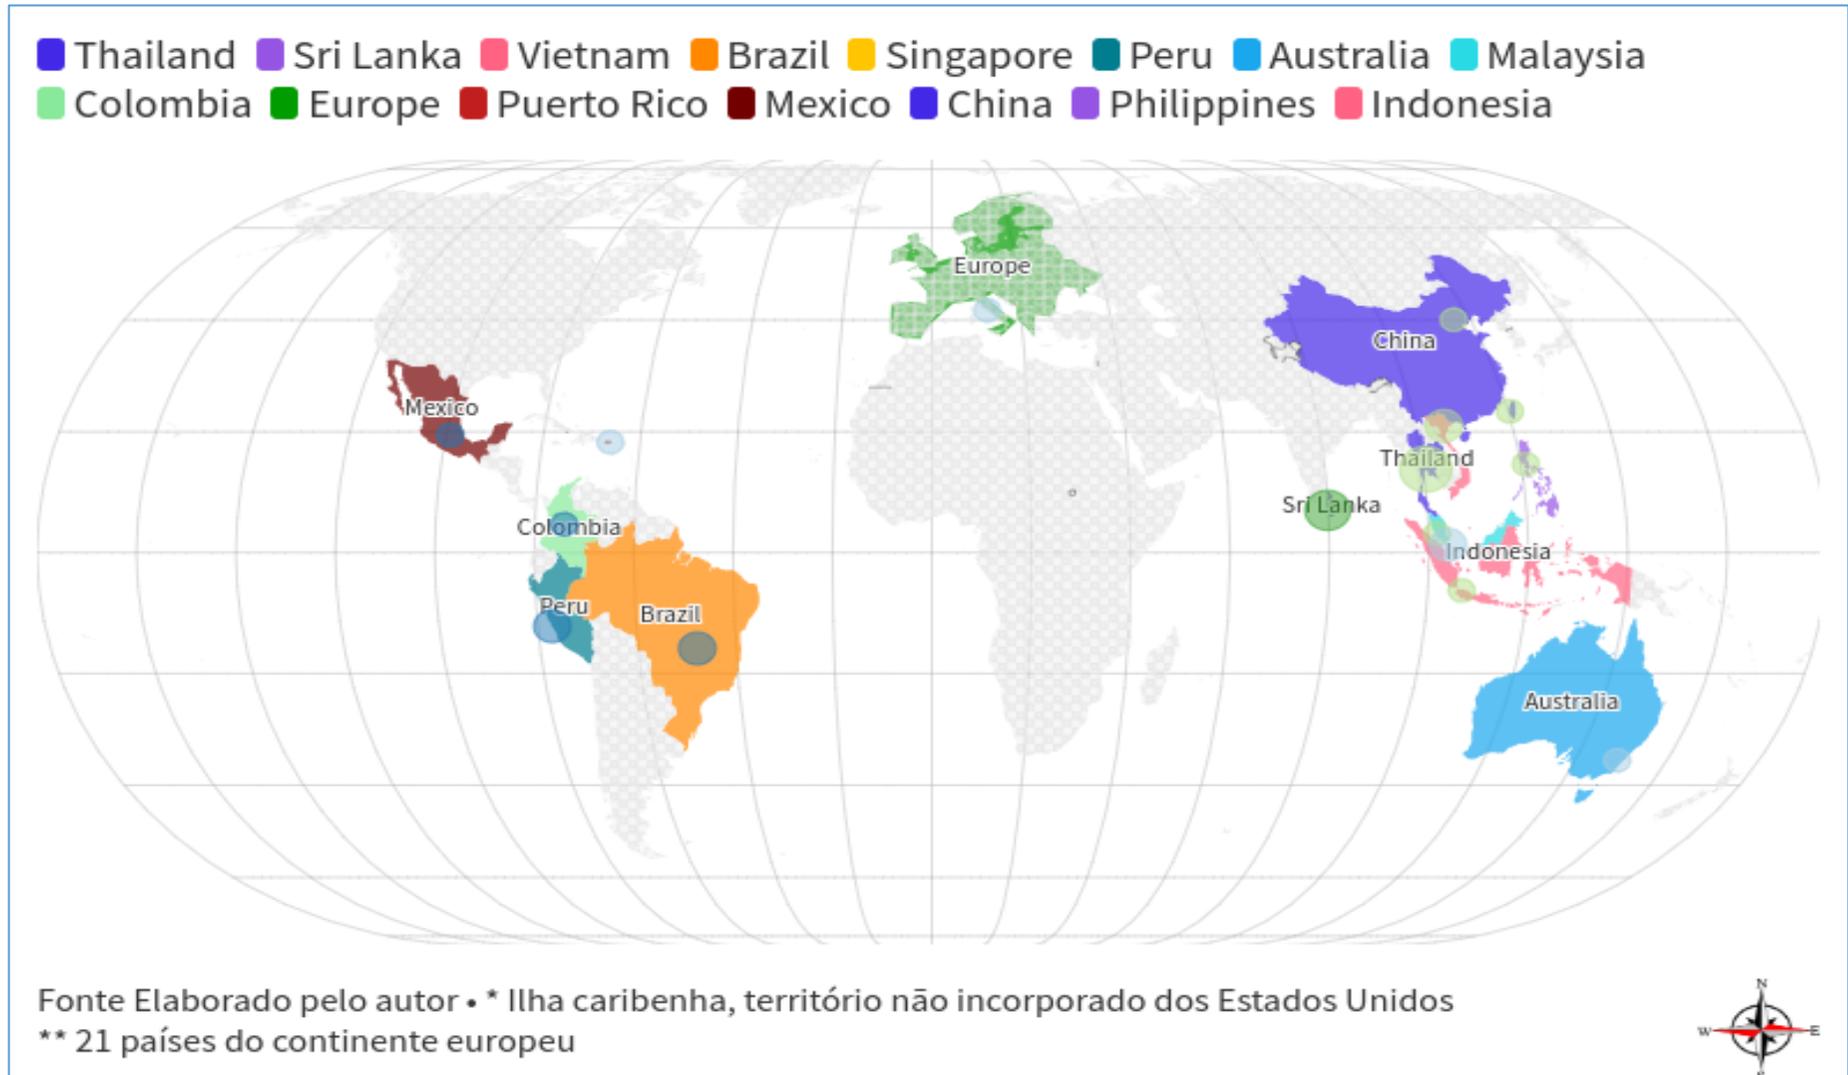
\* nd: não declarado.

\*\* 21 países europeus que reportaram casos confirmados de dengue com história de viagem conhecida.

\*\*\* Ilha caribenha, território não incorporado dos Estados Unidos.

# Os artigos publicados nas revistas PLOS não trazem as palavras-chave, neste caso foram informadas as áreas temáticas (subject areas) atribuídas à cada artigo no site da revista.

## Os artigos publicados na revista NATURE não trazem as palavras-chave, neste caso foram informados os temas ou assuntos (subjects) atribuídos a cada artigo no site da revista, disponível na área "About this article".



**Figura 3** Mapa de localização dos países alvo dos estudos por continentes.

Os artigos incluídos estavam indexados em periódicos científicos, principalmente, nas seguintes categorias: Ciências multidisciplinares (29%); Medicina tropical (17%); Saúde pública, ambiental e ocupacional & Ciências ambientais (13%). Seguidas das categorias Doenças infecciosas, Medicina tropical e parasitologia, Medicina geral e interna, que corresponderam a 8%, cada. As categorias com menor frequência (4%, cada) foram: Biologia; Biologia matemática e computacional; Informática médica e Matemática e Biologia computacional.

No que concerne as palavras-chave, os artigos publicados pelas revistas PLOS e Nature não trazem as palavras-chave. Neste caso, foram informadas as áreas temáticas ou assuntos (*subject areas*, na PLOS, e *subjects*, na Nature), atribuídos aos artigos incluídos, conforme o site de cada revista. No site da revista Nature também poderá ser encontrado na área "About this article". Os demais 14 artigos publicados por outras revistas científicas descreveram as palavras-chaves.

Os termos DENGUE FEVER, EPIDEMIOLOGY, FORECASTING, MOSQUITOS, RAIN, MACHINE LEARNING, PUBLIC AND OCCUPATION HEALTH, HUMITY, foram, respectivamente, os 8 mais frequentes nas áreas temáticas, de um total de 36 termos mapeados.

Enquanto nas palavras-chave, somente 4 termos apareceram com maior frequência, DENGUE, PREDICTION MODEL, EARLY WARNING SYSTEM, INFECTIOUS DISEASE, respectivamente, dentro de um total de 53 palavras mapeadas nos artigos.

As Figuras 4 e 5 destacam visualmente os melhores resultados para as palavras-chave utilizadas e as áreas temáticas atribuídas.



No Apêndice C estão apresentados os dados com todas as frequências, tanto para palavras-chave e áreas temáticas.

Quanto a fonte de financiamento, 58% (n = 14) dos artigos incluídos declararam fonte financeira para custear suas pesquisas, 17% (n =4) declararam fonte financeira e intelectual<sup>1</sup>, 8% (n = 2) declararam somente fonte intelectual<sup>1</sup>, 12% (n =3) declararam nenhuma fonte de financiamento e um artigo não informou.

Somente um artigo não declarou conflitos de interesse, os demais anunciaram ausência de conflitos de interesses.

## 4.2 MODELAGEM PREDITIVA EM DENGUE

Todos os vinte e quatro artigos incluídos aplicaram métodos de modelagem em cenários realísticos.

Os resultados a seguir serão apresentados com o recorte das técnicas de modelagens, número de variáveis e fatores associados à predição. Para tanto, foram analisados um conjunto de dez parâmetros, que são fundamentais nesse processo:

1. Tipos de modelagens
2. Métodos de modelagens
3. Programas – pacotes e/ou bibliotecas

---

<sup>1</sup> Apoio, orientação, mentoria recebido de pessoas com alto grau de intelecto, como de pesquisadores, especialistas, com conhecimento renomado e profundo nas áreas em que atuam.

4. Variáveis utilizadas:
  - a. incidência
  - b. entomológicas
  - c. climáticas ou ambientais
  - d. fator calendário
  - e. contexto territorial
  - f. demográfico e socioeconômico
  - g. contexto saúde
5. Número variáveis preditoras
6. Escala espacial dos dados
7. Localização
8. Unidade temporal de previsão
9. Período de previsão antecipada
10. Período de experimento

O mapeamento total destas informações de forma agregada para cada artigo incluído será apresentado no Apêndice D (Tabelas 2 a 3).

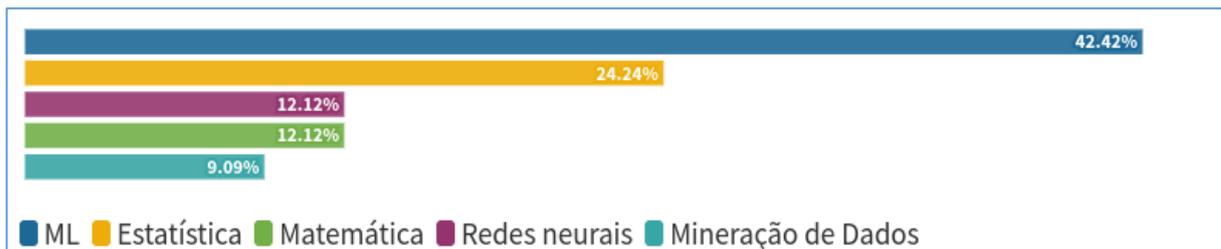
No apêndice E (Tabelas 6 a 20) estão descritas todas as frequências individuais, ordenadas (das mais frequentes as menos frequentes), para cada grupo de parâmetros mapeados.

A exceção foi para o parâmetro método de modelagens, que foi descrito de forma agrupada por semelhança dos métodos no apêndice F.

Os dados apresentados nas Figuras 6 a 12 mostram os resultados sobre o mapeamento das técnicas de modelagens e parâmetros intimamente associados nos dados de entrada e saída do modelo.

A Tabela 2, do apêndice D, apresenta os resultados consolidados por cada artigo incluído, sobre o mapeamento das técnicas de modelagens e parâmetros intimamente associados nos dados de entrada e saída do modelo.

Os tipos mais frequentes de modelagens foram: aprendizado de máquina ou *machine learning* 42,42% (n = 14), estatística 24,24% (n = 8) – Figura 6.



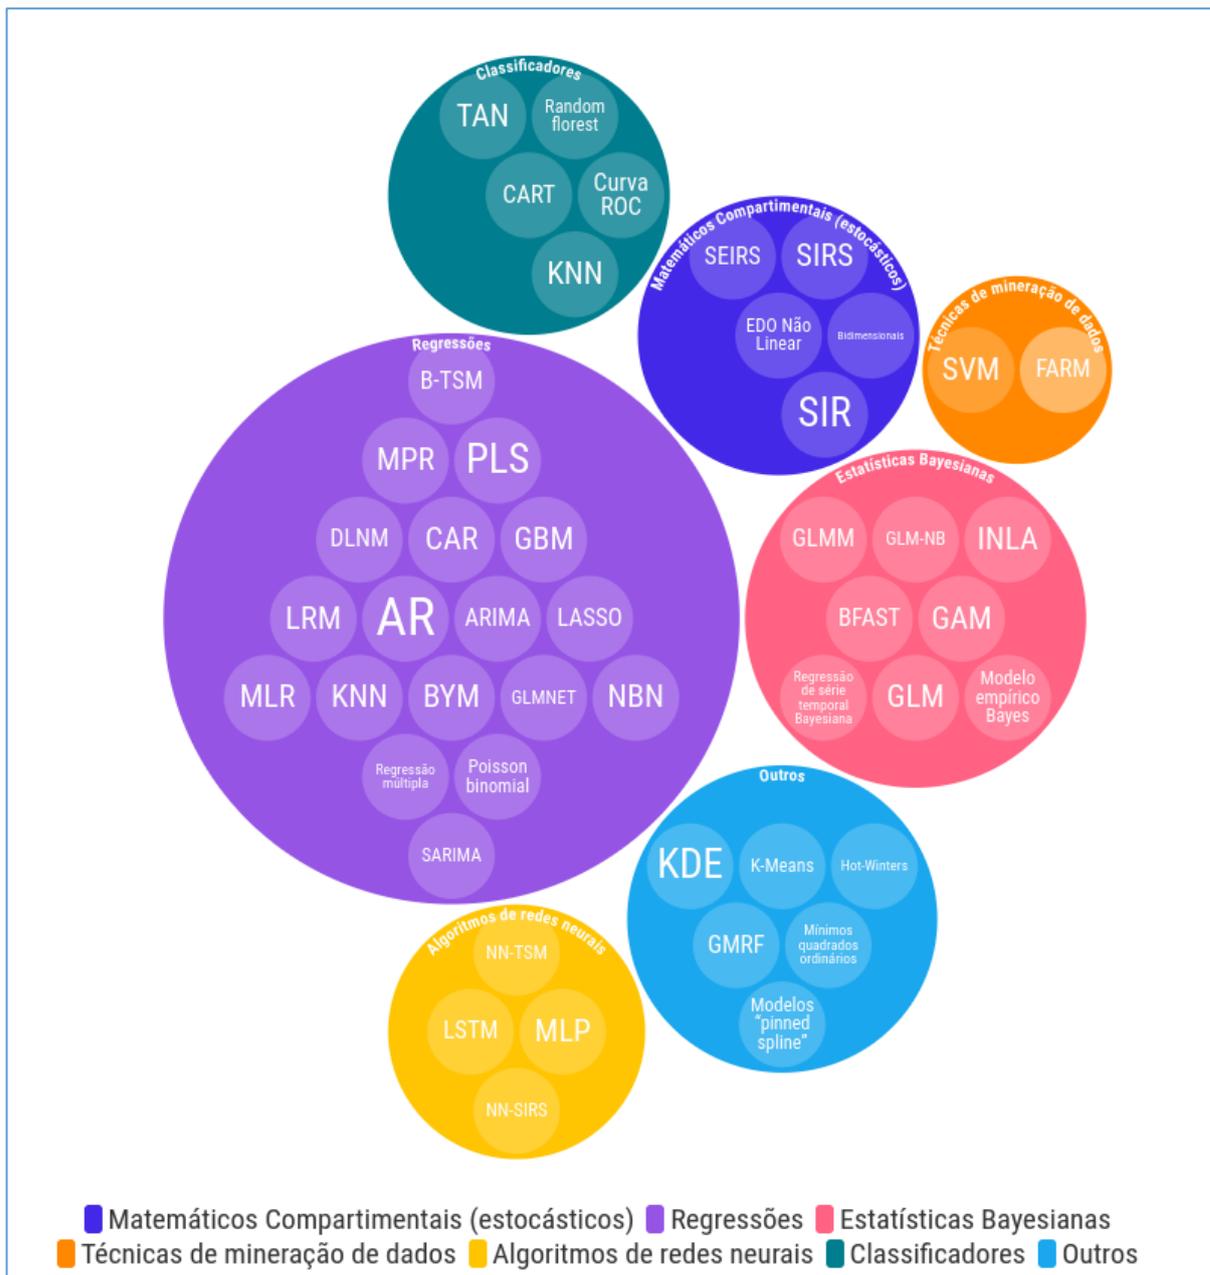
Fonte: elaborado pelo autor

**Figura 6** Frequência do parâmetro: tipos de modelagens.

Os métodos de modelagens foram agrupados em 7 grupos, conforme suas semelhanças, em: matemáticos compartimentais, também chamado de estocástico; regressões logísticas; estatísticas Bayesianas; técnicas de mineração de dados; algoritmos de redes neurais; classificadores e outros (Figura 7 e Apêndice F).

Em 29% (n = 7) dos estudos a estratégia de predição combinou os tipos de modelagens (2 a 3 tipos) – principalmente, para ML associado com RNA e/ou mineração de dados (n = 6) – Apêndice D, Tabela 2.

Observa-se que 46% (n = 11) dos artigos incluídos usaram métodos de modelagens de forma combinada, o que sugere o propósito em melhorar as acurácias das predições - Apêndice D, Tabela 2.

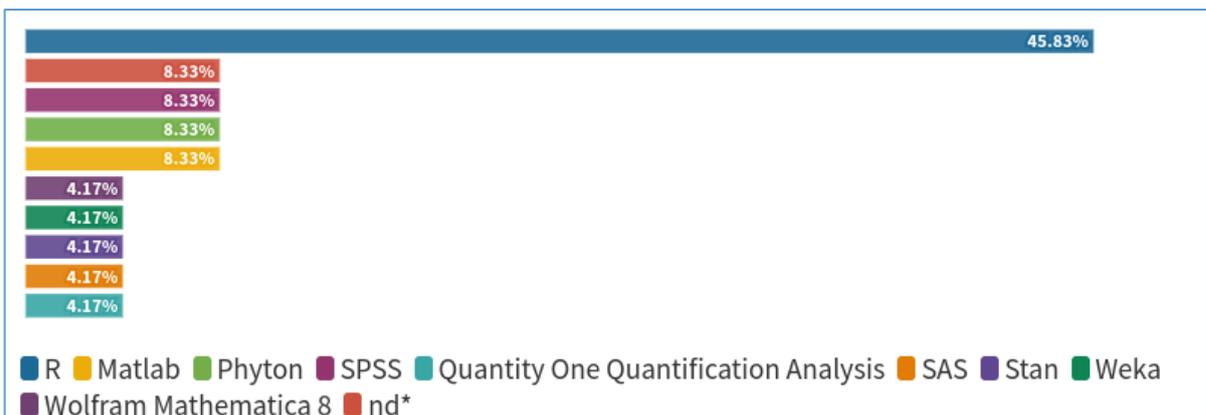


Fonte: elaborado pelo autor.

Legenda: Métodos de Modelagens: AR "Autoregressive model" - Modelo autorregressivo / ARIMA "Autoregressive integrated moving average model" - Modelo autorregressivo integrado de médias móveis / B-TSM "Bayesian time series model"- modelo de séries temporais Bayesiano/ BFAST "Breaks For Additive Seasonal Trend" - Quebras para o algoritmo aditivo de sazonalidade e tendência / BYM "Besag-York-Mollie model" - Modelo Besag-York-Mollie / CAR "Conditional autoregressive model" - Modelo auto-regressivo condicional / CART "Classification and Regression Trees" - Árvores de decisão, classificação e regressão / DLNM "Distributed lag non-linear models" - Modelos não lineares de atraso distribuído / FARM "Fuzzy Association Rule Mining" - Associação Fuzzy Regra de Mineração / GAM "Generalized additive model" - Modelo aditivo generalizado / GBM "Gradient boosted regression tree algorithm" - Algoritmo de árvore de regressão impulsionada por gradiente / GLM "Generalized linear bayesian models" - Modelos lineares generalizados bayesianos / GLM-NB "Generalized linear bayesian models with negative binomial regression" - Modelos lineares generalizados bayesianos com regressão binomial negativa/ GLMM "Generalized linear bayesian mixed models" - Modelos lineares generalizados bayesianos mistos / GLMNET "Lasso and elastic-net regularized generalized linear models" - Modelos lineares generalizados regularizados LASSO e elastic-net / GMRF "Gaussian Markov random field" - Campo aleatório gaussiano Markov / INLA "Integrated nested Laplace approximation methods" - Métodos integrados de aproximação Laplace aninhados / KNN "K-Nearest Neighbor" - vizinhos mais próximos-K / LASSO "Least absolute shrinkage and selection operator based models" - Modelo baseado no mínimo de encolhimento absoluto e operador de seleção / LRM - Modelos logísticos de início de transmissão e propagação / LSTM "Long Short-Term Memory" - Rede neural memória longa e curta / MLP "Multilayer perceptron" - Rede neural perceptron de múltiplas camadas / MLR "Multinomial logistic regression" - Regressão logística multinomial / MPR "Multivariate Poisson regression" - Regressão multivariada de Poisson / NBN - "Negative binomial regression model" - Modelo de regressão binomial negativo / NN - "Neural Network" - Rede neural / NN-SIRS "neural network informed by a susceptible-infectious-recovered-susceptible (SIRS) compartmental model" - rede neural formada por um modelo de compartimento suscetível-infectado-recuperado-susceptível (SIRS) / NN-TSM "neural network time series model" - modelo de séries temporais de redes neurais / PLS "Partial least squares" - Mínimos quadrados parciais / RF "Random forests" - Florestas aleatórias / ROC "Receiver operating characteristics" - Características de funcionamento do receptor / SARIMA "Seasonal autoregressive integrated moving average model" - Modelo auto-regressivo integrado de médias móveis sazonais / SEIRS "susceptible-exposed-infectious-recovered compartmental model" - modelo compartmental suscetível-exposto-infectado-recuperado / SIR susceptible-infectious-recovered compartmental model" - modelo compartmental suscetível--infectado-recuperado / SVM "Support vector machine" - Máquina de vetor de suporte / TAN "Tree Augmented Naive Bayes" - Árvore aumentada do Naive Bayes (construção de classificadores)

**Figura 7** Descrição agrupada por semelhança dos métodos de modelagens mapeados.

A linguagem R (programa) foi a mais utilizada (45%,  $n = 11$ ), inclusive para rodar as modelagem do tipo ML, seguida dos programas Matlab, Python e SPSS (8,33%,  $n = 2$ , para cada) – Figura 8.



Fonte: elaborado pelo autor.

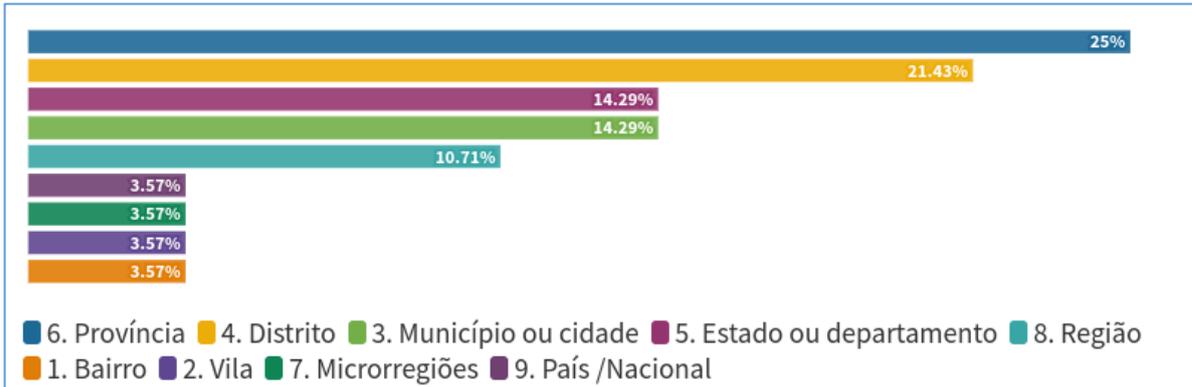
**Figura 8** Frequência do parâmetro: programas (*softwares*) para modelagens.

Há uma tendência em utilizar acima de 4 variáveis preditoras, com média de 10, com o máximo de 23 variáveis – Apêndice D, Tabela 2.

A escala espacial dos dados utilizadas nos artigos variou de vila até país, distribuídos assim: província (25%,  $n = 7$ ), distrito (21,43%,  $n = 6$ ), município ou cidade, (14,29%,  $n = 4$ ), estado ou departamento (14,29%,  $n = 4$ ), região (10,71%,  $n = 3$ ), bairro, vila, microrregiões, país/nacional (3,57%,  $n = 1$ , cada) – Figura 9.

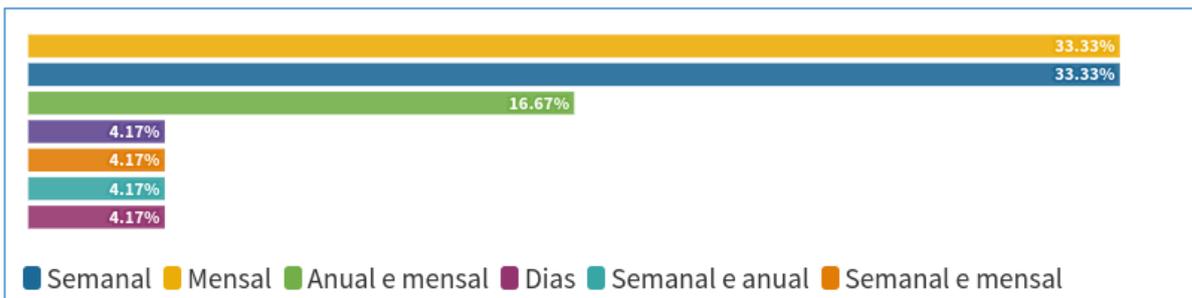
Quatro artigos analisaram o território utilizando escalas espaciais diferentes: região e país (54), município e província (13) e província e região (17,55).

As unidades temporais de predição dos modelos foram, respectivamente: semanal (33,33%,  $n = 8$ ), mensal (33,33%,  $n = 8$ ), anual e mensal (16,67%,  $n = 4$ ), dias, semanal e anual, semanal e mensal, e tempo real (4,17%,  $n = 1$ , cada) – Figura 10.



Fonte: elaborado pelo autor.

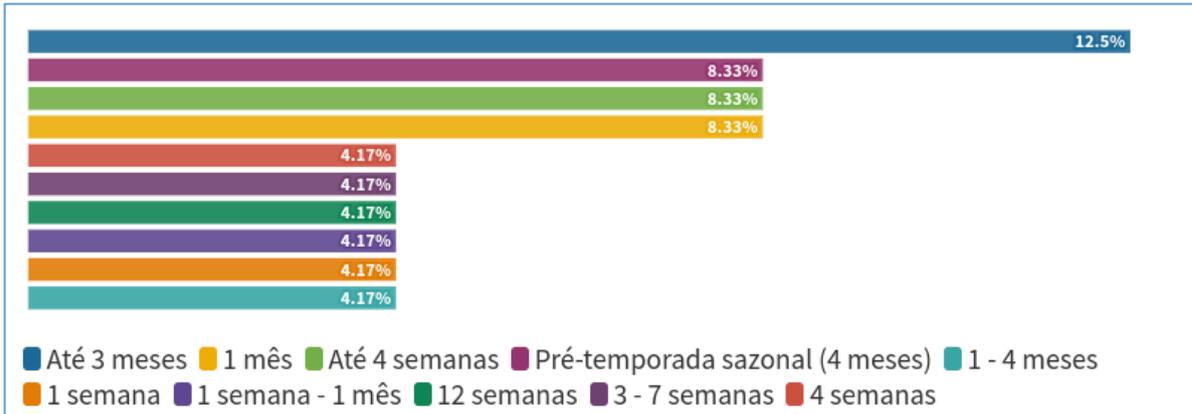
**Figura 9** Frequência percentual do parâmetro: escala espacial dos dados.



Fonte: elaborado pelo autor.

**Figura 10** Frequência percentual do parâmetro: unidade temporal de previsão.

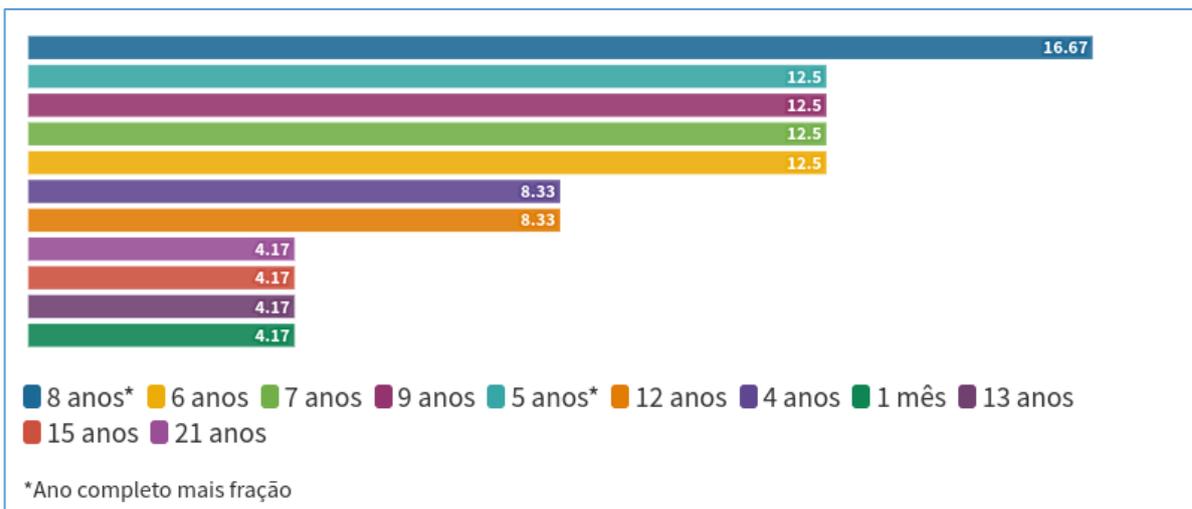
Houve diversidade na determinação dos períodos de previsão antecipadas, sendo mapeados da seguinte forma: até 3 meses (12,50%, n = 3), 1 mês, até 4 semanas, e pré-temporada sazonal (4 meses) - (2,33 %, n = 2, cada), 1 – 4 meses, 1 semana, 1 semana – 1 mês, 12 semanas, 3 – 7 semanas, 4 semanas, anual (verificar o pico de incidência, semana do pico e incidência total), até 12 semanas, até 30 dias, até 6 meses, pré-temporada (3 meses), semanas do ano e tempo real (4,17%, n = 1, cada) – Figura 11. Um estudo quis prevê a probabilidade de ter um caso importado de dengue na Europa, e um artigo não informou o dado (56).



Fonte: elaborado pelo autor.

**Figura 11** Frequência percentual do parâmetro: período de previsão antecipada.

O período de experimento (tempo de observação dos dados incluídos nos modelos) variou de 1 mês a 21 anos, sendo os mais frequentes no período de 5 a 8 anos – Figura 12.



Fonte: elaborado pelo autor.

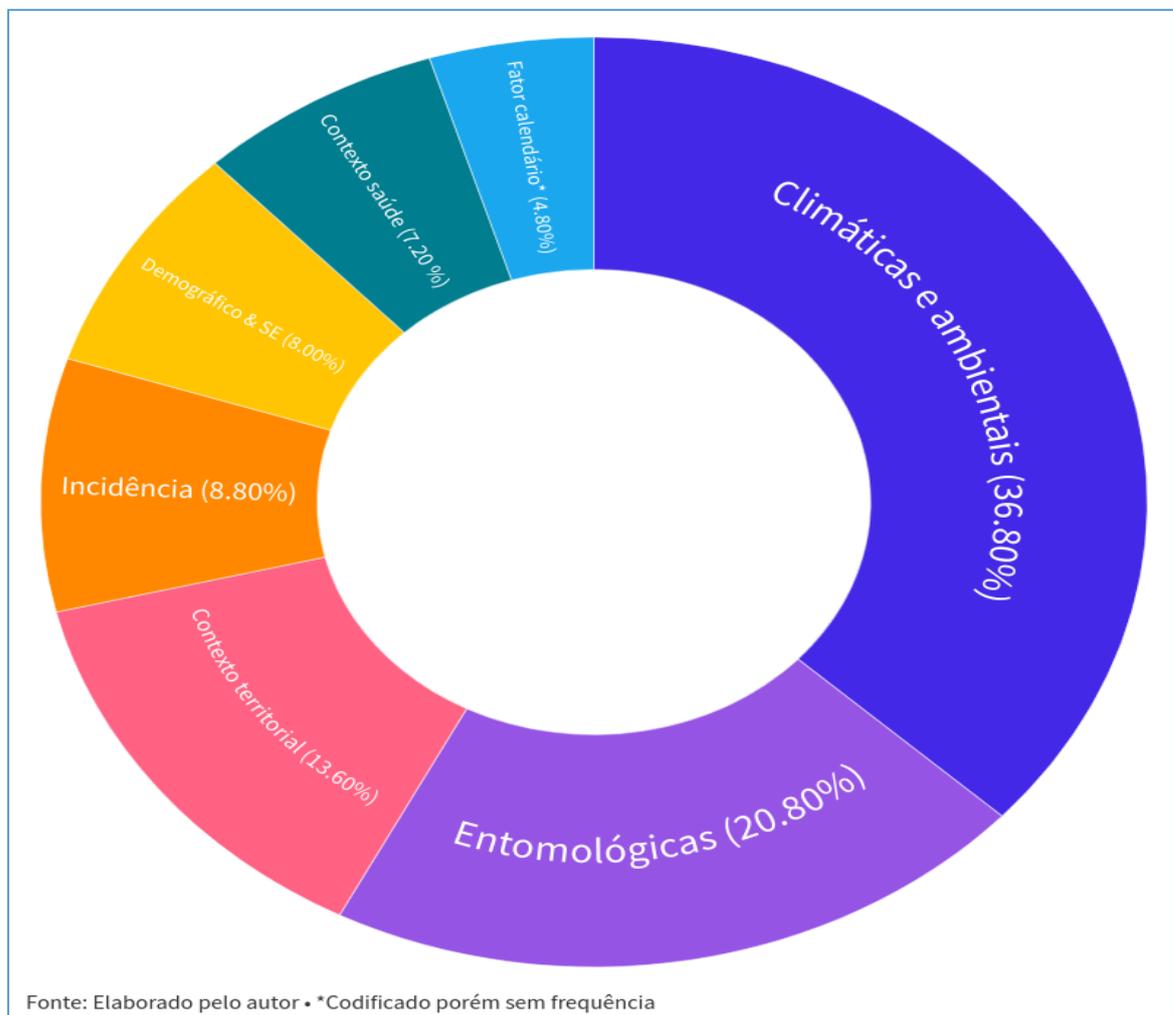
**Figura 12** Frequência percentual do parâmetro: período de experimento.

A seguir apresenta-se o mapeamento do parâmetro variáveis utilizadas (Figuras 13 a 19).

O levantamento completo e frequências para cada variável está disponível no Apêndice E (Tabelas 8 a 14).

Foram utilizadas ao todo 75 tipos de variáveis predictoras, categorizadas em 7 grupos, conforme suas semelhanças, em: incidência (7 tipos); entomológicas (15 tipos); climáticas e ambientais (13 tipos); fator calendário (7 tipos); contexto territorial (17 tipos); demográfico / socioeconômico (7 tipos); e contexto saúde. (9 tipos).

Quando se somam os subtipos de variáveis, dentro de cada grupo, podem ser contabilizadas ao todo 125 variáveis. A Figura 13 representa essa distribuição.

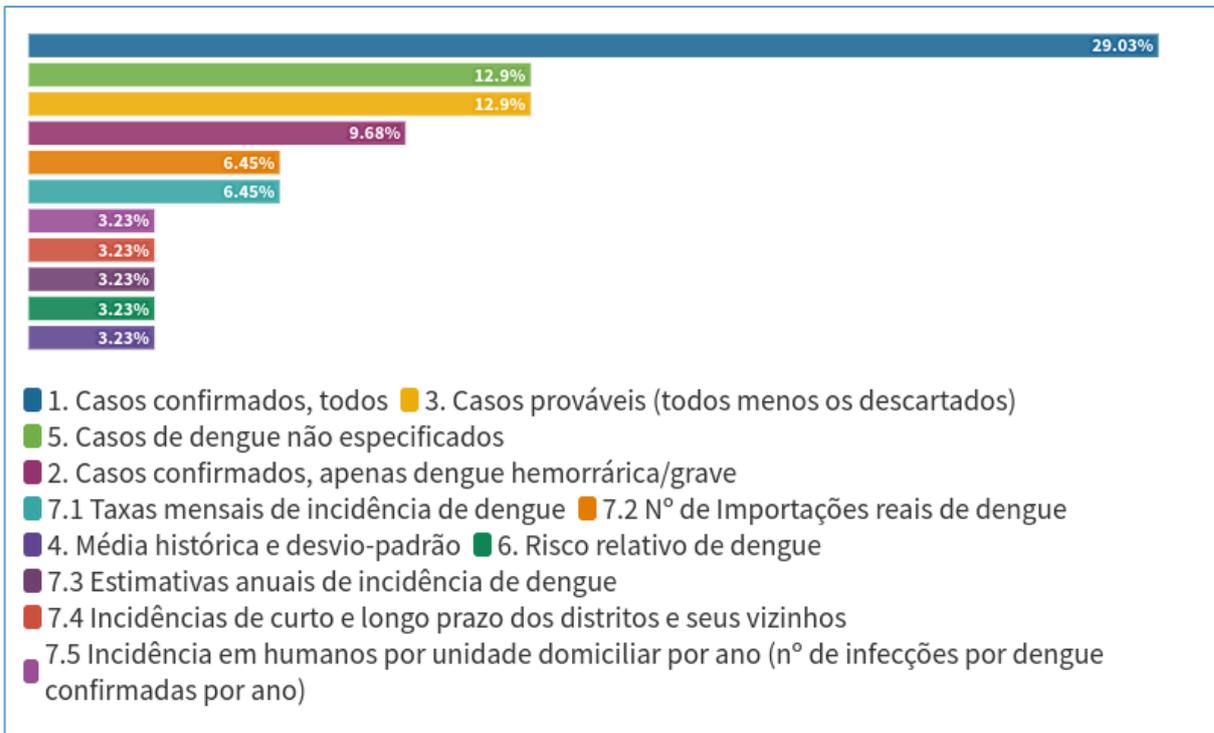


**Figura 13** Frequência percentual das variáveis predictoras por grupo.

Novamente, não é possível observar um padrão na utilização dessas variáveis frente aos tipos de modelagens e escala espacial de dados – Apêndice C, Tabela 3.

Observa-se que para alguns tipos de variáveis existem subtipos que melhor especificam a característica do dado, principalmente, nos grupos das variáveis entomológicas e climáticas.

A variável incidência foi utilizada em 100% os estudos incluídos. Isso se justifica pelo critério obrigatório para a seleção dos artigos nesta ScR. Recordando, todos os artigos deveriam utilizar ao menos 3 parâmetros na modelagem, sendo obrigatória a incidência de casos. Nesta variável o mapeamento encontrou 11 formas para o cálculo da incidência, que pode refletir a disponibilidade e/ou a qualidade do dado advinda da fonte retirada – Figura 14.

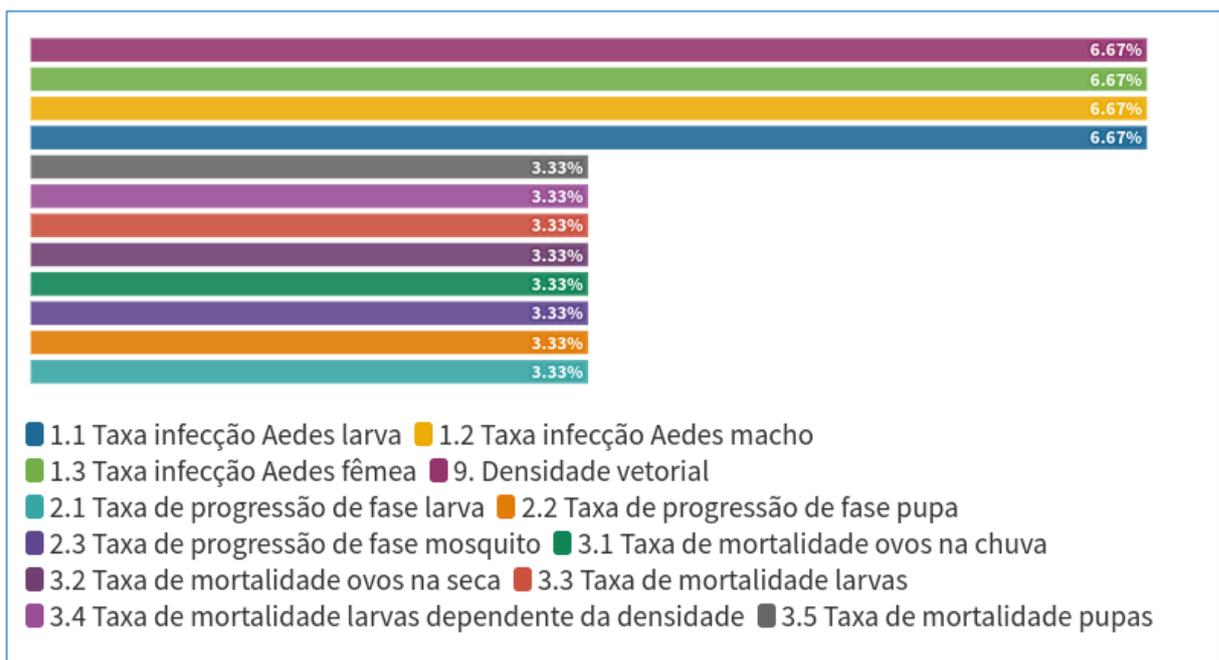


Fonte: elaborado pelo autor.

**Figura 14** Frequência percentual do parâmetro: variável - incidência.

Para as variáveis entomológicas os estudos especificaram em subtipos a taxa de infecção do Aedes (larva, macho e fêmea), a taxa de progressão de fase (larva, pupa e mosquito), taxa de mortalidade (ovos na chuva, ovos na seca, larvas, larvas dependentes de densidade, pupas, mosquitos saudáveis, mosquitos infectados) – Figura 15.

Houve interesse também em utilizar variedades de dados obtidos de outras formas, como: índice de Breteau<sup>1</sup>, Índice de casas<sup>2</sup>, índice médio de fêmeas de *Aedes aegypti* por armadilha, densidade vetorial, probabilidade de infecção do mosquito pelo vírus dengue, percentual semanal de reprodução *Aedes aegypti*, taxa de refeições infecciosas dos seres humanos para os mosquitos, taxa de picadas infecciosas de mosquitos para humanos, taxa de oviposição dos mosquitos e níveis de ativação da emergência do mosquito pela chuva e seca – Figura 15.



Fonte: elaborado pelo autor.

**Figura 15** Frequência percentual do parâmetro: variável – entomológica (top 12). (somente as 12 variáveis mais frequentes)

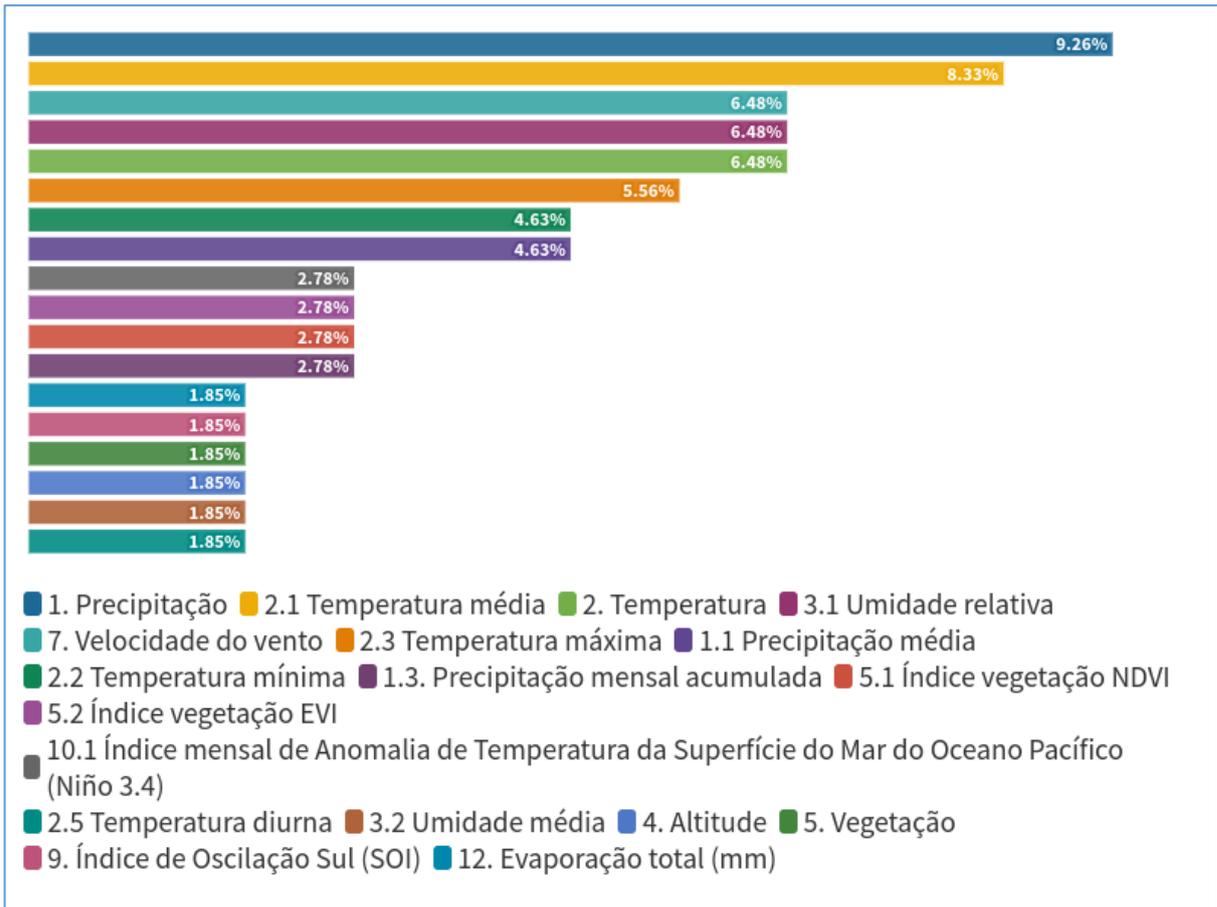
No que tange as variáveis climáticas nota-se um rigor no detalhamento dos tipos de precipitação, umidade e temperatura, com maior especificidade para os dois últimos, com variações que chegam até 12 subtipos para cada – Apêndice D – Tabela 10.

<sup>1</sup> Índice de Breteau – indicador entomológico que representa o número de recipientes positivos para larvas / número total de recipientes encontrados.

<sup>2</sup> Índice de Casas ou Índice de Infestação Predial - indicador entomológico que representa o número de recipientes positivos / número total de casas ou edificações inspecionadas.

Também foram explorados dados de vegetação e cobertura do solo, altitude, pressão atmosférica, temperatura da superfície do mar, índice de oscilação sul, retrocessos climáticos, duração do sol em horas e evaporação –

A Figura 16 demonstra os 18 tipos e subtipos de variáveis climáticas e ambientais mais frequentes nos estudos incluídos.



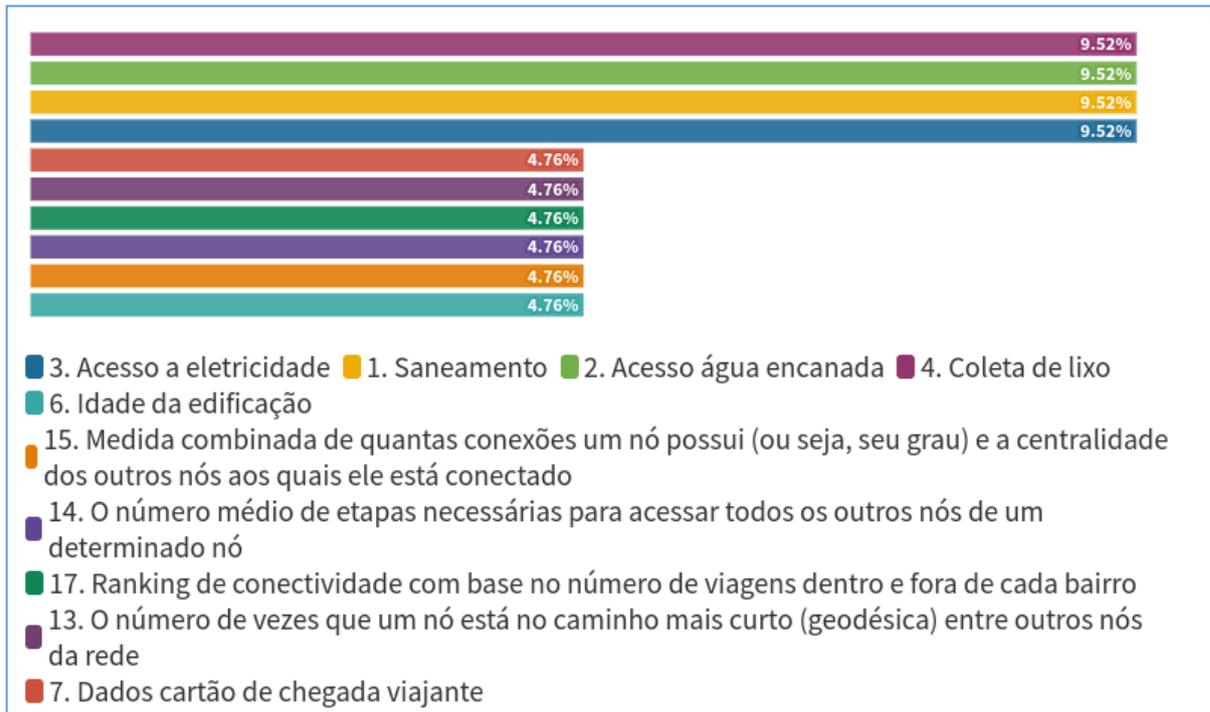
Fonte: elaborado pelo autor.

**Figura 16** Frequência percentual do parâmetro: variável - climática e ambiental (top 18).

Para o contexto territorial surpreendeu a gama de possibilidades atribuídas aos tipos utilizados, que perpassam pelo saneamento básico, acesso à eletricidade, água encanada, idade da edificação. Estes completamente associados à proliferação do vetor. Porém foram somados dados mais complexos de obtenção, como a estabilidade política, inquéritos de soroprevalência

para a dengue, e dados de conexões e conectividade em viagens (neste caso malha aérea em determinadas rotas) – Apêndice D – Tabela 12.

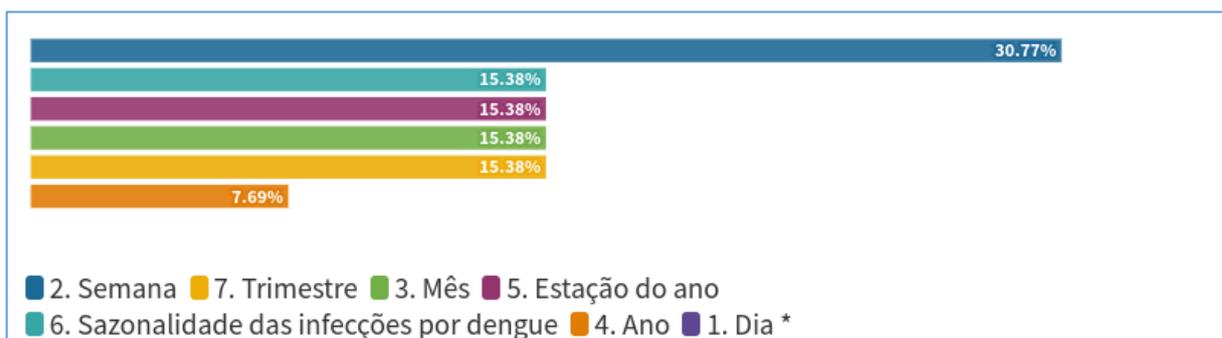
A Figura 17 demonstra os 10 tipos das variáveis de contexto territorial mais frequentes nos estudos incluídos.



Fonte: elaborado pelo autor.

**Figura 17** Frequência percentual do parâmetro: variável - contexto territorial (top 10).

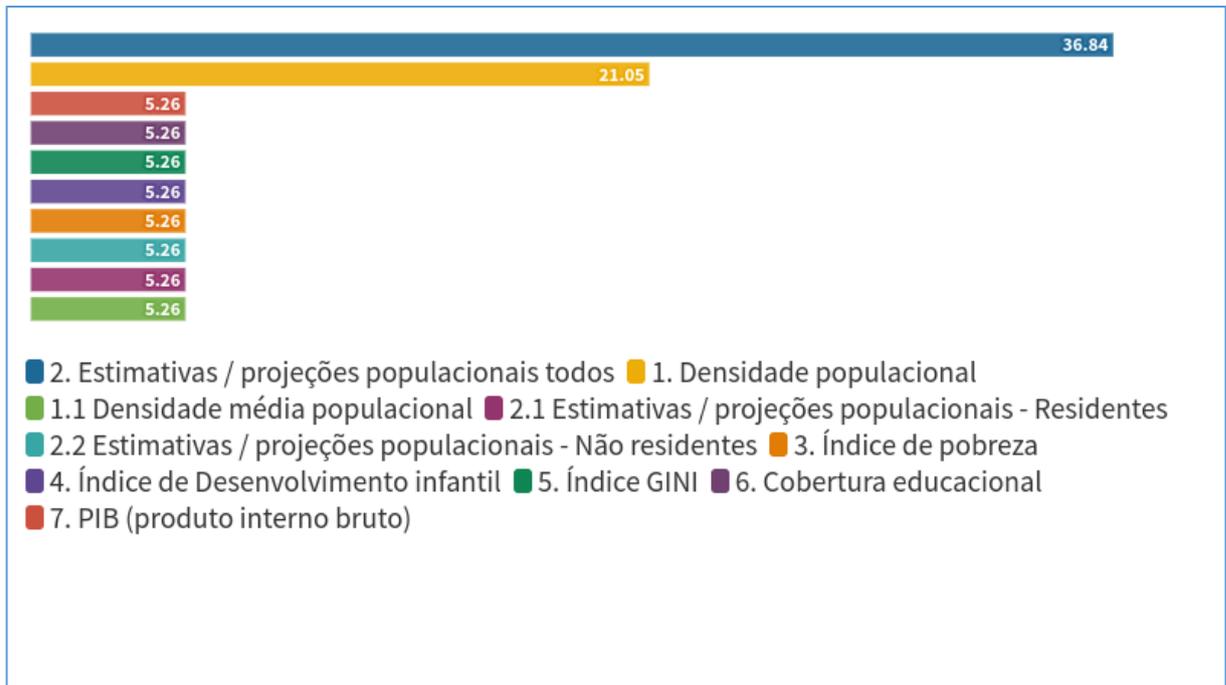
A Figura 18 apresenta a distribuição da variável fator calendário. Semana foi o fator mais usado (30,77%, n = 4), seguido de trimestre, mês, estação do ano e sazonalidade (15,38%, n = 2 cada). Não houve frequência para o fator “dia”, apenas foi codificado.



Fonte: elaborado pelo autor.

**Figura 18** Frequência percentual do parâmetro: variável - fator calendário.

A Figura 19 apresenta a distribuição da variável - demográfica / socioeconômica. Estimativas e projeções populacionais o fator mais usado (36,84%, n = 7), seguido de densidade populacional (21,05%, n = 4).

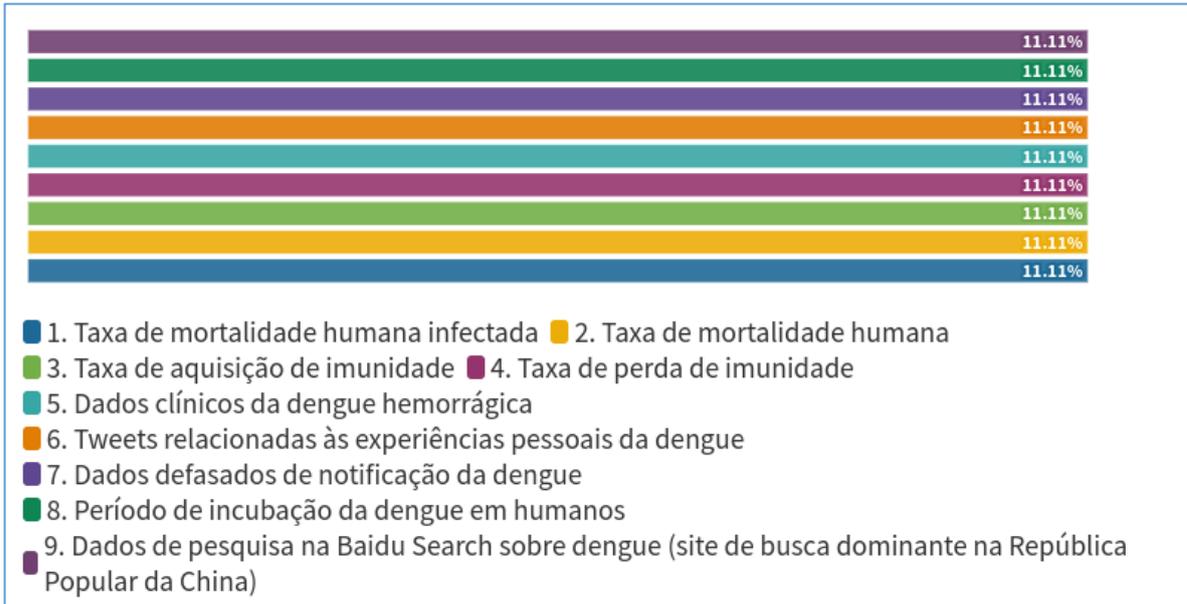


Fonte: elaborado pelo autor.

**Figura 19** Frequência percentual do parâmetro: variável - demográfica / socioeconômica.

Quanto a variável contexto saúde foram mapeados 9 tipos, em iguais frequências, conforme demonstrada na Figura 20.

A Tabela 3, do apêndice D, apresenta os resultados consolidados por cada artigo incluído pelo recorte: variáveis utilizadas, tipos de modelagens e escala espacial dos dados. Nota-se que a escolha de um tipo de modelagem não influencia no número nem na categoria das variáveis utilizadas.



Fonte: elaborado pelo autor.

**Figura 20** Frequência percentual do parâmetro: variável - contexto saúde.

Por todo o exposto, diante de um arsenal tão variado de possibilidades de parâmetros utilizados nas modelagens preditivas para a dengue nos artigos incluídos nesta ScR, foi premente identificar quais são aplicados com maior frequência (Tabela 4).

Destaca-se, em suma, os parâmetros mais frequentes:

- Tipos de modelagens: ML (42%, n = 14), estatísticas (24,24%, n= 8), matemática e redes neurais (12,12%, n = 4);
- Programas: R (45,83%, n = 11), Matlab, Python, SPSS (8,33%, n = 2, cada);
- Escala espacial de dados: província (25%, n = 7), distrito (21,4%), município ou cidade (14,29%, n = 4), estado ou departamento (14,29%, n = 4);
- Unidade temporal de previsão: semanal e mensal (33%, n = 8, cada), anual e mensal (16,67%, n = 4);
- Período de previsão antecipada: até 3 meses (12,50%, n = 3), 1 mês, até 4 semanas, pré-temporada sazonal - 4 meses - (8,33%, n = 2);

- Período de experimento: 8 anos (16,67%, n = 4), 6, 7, 9 e 5 anos (12,50%, n = 3, cada)
- Variáveis:
  - Incidências: todos os casos confirmados (31,03%, n = 9), casos de dengue não especificados, casos prováveis – todos menos os descartados (13,79%, n = 4, cada);
  - Entomológicas: Densidade vetorial, taxa de infecção Aedes macho, taxa de infecção Aedes larva, taxa infecção Aedes fêmea (6,67%, n = 2);
  - Climáticas e ambientais: precipitação e temperatura média (9,26%, 8,33%, n = 10, n = 9, respectivamente), umidade relativa, temperatura, velocidade do vento (6,48%, n = 7, cada), temperatura máxima (5,56%, n = 6);
  - Fator calendário: semana (30,77%, n = 4), trimestre, mês, estação do ano, sazonalidade das infecções por dengue (15,35%, n = 2, cada);
  - Contexto territorial: acesso à eletricidade, saneamento, acesso à água encanada, coleta de lixo (9,52%, n = 2, cada);
  - Demográfico / socioeconômico: estimativas / projeções populacionais todos (44,44%, n = 8), densidade populacional (22,22%, n = 4).

O levantamento completo e frequências para todos os parâmetros extraídos estão disponíveis no Apêndice E (Tabelas 6 a 20).

**Tabela 4** Resumo dos parâmetros mais frequentes, por grupo mapeado.

Grupos dos parâmetros	Códigos - descrição dos parâmetros	Freq	%	
<b>Tipos de Modelagens</b>	3 - Aprendizado de máquina ou Machine learning	14	42,42	
	1 - Estatística	8	24,24	
	2 - Matemática	4	12,12	
	4. Redes Neurais Artificiais	4	12,12	
<b>Programas (Softwares)</b>	R	11	45,83	
	Matlab	2	8,33	
	Phyton	2	8,33	
	SPSS	2	8,33	
<b>Escala Espacial Dados</b>	6. Província	7	25,00	
	4. Distrito	6	21,43	
	3. Município ou cidade	4	14,29	
	5. Estado ou departamento	4	14,29	
<b>Unidade Temporal de Previsão</b>	Semanal	8	33,33	
	Mensal	8	33,33	
	Anual e mensal	4	16,67	
<b>Período de Previsão Antecipada</b>	até 3 meses	3	12,50	
	1 mês	2	8,33	
	até 4 semanas	2	8,33	
	pré-temporada sazonal (4 meses)	2	8,33	
<b>Período de Experimento</b>	8 anos	4	16,67	
	6 anos	3	12,50	
	7 anos	3	12,50	
	9 anos	3	12,50	
	5 anos*	3	12,50	
<b>Variáveis</b>	<b>Incidências</b>	1. Casos confirmados todos	9	31,03
		5. Casos de dengue não especificados	4	13,79
		3. Casos prováveis (todos menos os descartados)	4	13,79
	<b>Entomológicas</b>	9. Densidade vetorial	2	6,67
		1.2 Taxa de infecção Aedes macho	2	6,67
		1.1 Taxa de infecção Aedes larva	2	6,67
		1.3 Taxa infecção Aedes fêmea	2	6,67
	<b>Climáticas e Ambientais</b>	1. Precipitação	10	9,26
		2.1 Temperatura média	9	8,33
		3.1 Umidade relativa	7	6,48
		2. Temperatura	7	6,48
		7. Velocidade do vento	7	6,48
<b>Fator Calendário</b>	2.3 Temperatura máxima	6	5,56	
	2. Semana	4	30,77	
	7. Trimestre	2	15,38	
	3. Mês	2	15,38	
	5. Estação do ano	2	15,38	
	6. Sazonalidade das infecções por dengue	2	15,38	
<b>Contexto Territorial</b>	3. Acesso a eletricidade	2	9,52	
	1. Saneamento	2	9,52	
	2. Acesso água encanada	2	9,52	
	4. Coleta de lixo	2	9,52	
<b>Demográfico / Sócio-econômico</b>	2. Estimativas / projeções populacionais todos	8	44,44	
	1. Densidade populacional	4	22,22	

Fonte: elaborado pelo autor

Não houve alteração de frequência nas variáveis do contexto saúde, portanto não foram listadas nesta tabela; os métodos de modelagens não foram frequentados, apenas descritos e classificados de forma macro, devido a diversidade e o grau de complexidade que podem atingir numa análise preditiva.

\*Ano completo mais fração

Todos os artigos incluídos afirmavam que suas pesquisas poderiam ser aplicadas à saúde pública. Desta forma, não foi necessário dispor a frequência do último parâmetro extraído dos dados.

Um último recorte que engloba o número de variáveis preditoras e os grupos de variáveis utilizadas por artigo incluído (Tabela 5). Observa-se a distribuição, respectivamente: incidência em 100% (n = 24), climáticas e ambientais em 96% (n = 23), demográfico / socioeconômico em 54% (n = 13), fator calendário em 46% (n = 11), contexto territorial em 33% (n = 8), entomológicas em 29% (n = 7), contexto saúde em 17% (n = 4).

**Tabela 5** Número de variáveis preditoras e grupos de variáveis por artigo incluído.

Estudos incluídos	N° variáveis preditoras	Grupo de Variáveis							N° Fontes dos Dados	
		Incidência	Entomológicas	Climáticas e Ambientais	Fator Calendário	Contexto Territorial	Demográfico / Socioeconômico	Contexto Saúde		
1	5	X		X				X	3	
2	4	X	X	X					2	
3	10	X	X	X	X	X			7	
4	10	X		X	X	X			3	
5	9	X		X				X	10	
6	7	X		X				X	5	
7	13	X			X	X		X	7	
8	11	X		X	X			X	6	
9	7	X		X		X			X	3
10	10	X	X	X		X			X	5
11	15	X		X	X					4
12	8	X		X						2
13	9	X		X		X				6
14	23	X	X	X				X	X	6
15	7	X		X	X			X		4
16	6	X		X	X				X	9
17	10	X	X	X	X			X		5
18	8	X		X	X			X		3
19	10	X	X	X	X			X		3
20	4	X		X				X		3
21	9	X	X	X				X		4
22	14	X		X		X		X		10
23	13	X		X	X	X				8
24	7	X		X						6
<b>Totais</b>		<b>24</b>	<b>7</b>	<b>23</b>	<b>11</b>	<b>8</b>	<b>13</b>	<b>4</b>		
<b>%</b>		<b>100</b>	<b>29</b>	<b>96</b>	<b>46</b>	<b>33</b>	<b>54</b>	<b>17</b>		
<b>Média</b>	<b>10</b>									<b>5,2</b>

Fonte: elaborado pelo autor.

Nota-se a utilização de um mínimo de quatro, máximo de 23, média de 10, variáveis preditoras por estudo.

No que se refere as fontes dos dados que deram origem as variáveis utilizadas, observa-se o emprego de no mínimo 3 e no máximo 10, com média de 5 fontes (Tabela 5).

Verifica-se que vários dados de origem climática e ambiental foram obtidos de forma gratuita, disponíveis nas plataformas: *National Aeronautics and Space Administration - NASA EARTHDATA*<sup>1</sup>, *Tropical Rainfall Measuring Mission (TRMM)*<sup>2</sup>, *National Oceanic and Atmospheric Administration (NOAA)*<sup>3</sup>.

Os dados sobre os casos confirmados e suspeitos de dengue foram obtidos pelos serviços públicos de saúde de cada país e/ ou região. Demais fontes para variáveis atreladas ao contexto territorial e de saúde foram obtidas de serviços oficiais governamentais, conforme disponibilidade.

No Apêndice G foram listadas todas as fontes de dados, no formato original (sem tradução) como foram descritas nos artigos incluídos.

Por fim, foram descritos no Apêndice H, os objetivos dos artigos incluídos, como informação complementar.

---

<sup>1</sup> NASA's Earth Science Data Systems (ESDS) – programa que supervisiona os dados de ciências da terra obtidos pelas missões espaciais da NASA, e disponibiliza na forma de dados abertos e gratuitos, interativos, interoperáveis e acessíveis para a pesquisa e a sociedade, com o intuito de maximizar o retorno científico das missões - <https://www.earthdata.nasa.gov/>.

<sup>2</sup> Refere-se tanto à missão espacial quanto dá nome ao satélite que forneceu informações importantes sobre precipitação por meio de instrumentos espaciais e melhorou a compreensão das interações entre vapor de água, nuvens e precipitação, que são fundamentais para regular o clima da Terra, sobretudo nas regiões tropicais e subtropicais. Também é um produto desenvolvido pela NASA - <https://gpm.nasa.gov/missions/trmm>.

<sup>3</sup> Conta com três grandes Centros Nacionais de informações ambientais dos Estados Unidos - Centro Nacional de Dados Climáticos, o Centro Nacional de Dados Geofísicos e o Centro Nacional de Dados Oceanográficos, que inclui o Centro Nacional de Desenvolvimento de Dados Costeiros. São responsáveis por hospedar e fornecer acesso a arquivos importantes da terra, com dados oceânicos, atmosféricos e geofísicos abrangentes, desde as profundezas do oceano à superfície do sol, além de registros de sedimentos de milhões de anos, e imagens de satélite quase em tempo real - <https://www.ngdc.noaa.gov/>.

## 5 DISCUSSÃO

Nesta revisão de escopo foram identificados 24 estudos que abordavam a modelagem preditiva de cenários epidemiológicos para a dengue e utilizavam ao menos 3 parâmetros, sendo obrigatória a incidência de casos, publicados entre 2008 e 2021.

Embora o período de rastreamento tenha sido maior (1968 a 2021), é possível que os critérios de elegibilidades definidos possam ter tendenciado a captura com publicações mais recentes, ou, ainda, ser um reflexo do aprimoramento das técnicas de modelagens, devido aos avanços tecnológicos na ciência da computação, evidenciando as oportunidades trazidas pela inteligência artificial, por exemplo com as técnicas de *machine learning* e mineração de dados.

Quanto aos indicadores bibliométricos dos artigos percebe-se que os estudos incluídos foram publicados em revistas de alto impacto (Fator JIF > 70, média de 78,92). Portanto, os artigos incluídos refletem boa qualidade, em termo de comunicação científica, tendo em vista o rigor metodológico necessário e revisão por pares exigidos pelos editoriais das revistas.

A população alvo dos estudos estava concentrada na região do sudeste asiático e continente americano (central e sul), que são compatíveis com as regiões tropicais e subtropicais previstas como zonas de maior potencial para transmissão da dengue (1).

Observou-se o interesse de pesquisadores vinculados a instituições sediadas em países com baixo risco para a transmissão da dengue, a realizarem pesquisas em países com alto risco. Estados Unidos liderou as pesquisas em outros países.

Sobre a fonte de financiamento, observa-se que não há interesse de instituições privadas no financiamento desse tipo de pesquisa, havendo uma concentração em fontes de financiamento públicas.

Ressalta-se a importância de publicações sobre a temática, em periódicos indexados, onde a pesquisa encontrou mais concentração das palavras-chave na categoria das ciências multidisciplinares, seguido da medicina tropical. Isso pode refletir o enquadramento adotado para estas publicações nos periódicos científicos.

Ainda sobre as palavras-chave que caracterizam os artigos, o mapeamento encontrou 53 termos empregados. No entanto, 4 termos foram mais frequentes, DENGUE, PREDICTION MODEL, EARLY WARNING SYSTEM, INFECTIOUS DISEASE.

Por outro lado, algumas revistas (Plos e Nature) adotam a perspectiva de áreas temáticas para classificar os artigos. Desta maneira há uma diferença nos termos aplicados. Lideraram as áreas temáticas DENGUE FEVER, FORECASTING e EPIDEMIOLOGY.

Esta ScR conseguiu mapear 10 principais parâmetros envolvidos nas análises preditivas de cenários epidemiológicos para a dengue. Com destaque para o parâmetro, variáveis utilizadas, encontrados 75 tipos. Foi possível listar e agrupar em 7 categorias.

O mapeamento das técnicas de modelagens e parâmetros intimamente associados nos dados de entrada e saída do modelo (Tabela 2) demonstrou que não há uma padronização para a utilização desses parâmetros.

A escala espacial dos dados esteve mais evidente para província e distrito, por serem organizações territoriais adotadas em países do sudeste asiático (Tailândia, Vietnã, Sri Lanka, Singapura, Filipinas). Seria possível a extrapolação desses territórios para o contexto de estados e municípios, como ocorre na organização do Brasil.

Entretanto, ainda sobre a escala espacial dos dados, houve uma pesquisa que se concentrou numa unidade menor, vila (57), e outra em bairro (58). Um dado relevante que pode facilitar a predição de cenários em áreas menores, ou mais críticas para o desenvolvimento de epidemias de dengue. Também há estudos para as escalas regiões, macro e microrregiões.

O artigo (58) que analisou previsões em nível de bairro, em ambientes com grande densidade populacional, demonstrou que o modelo foi melhor em janelas de predição mais curta (1 mês). Entretanto, é altamente dependente de um conjunto de dados georreferenciados (9 variáveis), quase em tempo real. Por outro lado, usou apenas modelo estatístico, com emprego do método LASSO, que, a priori simplifica a técnica de modelagem.

Esse tipo de modelo adequado para escala espacial de bairro parece ser apropriado para a mitigação preventiva ao ser capaz de monitorar novas áreas potenciais para a dengue, ao invés de monitorar os locais onde já está estabelecida. Assim, pode ser uma alternativa para gerar maior eficiência no controle da transmissão da doença e reduzir os custos em grandes centros urbanos (12).

Um ponto de destaque é que a modelagem preditiva tende a não se adequar para áreas com baixa densidade populacional, pois os modelos não se ajustam corretamente nesta situação.

A estratégia de predição dos modelos esteve concentrada nas unidades temporais semanal e mensal (33,33%,  $n = 8$ ).

Quanto ao período de previsão antecipada, nota-se preferência para tempos menores de até 4 semanas a 3 meses (período máximo).

Percebe-se uma tendência na utilização de métodos que associam modelos compartimentais, regressões e/ou estatísticas Bayesianas na base de construção dos modelos, que posteriormente são aprimorados com técnicas de mineração de dados e classificadores.

Existe uma diversidade metodológica dos modelos que dificultou a análise no curso desta ScR, uma vez que exige o conhecimento de uma equipe multidisciplinar, composta por cientista de dados, estatísticos, matemáticos, entre outros.

Isso merece um aprofundamento futuro sobre as técnicas de modelagens utilizadas com foco na predição epidemiológica de arboviroses, uma vez que esta análise pontual não faz parte do escopo desta revisão.

Sobre a utilização da variável incidência, existe crítica em utilizar no cálculo da incidência dados advindos apenas dos casos notificados que foram confirmados por exame laboratorial. Pois, tanto a dinâmica de transmissão subjacente quanto a carga de casos de dengue, são capturadas de forma imperfeita, e tal condição pode afetar as entradas e saídas do modelo de previsão, gerando incertezas de difícil quantificação (11,59).

Verifica-se que para alguns parâmetros (período de previsão antecipada, período de experimento, variáveis entomológicas, fator calendário, contexto territorial e contexto saúde) não houve diferenças significativas de frequências.

Isso sugere que não há um padrão na seleção desses parâmetros. Ou seja, podem ser utilizados conforme a prioridade, disponibilidade dos dados e/ ou regra estabelecida no modelo de predição, que melhor responda ao problema naquele território.

Para o período de previsão antecipada, os desempenhos foram mais favoráveis para até 3 meses, com maior acurácia para até 4 semanas. Entretanto, requer que os dados de entrada (variáveis preditoras) estejam disponíveis quase em tempo real.

Por outro lado, há uma tendência em explorar novas variáveis, o que é compreensível devido à complexa dinâmica vinculada a dinâmica de transmissão da dengue.

Dois estudos sinalizaram que para aumentar a capacidade de previsão de modelos é interessante incorporar dados de mobilidade urbana, comportamento humano e/ou atividades socioeconômicas, que afetam a transmissão da dengue (60,61)

Uma dificuldade listada por vários artigos foi a disponibilidade de dados contínuos e de longo prazo que possam ser usados para informar os esforços de modelagem e, ainda, as incertezas devido à potencial subnotificação ou má notificação de casos de dengue foram

questões pontuadas nos artigos podem trazer grandes limitações para o desempenho dos modelos (11,12,16,33,57,59–63).

Dos artigos analisados, os dados primários foram obtidos, em sua maioria, de fontes governamentais por meio de dados abertos à sociedade. Foi notório o emprego de dados climáticos e ambientais que são tratados e disponibilizados gratuitamente pela Nasa.

A capacidade em identificar os fatores relacionados à transmissão da dengue, associados a reprodução e ambientação vetorial foram objetos de diversos estudos com o intuito de conhecer para prevenir os surtos, no entanto, a diversidade imbricada nestes fatores, impede sua larga e vasta utilização.

Entende-se que entes governamentais de saúde pública, sobretudo à nível municipal e estadual, podem dispor de mais uma ferramenta para prever surtos/epidemias de dengue, como o objetivo de prever antecipadamente o risco, melhorar o planejamento das ações e ativação de processos que envolvem o controle da doença nos seus territórios.

No contexto da saúde pública projeções detalhadas e sistematizadas fornecem uma base de evidências que pode ser atualizada constantemente para priorizar recursos e orientar o planejamento de longo prazo (24).

Todos os estudos incluídos nesta revisão estavam aptos ou foram aplicados na saúde pública. Apontam que as modelagens preditivas desenvolvidas para os cenários de dengue são ferramentas confiáveis e com aplicabilidade real em contextos de saúde pública. Portanto são úteis para a gestão dos serviços de saúde.

É perceptível que as técnicas de modelagens preditivas mais robustas e sofisticadas exigem disponibilidade de recursos intelectuais (pessoal capacitado) e materiais (computadores e *softwares*). Isso esbarra em habilidades específicas, sobretudo na computação científica e custos financeiros elevados.

Observa-se que no Brasil é relativamente baixa a capacidade de implementar tecnologias computacionais mais robustas, sobretudo para municípios e estados nas áreas da vigilâncias no âmbito da saúde pública.

Um horizonte possível de ser implementado são parcerias com universidades e instituições de pesquisa detentoras desse conhecimento, com capacidade de oferecerem esses modelos de previsões, para subsidiar o aperfeiçoamento dos métodos e estratégias de controle dos serviços de saúde.

No governo federal já há iniciativas implementadas no SUS, voltadas para análises preditivas de cenários. À exemplo disso tem-se o sistema de informação em saúde silvestre (SISS-Geo), da Fiocruz - desenvolvido pela Plataforma Institucional Biodiversidade e Saúde Silvestre, com apoio do Laboratório Nacional de Computação Científica (LNCC)<sup>1</sup>.

Um sistema gratuito que apoia cidadãos, colaboradores, pesquisadores, especialistas, profissionais de saúde e gestores, nos monitoramento, investigação, prevenção e controle de zoonoses. Nele está disponível uma aplicação de geração de modelos de previsão de oportunidades ecológicas para emergência de zoonoses (64).

Outra iniciativa semelhante é o InfoGripe, um sistema de monitoramento de casos de síndrome respiratória aguda grave (SRAG), notificados no SIVEP-Gripe<sup>2</sup>. Desenvolvido em parceria entre a FioCruz e o Programa de Pós-Graduação em Ciência da Computação da Fundação Universidade Federal de Sergipe (PROCC), além da Escola de Matemática aplicada da Fundação Getúlio Vargas (FGV-EMAp).

O InfoDengue, um sistema de alerta para arboviroses, desenvolvido em parceria com a Fiocruz e FGV-EMAp, que utiliza dados híbridos gerados por meio da análise integrada de dados minerados a partir da web social e de dados climáticos e epidemiológicos.

---

<sup>1</sup> O LNCC é uma instituição brasileira de pesquisa científica e desenvolvimento tecnológico do Ministério da Ciência, Tecnologia e Inovação e Comunicações, especializada em computação científica.

<sup>2</sup> Sistema de Informação de Vigilância Epidemiológica da Gripe, gerido pelo Ministério da Saúde em conjunto com as secretarias estaduais e municipais de saúde.

Entretanto, não está disponível no InfoDengue a aplicação para geração de modelos de previsão. Algo que poderá ser implementado no futuro.

Os resultados obtidos nesta pesquisa poderão facilitar a construção de cenários de risco epidemiológicos para a ocorrência da dengue pelos gestores públicos em saúde.

Este estudo foi atualizado com dados até dezembro de 2021. Devido ao grande volume de dados vinculados nos artigos e parâmetros necessários para análise dos modelos, considerando a complexidade atribuída à dinâmica de transmissão da dengue, exigiu maior tempo para extração dos dados e análise dos resultados.

Isto talvez possa ser uma das limitações desta ScR que impacta na atualização, pois os dados estão defasados em cerca de 11 meses. Sendo que foi observado crescente número de publicações nos últimos 3 anos, porém o tempo necessário para análise dos estudos é desafiador. Um fator que deve ser considerado, inclusive, para futuras revisões sistemáticas envolvendo esse tema.

Outra limitação encontrada no processo foi que diante do número considerável de publicações (mais de 4 mil), disponíveis apenas nas 3 principais bases de dados, não foi possível incluir por exemplo literatura cinzenta, ou ainda, complementar a busca dos artigos por outras abordagens, como identificar material relevante adicional com os autores, ou também o escaneamento das listas de referências dos artigos incluídos.

A evolução nas técnicas utilizadas pelas ciências de dados nos últimos anos alavancou sobremaneira a sofisticação dos modelos na análise preditiva de cenários epidemiológicos. É provável que essa perspectiva cresça nos próximos anos. Acompanhar as técnicas de modelagens com revisões mais rápidas pode favorecer a implementação e adaptação mais ágeis dos modelos, favorecendo o uso por entes governamentais

## 6 CONCLUSÃO

A complexa dinâmica de transmissão da dengue oportuniza inúmeras formas de modelagens capazes de avaliar e prever o seu risco de transmissão. Neste contexto, esta ScR mapeou sistematicamente as evidências disponíveis na literatura científica nesta área.

Identificou-se de forma abrangente quais são as técnicas de modelagens (tipos e métodos) que estão sendo usadas e os parâmetros aplicados para prever cenários de dengue, descritos na literatura científica mundial.

O advento dos processos de modelagens que envolvem ML e mineração de dados está ganhando notoriedade. Inclusive com o uso de programas gratuitos como as linguagens R e Python. Vários estudos estão utilizando tipos de modelagens combinadas e é possível obter resultados satisfatórios utilizando apenas um tipo modelagem, como a estatística, aplicando por exemplo metodologia com LASSO ou GAM.

As variáveis listadas nos estudos revelam amplo escopo de possibilidades, que vão além das climáticas e entomológicas, tão largamente empregadas, com destaque para dados que retratam os contextos territoriais e de saúde, sendo imprescindível, por exemplo, identificar condições adicionais no território que garantem a proliferação do vetor, e monitorar a mobilidade humana.

Há uma tendência na utilização de 10 variáveis preditoras (em média) nos modelos, com destaque para as variáveis mais frequentes: 1. todos os casos confirmados de dengue (incidência), 2. densidade vetorial, 3. taxa de infecção Aedes, 4. precipitação, 7. temperatura, 8. Fator calendário semanal, 9. Acessos à eletricidade, água encanada e coleta seletiva de lixo, 10. estimativas/projeções populacionais.

Quanto ao nível de aplicação no território existe ampla oportunidade tanto para escalas espaciais mais detalhadas, como bairro e vila (menores tendências), quanto para

distritos, municípios ou cidades, estados ou províncias (maiores tendências), regiões e país. Ocorre que os modelos se ajustam melhor em áreas com maior densidade populacional. Um ponto a ser observado para o emprego adequado da modelagem de predição de cenários.

De uma forma geral a evidência descrita demonstra que existem diversas formas em realizar as modelagens preditivas de cenários para a dengue, entretanto indicam que não há padronização da aplicação. Portanto, analisar os desafios de implementação desses modelos no SUS, é uma lacuna do conhecimento, que poderá ser explorada em novas pesquisas.

No contexto brasileiro, seguramente, pela ótica econômica, seria vantajoso se houvesse um maior aporte de recursos para as ações de vigilância preventiva da dengue, direcionados para o incremento de novas tecnologias, como por exemplo aplicações com ML para predição de cenários.

Esta revisão de escopo elenca um catálogo de tipo diversos de modelos que pode trazer oportunidades para a implementação ou o aperfeiçoamento de análises preditivas nos serviços públicos de vigilância da dengue.

Experiências bem-sucedidas de parcerias entre o governo e instituições de pesquisas, que fazem modelagens preditivas e ajudam na gestão, como observado no InfoGripe e o SISS-Geo, demonstram uma possibilidade factível e assertiva a ser espelhada, com o intuito de oferecer aos serviços, de diferentes esferas de gestão, aplicações com modelagens preditivas para a dengue. Assim, os dados desta ScR podem subsidiar, para quem sabe, a construção e disponibilização de modelagem preditiva de cenários, pelo InfoDengue à sociedade.

Por todo o exposto, os resultados obtidos nesta pesquisa poderão favorecer a aplicabilidade da modelagem para a tomada de decisão oportuna em saúde, baseada em evidências, seja no âmbito do governo federal, estadual ou mesmo municipal.

## REFERÊNCIAS

1. Bhatt S, Gething PW, Brady OJ, Messina JP, Farlow AW, Moyes CL, et al. The global distribution and burden of dengue. *Nature*. abril de 2013;496(7446):504–7.
2. Guzman MG, Harris E. Dengue. *The Lancet*. janeiro de 2015;385(9966):453–65.
3. Salles TS, da Encarnação Sá-Guimarães T, de Alvarenga ESL, Guimarães-Ribeiro V, de Meneses MDF, de Castro-Salles PF, et al. History, epidemiology and diagnostics of dengue in the American and Brazilian contexts: a review. *Parasit Vectors*. 24 de abril de 2018;11(1):264.
4. Blitvich B. Arboviruses: Molecular Biology, Evolution and Control. Nikos Vasilakis and Duane J. Gubler. *Am J Trop Med Hyg*. agosto de 2016;95(2):488–9.
5. Valle D, Pimenta DN, Cunha RV da. orgs. Dengue: teorias e práticas [online]. Editora FIOCRUZ; 2015.
6. Dengue - OPAS/OMS | Organização Pan-Americana da Saúde [Internet]. [citado 30 de maio de 2022]. Disponível em: <https://www.paho.org/pt/topicos/dengue>
7. Tauil PL. Urbanization and dengue ecology. *Cad Saúde Pública Minist Saúde Fundação Oswaldo Cruz Esc Nac Saúde Pública*. 2001;17 Suppl:99–102.
8. Lowe R, Coelho CA, Barcellos C, Carvalho MS, Catão RDC, Coelho GE, et al. Evaluating probabilistic dengue risk forecasts from a prototype early warning system for Brazil. *eLife*. fevereiro de 2016;5:e11285.
9. Gubler DJ. Dengue and Dengue Hemorrhagic Fever. *Clin Microbiol Rev*. julho de 1998;11(3):480–96.
10. Xu Z, Bambrick H, Frentiu FD, Devine G, Yakob L, Williams G, et al. Projecting the future of dengue under climate change scenarios: Progress, uncertainties and research needs. Blacksell SD, organizador. *PLoS Negl Trop Dis*. 2 de março de 2020;14(3):e0008118.

11. Johansson MA, Apfeldorf KM, Dobson S, Devita J, Buczak AL, Baugher B, et al. An open challenge to advance probabilistic forecasting for dengue epidemics. *Proc Natl Acad Sci U S A*. 26 de novembro de 2019;116(48):24268–74.
12. Zhao N, Charland K, Carabali M, Nsoesie EO, Maheu-Giroux M, Rees E, et al. Machine learning and dengue forecasting: Comparing random forests and artificial neural networks for predicting dengue burden at national and sub-national scales in Colombia. *PLoS Negl Trop Dis*. setembro de 2020;14(9):e0008056.
13. Guo P, Liu T, Zhang Q, Wang L, Xiao J, Zhang Q, et al. Developing a dengue forecast model using machine learning: A case study in China. *PLoS Negl Trop Dis*. 16 de outubro de 2017;11(10):e0005973.
14. Petropoulos F, Apiletti D, Assimakopoulos V, Babai MZ, Barrow DK, Ben Taieb S, et al. Forecasting: theory and practice. *Int J Forecast*. 1º de julho de 2022;38(3):705–871.
15. Guo P, Liu T, Zhang Q, Wang L, Xiao J, Zhang Q, et al. Developing a dengue forecast model using machine learning: A case study in China. *PLoS Negl Trop Dis*. outubro de 2017;11(10).
16. Edussuriya C, Deegalla S, Gawarammana I. An accurate mathematical model predicting number of dengue cases in tropics. *PLoS Negl Trop Dis*. 8 de novembro de 2021;15(11):e0009756.
17. Kesorn K, Ongruk P, Chomposri J, Phumee A, Thavara U, Tawatsin A, et al. Morbidity Rate Prediction of Dengue Hemorrhagic Fever (DHF) Using the Support Vector Machine and the *Aedes aegypti* Infection Rate in Similar Climates and Geographical Areas. *PLoS ONE*. 11 de maio de 2015;10(5):e0125049.
18. Gough D, Davies P, Jamtvedt G, Langlois E, Littell J, Lotfi T, et al. Evidence Synthesis International (ESI): Position Statement. *Syst Rev*. 10 de julho de 2020;9(1):155.
19. Munn Z, Pollock D, Khalil H, Alexander L, McInerney P, Godfrey CM, et al. What are

scoping reviews? Providing a formal definition of scoping reviews as a type of evidence synthesis. *JBIEvid Synth.* abril de 2022;20(4):950–2.

20. Grant MJ, Booth A. A typology of reviews: an analysis of 14 review types and associated methodologies. *Health Inf Libr J.* junho de 2009;26(2):91–108.

21. Peters MDJ, Marnie C, Tricco AC, Pollock D, Munn Z, Alexander L, et al. Updated methodological guidance for the conduct of scoping reviews. *JBIEvid Synth.* outubro de 2020;18(10):2119–26.

22. Allicock OM, Sahadeo N, Lemey P, Auguste AJ, Suchard MA, Rambaut A, et al. Determinants of dengue virus dispersal in the Americas. *Virus Evol.* julho de 2020;6(2):veaa074.

23. Mustafa MS, Rasotgi V, Jain S, Gupta V. Discovery of fifth serotype of dengue virus (DENV-5): A new public health dilemma in dengue control. *Med J Armed Forces India.* janeiro de 2015;71(1):67–70.

24. Messina JP, Brady OJ, Golding N, Kraemer MUG, Wint GRW, Ray SE, et al. The current and future global distribution and population at risk of dengue. *Nat Microbiol.* 2019;4(9):1508–15.

25. Gubler DJ, Clark GG. Dengue/dengue hemorrhagic fever: the emergence of a global health problem. *Emerg Infect Dis.* 1995;1(2):55–7.

26. Boletim Epidemiológico Vol.53 Nº34 — Português (Brasil) [Internet]. [citado 15 de setembro de 2022]. Disponível em: <https://www.gov.br/saude/pt-br/centrais-de-conteudo/publicacoes/boletins/epidemiologicos/edicoes/2022/boletim-epidemiologico-vol-53-no34/view>

27. Harapan H, Ryan M, Yohan B, Abidin RS, Nainu F, Rakib A, et al. Covid-19 and dengue: Double punches for dengue-endemic countries in Asia. *Rev Med Virol* [Internet]. março de 2021 [citado 15 de setembro de 2022];31(2). Disponível em:

<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7536968/>

28. Lim JT, Dickens BSL, Chew LZ, Choo ELW, Koo JR, Aik J, et al. Impact of sars-cov-2 interventions on dengue transmission. *PLoS Negl Trop Dis.* outubro de 2020;14(10):e0008719.
29. Urban Health Repository [Internet]. [citado 15 de setembro de 2022]. Disponível em: <https://urbanhealth-repository.who.int>
30. Huang CH, Tsai YT, Wang SF, Wang WH, Chen YH. Dengue vaccine: an update. *Expert Rev Anti Infect Ther.* 2 de dezembro de 2021;19(12):1495–502.
31. Senior K. Dengue fever: what hope for control? *Lancet Infect Dis.* 2007;7(10):636.
32. Runge-Ranzinger S, Horstick O, Marx M, Kroeger A. What does dengue disease surveillance contribute to predicting and detecting outbreaks and describing trends? *Trop Med Int Health.* agosto de 2008;13(8):1022–41.
33. Sánchez-González G, Condé R, Noguez Moreno R, López Vázquez PC. Prediction of dengue outbreaks in Mexico based on entomological, meteorological and demographic data. *PLoS ONE.* 6 de agosto de 2018;13(8):e0196047.
34. Ashmore P, Lindahl JF, Colón-González FJ, Nam VS, Tan DQ, Medley GF. Spatiotemporal and Socioeconomic Risk Factors for Dengue at the Province Level in Vietnam, 2013-2015: Clustering Analysis and Regression Model. *Trop Med Infect Dis.* junho de 2020;5(2).
35. Teich V, Arinelli R, Fahham L. *Aedes aegypti* e sociedade: o impacto econômico das arboviroses no Brasil. *J Bras Econ Saúde.* dezembro de 2017;9(3):267–76.
36. Em 2016, PIB chega a R\$ 6,3 trilhões e cai 3,3% em volume | Agência de Notícias [Internet]. Agência de Notícias - IBGE. 2018 [citado 23 de outubro de 2022]. Disponível em: <https://agenciadenoticias.ibge.gov.br/agencia-sala-de-imprensa/2013-agencia-de-noticias/releases/22936-em-2016-pib-chega-a-r-6-3-trilhoes-e-cai-3-3-em-volume>

37. Tian N, Zheng JX, Guo ZY, Li LH, Xia S, Lv S, et al. Dengue Incidence Trends and Its Burden in Major Endemic Regions from 1990 to 2019. *Trop Med Infect Dis*. 12 de agosto de 2022;7(8):180.
38. Forecasting: Principles and Practice (3rd ed) [Internet]. [citado 18 de outubro de 2022]. Disponível em: <https://otexts.com/fpp3/>
39. Bacaër N. A Short History of Mathematical Population Dynamics [Internet]. London: Springer London; 2011 [citado 11 de junho de 2022]. Disponível em: <http://link.springer.com/10.1007/978-0-85729-115-8>
40. Reis MM. Análise de séries temporais. :55.
41. Liu K, Wang T, Yang Z, Huang X, Milinovich GJ, Lu Y, et al. Using Baidu Search Index to Predict Dengue Outbreak in China. *Sci Rep*. 1º de dezembro de 2016;6:38040.
42. Levin SA. Mathematics and Biology: the interface [Internet]. Cornell University; 1992. Disponível em: [https://digital.library.unt.edu/ark:/67531/metadc1187962/m2/1/high\\_res\\_d/7007108.pdf](https://digital.library.unt.edu/ark:/67531/metadc1187962/m2/1/high_res_d/7007108.pdf)
43. Agresti A, Coull BA. Approximate Is Better than “Exact” for Interval Estimation of Binomial Proportions. *Am Stat*. maio de 1998;52(2):119.
44. Minewiskan OD, Coulter D, Sherer T, Hu J. Data Mining Concepts [Internet]. Learn. Microsoft. All Analysis Services. [citado 25 de setembro de 2022]. Disponível em: <https://learn.microsoft.com/en-us/analysis-services/data-mining/data-mining-concepts>
45. Neumann G. Artificial Intelligence Programming. Em: Bidgoli H, organizador. Encyclopedia of Information Systems [Internet]. New York: Elsevier; 2003 [citado 23 de outubro de 2022]. p. 31–45. Disponível em: <https://www.sciencedirect.com/science/article/pii/B0122272404000034>
46. Hii YL, Rocklöv J, Wall S, Ng LC, Tang CS, Ng N. Optimal Lead Time for Dengue Forecast. *PLoS Negl Trop Dis*. outubro de 2012;6(10).

47. Attaway DF, Jacobsen KH, Falconer A, Manca G, Waters NM. Assessing the methods needed for improved dengue mapping: a SWOT analysis. *Pan Afr Med J.* 16 de abril de 2014;17:289.
48. Hossam, Zbys F, Mourad EAO, Hammady. Rayyan—a web and mobile app for systematic reviews. *Syst Rev.* 2016;5(1):210.
49. Thomson. JCR Reports (2020). Thomson Reuters. [citado 26 de março de 2022]; Disponível em: <https://jcr-clarivate.ez68.periodicos.capes.gov.br/jcr/search-results>
50. Yu L, Yu H. Does the average JIF percentile make a difference? *Scientometrics.* dezembro de 2016;109(3):1979–87.
51. Aromataris E, Munn Z, organizadores. JBI Manual for Evidence Synthesis [Internet]. JBI; 2020 [citado 20 de setembro de 2022]. Disponível em: <https://wiki.jbi.global/display/MANUAL>
52. Tricco AC, Lillie E, Zarin W, O'Brien KK, Colquhoun H, Levac D, et al. PRISMA Extension for Scoping Reviews (PRISMA-ScR): Checklist and Explanation. *Ann Intern Med.* 2 de outubro de 2018;169(7):467–73.
53. Page MJ, McKenzie JE, Boutron I, Hoffmann TC, Mulrow CD, al et. The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. *BMJ.* 2021;71:undefined-372.
54. Salami D, Sousa CA, Martins M do RO, Capinha C. Predicting dengue importation into Europe, using machine learning and model-agnostic methods. *Sci Rep.* 16 de junho de 2020;10:9689.
55. Siriyasatien P, Phumee A, Ongruk P, Jampachaisri K, Kesorn K. Analysis of significant factors for dengue fever incidence prediction. *BMC Bioinformatics.* 16 de abril de 2016;17:166.
56. Bett B, Grace D, Lee HS, Lindahl J, Nguyen-Viet H, Phuc PD, et al. Spatiotemporal analysis of historical records (2001–2012) on dengue fever in Vietnam and development of a

statistical model for forecasting risk. Wen TH, organizador. PLOS ONE. 27 de novembro de 2019;14(11):e0224353.

57. Chan TC, Hu TH, Hwang JS. Daily forecast of dengue fever incidents for urban villages in a city. *Int J Health Geogr.* dezembro de 2015;14(1):9.

58. Chen Y, Ong JHY, Rajarethinam J, Yap G, Ng LC, Cook AR. Neighbourhood level real-time forecasting of dengue cases in tropical urban Singapore. *BMC Med.* 6 de agosto de 2018;16:129.

59. Colón-González FJ, Soares Bastos L, Hofmann B, Hopkin A, Harpham Q, Crocker T, et al. Probabilistic seasonal dengue forecasting in Vietnam: A modelling study using superensembles. *PLoS Med.* março de 2021;18(3):e1003542.

60. Erandi K, Perera S, Mahasinghe A. Analysis and forecast of dengue incidence in urban Colombo, Sri Lanka. *Theor Biol Med Model.* 7 de janeiro de 2021;18:3.

61. Liebig J, de Hoog F, Paini D, Jurdak R. Forecasting the probability of local dengue outbreaks in Queensland, Australia. *Epidemics.* março de 2021;34:100422.

62. Marques-Toledo CA, Bendati MM, Codeço CT, Teixeira MM. Probability of dengue transmission and propagation in a non-endemic temperate area: conceptual model and decision risk levels for early alert, prevention and control. *Parasit Vectors.* 16 de janeiro de 2019;12:38.

63. Buczak AL, Baugher B, Babin SM, Ramac-Thomas LC, Guven E, Elbert Y, et al. Prediction of High Incidence of Dengue in the Philippines. *PLoS Negl Trop Dis.* 10 de abril de 2014;8(4):e2771.

64. Caderno-de-Textos-Vigilancia-em-Saude-nos-municipios-1-3-1.pdf [Internet]. [citado 1º de outubro de 2022]. Disponível em: <https://www.conasems.org.br/wp-content/uploads/2020/11/Caderno-de-Textos-Vigilancia-em-Saude-nos-municipios-1-3-1.pdf>

65. Salim NAM, Wah YB, Reeves C, Smith M, Yaacob WFW, Mudin RN, et al. Prediction of dengue outbreak in Selangor Malaysia using machine learning techniques. *Sci Rep.* 13 de

janeiro de 2021;11:939.

66. Jain R, Sontisirikit S, Iamsirithaworn S, Prendinger H. Prediction of dengue outbreaks based on disease surveillance, meteorological and socio-economic data. *BMC Infect Dis.* dezembro de 2019;19(1):272.
67. Withanage GP, Viswakula SD, Nilmini Silva Gunawardena YI, Hapugoda MD. A forecasting model for dengue incidence in the District of Gampaha, Sri Lanka. *Parasit Vectors.* 24 de abril de 2018;11(1):262.
68. Lauer SA, Sakrejda K, Ray EL, Keegan LT, Bi Q, Suangtho P, et al. Prospective forecasts of annual dengue hemorrhagic fever incidence in Thailand, 2010–2014. *Proc Natl Acad Sci U S A.* 6 de março de 2018;115(10):E2175–82.
69. Lowe R, Coelho CA, Barcellos C, Carvalho MS, Catão RDC, Coelho GE, et al. Evaluating probabilistic dengue risk forecasts from a prototype early warning system for Brazil. *eLife.* 5:e11285.
70. Shi Y, Liu X, Kok SY, Rajarethinam J, Liang S, Yap G, et al. Three-Month Real-Time Dengue Forecast Models: An Early Warning System for Outbreak Alerts and Policy Decision Support in Singapore. *Environ Health Perspect.* setembro de 2016;124(9):1369–75.
71. Buczak AL, Koshute PT, Babin SM, Feighner BH, Lewis SH. A data-driven epidemiological prediction method for dengue outbreaks using local and remote sensing data. *BMC Med Inform Decis Mak.* 5 de novembro de 2012;12:124.
72. Halide H, Ridd P. A predictive model for Dengue Hemorrhagic Fever epidemics. *Int J Environ Health Res.* agosto de 2008;18(4):253–65.

## APENDICE A – ESTRATÉGIAS APLICADAS NAS BASES DE DADOS

A partir do construtor de pesquisa avançada PubMed foi elaborada a estratégia de busca principal dos artigos.

Na caixa de consulta foram informados os blocos de termos específicos, obtidos previamente no vocabulário controlado do Mesh. Aplicou-se o filtro para seleção apenas de resultados publicados no formato de artigos e exclusivamente do Pubmed. Utilizou-se o operador booleano “AND”, para fazer a junção dos blocos de termos.

Para o portal BVS utilizou-se as estratégias de linguagem da ferramenta para a tradução dos vocabulários, nas quatro línguas (português, inglês, espanhol francês).

Foram aplicados os filtros para seleção apenas de resultados publicados no formato de artigos e para não trazer os resultados do Medline e PubMed, com o intuito de não sobrepor resultados. Isso aumentaria as ocorrências de artigos duplicados. A busca diretamente nas bases do Medline e PubMed oferecem maior completude dos dados.

Por fim, a estratégia de busca na base de dados do EMBASE via Elsevier, foi executada com o acesso pelo portal da CAPES.

Foi realizada a busca avançada utilizando os termos principais e sinônimos do *Emtree*<sup>1</sup>. Aplicou-se os filtros para seleção apenas de resultados publicados no formato de artigos e resultados exclusivamente do EMBASE.

Estratégias de buscas aplicada aos PubMed, portal BVS e EMBASE, estão apresentadas a seguir.

---

<sup>1</sup> Ferramenta de indexação profunda do conteúdo do Embase. Constitui a representação poli hierárquica do conhecimento biomédico destinado a indexação do texto completo de artigos de periódicos no Embase.

Bases de dados	Estratégias de busca dos artigos e resultados
PubMed	<p>(((((((“Models, Theoretical”[Mesh] OR (Model, Theoretical) OR (Theoretical Model) OR (Theoretical Models) OR (Models, Theoretic) OR (Models (Theoretical)) OR (Model (Theoretical)) OR (Experimental Model) OR (Model, Experimental) OR (Models, Experimental) OR (Experimental Models) OR (Mathematical Model) OR (Mathematical Models) OR (Model, Mathematical) OR (Models, Mathematical) OR (Theoretical Study) OR (Studies, Theoretical) OR (Study, Theoretical) OR (Theoretical Studies)) OR (“Models, Statistical”[Mesh] OR (Statistical Model) OR (Probabilistic Models) OR (Model, Probabilistic) OR (Models, Probabilistic) OR (Probabilistic Model) OR (Model, Statistical) OR (Statistical Models) OR (Models, Polynomial) OR (Model, Polynomial) OR (Polynomial Model) OR (Polynomial Models) OR (Two-Parameter Models) OR (Model, Two-Parameter) OR (Models, Two-Parameter) OR (Two Parameter Models) OR (Two-Parameter Model) OR (Models, Binomial) OR (Binomial Model) OR (Binomial Models) OR (Model, Binomial))) OR (“Artificial Intelligence”[Mesh] OR (Intelligence, Artificial) OR (Computational Intelligence) OR (Intelligence, Computational) OR (Machine Intelligence) OR (Intelligence, Machine) OR (Computer Reasoning) OR (Reasoning, Computer) OR (AI (Artificial Intelligence)) OR (Computer Vision Systems) OR (Computer Vision System) OR (System, Computer Vision) OR (Systems, Computer Vision) OR (Vision System, Computer) OR (Vision Systems, Computer) OR (Knowledge Acquisition (Computer)) OR (Acquisition, Knowledge (Computer)) OR (Knowledge Representation (Computer)) OR (Knowledge Representations (Computer)) OR (Representation, Knowledge (Computer)))) OR (“Machine Learning”[Mesh] OR (Learning, Machine) OR (Transfer Learning) OR (Learning, Transfer))) OR (“Deep Learning”[Mesh] OR (Learning, Deep) OR (Hierarchical Learning) OR (Learning, Hierarchical))) OR (“Neural Networks, Computer”[Mesh] OR (Computer Neural Network) OR (Computer Neural Networks) OR (Network, Computer Neural) OR (Networks, Computer Neural) OR (Neural Network, Computer) OR (Models, Neural Network) OR (Model, Neural Network) OR (Network Model, Neural) OR (Network Models, Neural) OR (Neural Network Model) OR (Neural Network Models) OR (Computational Neural Networks) OR (Computational Neural Network) OR (Network, Computational Neural) OR (Networks, Computational Neural) OR (Neural Network, Computational) OR (Neural Networks, Computational) OR (Perceptrons) OR (Perceptron) OR (Connectionist Models) OR (Connectionist Model) OR (Model, Connectionist) OR (Models, Connectionist) OR (Neural Networks (Computer)) OR (Network, Neural (Computer)) OR (Networks, Neural (Computer)) OR (Neural Network (Computer)))) OR (“Forecasting”[Mesh] OR (Projections and Predictions) OR (Predictions and Projections) OR (Future OR Futurology))) AND (“Dengue”[Mesh] OR (Breakbone Fever) OR (Fever, Breakbone) OR (Classical Dengue Fever) OR (Classical Dengue Fevers) OR (Dengue Fever, Classical) OR (Break-Bone Fever) OR (Break Bone Fever) OR (Fever, Break-Bone) OR (Dengue Fever) OR (Fever, Dengue) OR (Classical Dengue) OR (Classical Dengues) OR (Dengue, Classical) OR (Breakbone Fever) OR (Fever, Breakbone) OR (Classical Dengue</p>

	<p>Fever) OR (Classical Dengue Fevers) OR (Dengue Fever, Classical) OR (Break-Bone Fever) OR (Break Bone Fever) OR (Fever, Break-Bone) OR (Dengue Fever) OR (Fever, Dengue) OR (Classical Dengue) OR (Classical Dengues) OR (Dengue, Classical))</p> <p>Data: 29/12/2021</p> <p>Resultados: 4.482 somente do PubMed (2 retratados = 4.480)</p> <p>Trouxe artigos publicados a partir do ano 1968 a 2021.</p>
<p><b>Portal BVS</b></p>	<p>(mh:"Modelos Teóricos" OR (modelos teóricos) OR (models, theoretical) OR (modelos teóricos) OR (modèles théoriques) OR (modelo ecológico) OR mh:e05.599* OR mh:sp4.122.408.599* OR mh:sp8.473.654.692.792.707*) OR (mh:" Modelos Estatísticos" OR (models, statistical) OR (modelos estadísticos) OR (modèles statistiques) OR (modelos probabilísticos) OR (modelos com dois parâmetros) OR mh:e05.318.740.500* OR mh:e05.599.835* OR mh:n05.715.360.750.530* OR mh:n06.850.520.830.500*) OR (mh:"Inteligência Artificial" OR (inteligência artificial) OR (artificial intelligence) OR (inteligencia artificial) OR (intelligence artificielle) OR (aquisição de conhecimento (computador)) OR (aquisição de conhecimentos (informática)) OR (ia (inteligência artificial)) OR (inteligência de máquina) OR (raciocínio automático) OR (raciocínio computacional) OR (representação de conhecimento (computador)) OR (representação do conhecimento (computador)) OR (sistemas de visão artificial) OR (sistemas de visão computacional) mh:g17.035.250* OR mh:l01.224.050.375*) OR (mh:"Aprendizado de Máquina" OR (aprendizado de máquina) OR (machine learning) OR (aprendizaje automático) OR (apprentissage machine)or (aprendizado automático) OR (aprendizado de transferência) OR (aprendizagem automática) OR (aprendizagem de máquina) OR (aprendizagem de transferência) OR mh: g17.035.250.500* OR mh:l01.224.050.375.530*) OR (mh:"Aprendizado Profundo" OR (aprendizado profundo) OR (deep learning) OR (aprendizaje profundo) OR (apprentissage profond) OR (aprendizado estruturado profundo) OR (aprendizado hierárquico) OR mh:g17.035.250.500.250* mh:g17.485.500* OR mh:l01.224.050.375.530.250* OR mh:l01.224.050.375.605.500*) OR (mh:"Redes Neurais de Computação" OR (redes neurais de computação) OR (neural networks, computer) OR (redes neurales de la computación) OR (modelos conexionistas) OR (modelos de rede neural) OR (modelos de redes neurais) OR (perceptrons) OR (redes neurais (computação)) OR (redes neurais computacionais) OR (redes neurais de computador) OR (redes neurais em computação) OR (redes neurais, computador) OR (redes neuronais em informática) OR mh:g17.485* OR mh:l01.224.050.375.605*) OR (mh:previsões OR (previsões) OR (forecasting) OR (predicción) OR (prévision) OR (futurologia) OR (modelos de predição) OR (predição) OR (previsão de terremotos) OR (projeções e predições) OR mh: i01.320* mh:sp4.127.413.669* mh:sp8.946.819.874*) AND (mh:dengue OR (dengue) OR (dengue) OR (dengue) OR (dengue) OR (febre quebra-ossos) OR (febre da dengue) OR (infecção pelo vírus da dengue) OR (infecção por vírus da dengue) OR (infecção por vírus de dengue) OR mh:c01.920.500.270*</p>

	<p>OR mh:c01.925.081.270* OR mh:c01.925.782.350.250.214* OR mh:c01.925.782.417.214* OR mh:sp4.012.148.144*)</p> <p>Data: 21/12/2021</p> <p>Resultados: 6 artigos publicados no Lilacs</p>
<b>EMBASE</b>	<p>('theoretical model'/exp OR (model, AND theoretical) OR (models, AND theoretical) OR (theoretical AND models) OR 'statistical model'/exp OR (likelihood AND functions) OR (linear AND model) OR (linear AND models) OR (logistic AND models) OR (models, AND statistical) OR (statistic AND model) OR (statistical AND models) OR (statistics AND model) OR 'artificial intelligence'/exp OR (machine AND intelligence) OR 'machine learning'/exp OR (learning AND machine) OR (learning AND machines) OR 'deep learning'/exp OR (hierarchical AND learning) OR 'artificial neural network'/exp OR (algorithmic AND neural AND network) OR (ann AND artificial AND neural AND network) OR (ann AND analysis) OR (ann AND approach) OR (ann AND method) OR (ann AND methodology) OR (ann AND methods) OR (ann AND model) OR (ann AND modeling) OR (ann AND modelling) OR (ann AND models) OR (ann AND output) OR (ann AND technique) OR (ann AND techniques) OR (ann AND training) OR (anns AND artificial AND neural AND networks) OR (artificial AND neural AND networks) OR (artificial AND nn) OR (artificial AND nns) OR (computational AND neural AND network) OR (computer AND neural AND network) OR (computer AND neural AND networks) OR (computerized AND neural AND network) OR (connectionist AND model) OR (connectionist AND network) OR (connectionist AND neural AND network) OR (connectionist AND system) OR (mathematical AND neural AND network) OR (neural AND network AND artificial) OR (neural AND network AND computer) OR (neural AND network AND algorithm) OR (neural AND network AND model) OR (neural AND networks AND computer) OR (neural AND networks, AND computer) OR 'forecasting'/exp OR divination) AND ('dengue'/exp OR (aden AND fever) OR (bouquet AND fever) OR ('break bone' AND fever) OR (breakbone AND fever) OR (classical AND dengue) OR (classical AND dengue AND fever) OR (dandy AND fever) OR (dengue AND fever) OR (dengue AND virus AND infection) OR (solar AND fever) OR (sun AND fever))</p> <p>Data: 29/12/2021</p> <p>Resultados: 280 artigos publicados exclusivamente no EMBASE (2 retratados = 278)</p>

Fonte: elaborado pelo autor

## APÊNDICE B – GUIA DE REDAÇÃO PRISMA

SEÇÃO	ITEM	PRISMA-ScR LISTA DE VERIFICAÇÃO	REPORTADO
<b>TÍTULO</b>			
Título	1	Identifique o relatório como uma revisão de escopo.	CAPA
<b>RESUMO</b>			
Resumo estruturado	2	Fornecer um resumo estruturado que inclua (se aplicável): antecedentes, objetivos, critérios de elegibilidade, fontes de evidências, métodos gráficos, resultados e conclusões relacionadas com as questões e objetivos da revisão.	Pag. 7
<b>INTRODUÇÃO</b>			
Justificativa	3	Descreva a justificativa para a revisão no contexto do que já é conhecido. Explique por que as perguntas ou objetivos da revisão se prestam a uma abordagem de revisão de escopo.	Pag. 20-22
Objetivos	4	Forneça uma declaração explícita das perguntas e objetivos que estão sendo abordados com referência aos seus elementos-chave (por exemplo, população ou participantes, conceitos e contexto) ou outros elementos-chave relevantes usados para conceituar as perguntas ou objetivos da revisão.	Pag. 22
<b>MÉTODOS</b>			
Protocolo e registro	5	Indique se existe um protocolo de revisão; informe se e onde pode ser acessado (por exemplo, um endereço da Web); e, se disponível, fornecer informações de registro, incluindo o número de registro.	Pag. 37
Fontes de Informação	7	Descreva todas as fontes de informação na busca (por exemplo, bases de dados com datas de cobertura e contato com autores para identificar fontes adicionais), bem como a data em que a busca mais recente foi realizada.	Pag. 38-39 e Apêndice A
Critérios de elegibilidade	6	Especifique as características das fontes de evidência usadas como critérios de elegibilidade (por exemplo, anos considerados, idioma e status de publicação) e forneça uma justificativa.	Pag. 40-41
Pesquisa	8	Apresente a estratégia de busca eletrônica completa para pelo menos 1 banco de dados, incluindo quaisquer limites utilizados, de forma que possa ser repetido.	Pag. 89-92 Apêndice A
Seleção de fontes de evidências	9	Indique o processo de seleção de fontes de evidência (ou seja, triagem e elegibilidade) incluídas na revisão de escopo.	Pag. 39 - 41
Processo de criação de gráficos de dados	10	Descrever os métodos de gráficos de dados das fontes de evidência incluídas (por exemplo, formulários calibrados ou formulários que foram testados pela equipe antes de seu uso e se o gráfico de dados foi feito de forma independente ou duplicada) e quaisquer processos para obter e confirmar dados dos investigadores.	Pag. 37-43

<b>SEÇÃO</b>	<b>ITEM</b>	<b>PRISMA-ScR LISTA DE VERIFICAÇÃO</b>	<b>REPORTADO</b>
Itens de dados	11	Liste e defina todas as variáveis para as quais os dados foram buscados e quaisquer suposições e simplificações feitas.	Pag. 42 Quadro 1
Avaliação Crítica de fontes Individuais de Evidência (opcional)	12	Se feito, forneça uma justificativa para a realização de uma avaliação crítica das fontes de evidência incluídas; descrever os métodos usados e como essas informações foram usadas em qualquer síntese de dados (se apropriado).	Não realizado
Síntese de Resultados	13	Descrever os métodos de manipulação e resumir os dados que foram mapeados	Pag. 43-44
<b>RESULTADOS</b>			
Seleção de Fontes de Evidência	14	Forneça o número de fontes de evidência selecionadas, avaliadas quanto à elegibilidade e incluídas na revisão, com os motivos das exclusões em cada estágio, de preferência usando um diagrama de fluxo.	Pag. 43-44
Características das Fontes de Evidência	15	Para cada fonte de evidência, apresente as características para as quais os dados foram mapeados e forneça as citações.	Tabelas 1, 2 e 3
Avaliação Crítica dentro das Fontes de Evidência (opcional)	16	Se feito, apresente dados sobre a avaliação crítica das fontes de evidência incluídas (ver item 12)	Não realizado
Resultados de Fontes Individuais de evidência	17	Para cada fonte de evidência incluída, apresente os dados relevantes que foram mapeados relacionados às questões e objetivos da revisão.	Tabelas 1, 2 e 3
Síntese de Resultados	18	Resuma ou apresente os resultados do gráfico à medida que se relacionam com as perguntas e os objetivos da revisão.	Pag. 45 - 71
<b>DISCUSSÃO</b>			
Resumo das evidências	19	Resuma os principais resultados (incluindo uma visão geral dos conceitos, temas e tipos de evidências disponíveis), faça um link para as perguntas e objetivos da revisão e considere a relevância para os grupos-chave.	72-78
Limitações	20	Discuta as limitações do processo de revisão de escopo.	78
Conclusões	21	Fornecer uma interpretação geral dos resultados em relação às questões e objetivos da revisão, bem como possíveis implicações ou próximos passos.	79 - 80
<b>FINANCIAMENTO</b>			
Financiamento	22	Descreva as fontes de financiamento para as fontes de evidência incluídas, bem como as fontes de financiamento para a revisão de escopo. Descreva o papel dos financiadores da revisão de escopo.	Tabela 1 – evidências incluídas e Pag. 44, 54, 118-122

Fonte: Preferred Reporting Items for Systematic reviews and Meta-Analyses extension for Scoping Reviews (PRISMA-ScR) Checklist (52) – Tabela traduzida para o português.

## APÊNDICE C – PALAVRAS-CHAVE E ÁREAS TEMÁTICAS

Seq.	Palavras-chave	Freq	%	Áreas temáticas	Freq.	%
1	DENGUE	8	12,70	DENGUE FEVER	7	10,61
2	PREDICTION MODEL	2	3,17	EPIDEMIOLOGY	6	9,09
3	EARLY WARNING SYSTEM	2	3,17	FORECASTING	6	9,09
4	INFECTIOUS DISEASE	2	3,17	MOSQUITOES	4	6,06
5	STATISTIC	1	1,59	RAIN	4	6,06
6	SPATIO-TEMPORAL PREDICTION	1	1,59	MACHINE LEARNING	3	4,55
7	IR MODEL	1	1,59	PUBLIC AND OCCUPATIONAL HEALT	3	4,55
8	LASSO	1	1,59	HUMIDITY	3	4,55
9	LOGISTIC REGRESSION	1	1,59	VIETNAM	2	3,03
10	MICROBIOLOGY	1	1,59	DENGUE VIRUS	2	3,03
11	MODEL	1	1,59	POPULATION DENSITY	1	1,52
12	MULTIVARIATE POISSON REGRESSIOI	1	1,59	NEURONS	1	1,52
13	NON-ENDEMIC	1	1,59	OPTIMIZATION	1	1,52
14	NONE	1	1,59	PHILIPPINES	1	1,52
15	PERU	1	1,59	ARTIFICIAL NEURAL NETWORKS	1	1,52
16	PREDICTION	1	1,59	MEXICO	1	1,52
17	TIME SERIES REGRESSION	1	1,59	PUBLIC HEALTH	1	1,52
18	HUMAN MOBILITY	1	1,59	SEASONS	1	1,52
19	PREDICTION SKILL	1	1,59	SRI LANKA	1	1,52
20	PREDICTOR VARIABLES	1	1,59	SUPPORT VECTOR MACHINES	1	1,52
21	PROBABILISTIC	1	1,59	MORBIDITY	1	1,52
22	PUERTO RICO	1	1,59	LINEAR REGRESSION ANALYSIS	1	1,52
23	RISK FACTORS	1	1,59	MEDICAL RISK FACTORS	1	1,52
24	RISK MODEL	1	1,59	CHINA	1	1,52
25	SEASONAL PATTERN	1	1,59	LARVAE	1	1,52
26	STATISTICAL MODEL	1	1,59	KERNEL FUNCTIONS EPIDEMIOLOGY	1	1,52
27	ASSOCIATION RULE MINING	1	1,59	INTERNET ALGORITHMS	1	1,52
28	GLOBAL HEALTH	1	1,59	INFECTIOUS DISEASES	1	1,52
29	CLIMATE	1	1,59	GEOGRAPHIC INFORMATION SYSTEM	1	1,52
30	DISTRICT OF GAMPAHA	1	1,59	EGGS	1	1,52
31	CLIMATE FACTOR ANALYSIS	1	1,59	DENGUE	1	1,52
32	CONTROL AND PREVENTION	1	1,59	DECISION MAKING	1	1,52
33	DATA-DRIVEN EPIDEMIOLOGY	1	1,59	DEATH RATES	1	1,52
34	DECISION SUPPORT	1	1,59	DATA MINING	1	1,52
35	DENGUE FEVER	1	1,59	COLOMBIA	1	1,52
36	DENGUE FORECAST	1	1,59	WOLVES	1	1,5
37	DENGUE FORECASTING	1	1,59			
38	DENGUE HEMORRHAGIC FEVER	1	1,59			
39	DHF EPIDEMICS	1	1,59			
40	DISEASE SURVEILLANCE	1	1,59			
41	DYNAMIC THRESHOLD	1	1,59			
42	GENERALIZED ADDITIVE MODELS (G/	1	1,59			
43	ECOLOGY	1	1,59			
44	EPIDEMIC	1	1,59			
45	EPIDEMIOLOGY	1	1,59			
46	EVALUATION	1	1,59			
47	FORECAST	1	1,59			
48	FORECASTING	1	1,59			
49	FORECASTING DISEASE SPREAD	1	1,59			
50	FORECASTING MODEL	1	1,59			
51	FOURIER ANALYSIS	1	1,59			
52	FUZZY LOGIC	1	1,59			
53	TRANSMISSION	1	1,59			
<b>Totais</b>		<b>63</b>	<b>100</b>		<b>66</b>	<b>100</b>

Fonte: elaborado pelo autor

## APENDICE D - RECORTE DAS TÉCNICAS DE MODELAGENS, NÚMERO DE VARIÁVEIS E FATORES ASSOCIADOS À PREDIÇÃO

**Tabela 2** Mapeamento das técnicas de modelagens e parâmetros intimamente associados nos modelo.

Seq.	Primeiro autor / ano	MODELAGENS		Programas - pacotes e/ou bibliotecas	N° variáveis preditoras	Escala espacial dados	Unidade temporal previsão	Período de previsão antecipada	Período de experimento
		Tipos	Métodos						
1	Chathurangi Edussuriya / 2021	2 3 4	LSTM	Python - keras API	5	4	mensal	1 mês	8 anos e 4 meses
2	K.K.W.H. Erandi / 2021	2	Modelo compartimental baseado em dados bidimensionais	Matlab	4	4	semanal	até 4 semanas	7 anos
3	Jessica Liebig / 2021	2	Probabilidades - regressão multipla, Poisson binomial	nd	10	5	semanal	1 semana	12 anos
4	Nurul Azam Mohd Salim / 2021	3 4	CART MLP SVM- kernel linear SVM - kernel polinomial SVM - kernel de base radial Rede Bayes (TAN)	SPSS	10	4	semanal	semanas do ano	5 anos
5	Felipe J. Colón-González / 2021	3	GLMM	R - INLA	9	6	mensal	até 3 meses	21 anos
6	Naizhuo Zhao / 2020	3 4	RF NN	R - ML - keras e forecast	7	5	semanal	até 12 semanas	5 anos
7	Donald Salami / 2020	3	PSL GLMNET RF	R - ML - caret e outros	13*	8 9	mensal	nd**	6 anos

Seq.	Primeiro autor / ano	MODELAGENS		Programas - pacotes e/ou bibliotecas	N° variáveis preditoras	Escala espacial dados	Unidade temporal previsão	Período de previsão antecipada	Período de experimento
		Tipos	Métodos						
8	Michael A. Johansson / 2019	3	Desafio aberto - variedade de métodos: A. SEIRS B. Suavização exponencial de Hot-Winters; análogos multidimensionais C. SIR-Kalman filter D. Algoritmo de agrupamento de centroides de espectro K E. GLM-NB e Processo Gaussiano F. GLM G. SIR H. SARIMA I. SEIR J. Modelo empírico Bayes; Modelo de pinned spline K. MRL L. NN-SIRS; NN-TSM; B-TSM M. Autocorrelação aditiva não paramétrica; SARIMA N. Mínimos quadrados ordinários O. Reconstrução não-paramétrica do espaço de estado de Kernel-densidade P. Regressão de série temporal Bayesiana	Stan - rstanarm	11	5	semanal anual	anual ***	9 anos
9	Raghvendra Jain / 2019	3	GAM	R - DLNM	7	4	mensal	1 - 4 meses	8 anos
10	Cecilia A. Marques-Toledo / 2019	3	LRM Modelo de decisão para classificação de risco (curva ROC)	R e bibliotecas	10	3	semanal	até 4 semanas	6 anos
11	Bernard Bett / 2019	1	INLA BYM AR CAR	R - INLA, RINLA	15	6	anual mensal	nd	12 anos

Seq.	Primeiro autor / ano	MODELAGENS		Programas - pacotes e/ou bibliotecas	Nº variáveis preditoras	Escala espacial dados	Unidade temporal previsão	Período de previsão antecipada	Período de experimento
		Tipos	Métodos						
12	Gayana P. Withanage / 2018	3	Modelos de regressão de séries temporais múltiplas	R - linear model	8	4	mensal	1 mês	5 anos e 4 meses
13	Yirong Chen / 2018	1	LASSO	R e bibliotecas	9	1	mensal	até 3 meses	7 anos
14	Gilberto Sánchez-González / 2018	2	Sistema de equações diferenciais ordinárias	Wolfram Mathematica 8	23	3	tempo real	tempo real	9 anos
15	Stephen A. Lauer / 2018	1	GAM	R e bibliotecas	7	6	anual mensal	pré-temporada (3 meses)	15 anos
16	Pi Guo / 2017	3	SVM LRM descendente GBM NBM LASSO GAM	Phyton	6	3 6	semanal mensal	1 semana 1 mês	4 anos
17	Padet Siriyasatien / 2016	1	MPR	Quantity One Quantification Analysis	10	6 8	anual mensal	pré-temporada sazonal (4 meses)	6 anos
18	Rachel Lowe / 2016	1	Modelo espaço-temporal bayesiano - previsões probabilísticas	nd	8	7	mensal	até 3 meses	1 mês
19	Yuan Shi / 2016	1 3	BFAST LASSO SARIMA	R	10	5	semanal	12 semanas	13 anos
20	Ta-Chien Chan / 2015	1	Regressão logística	R	4	2	dias	até 30 dias	4 anos

Seq.	Primeiro autor / ano	MODELAGENS		Programas - pacotes e/ou bibliotecas	N° variáveis preditoras	Escala espacial dados	Unidade temporal previsão	Período de previsão antecipada	Período de experimento
		Tipos	Métodos						
21	Kraisak Kesorn / 2015	3	KNN	Weka	9	6	anual	pré-temporada sazonal (4 meses)	7 anos
		4	DT						
		5	NN						
		5	SVM- kernel linear SVM - kernel polinomial SVM - kernel de base radial						
22	Anna L. Buczak / 2014	3	FARM	SAS	14	6	semanal	4 semanas	8 anos e 8 meses
		5							
23	Anna L. Buczak / 2012	3	FARM + 3 Modelos de predição com regras de associação difusa	Matlab	13	4	semanal	3 - 7 semanas	9 anos
		5							
24	Halmar Halide / 2008	1	GLM	SPSS	7	3	mensal	até 6 meses	8 anos

Fonte: elaborado pelo autor

Legenda:

\*\* não disponível - prevê a probabilidade de ter um caso importado de dengue na Europa / \*\*\*anual (pico de incidência, semana do pico e incidência total)

**Tipo de modelagens:** 1. Estatística, 2. Matemática, 3. Aprendizado de máquina ou Machine learning, 4. Redes Neurais Artificiais, 5. Mineração de dados

**Programas:** ML "Machine learning" / Python "Python Programming Language" / R "The R project - free software environment for statistical computing and graphics" / SAS "Statistical Analysis Software" / SSPSS "BM® SPSS Statistics"/ Weka "WEKA data mining software"

**Escala espacial dos dados:** 1. Bairro, 2. Vila, 3. Município ou cidade, 4. Distrito, 5. Estado ou departamento, 6. Província, 7. Microrregiões, 8. Região, 9. País/Nacional

Tabela 2 - Legenda - continuação:

**Métodos de Modelagens:** AR "Autoregressive model" - Modelo autorregressivo / ARIMA "Autoregressive integrated moving average model" - Modelo autorregressivo integrado de médias móveis / B-TSM "Bayesian time series model"- modelo de séries temporais Bayesiano/ BFAST "Breaks For Additive Seasonal Trend" - Quebras para o algoritmo aditivo de sazonalidade e tendência / BYM "Besag-York-Mollie model" - Modelo Besag-York-Mollie / CAR "Conditional autoregressive model" - Modelo auto-regressivo condicional / CART "Classification and Regression Trees" - Árvores de decisão, classificação e regressão / DLNM "Distributed lag non-linear models"- Modelos não lineares de atraso distribuído / FARM "Fuzzy Association Rule Mining" - Associação Fuzzy Regra de Mineração / GAM "Generalized additive model"- Modelo aditivo generalizado / GBM "Gradient boosted regression tree algorithm"- Algoritmo de árvore de regressão impulsionada por gradiente / GLM "Generalized linear bayesian models"- Modelos lineares generalizados bayesianos / GLM-NB "Generalized linear bayesian models with negative binomial regression"- Modelos lineares generalizados bayesianos com regressão binomial negativa/ GLMM "Generalized linear bayesian mixed models"- Modelos lineares generalizados bayesianos mistos / GLMNET "Lasso and elastic-net regularized generalized linear models"- Modelos lineares generalizados regularizados LASSO e elastic-net / GMRF "Gaussian Markov random field"- Campo aleatório gaussiano Markov / INLA "Integrated nested Laplace approximation methods"- Métodos integrados de aproximação Laplace aninhados / KNN "K-Nearest Neighbor" - vizinhos mais próximos-K / LASSO "Least absolute shrinkage and selection operator based models"- Modelo baseado no mínimo de encolhimento absoluto e operador de seleção / LRM - Modelos logísticos de início de transmissão e propagação / LSTM "Long Short-Term Memory"- Rede neural memória longa e curta / MLP "Multilayer perceptron"- Rede neural perceptron de múltiplas camadas / MLR "Multinomial logistic regression" - Regressão logística multinomial / MPR "Multivariate Poisson regression" - Regressão multivariada de Poisson / NBN - " Negative binomial regression model" - Modelo de regressão binomial negativo / NN - "Neural Network" - Rede neural / NN-SIRS "neural network informed by a susceptible-infectious-recovered-susceptible (SIRS) compartmental model" - rede neural formada por um modelo de compartimento suscetível-infectado-recuperado-susceptível (SIRS) / NN-TSM "neural network time series model" - modelo de séries temporais de redes neurais / PLS "Partial least squares"- Mínimos quadrados parciais / RF "Random forests"- Florestas aleatórias / ROC "Receiver operating characteristics"- Características de funcionamento do receptor / SARIMA "Seasonal autoregressive integrated moving average model"- Modelo auto-regressivo integrado de médias móveis sazonais / SEIRS "susceptible-exposed-infectious-recovered compartmental model" - modelo compartimental suscetível-exposto-infectado-recuperado / SIR susceptible-infectious-recovered compartmental model" - modelo compartimental suscetível-infectado-recuperado / SVM "Support vector machine"- Máquina de vetor de suporte / TAN "Tree Augmented Naïve Bayes"- Árvore aumentada do Naive Bayes (construção de classificadores)

**Tabela 3** Mapeamento das variáveis, tipos de modelagens e escala espacial dos dados, nos artigos incluídos.

Seq.	Primeiro autor (ano)	Tipos de Modelagem	Descrição das variáveis preditoras							Nº variáveis preditoras	Escala espacial dos dados
			Incidência	Entomológicas	Climáticas e Ambientais	Fator Calendário	Contexto Territorial	Demográfico / Socioeconômico	Contexto Saúde		
1	Chathurangi Edussuriya (2021)	2 3 4	5	–	1 7 2	–	–	1	–	5	4
2	K.K.W.H. Erandi (2021)	2	5	9	1 2	–	–	–	–	4	4
3	Jessica Liebig (2021)	2	7.1 7.2	4 8 9 13	2 3.1	6	7	–	–	10	5
4	Nurul Azam Mohd Salim (2021)	3 4	1	–	1.1 2.1 2.2 2.3 3.2 7	2 4	4	–	–	10	4
5	Felipe J. Colón-González (2021)	3	3	–	1 2 3.4 5 7 10.1 12	–	–	2	–	9	6
6	Naizhuo Zhao (2020)	3 4	3	–	1 2 5.2	–	–	2 5 6	–	7	5

Seq.	Primeiro autor (ano)	Tipos de Modelagem	Descrição das variáveis preditoras							Nº variáveis preditoras	Escala espacial dos dados
			Incidência	Entomológicas	Climáticas e Ambientais	Fator Calendário	Contexto Territorial	Demográfico / Socioeconômico	Contexto Saúde		
7	Donald Salami (2020)	3	1 7.2 7.3	–	–	3	8 9 11 12 13 14 15	2 7	–	13*	8 9
8	Michael A. Johansson (2019)	3	1	–	1 2 2.8 3.1 3.5 5.1 10.1	5 6	–	2	–	11	5
9	Raghendra Jain (2019)	3	2 7.4	–	1.3 2.5	–	4	–	5 7	7	4
10	Cecilia A. Marques-Toledo (2019)	3	1	5 6 7	1 2.3 2.2 3.1	–	10	–	6	10	3
11	Bernard Bett (2019)	1	7.1	–	1.2 1.3 2.1 2.9 2.10 3.1 3.6 4 5.3 6 7 12 13	3	–	–	–	15	6

Seq.	Primeiro autor (ano)	Tipos de Modelagem	Descrição das variáveis preditoras							Nº variáveis preditoras	Escala espacial dos dados
			Incidência	Entomológicas	Climáticas e Ambientais	Fator Calendário	Contexto Territorial	Demográfico / Socioeconômico	Contexto Saúde		
12	Gayana P. Withanage (2018)	3	3	-	1.3 1.4 2.2 2.3 3.7 3.8 7	-	-	-	-	8	4
13	Yirong Chen (2018)	1	1	-	2.1 2.2 2.3 3.9 5	-	6 16 17	-	-	9	1
14	Gilberto Sánchez-González (2018)	2	7.5	-	2.2 2.3 2.4 3.1 3.2 3.3 3.4 3.5 3.6 3.7 11 12 14 15.1 15.2	1.6	-	-	1 2 3 4 8	23	3
15	Stephen A. Lauer (2018)	1	2	-	1.5 2.11 2.12 3.10	7	-	2	-	7	6
16	Pi Guo (2017)	3	1	-	1.1 2.1 3.1	2	-	-	9	6	3 6

Seq.	Primeiro autor (ano)	Tipos de Modelagem	Descrição das variáveis predictoras							Nº variáveis predictoras	Escala espacial dos dados
			Incidência	Entomológicas	Climáticas e Ambientais	Fator Calendário	Contexto Territorial	Demográfico / Socioeconômico	Contexto Saúde		
17	Padet Siriyasatien (2016)	1	1	1.1 1.2 1.3	1.1 2.1 3.2 7.1	5	–	2	–	10	6 8
18	Rachel Lowe (2016)	1	1 6	–	1.1 2.1 4	7	–	1 2	–	8	7
19	Yuan Shi (2016)	1 3	3	10	2.1 2.3 2.7 3.1 3.11	2	–	2.1 2.2	–	10	5
20	Ta-Chien Chan (2015)	1	1	–	1.1 2.1	–	–	1.1	–	4	2
21	Kraisak Kesorn (2015)	3 4 5	5	1.1 1.2 1.3	1 2 3 7	–	–	1	–	9	6 8
22	Anna L. Buczak (2014)	3 5	4	–	1 2.4 5.1 5.2 7 8 9 10	–	1 2 3	3 4	–	14	6
23	Anna L. Buczak (2012)	3 5	5	–	1 2.5 2.6 5.1 5.2 9 10.2	2	1 2 3 5	–	–	13	4

Seq.	Primeiro autor (ano)	Tipos de Modelagem	Descrição das variáveis preditoras							Nº variáveis preditoras	Escala espacial dos dados
			Incidência	Entomológicas	Climáticas e Ambientais	Fator Calendário	Contexto Territorial	Demográfico / Socioeconômico	Contexto Saúde		
24	Halmar Halide (2008)	1	2	-	1 3.1 2.1 2.2 2.3 10.1	-	-	-	-	7	3

Fonte: Elaborado pelo autor

Códigos para Tabela 3

	1. Estatística	2. Matemática	3. Aprendizado de máquina ou Machine learning	4. Redes Neurais Artificiais	5. Mineração de dados
<b>Tipo de modelagens</b>					
<b>Incidência</b>	1. Casos confirmados todos	2. Casos confirmados apenas de dengue hemorrágica/grave	3. Casos prováveis (todos menos os descartados)	4. Média histórica e desvio-padrão	5. Casos de dengue não especificados 6. Risco relativo de dengue 7. Outras formas de cálculo de incidência 7.1 Taxas mensais de incidência de dengue 7.2 Nº de Importações reais de dengue 7.3 Estimativas anuais de incidência de dengue 7.4 Incidências de curto e longo prazo dos distritos e seus vizinhos 7.5 Incidência em humanos por unidade domiciliar por ano (nº de infecções por dengue confirmadas por ano)
<b>Entomológicas</b>	1. Taxa infecção Aedes 1.1 Larva 1.2 Macho 1.3 Fêmea 2. Taxa de progressão de fase 2.1 Larva 2.2 Pupa 2.3 Mosquito 3. Taxa de mortalidade 3.1 Ovos na chuva 3.2 Ovos na seca 3.3 Larvas 3.4 Larvas dependente da densidade 3.5 Pupas 3.6 Mosquitos saudáveis 3.7 Mosquitos infectados	4. Taxa de sobrevivência diária de mosquitos 5. Índice de casas 6. Índice de Breteau	7. Índice médio de fêmeas de Ae. aegypti por armadilha 8. Probabilidade de infecção do mosquito 9. Densidade vetorial	10. Percentual semanal de Reprodução Ae. Aegypti 11. Taxa de refeições infecciosas dos seres humanos para os mosquitos 12. Taxa de picadas infecciosas de mosquitos para humanos	13. Período de incubação extrínscica 14. Taxa de oviposição dos mosquitos 15. Emergência do mosquito 15.1 Ativação da emergência do mosquito pela chuva 15.2 Desativação da emergência do mosquito pela seca

Códigos para Tabela 3 - continuação

	1. Precipitação 1.1 Média 1.2 Maior precipitação (mm) mensal 1.3 Mensal acumulada 1.4 Nº de dias chuvosos 1.5 Máxima e total trimestral 1.6 Ponderações dependentes da chuva	3. Umidade 3.1 Relativa 3.2 Média 3.3 Máxima 3.4 Superficial (vapor d'água) 3.5 Específica 3.6 Mínima absoluta 3.7 Relativa mínima 3.8 Relativa máxima 3.9 Relativa média 3.10 Umidade média e máxima trimestral 3.11 Absoluta	5. Vegetação 5.1 Índice NDVI 5.2 Índice EVI 5.3 Cobertura do solo (florestas, bosques, gramíneas/cereais, arbustos, terras cultivadas/mosaicos, zonas úmidas)	7. Velocidade do vento 7.1 Média	9. Índice de Oscilação Sul (SOI)	11. Retrocessos climáticos sazonais	13. Duração total do sol em horas
<b>Climáticas e Ambientais</b>	2. Temperatura 2.1 Média 2.2 Mínima 2.3 Máxima 2.4 Superfície terrestre 2.5 Diurna 2.6 Noturna 2.7 Nº horas temperatura elevada 2.8 Ponto de orvalho 2.9 Temperaturas média mínima e máxima 2.10 Temperaturas mínima e máxima absoluta 2.11 Temperaturas mínima, máxima e média trimestral 2.12 Temperatura média durante a baixa temporada de dengue	4. Altitude	6. Pressão atmosférica	8. Status p/ tufão	10. Temperatura da superfície do mar 10.1 Índice mensal de Anomalia de Temperatura da Superfície do Mar do Oceano Pacífico (Niño 3.4) 10.2 Anomalia semanal da temperatura da superfície do mar (SSTA)	12. Evaporação total (mm)	
<b>Fator Calendário</b>	1. Dia	2. Semana	3. Mês	4. Ano	5. Estação do ano	6. Sazonalidade das infecções por dengue	7. Trimestre
	1. Saneamento	4. Coleta de lixo	7. Dados cartão de chegada viajante	10. Nível de exposição da população à dengue (inquérito de soroprevalência no banco de sangue de doadores saudáveis)	13. O número de vezes que um nó está no caminho mais curto (geodésica) entre outros nós da rede	16. Potencial de transmissão ponderado pela conectividade	
<b>Contexto Territorial</b>	2. Acesso água encanada / potável	5. Estabilidade política	8. Vulnerabilidade epidêmica do país de origem	11. Total de passageiros aéreos do país de origem para um país de destino na Europa	14. O número médio de etapas necessárias para acessar todos os outros nós de um determinado nó	17. Ranking de conectividade com base no número de viagens dentro e fora de cada bairro	
	3. Acesso Eletricidade	6. Idade da edificação	9. Distância geográfica (grande círculo) entre os centróides do país de origem e do país de destino (conectividade espacial)	12. O número de links ou conexões que um nó possui	15. Medida combinada de quantas conexões um nó possui (ou seja, seu grau) e a centralidade dos outros nós aos quais ele está conectado		

Códigos para Tabela 3 - continuação

	1. Densidade populacional 1.1 Média	2. Estimativas / projeções populacionais Todos 2.1 Residentes 2.2 Não residentes	3. Índice de pobreza	4. Índice de Desenvolvimento infantil	5. Índice GINI	6. Cobertura educacional	7. PIB (produto interno bruto)
<b>Demográfico / Socioeconômico</b>							
	1. Taxa de mortalidade humana infectada	3. Taxa de aquisição de imunidade	5. Dados clínicos da dengue hemorrágica	7. Dados defasados de notificação da dengue	9. Dados de pesquisa na Baidu Search sobre dengue (site de busca dominante na República Popular da China)		
<b>Contexto Saúde</b>	2. Taxa de mortalidade humana	4. Taxa de perda de imunidade	6. Tweets relacionadas às experiências pessoais da dengue	8. Período de incubação da dengue em humanos			
	1. Bairro	3. Município ou cidade	5. Estado ou departamento	7. Microrregiões	9. País /Nacional		
<b>Escala espacial dos dados</b>	2. Vila	4. Distrito	6. Província	8. Região			

## APÊNDICE E - FREQUÊNCIAS DOS PARÂMETROS

**Tabela 6** Frequência do parâmetro: tipos de modelagens.

Tipos de modelagens	Freq.	%
3. Aprendizado de máquina ou <i>machine learning</i>	14	42,42
1. Estatística	8	24,24
2. Matemática	4	12,12
4. Redes Neurais Artificiais	4	12,12
5. Mineração de dados	3	9,09
<b>Totais</b>	<b>33</b>	<b>100</b>

Fonte: elaborado pelo autor

**Tabela 7** Frequência do parâmetro: programas (softwares) para modelagens.

Programas (Softwares)	Freq.	%
R	11	45,83
Matlab	2	8,33
Phyton	2	8,33
SPSS	2	8,33
Quantity One Quantification Analysis	1	4,17
SAS	1	4,17
Stan	1	4,17
Weka	1	4,17
Wolfram Mathematica 8	1	4,17
nd*	2	8,33
<b>Totais</b>	<b>24</b>	<b>100</b>

Fonte: elaborado pelo autor

\* não disponível ou informado

**Tabela 8** Frequência do parâmetro: variável – incidência.

Incidência	Freq.	%
1. Casos confirmados, todos	9	29,03
3. Casos prováveis (todos menos os descartados)	4	12,90
5. Casos de dengue não especificados	4	12,90
2. Casos confirmados, apenas dengue hemorrágica/grave	3	9,68
7.1 Taxas mensais de incidência de dengue	2	6,45
7.2 N° de Importações reais de dengue	2	6,45
4. Média histórica e desvio-padrão	1	3,23
6. Risco relativo de dengue	1	3,23
7.3 Estimativas anuais de incidência de dengue	1	3,23
7.4 Incidências de curto e longo prazo dos distritos e seus	1	3,23
7.5 Incidência em humanos por unidade domiciliar por ano	1	3,23
7.2 N° de Importações reais de dengue	2	6,45
<b>Totais</b>	<b>31</b>	<b>100</b>

Fonte: elaborado pelo autor

**Tabela 9** Frequência do parâmetro: variável – entomológicas.

<b>Entomológicas</b>	<b>Freq.</b>	<b>%</b>
1.1 Taxa infecção Aedes larva	2	6,67
1.2 Taxa infecção Aedes macho	2	6,67
1.3 Taxa infecção Aedes fêmea	2	6,67
9. Densidade vetorial	2	6,67
2.1 Taxa de progressão de fase larva	1	3,33
2.2 Taxa de progressão de fase pupa	1	3,33
2.3 Taxa de progressão de fase mosquito	1	3,33
3.1 Taxa de mortalidade ovos na chuva	1	3,33
3.2 Taxa de mortalidade ovos na seca	1	3,33
3.3 Taxa de mortalidade larvas	1	3,33
3.4 Taxa de mortalidade larvas dependente da densidade	1	3,33
3.5 Taxa de mortalidade pupas	1	3,33
3.6 Taxa de mortalidade mosquitos saudáveis	1	3,33
3.7 Taxa de mortalidade mosquitos infectados	1	3,33
4. Taxa de sobrevivência diária de mosquitos	1	3,33
5. Índice de casas	1	3,33
6. Índice de Breteau	1	3,33
7. Índice médio de fêmeas de <i>Aedes aegypti</i> por armadilha	1	3,33
8. Probabilidade de infecção do mosquito	1	3,33
10. Percentual semanal de Reprodução <i>Aedes aegypti</i>	1	3,33
11. Taxa de refeições infecciosas dos seres humanos para os mosquitos	1	3,33
12. Taxa de picadas infecciosas de mosquitos para humanos	1	3,33
13. Período de incubação extrínseca	1	3,33
14. Taxa de oviposição dos mosquitos	1	3,33
15.1 Ativação da emergência do mosquito pela chuva	1	3,33
15.2 Desativação da emergência do mosquito pela seca	1	3,33
<b>Totais</b>	<b>30</b>	<b>100</b>

Fonte: elaborado pelo autor

**Tabela 10** Frequência do parâmetro: variável - climáticas e ambientais.

<b>Climáticas e ambientais</b>	<b>Fre</b>	<b>%</b>
1. Precipitação	10	9,26
2.1 Temperatura média	9	8,33
2. Temperatura	7	6,48
3.1 Umidade relativa	7	6,48
7. Velocidade do vento	7	6,48
2.3 Temperatura máxima	6	5,56
1.1 Precipitação média	5	4,63
2.2 Temperatura mínima	5	4,63
1.3. Precipitação mensal acumulada	3	2,78
5.1 Índice vegetação NDVI	3	2,78
5.2 Índice vegetação EVI	3	2,78
10.1 Índice mensal de Anomalia de Temperatura da Superfície do	3	2,78
2.5 Temperatura diurna	2	1,85
3.2 Umidade média	2	1,85
4. Altitude	2	1,85
5. Vegetação	2	1,85
9. Índice de Oscilação Sul (SOI)	2	1,85
12. Evaporação total (mm)	2	1,85
1.2 Maior precipitação (mm) mensal	1	0,93
1.4 Precipitação - número de dias chuvosos	1	0,93
1.5 Precipitação máxima e total trimestral	1	0,93
1.6 Ponderações dependentes de chuva	1	0,93
2.4 Superfície terrestre	1	0,93
2.6 Temperatura noturna	1	0,93
2.7 N° de horas temperatura elevada	1	0,93
2.8 Ponto de orvalho	1	0,93
2.9 Temperaturas média mínima e máxima	1	0,93
2.10 Temperaturas mínima e máxima absoluta	1	0,93
2.11 Temperaturas mínima, máxima e média trimestral	1	0,93
2.12 Temperatura média durante a baixa temporada de dengue	1	0,93
3. Umidade	1	0,93
3.4 Umidade superficial (vapor d'água)	1	0,93
3.5 Umidade específica	1	0,93
3.6 Umidade mínima absoluta	1	0,93
3.7 Umidade relativa mínima	1	0,93
3.8 Umidade relativa máxima	1	0,93
3.9 Umidade relativa média	1	0,93
3.10 Umidade média e máxima trimestral	1	0,93
3.11 Umidade absoluta	1	0,93
5.3 Cobertura do solo (florestas, bosques, gramíneas/cereais,	1	0,93
6. Pressão atmosférica	1	0,93
7.1 Velocidade média do vento	1	0,93
8. Status p/ tufão	1	0,93
10. Temperatura da superfície do mar	1	0,93
10.2 Anomalia semanal da temperatura da superfície do mar	1	0,93
13. Duração total do sol em horas	1	0,93
<b>Totais</b>	<b>108</b>	<b>100</b>

Fonte: elaborado pelo autor

**Tabela 11** Frequência do parâmetro: variável - fator calendário.

<b>Fator Calendário</b>	<b>Freq.</b>	<b>%</b>
2. Semana	4	30,77
7. Trimestre	2	15,38
3. Mês	2	15,38
5. Estação do ano	2	15,38
6. Sazonalidade das infecções por dengue	2	15,38
4. Ano	1	7,69
1. Dia *	0	0,00
<b>Totais</b>	<b>13</b>	<b>100</b>

Fonte: elaborado pelo autor

\*Não houve frequência para o fator "dia", apenas codificado.

**Tabela 12** Frequência do parâmetro: variável - contexto territorial.

<b>Contexto territorial</b>	<b>Freq.</b>	<b>%</b>
3. Acesso Eletricidade	2	9,52
1. Saneamento	2	9,52
2. Acesso água encanada / potável	2	9,52
4. Coleta de lixo	2	9,52
6. Idade da edificação	1	4,76
15. Medida combinada de quantas conexões um nó possui	1	4,76
14. O número médio de etapas necessárias para acessar todos	1	4,76
17. Ranking de conectividade com base no número de	1	4,76
13. O número de vezes que um nó está no caminho mais	1	4,76
7. Dados cartão de chegada viajante	1	4,76
5. Estabilidade política	1	4,76
9. Distância geográfica (grande círculo) entre os centroides	1	4,76
8. Vulnerabilidade epidêmica do país de origem	1	4,76
10. Nível de exposição da população à dengue (inquérito de	1	4,76
16. Potencial de transmissão ponderado pela conectividade	1	4,76
12. O número de links ou conexões que um nó possui	1	4,76
11. Total de passageiros aéreos do país de origem para um	1	4,76
<b>Totais</b>	<b>21</b>	<b>100</b>

Fonte: elaborado pelo autor.

**Tabela 13** Frequência do parâmetro: variável - demográfico / socioeconômico.

<b>Demográfico / Socioeconômico</b>	<b>Freq.</b>	<b>%</b>
2. Estimativas / projeções populacionais - todos	7	36,84
1. Densidade populacional	4	21,05
1.1 Densidade média populacional	1	5,26
2.1 Estimativas / projeções populacionais - Residentes	1	5,26
2.2 Estimativas / projeções populacionais - Não residentes	1	5,26
3. Índice de pobreza	1	5,26
4. Índice de Desenvolvimento infantil	1	5,26
5. Índice GINI	1	5,26
6. Cobertura educacional	1	5,26
7. PIB (produto interno bruto)	1	5,26
<b>Totais</b>	<b>19</b>	<b>100</b>

Fonte: elaborado pelo autor.

**Tabela 14** Frequência do parâmetro: variável - contexto saúde.

<b>Contexto saúde</b>	<b>Freq.</b>	<b>%</b>
1. Taxa de mortalidade humana infectada	1	11,11
2. Taxa de mortalidade humana	1	11,11
3. Taxa de aquisição de imunidade	1	11,11
4. Taxa de perda de imunidade	1	11,11
5. Dados clínicos da dengue hemorrágica	1	11,11
6. Tweets relacionadas às experiências pessoais da dengue	1	11,11
7. Dados defasados de notificação da dengue	1	11,11
8. Período de incubação da dengue em humanos	1	11,11
9. Dados de pesquisa na Baidu Search sobre dengue (site de busca dominante na República Popular da China)	1	11,11
<b>Totais</b>	<b>9</b>	<b>100</b>

Fonte: elaborado pelo autor.

**Tabela 15** Frequência do parâmetro: variáveis preditoras por grupo.

<b>Variáveis preditoras por grupo</b>	<b>Freq.</b>	<b>%</b>
Climáticas e ambientais	46	36,80
Entomológicas	26	20,80
Contexto territorial	17	13,60
Incidência	11	8,80
Demográfico / socioeconômico	10	8,00
Contexto saúde	9	7,20
Fator calendário*	6	4,80
<b>Totais</b>	<b>125</b>	<b>100</b>

Fonte: elaborado pelo autor.

**Tabela 16** Frequência do parâmetro: escala espacial dos dados.

<b>Escala espacial dos dados</b>	<b>Freq.</b>	<b>%</b>
6. Província	7	25,00
4. Distrito	6	21,43
3. Município ou cidade	4	14,29
5. Estado ou departamento	4	14,29
8. Região	3	10,71
1. Bairro	1	3,57
2. Vila	1	3,57
7. Microrregiões	1	3,57
9. País /Nacional	1	3,57
<b>Totais</b>	<b>28</b>	<b>100</b>

Fonte: elaborado pelo autor.

**Tabela 17** Frequência do parâmetro: localização.

<b>Localização</b>		<b>Freq.</b>	<b>%</b>
<b>Países</b>	<b>Continentes</b>		
Tailândia	Sudeste asiático	4	16
Sri Lanka	Sudeste asiático	3	12
Vietnã	Sudeste asiático	2	8
Brasil	América do sul	2	8
Singapura	Sudeste asiático	2	8
Perú	América do sul	2	8
Austrália	Oceania	1	4
Malásia	Sudeste asiático	1	4
Colômbia	América do sul	1	4
Europa **	Europa	1	4
Porto Rico*	América central	1	4
México	América central	1	4
China	Ásia oriental	1	4
Taiwan	Leste asiático	1	4
Filipinas	Sudeste asiático	1	4
Indonésia	Sudeste asiático	1	4
<b>Totais</b>		<b>25</b>	<b>100</b>

Fonte: elaborado pelo autor.

\* Ilha caribenha, território não incorporado dos Estados Unidos

\*\* 21 países do continente europeu

**Tabela 18** Frequência do parâmetro: unidade temporal de previsão.

<b>Unidade temporal de previsão</b>	<b>Freq.</b>	<b>%</b>
Semanal	8	33,33
Mensal	8	33,33
Anual e mensal	4	16,67
Dias	1	4,17
Semanal e anual	1	4,17
Semanal e mensal	1	4,17
Tempo real	1	4,17
<b>Totais</b>	<b>24</b>	<b>100</b>

Fonte: elaborado pelo autor

**Tabela 19** Frequência do parâmetro: período de previsão antecipada.

<b>Período de previsão antecipada</b>	<b>Freq.</b>	<b>%</b>
até 3 meses	3	12,50
1 mês	2	8,33
até 4 semanas	2	8,33
pré-temporada sazonal (4 meses)	2	8,33
1 - 4 meses	1	4,17
1 semana	1	4,17
1 semana - 1 mês	1	4,17
12 semanas	1	4,17
3 - 7 semanas	1	4,17
4 semanas	1	4,17
anual ****	1	4,17
até 12 semanas	1	4,17
até 30 dias	1	4,17
até 6 meses	1	4,17
nd	1	4,17
nd***	1	4,17
pré-temporada (3 meses)	1	4,17
semanas do ano	1	4,17
tempo real	1	4,17
<b>Totais</b>	<b>24</b>	<b>100</b>

Fonte: elaborado pelo autor.

\*\*\*nd = não disponível ou informado - prevê a probabilidade de ter um caso importado de dengue na Europa

\*\*\*\*anual (pico de incidência, semana do pico e incidência total)

nd = não disponível ou informado

**Tabela 20** Frequência do parâmetro: período de experimento.

<b>Período de experimento</b>	<b>Freq.</b>	<b>%</b>
8 anos*	4	16,67
6 anos	3	12,50
7 anos	3	12,50
9 anos	3	12,50
5 anos*	3	12,50
12 anos	2	8,33
4 anos	2	8,33
1 mês	1	4,17
13 anos	1	4,17
15 anos	1	4,17
21 anos	1	4,17
<b>Totais</b>	<b>24</b>	<b>100</b>

Fonte: elaborado pelo autor

\*Ano completo mais fração

## APÊNDICE F - DESCRIÇÃO AGRUPADA POR SEMELHANÇA DOS MÉTODOS DE MODELAGENS MAPEADOS

Seq.	Grupos	Métodos de modelagens
1	Matemáticos Compartimentais (estocásticos)	<p>Equações diferenciais ordinárias não lineares</p> <p>Modelo compartimental baseado em dados bidimensionais</p> <p>SIR "susceptible-infectious-recovered compartmental model" - modelo compartimental suscetível--infectado-recuperado</p> <p>SIRS "susceptible-infectious-recovered-susceptible" compartmental model" - modelo compartimental suscetível-infectado-recuperado-susceptível (SIRS)</p> <p>SEIRS "susceptible-exposed-infectious-recovered compartmental model" - modelo compartimental suscetível-exposto-infectado-recuperado</p>
2	Regressões	<p>AR "Autoregressive model" - Modelo autorregressivo</p> <p>ARIMA "Autoregressive integrated moving average model" - Modelo autorregressivo integrado de médias móveis</p> <p>BYM "Besag-York-Mollie model" - Modelo Besag-York-Mollie</p> <p>CAR "Conditional autoregressive model" - Modelo auto-regressivo condicional</p> <p>DLNM "Distributed lag non-linear models" - Modelos não lineares de atraso distribuído</p> <p>GBM "Gradient boosted regression tree algorithm" - Algoritmo de árvore de regressão impulsionada por gradiente</p> <p>GLMNET "Lasso and elastic-net regularized generalized linear models" - Modelos lineares generalizados regularizados LASSO e elastic-net</p> <p>KNN "K-Nearest Neighbor" - vizinhos mais próximos-K</p> <p>LRM - Modelos logísticos de início de transmissão e propagação</p> <p>LASSO "Least absolute shrinkage and selection operator based models" - Modelo baseado no mínimo de encolhimento absoluto e operador de seleção</p> <p>NBN - " Negative binomial regression model" - Modelo de regressão binomial negativo</p> <p>MLR "Multinomial logistic regression" - Regressão logística multinomial</p> <p>MPR "Multivariate Poisson regression" - Regressão multivariada de Poisson</p> <p>PLS "Partial least squares regression" - Mínimos quadrados parciais</p> <p>Poisson binomial</p> <p>Regressão múltipla</p> <p>SARIMA "Seasonal autoregressive integrated moving average model" - Modelo auto-regressivo integrado de médias móveis sazonais</p>

Seq.	Grupos	Métodos de modelagens
3	Estatísticas Bayesianas	<p>B-TSM "Bayesian time series model" - modelo de séries temporais Bayesino</p> <p>BFAST "Breaks For Additive Seasonal Trend" - Quebras para o algoritmo aditivo de sazonalidade e tendência</p> <p>GAM "Generalized additive model" - Modelo aditivo generalizado</p> <p>GLM "Generalized linear bayesian models" - Modelos lineares generalizados bayesianos</p> <p>GLM-NB "Generalized linear bayesian models with negative binomial regression" - Modelos lineares generalizados bayesianos com regressão binomial negativa</p> <p>GLMM "Generalized linear bayesian mixed models" - Modelos lineares generalizados bayesianos mistos</p> <p>INLA "Integrated nested Laplace approximation methods" - Métodos integrados de aproximação Laplace aninhados</p> <p>Modelo empírico Bayes</p> <p>Regressão de série temporal Bayesiana</p>
4	Técnicas de mineração de dados	<p>SVM "Support vector machine" - Máquina de vetor de suporte</p> <p>FARM "Fuzzy Association Rule Mining" - Associação Fuzzy Regra de Mineração</p>
5	Algoritmos de redes neurais	<p>LSTM "Long Short-Term Memory" - Rede neural memória longa e curta</p> <p>MLP "Multilayer perceptron" - Rede neural perceptron de múltiplas camadas</p> <p>NN-SIRS "neural network informed by a SIRS compartmental model" - rede neural formada por um modelo de compartimento SIRS</p> <p>NN-TSM "neural network time series model" - modelo de séries temporais de redes neurais</p>
6	Classificadores	<p>CART "Classification and Regression Trees" - Árvores de decisão, classificação e regressão</p> <p>Curva ROC - Modelo de decisão para classificação de risco</p> <p>KNN "K-Nearest Neighbor" - vizinhos mais próximos-K</p> <p>RF "Random florest" - Florestas aleatórias</p> <p>TAN "Tree Augmented Naïve Bayes" - Árvore aumentada do Naive Bayes</p>
7	Outros	<p>GMRF "Gaussian Markov random field" - Campo aleatório gaussiano de Markov</p> <p>Mínimos quadrados ordinários</p> <p>Modelos "pinned spline"</p> <p>Algoritmo de agrupamento de centroides de espectro K</p> <p>Reconstrução não-paramétrica do espaço de estado de Kernel-densidade</p> <p>Suavização exponencial de Hot-Winters análogos multidimensionais</p>

## APÊNDICE G - FONTES DOS DADOS DOS ARTIGOS INCLUÍDOS

Seq	Primeiro autor (ano)	Fonte dos dados*
1	Chathurangi Edussuriya (2021)	<ol style="list-style-type: none"> <li>1. Sri Lanka Meteorological Department</li> <li>2. Epidemiology Unit, Ministry of Health, Sri Lanka</li> <li>3. Central Bank of Sri Lanka Economic and Social Statistics</li> </ol>
2	K.K.W.H. Erandi (2021)	<ol style="list-style-type: none"> <li>1. Sri Lanka Meteorological Department</li> <li>2. Epidemiology Unit, Ministry of Health, Sri Lanka</li> </ol>
3	Jessica Liebig (2021)	<ol style="list-style-type: none"> <li>1. Queensland Health Research Australia</li> <li>2. Tourism Research Australia</li> <li>3. Australian Bureau of Meteorology</li> <li>4. Australian Bureau of Statistics</li> <li>5. Australian Department of Home Affairs</li> <li>6. Global Burden of Disease Collaborative Network, 2017</li> <li>7. International Association for Medical Assistance to Travelers (IAMAT)</li> </ol>
4	Nurul Azam Mohd Salim (2021)	<ol style="list-style-type: none"> <li>1. Ministry of Health through eNotifikasi</li> <li>2. eDengueV2 system</li> <li>3. Malaysian Meteorology Department</li> </ol>
5	Felipe J. Colón- González (2021)	<ol style="list-style-type: none"> <li>1. Vietnam's Ministry of Health</li> <li>2. Socioeconomic Data and Applications Center (SEDAC) Gridded Population of the World project version 4.11</li> <li>3. ESA CCI Land Cover project</li> <li>4. Tropical Rainfall Measurement Mission</li> <li>5. Global Precipitation Mission</li> <li>6. European Centre for Medium-Range Weather Forecasts</li> <li>7. NOAA Climate Forecast System</li> <li>8. NOAA Center for Weather and Climate Prediction Climate Prediction Center</li> <li>9. Vietnamese General Department of Preventive Medicine, Hanoi</li> <li>10. UK Met Office Global Seasonal Forecasting System version 5</li> </ol>
6	Naizhuo Zhao (2020)	<ol style="list-style-type: none"> <li>1. SIVIGILA, created by the Colombia national surveillance program</li> <li>2. CMORPH (Climate Prediction Center morphing method), from NOAA's CPC</li> <li>3. MODIS Terra Land Surface Temperature 8-day image products (MOD11C2.006), from NASA's LP DAAC</li> <li>4. MODIS Terra Vegetation Indices 16-Day image products (MOD13C1.006), from NASA's LP DAAC</li> <li>5. Departamento Administrativo Nacional de Estadística da Colômbia</li> </ol>

Seq	Primeiro autor (ano)	Fonte dos dados*
7	Donald Salami (2020)	<ol style="list-style-type: none"> <li>1. European Centre for Disease Prevention and Control (ECDC)</li> <li>2. International Air Travel Association, passenger intelligence services (IATA-PaxIS)</li> <li>3. HealthMap. DengueMap, <a href="https://www.healthmap.org/dengue/en/index.php">https://www.healthmap.org/dengue/en/index.php</a></li> <li>4. Institute for Health Metrics and Evaluation. Global Burden of Disease Study Results, <a href="http://ghdx.healthdata.org/gbd-results-tool">http://ghdx.healthdata.org/gbd-results-tool</a></li> <li>5. Centre d'Etudes Prospectives et d'Informations. CEPII Database, <a href="http://www.cepii.fr/cepii/en/bdd_modele/bdd.asp">http://www.cepii.fr/cepii/en/bdd_modele/bdd.asp</a></li> <li>6. The World Bank open data, <a href="https://data.worldbank.org">https://data.worldbank.org</a></li> <li>7. Identifying future disease hot spots: infectious disease vulnerability index. Rand health quarterly. <a href="https://www.ncbi.nlm.nih.gov/pmc/articles/PMC5568150">https://www.ncbi.nlm.nih.gov/pmc/articles/PMC5568150</a></li> </ol>
8	Michael A. Johansson (2019)	<ol style="list-style-type: none"> <li>1. Station data - Temperature and precipitation - NOAA's GHCN daily climate data</li> <li>2. Satellite precipitation - Precipitation - NOAA's CDR PERSIANN Precipitation Product</li> <li>3. Reanalysis - Temperature and precipitation - NOAA's NCEP Climate Forecast System Reanalysis</li> <li>4. Satellite vegetation - Normalized difference vegetation index (NDVI) - NOAA's CDR Normalized Difference Vegetation Index</li> <li>5. U.S. Census Bureau (San Juan-Carolina-Caguas Metropolitan Statistical Area)</li> <li>6. National Statistics Institute of Peru (Iquitos, Punchana, Belen and San Juan Bautista)</li> </ol>
9	Raghvendra Jain (2019)	<ol style="list-style-type: none"> <li>1. Department of Disease Control, Bangkok</li> <li>2. Department of Drainage and Sewerage, Bangkok</li> <li>3. Meteorological Department, Thailand</li> </ol>
10	Cecilia A. Marques-Toledo (2019)	<ol style="list-style-type: none"> <li>1. Hemocentro do Rio Grande do Sul (Hemorgs)</li> <li>2. Sistema de notificação de doenças do Ministério da Saúde do Brasil (Sinannet)</li> <li>3. Instituto Nacional de Meteorologia (INMET)</li> <li>4. Secretaria de Saúde de Porto Alegre</li> <li>5. Aplicativo da web (<a href="http://www.observatorio.inweb.org.br/dengue">www.observatorio.inweb.org.br/dengue</a>)</li> </ol>
11	Bernard Bett (2019)	<ol style="list-style-type: none"> <li>1. Programa NCDP, Ministry of Health Vietnan</li> <li>2. Meteorology and Hydrology and Climate Change, Hanoi</li> <li>3. NASA's Moderate Resolution Imaging Spectroradiometer (MODIS) website</li> <li>4. Food and Agriculture Organization of the United Nation's soil data portal</li> </ol>
12	Gayana P. Withanage (2018)	<ol style="list-style-type: none"> <li>1. Regional Epidemiology Unit in the District of Gampaha</li> <li>2. Department of Meteorology, Colombo, Sri Lanka</li> </ol>
13	Yirong Chen (2018)	<ol style="list-style-type: none"> <li>1. Ministry of Health, Singapore</li> <li>2. Starhub Ltd (empresa de telefonia movel)</li> <li>3. Housing Development Board e da Urban Redevelopment Authority</li> <li>4. Meteorological Services Singapore</li> <li>5. Centre for Remote Imaging, Sensing and Processing in the National University of Singapore</li> <li>6. EZLink cards (cartão para pagar tarifas de transporte público em Singapura)</li> </ol>

Seq	Primeiro autor (ano)	Fonte dos dados*
14	Gilberto Sánchez-González (2018)	<ol style="list-style-type: none"> <li>1. Mexican Health Department data</li> <li>2. Epidemiological History Bulletin available at <a href="https://www.gob.mx/salud/acciones-y-programas/historico-boletin-epidemiologico">https://www.gob.mx/salud/acciones-y-programas/historico-boletin-epidemiologico</a></li> <li>3. National Household Survey 2015 (available at: <a href="http://www.inegi.org.mx/saladeprensa/boletines/2016/especiales/especiales2016_06_05.pdf">http://www.inegi.org.mx/saladeprensa/boletines/2016/especiales/especiales2016_06_05.pdf</a>.)</li> <li>4. National Statistical and Geographic Information System (available at <a href="http://cuentame.inegi.org.mx/monografias/default.aspx?tema=me">http://cuentame.inegi.org.mx/monografias/default.aspx?tema=me</a>)</li> <li>5. Healthcare coverage - CONEVAL (available at evaluation of social policy <a href="http://www.coneval.org.mx/Evaluacion/Paginas/Indicadores_de_acceso_y_uso_efectivo_de_los_servicios_de_salud_de_afiliados_al-Seguro_Popular.aspx">http://www.coneval.org.mx/Evaluacion/Paginas/Indicadores_de_acceso_y_uso_efectivo_de_los_servicios_de_salud_de_afiliados_al-Seguro_Popular.aspx</a>.)</li> <li>6. Mathematica 8 “WeatherData” centers</li> </ol>
15	Stephen A. Lauer (2018)	<ol style="list-style-type: none"> <li>1. Thailand Ministry of Public Health (MOPH)</li> <li>2. National Statistical Office of Thailand</li> <li>3. Earth System Research Laboratory (ESRL) da NOAA</li> <li>4. National Climatic Data Center (NCDC)</li> </ol>
16	Pi Guo (2017)	<ol style="list-style-type: none"> <li>1. Guangdong Provincial Institute of Public Health</li> <li>2. Guangdong Provincial Center for Disease Control and Prevention</li> <li>3. China National Notifiable Disease Surveillance System</li> <li>4. Statistics Bureau of Guangdong Province</li> <li>6. Public Health Science Data Center managed by the China CDC</li> <li>7. Chinese Ministry of Health</li> <li>8. China Meteorological Data Sharing Service System</li> <li>9. Baidu Index (<a href="https://index.baidu.com/">https://index.baidu.com/</a>)</li> </ol>
17	Padet Siriyasatien (2016)	<ol style="list-style-type: none"> <li>1. Thailand’s National Institute of Health</li> <li>2. Bureau of Epidemiology, Department of Disease Control, Ministry of Public Health, Tailândia</li> <li>3. National Trustworthy and Competent Authority Epidemiological Surveillance and Investigation Department (NTCAESI)</li> <li>4. Thai Meteorological department</li> <li>5. Parasitology Department, Chulalongkorn University</li> </ol>
18	Rachel Lowe (2016)	<ol style="list-style-type: none"> <li>1. Sistema de Informação de Agravos de Notificação (SINAN), organizado pelo Ministério da Saúde do Brasil e Departamento de Informação em Saúde (DATASUS)</li> <li>2. Instituto Brasileiro de Geografia e Estatística (IBGE, 2014)</li> <li>3. Centro de Previsão de Tempo e Pesquisa Climática (CPTEC) como parte do EUROBRISA: Uma Iniciativa Euro-Brasileira para melhorar as previsões sazonais da América do Sul (<a href="http://eurobrisa.cptec.inpe.br">http://eurobrisa.cptec.inpe.br</a>)</li> </ol>

Seq	Primeiro autor (ano)	Fonte dos dados*
19	Yuan Shi (2016)	1. Singapore's Ministry of Health - Weekly Infectious Diseases Bulletin ( <a href="https://www.moh.gov.sg/content/moh_web/home/statistics/infectiousDiseasesStatistics/weekly_infectiousdiseasesbulletin.html">https://www.moh.gov.sg/content/moh_web/home/statistics/infectiousDiseasesStatistics/weekly_infectiousdiseasesbulletin.html</a> ) 2. Singapore Department of Statistics (Department of Statistics, Singapore 2015) 3. Meteorological Services Singapore
20	Ta-Chien Chan (2015)	1. National Notifiable Diseases Surveillance System, que pertence ao Taiwan Centers for Disease Control (CDC) 2. Taiwan socio-economic database, mantido pelo, Ministry of the Interior ( <a href="http://segis.moi.gov.tw/">http://segis.moi.gov.tw/</a> ) 3. Taiwan's Central Weather Bureau
21	Kraisak Kesorn (2015)	1. National Trustworthy and Competent Authority Epidemiological Surveillance and Investigation Department (NTCAESI) 2. Thai Meteorological Department 3. Departamento de Parasitologia da Universidade de Chulalongkorn (taxa infecção do vetor) 4. Ministry of interior
22	Anna L. Buczak (2014)	1. Chuva - Missão de Medição de Chuvas Tropicais da NASA <a href="http://mirador.gsfc.nasa.gov">http://mirador.gsfc.nasa.gov</a> 2. Temperatura- USGS Land Processes Distributed Active Archive Center <a href="https://lpdaac.usgs.gov/get_data">https://lpdaac.usgs.gov/get_data</a> 3. Status do tufão e vento - Unisys Weather <a href="http://weather.unisys.com/hurricane/w_pacific">http://weather.unisys.com/hurricane/w_pacific</a> 4. NDVI - USGS Land Processes Distributed Active Archive Center <a href="https://lpdaac.usgs.gov/get_data">https://lpdaac.usgs.gov/get_data</a> 5. EVI - USGS Land Processes Distributed Active Archive Center <a href="https://lpdaac.usgs.gov/get_data">https://lpdaac.usgs.gov/get_data</a> 6. Índice de Oscilação Sul - Centro Nacional dos EUA para Pesquisa Atmosférica <a href="http://mirador.gsfc.nasa.gov">http://mirador.gsfc.nasa.gov</a> 7. Sea Surf. Temp. Anomaly - Diretório de Domínio de Mudança Global da NASA <a href="https://lpdaac.usgs.gov/get_data">https://lpdaac.usgs.gov/get_data</a> 8. Altitude - Centro Nacional de Dados Geofísicos da NOAA <a href="http://www.ngdc.noaa.gov/mgg/topo">http://www.ngdc.noaa.gov/mgg/topo</a> 9. Socio-econômico - Escritório Nacional de Estatísticas das Filipinas <a href="http://census.gov.ph">http://census.gov.ph</a> 10. Estabilidade política - Projeto de Indicadores de Governança Mundial <a href="http://info.worldbank.org/governance/wgi/index.asp">http://info.worldbank.org/governance/wgi/index.asp</a>

Seq	Primeiro autor (ano)	Fonte dos dados*
23	Anna L. Buczak (2012)	<ol style="list-style-type: none"> <li>1. Peruvian Ministry of Health</li> <li>2. NASA Tropical Rainfall Measuring Mission <a href="http://mirador.gsfc.nasa.gov/">http://mirador.gsfc.nasa.gov/</a></li> <li>3. USGS Land Processes Distributed Active Archive Center <a href="https://lpdaac.usgs.gov/get_data">https://lpdaac.usgs.gov/get_data</a></li> <li>4. NOAA National Geophysical Data Center <a href="http://www.ngdc.noaa.gov/cgi-bin/mgg/ff/nph-newform.pl/mgg/topo/">http://www.ngdc.noaa.gov/cgi-bin/mgg/ff/nph-newform.pl/mgg/topo/</a></li> <li>5. Peru National Institute of Statistics and Information <a href="http://www.inei.gob.pe/">http://www.inei.gob.pe/</a></li> <li>6. Worldwide Governance Indicators Project <a href="http://info.worldbank.org/governance/wgi/index.asp">http://info.worldbank.org/governance/wgi/index.asp</a></li> <li>7. US National Center for Atmospheric Research <a href="http://mirador.gsfc.nasa.gov/">http://mirador.gsfc.nasa.gov/</a></li> <li>8. NASA Global Change Mastery Directory <a href="https://lpdaac.usgs.gov/get_data">https://lpdaac.usgs.gov/get_data</a> Tropical Rainfall Measuring Mission (TRMM)</li> </ol>
24	Halmar Halide (2008)	<ol style="list-style-type: none"> <li>1. Public Health Division at the city of Makassar</li> <li>2. Physics Department at Hasanuddin University</li> <li>3. Department of Public Health at Hasanuddin University</li> <li>4. Makassar Bureau of Meteorology and Geophysics</li> <li>5. Climate Prediction Center-NCEP-NOAA - <a href="http://www.cpc.ncep.noaa.gov/data/indices/sstoi.indices">www.cpc.ncep.noaa.gov/data/indices/sstoi.indices</a></li> <li>6. WMO Station - Hasanuddin Airport</li> </ol>

Fonte: elaborado pelo autor.

\* Descritos como foram informados nos artigos, sem tradução, para não comprometer a interpretação.

## APENDICE H – OBJETIVOS DOS ARTIGOS INCLUÍDOS

Seq.	Primeiro autor (ano)	Objetivos
1	Chaturangi Edussuriya / 2021 (16)	Estudar se existe uma relação matemática entre o número de casos de dengue e a precipitação média, umidade, velocidade do vento, temperatura e densidade populacional. Desenvolver um modelo para prever o número de casos de um determinado mês de um determinado distrito usando dados existentes. E, desenvolver um modelo preditivo de número de casos de meses sucessivos usando dados de um mês índice
2	K.K.W.H. Erandi / 2021 (60)	Introduzir o tempo na variação dos parâmetros do modelo, modificar o modelo compartimental clássico melhorando seu poder de previsibilidade. Determinar a função do parâmetro de densidade vetorial per capita orientada por dados climáticos
3	Jessica Liebig / 2021 (61)	Prever a probabilidade de viajantes importarem dengue de outros países, e a probabilidade desses viajantes causarem surtos locais
4	Nurul Azam Mohd Salim / 2021 (65)	Prever surtos de dengue utilizando modelos de aprendizado de máquina
5	Felipe J. Colón- González / 2021 (59)	Gerar um superconjunto de modelos probabilísticos de dengue para prever o risco de dengue com até 6 meses de antecedência. E demonstrar uma avaliação geral do desempenho do método
6	Naizhuo Zhao / 2020 (12)	Desenvolver dois conjuntos de modelos de florestas aleatórias em nível nacional e em nível de departamento na Colômbia para prever casos semanais de dengue com 12 semanas de antecedência
7	Donald Salami / 2020 (54)	Aplicar algoritmos de aprendizado de máquina para desenvolver um modelo preditivo para o risco de importação de dengue na Europa
8	Michael A. Johansson / 2019 (11)	Desenvolver um desafio de previsão colaborativo aberto para avaliar previsões probabilísticas para epidemias sazonais de dengue, utilizando uma variedade de métodos e dados para gerar previsões para 3 alvos epidemiológicos (pico de

<b>Seq.</b>	<b>Primeiro autor (ano)</b>	<b>Objetivos</b>
		incidência, semana do pico e incidência total) em 8 temporadas de dengue, nas cidades de Iquitos, no Peru, e San Juan, em Porto Rico
9	Raghvendra Jain / 2019 (66)	Criar um sistema que possa utilizar as informações relevantes disponíveis sobre os fatores responsáveis pela disseminação da dengue e usá-lo para prever a ocorrência de dengue dentro de uma região geográfica, para que os especialistas em saúde pública possam se preparar, gerenciar e controlar a epidemia
10	Cecilia A. Marques- Toledo / 2019 (62)	Desenvolver um modelo probabilístico útil para entender a dinâmica da dengue usando fatores de risco associados à vulnerabilidade e receptividade
11	Bernard Bett / 2019 (56)	Determinar tendências sazonais, desenvolver mapas de risco e um modelo de previsão de incidência
12	Gayan P. Withanage / 2018 (67)	Desenvolver e validar um modelo de previsão simples e preciso para o Distrito de Gampaha, no Sri Lanka
13	Yirong Chen / 2018 (58)	Desenvolver um conjunto de modelos, cada um dos quais fará uma previsão para uma janela de tempo especificada, com base nos dados disponíveis quando a previsão é feita
14	Gilberto Sánchez- González / 2018 (33)	Apresentar um modelo matemático que considera a maioria dos fatores biológicos que influenciam a dinâmica da infecção pelo vírus da dengue, tanto em mosquitos quanto em humanos
15	Stephen A. Lauer / 2018 (68)	Prever a incidência antecipada de temporadas de dengue hemorrágica nas províncias da Tailândia
16	Pi Guo / 2017 (13)	Usar os algoritmos de aprendizado de máquina de última geração para desenvolver um modelo preditivo preciso da dengue
17	Padet Siriyasatien / 2016 (55)	Analisar e aprimorar o poder preditivo de um novo modelo de previsão avaliado pelo critério de informação de Akaike (AIC), critério de informação Bayesiano (BIC), e erro percentual absoluto médio (MAPE)

<b>Seq.</b>	<b>Primeiro autor (ano)</b>	<b>Objetivos</b>
18	Rachel Lowe / 2016 (69)	Avaliar o protótipo utilizado como sistema de alerta precoce de dengue 3 meses antes a Copa de Mundo de 2014, em relação aos casos reais de dengue relatados durante o evento
19	Yuan Shi / 2016 (70)	Descrever uma nova abordagem para a previsão da dengue de Singapura no planejamento do controle do vetor e na comunicação pública
20	Ta-Chien Chan / 2015 (57)	Fornecer previsão de risco de dengue quase em tempo real para uma pequena área
21	Kraisak Kesorn / 2015 (17)	Melhorar um sistema de vigilância da dengue em áreas com clima semelhante, explorando a taxa de infecção no mosquito <i>Aedes aegypti</i>
22	Anna L. Buczak(63) / 2014	Prever a incidência elevada e baixa de dengue, a fim de fornecer advertências prévias oportunas nas Filipinas
23	Anna L. Buczak / 2012 (71)	Prever a incidência futura de dengue como ALTA (surto) ou BAIXA (sem surto), onde esses valores são definidos como acima e abaixo da incidência média anterior de dengue mais dois desvios padrão, respectivamente
24	Halmar Halide / 2008 (72)	Desenvolver e testar um modelo estatístico para prever casos mensais de Febre Hemorrágica da Dengue (FHD) da cidade de Makassar

Fonte: elaborado pelo autor.