

MODELAGEM ESPAÇO-TEMPORAL DA INCIDÊNCIA DE DENGUE NA REGIÃO DA GRANDE VITÓRIA (RGV) - ES

Bruna Campos LYRIO¹
Nátaly Adriana Jiménez MONROY ²
Fabio Alexander Fajardo MOLINARES²

- RESUMO: O Estado do Espírito Santo sofreu vários surtos de dengue nas últimas décadas, transformando essa doença em um grave problema de saúde pública. De acordo com o Ministério da Saúde, em 2013, o Estado ocupou o quinto lugar entre os onze Estados com maior incidência de dengue, já no ano de 2016, chegou a ocupar o terceiro lugar no ranking dos Estados em incidência da doença. O presente estudo propõe uma metodologia alternativa para a modelagem da incidência de dengue na Região da Grande Vitória (RGV) - Brasil, através do modelo ARMA espaço-temporal. O modelo mostrou-se bastante adequado para os dados aqui analisados. Foi identificada associação espacial e temporal, sendo que as taxas de incidência dos municípios são influenciadas diretamente pelas taxas observadas no período de até dois meses antes, tanto no município em questão quanto nos municípios vizinhos.
- PALAVRAS-CHAVE: Incidência de dengue; modelos espaço-temporais; modelo STARMA.

1 Introdução

A dengue é uma doença febril aguda, não contagiosa, cujo agente etiológico é um vírus do gênero Flavivírus. Atualmente são conhecidos quatro sorotipos distintos: DEN-1, DEN-2, DEN-3 e DEN-4. O vírus é transmitido para o ser humano pela picada da fêmea do mosquito *Aedes aegypti*, que ocorre preferencialmente durante o dia. A doença é típica de regiões tropicais e

¹Universidade Federal do Espírito Santo - UFES, Departamento de Estatística, CEP: 29075-910, Vitória, ES, Brasil. E-mail: *bclyrrio@gmail.com*

²Universidade Federal do Espírito Santo - UFES, Departamento de Estatística, Laboratório de Estatística e Computação Natural - LECON, CEP: 29075-910, Vitória, ES, Brasil. E-mail: *nataly.monroy@ufes.br; fabio.molinares@ufes.br*

subtropicais, ocorrendo mais frequentemente no verão, principalmente após períodos chuvosos.

Alguns sintomas da dengue envolvem febre, cefaléia intensa, dores nos olhos e nas articulações, além de manchas avermelhadas na pele. De acordo com Tauil (2001), com a intensificação do processo de urbanização e desmatamento, a incidência de dengue teve um aumento no Brasil. O mosquito, que antes vivia em áreas de florestas, se deslocou para as áreas urbanas, onde encontrou um ambiente propício para a sua proliferação.

Em julho de 2016 chegou ao mercado uma das estratégias mais aguardadas para combater a doença, uma vacina indicada para os quatro tipos do vírus da dengue. Entretanto, a vacina ainda levanta dúvidas entre os cientistas sobre sua eficácia e seus possíveis riscos. Um estudo feito por um grupo de pesquisadores da Universidade de Lisboa, em Portugal e da Universidade de Ciências da Saúde, nos Estados Unidos sugere que o uso em massa da vacina na população pode aumentar os casos graves da doença. Conseqüentemente, apesar do surgimento da vacina, formas alternativas de prevenção devem ser discutidas e adotadas.

Nesse contexto, a participação comunitária ainda é de grande importância para o controle do *Aedes aegypti*, uma vez que a maioria dos criadouros do mosquito situa-se no interior ou próximo às residências, como em reservatórios de água criados pelo próprio homem. Esse controle deve ser feito principalmente contra a forma larvária do mosquito.

Outra forma de combater o vírus consiste em entender a dinâmica da incidência de dengue nas regiões afetadas. Estudos relacionados foram desenvolvidos por diversos autores, sendo comumente abordados de forma univariada, isto é, com um enfoque temporal ou espacial isoladamente. Entre esses trabalhos temos por exemplo os estudos de Martinez, Silva e Fabbro (2011), que ajustaram um modelo SARIMA para a predição do número de casos de dengue em Campinas, SP. Costa (2013) analisou espacialmente o risco de dengue no município de Campinas considerando a abordagem bayesiana. Santos et al. (2013) analisaram a estratificação de áreas prioritárias de dengue no estado do Pará, fazendo uso de técnicas de estatística espacial como o índice de Moran local e global para confirmar a presença de autocorrelação nos casos da doença, já Silva, Silva e Chaves (2014) utilizaram o estimador de intensidade Kernel para obter o mapa das áreas de risco do município de João Pessoa, PB. Silva et al. (2016) analisaram a relação entre a pluviosidade, temperatura e ocorrência de casos de dengue em São Luís, MA.

Na perspectiva espaço-temporal, os modelos mais comumente encontrados são bayesianos, como no estudo de Monsalve, Rubio-Palis e Pérez (2010), que ajustaram um modelo bayesiano espaço-temporal de fatores associados com a incidência de dengue na área metropolitana de Maracay, Venezuela. Lowe et al. (2016) desenvolveram um modelo sazonal-espacial para explicar a dependência da dengue temporalmente e espacialmente em províncias da Tailândia.

Por sua vez, na perspectiva clássica, os modelos espaço-temporais autorregressivos de médias móveis (STARMA) propostos por Pfeifer e Deutsch (1980b) têm se destacado por sua aplicabilidade e por serem uma alternativa para

analisar a dinâmica espaço-temporal de conjuntos de dados em uma ampla variedade de cenários. O modelo STARMA é uma generalização do clássico modelo ARMA (BOX; JENKINS, 1976), que permite a incorporação de dependência espacial além da temporal.

Os modelos STARMA têm sido objeto de estudo nos últimos anos e diversas aplicações práticas podem ser encontradas na literatura, por exemplo, Rao e Antunes (2004) modelaram séries de temperaturas mensais em 9 regiões do Reino Unido utilizando modelos da classe STARMA e compararam com modelos da classe SARIMA. Os resultados mostraram que os modelos espaço-temporais foram mais eficientes se comparados com os temporais. Giacinto (2006) propôs a aplicação de um modelo STARMA generalizado para dados de desemprego regional na Itália. Glasbey e Allcroft (2008) desenvolveram um modelo Espaço-Temporal Autorregressivo (STAR) para dados de radiação solar e mostraram sua utilidade em outros conjuntos de dados semelhantes ao apresentado. Martins, Biz e Ozaki (2014) ajustaram modelos da classe STARMA sazonal para dados de temperaturas mínimas médias mensais provenientes de estações meteorológicas.

Entretanto, na área de saúde, mais especificamente no estudo de doenças, esses modelos ainda são pouco explorados, sendo essa a principal motivação para a realização deste estudo. Nesse contexto, o objetivo é realizar a análise espaço-temporal da incidência de dengue na Região da Grande Vitória, ES, usando o modelo STARMA. Os resultados podem ajudar a entender o comportamento epidemiológico do vírus simultaneamente no tempo e no espaço, o que é de suma importância para as autoridades locais no momento de instituir mecanismos e políticas de prevenção e controle da dengue.

O artigo encontra-se organizado da seguinte forma. Na Seção 2 apresentam-se uma breve descrição do conjunto de dados sob estudo, a definição do modelo utilizado para analisar os dados e uma discussão dos resultados encontrados no ajuste do modelo. Finalmente, a Seção 3 contém as principais conclusões desta pesquisa.

2 Material e métodos

2.1 Conjunto de dados

A Região Metropolitana da Grande Vitória (RMGV), localizada no Estado do Espírito Santo, é composta por sete municípios: Cariacica, Fundão, Guarapari, Serra, Viana, Vila Velha e Vitória, sendo a região mais populosa e de maior desenvolvimento comercial do Estado. Os dados aqui analisados são constituídos pelas taxas de incidência de dengue na RMGV, obtidos do site da Secretaria de Saúde do Estado do Espírito Santo pelo SINAN NET/SINAN *Online*. As taxas de incidência de dengue (por 100.000 habitantes) foram calculadas mensalmente para os sete municípios no período de janeiro de 2001 a dezembro de 2010, totalizando 120 observações. A Figura 1 mostra a incidência média para cada município no período avaliado.



Figura 1 - Incidência média de dengue (por 100.000 habitantes) na RMGV - ES, no período de janeiro de 2001 a dezembro de 2010.

2.2 Modelos STARMA

Modelos da classe STARMA foram desenvolvidos por Pfeifer e Deutsch (1980a) e Pfeifer e Deutsch (1980b). Essa classe de modelos considera uma dependência linear defasada tanto no tempo quanto no espaço, ou seja, tem-se uma variável aleatória $Z_i(t)$ observada em N localizações fixas no espaço em T períodos de tempo. Os N locais fixos no espaço podem ser representados por Países, Estados, estações de monitoramento de um material particulado, dentre outros.

A dependência entre as N localidades é incorporada no modelo por meio de matrizes de ponderação quadradas de dimensão $N \times N$. Mais especificamente, sob alguma definição arbitrária de vizinhança estabelecida pelo pesquisador, a matriz de ponderação de ordem l , $\mathbf{W}^{(l)}$, é formada pelos elementos $w_{ij}^{(l)}$, que são diferentes de zero apenas se as localidades i e j são vizinhas de l -ésima ordem. Além disso, as entradas $w_{ij}^{(l)}$ devem satisfazer:

$$\sum_{j=1}^N w_{ij}^{(l)} = 1. \quad (1)$$

O modelo STARMA($p_{\lambda_1 \dots \lambda_p}, q_{m_1 \dots m_q}$) pode ser representado por:

$$\mathbf{z}(t) = - \sum_{k=1}^p \sum_{l=0}^{\lambda_k} \phi_{kl} \mathbf{W}^{(l)} \mathbf{z}(t-k) + \sum_{k=1}^q \sum_{l=0}^{m_k} \theta_{kl} \mathbf{W}^{(l)} \epsilon(t-k) + \epsilon(t), \quad (2)$$

em que,

$z(t) = [z_1(t), \dots, z_N(t)]'$ é um vetor $N \times 1$ de observações no tempo t , $t = 1, \dots, T$;

p representa a ordem AR;

q representa a ordem MA;

λ_k representa a ordem espacial do k -ésimo termo AR;

m_k representa a ordem espacial do k -ésimo termo MA;

ϕ_{kl} e θ_{kl} são os parâmetros na defasagem temporal k e espacial l ;

$\mathbf{W}^{(l)}$ é a matriz $N \times N$ de ponderações, $l > 0$.

Se $l = 0$, tem-se que $\mathbf{W}^{(l)} = \mathbf{I}_N$, a matriz identidade de dimensão N . O modelo é estacionário se:

$$\det \left(\mathbf{I}_N + \sum_{k=1}^p \sum_{l=0}^{\lambda_k} \phi_{kl} \mathbf{W}^{(l)} x^k \right) \neq 0, \text{ com } |x| \leq 1.$$

A construção do modelo STARMA se dá em três estágios, são eles: identificação, estimação dos parâmetros e, por fim, a verificação do diagnóstico. A identificação do modelo constitui o primeiro passo na sua construção e é baseada principalmente nas funções de autocorrelação e autocorrelação parcial espaço-temporal.

Após a escolha do modelo candidato da classe STARMA no processo de identificação, é necessário estimar os parâmetros. A melhor estimativa dos parâmetros $\Phi = [\phi_{10}, \phi_{11}, \dots, \phi_{1\lambda_1}, \dots, \phi_{p0}, \phi_{p1}, \dots, \phi_{p\lambda_p}]'$ e $\Theta = [\theta_{10}, \theta_{11}, \dots, \theta_{1\lambda_1}, \dots, \theta_{q0}, \theta_{q1}, \dots, \theta_{q\lambda_q}]'$ é baseada nas estimativas de máxima verossimilhança.

Para verificar se o modelo ajustado se adequa corretamente aos dados, é necessário fazer uma análise residual e observar se estes são ruído branco, ou seja, possuem média zero e matriz variância-covariância $\sigma^2 \mathbf{I}_N$ e $\gamma_{lk}(s) = 0$ para todo $s \neq 0$, onde $\gamma_{lk}(s)$ são as autocovariâncias de defasagens espaciais diferentes de 0.

2.3 Resultados e discussões

A Tabela 1 apresenta algumas estatísticas descritivas das taxas de incidência de dengue relativas aos municípios da Grande Vitória no período analisado. Observa-se que apenas o município da Serra obteve incidência não nula para todos os meses. O fato de não haver nenhum mês com incidência nula na maioria dos municípios indica que a dengue tornou-se endêmica na região (CARDOSO, 2010). Ainda, a maior taxa média de incidência de dengue ocorreu para o município de Guarapari, o qual apresenta também taxas mais dispersas. Fundão, no entanto, obteve a menor média de incidência de dengue no período, uma vez que em um número considerável de meses não apresentou nenhum caso registrado da doença, o que levanta suspeitas de subnotificação. Dessa maneira, optou-se por desconsiderar o município na modelagem dos dados.

Tabela 1 - Estatísticas descritivas (mínimo, máximo, quartis e média) das taxas de incidência de dengue (100.000 habitantes) referentes aos municípios da RMGV no período de janeiro de 2001 a dezembro de 2010

Município	Mínimo	1 ^o Quartil	Mediana	Média	3 ^o Quartil	Máximo
Cariacica	0,00	2,99	9,86	31,25	27,78	616,88
Fundão	0,00	0,00	0,00	3,55	6,49	72,09
Guarapari	0,00	2,98	14,30	67,91	68,07	825,95
Serra	0,28	6,50	20,81	62,25	62,80	666,93
Viana	0,00	1,79	7,91	44,11	30,49	849,20
Vila Velha	0,00	2,62	6,12	46,48	45,75	679,20
Vitória	0,00	3,45	14,28	55,10	42,16	748,43

As séries temporais originais obtidas são mostradas na Figura 2. Observa-se que os meses de fevereiro, março e abril registraram grande número de casos de dengue na maioria dos municípios, consequências do calor e das chuvas esporádicas. Observa-se também que as maiores taxas históricas foram apresentadas nos anos de 2003 e 2009, sendo que depois deste ano, a tendência foi de diminuição das incidências na maioria dos municípios. Esses resultados estão de acordo com o estudo realizado por Cardoso (2010), em que se afirma que a região sofreu várias epidemias de dengue, sendo que as mais fortes foram identificadas em 2003 e 2009.

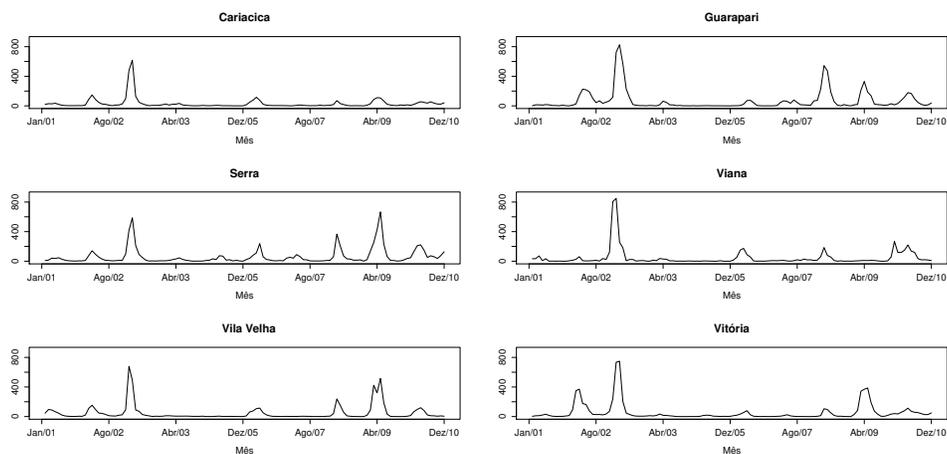


Figura 2 - Taxas de incidência de dengue (por 100.000 habitantes) para os seis municípios considerados na modelagem (janeiro de 2001 a dezembro de 2010).

Em uma série temporal é comum a presença de oscilações de subida e descida de forma suave e repetida, as quais chamamos de ciclos. A função de autocorrelação das séries univariadas indica a presença dessas oscilações (ver Figura 3). Sendo

assim, os dados foram tratados utilizando o método da Análise Espectral Singular - SSA (para maiores detalhes, ver Broomhead e King (1986) e Broomhead, Jones e King (1987)). As séries temporais dos dados já tratados são apresentadas na Figura 4, sendo esses dados transformados os considerados na modelagem.

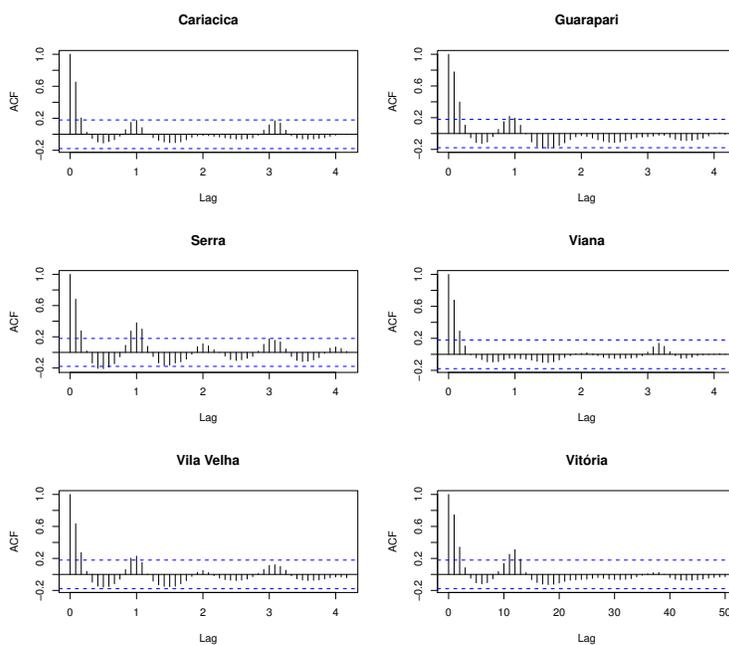


Figura 3 - Função de autocorrelação das séries temporais originais para os seis municípios da RMGV considerados na modelagem.

A modelagem e a análise dos dados foram realizadas com o auxílio do software R (R Core Team, 2018) utilizando o pacote STARMA. O primeiro passo da modelagem STARMA consiste na construção da matriz de ponderações \mathbf{W} , processo que envolve a transformação das coordenadas geodésicas dos municípios para o sistema UTM. A matriz \mathbf{W} foi calculada utilizando o inverso da distância euclidiana. Devido à proximidade dos municípios, a primeira ordem de vizinhança foi considerada

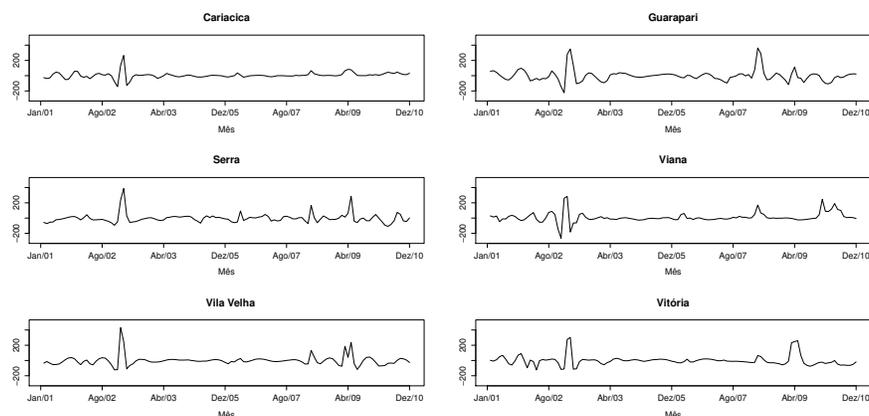


Figura 4 - Séries temporais dos municípios da RMGV após o tratamento pelo método da Análise Espectral Singular (período de janeiro de 2001 a dezembro de 2010).

suficiente na análise espacial. Assim, na modelagem foram consideradas as matrizes:

$$\mathbf{W}^{(0)} = I_6$$

$$\mathbf{W}^{(1)} = \begin{pmatrix} 0.0000 & 0.0918 & 0.1777 & 0.2351 & 0.2032 & 0.2922 \\ 0.1934 & 0.0000 & 0.1319 & 0.3016 & 0.1829 & 0.1903 \\ 0.2496 & 0.0879 & 0.0000 & 0.1431 & 0.2491 & 0.2703 \\ 0.2991 & 0.1821 & 0.1296 & 0.0000 & 0.1771 & 0.2122 \\ 0.1596 & 0.0682 & 0.1393 & 0.1093 & 0.0000 & 0.5237 \\ 0.2074 & 0.0641 & 0.1366 & 0.1184 & 0.4735 & 0.0000 \end{pmatrix}$$

Ressalta-se que, quanto maiores os pesos, mais próximas estão as localidades. De posse da matriz $\mathbf{W}^{(1)}$ é possível proceder ao ajuste do modelo. No processo de identificação da ordem do modelo STARMA faz-se necessário conhecer as funções de autocorrelação (STACF) e autocorrelação parcial espaço-temporal (STPACF) dos dados, representadas na Figura 5.

Observa-se que o tratamento dos dados com a técnica SSA cumpriu seu objetivo, retirando o efeito dos ciclos nos dados. Assim, os dados depurados mostram que há correlação espacial significativa até a terceira ordem autorregressiva (Figura 5a). Já a Figura 5b mostra que há correlação espacial significativa até a quarta ordem de médias móveis. Isto indica que há influência dos municípios vizinhos nas taxas de incidência.

A Tabela 2 apresenta alguns modelos ajustados, o valor do critério de informação BIC (Bayesian Information Criterion) e a variância (σ^2) estimada de cada um. Os modelos STARMA(2₁₁, 1) e STARMA(2₁₁, 0) foram os únicos que

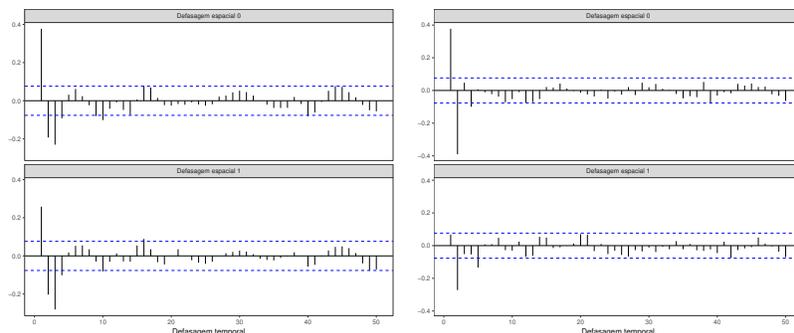


Figura 5 - Funções de autocorrelação espaço-temporal e autocorrelação parcial espaço-temporal dos dados tratados com a Análise Espectral Singular.

apresentaram todos os parâmetros significativamente diferentes de zero. Observa-se que os valores do BIC e da variância para esses modelos são bastante próximos. Assim, a escolha foi pelo modelo STARMA(2₁₁, 0) por ser o mais parcimonioso, isto é, o modelo com menos parâmetros.

Tabela 2 - Modelos identificados e seus respectivos BIC e σ^2 estimada

Modelo	BIC	σ^2 estimada
STARMA(1 ₁ , 1)	1772,70	0,868
STARMA(2 ₁ , 1 ₁)	1778,83	0,965
STARMA(1 ₁ , 2 ₁)	1819,09	1,081
STARMA(2 ₁₁ , 1)	1773,81	0,989
STARMA(2 ₁₁ , 0)	1765,93	0,991

A Tabela 3 apresenta o resumo dos parâmetros estimados do modelo selecionado, bem como seus respectivos erros-padrão e valores p. Pode-se observar que o erro-padrão relativo a cada estimativa é bastante pequeno, indicando alta precisão das estimativas. Isto certamente refletirá na capacidade do modelo para descrever a dinâmica da doença na região.

Tabela 3 - Resumo do modelo STARMA(2₁₁, 0) selecionado

Parâmetro	Estimativa	Erro-padrão	Valor p
ϕ_{10}	0,453	0,051	< 0,00001
ϕ_{11}	0,155	0,067	0,02186
ϕ_{20}	-0,266	0,051	< 0,00001
ϕ_{21}	-0,265	0,068	0,00011

Assim, o modelo ajustado pode ser expresso como:

$$\hat{z}(t) = -0,453z(t-1) - 0,155Wz(t-1) + 0,266z(t-2) + 0,265Wz(t-2).$$

O modelo indica que a taxa de incidência de dengue em uma cidade é influenciada diretamente pelas incidências observadas em até dois meses anteriores, não apenas no próprio município, mas também nos municípios mais próximos. Essa dependência espacial pode ser comprovada em outros trabalhos como em Defavari et al. (2017) que avaliaram a incidência e a distribuição espacial da dengue em um município do Estado de São Paulo no período de 2008 a 2015. Nesse estudo, os autores identificaram associação espacial da dengue com os bairros, nos anos de 2011, 2012 e 2013.

Observa-se também que as incidências observadas em até dois meses antes ($\phi_{20} = -0,266$ e $\phi_{21} = -0,265$) influenciam em maior medida às incidências estimadas, independentemente da ordem de vizinhança. No caso das incidências observadas no mês anterior, a maior contribuição é dada pelas taxas observadas no mesmo município ($\phi_{10} = 0,453$).

Assim como na classe dos modelos univariados, é necessário observar a função de autocorrelação espaço-temporal dos resíduos para verificar a suposição de que os erros são não correlacionados. A Figura 6 apresenta a STACF dos resíduos do modelo ajustado.

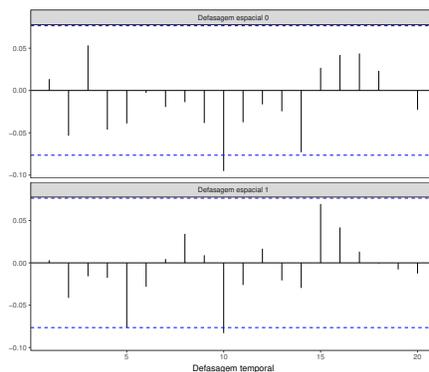


Figura 6 - Função de autocorrelação espaço-temporal dos resíduos do modelo ajustado.

Observa-se que as magnitudes das autocorrelações são pequenas e encontram-se dentro dos limites de confiança (intervalo de 95%). Adicionalmente, o teste de correlação de Box-Pierce indica a não rejeição da hipótese de resíduos não-correlacionados (valor $p = 0,39$). Uma vez que o modelo satisfaz os pressupostos, considera-se que o modelo é adequado.

As séries tratadas e ajustadas para cada município podem ser observadas na Figura 7, onde na cor vermelha encontram-se as séries tratadas e na cor azul as

estimadas. Observa-se que as séries estimadas acompanham o comportamento das séries tratadas, indicando que o modelo se ajustou adequadamente aos dados.

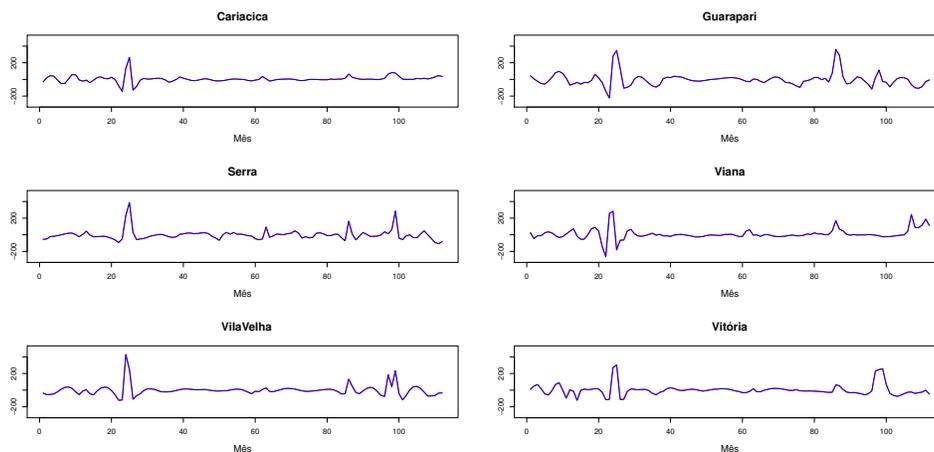


Figura 7 - Séries temporais tratadas (—) e estimadas (---).

Com o objetivo de verificar a qualidade do ajuste do modelo, algumas medidas que comparam os valores estimados pelo modelo com os valores observados podem ser usadas. Algumas delas são o Erro Médio (ME) e a Raiz do Erro Quadrático Médio (RMSE), calculadas como:

$$ME_i = \frac{1}{T} \sum_{t=1}^T [z_i(t) - \hat{z}_i(t)]$$

$$RMSE_i = \sqrt{\frac{1}{T} \sum_{t=1}^T [z_i(t) - \hat{z}_i(t)]^2},$$

onde $z_i(t)$ representa a t -ésima observação no local i . Aqui $i = 1, 2, \dots, 6$, $t = 1, \dots, 120$. A Tabela 4 apresenta os valores dessas medidas para cada um dos municípios da Região da Grande Vitória.

Verifica-se que os valores das medidas de precisão são significativamente pequenos, o que reforça o satisfatório ajuste do modelo aos dados. Os valores negativos do ME para a maioria dos municípios indica que o modelo tende a subestimar levemente os valores. O município de Cariacica apresentou as estimações mais precisas (RMSE=0,504) e o município de Viana mostrou a maior imprecisão nas estimações (RMSE=0,977). Isto indica que o modelo consegue estimar com maior precisão os conjuntos de dados com menor variabilidade.

Tabela 4 - Medidas de precisão (ME e RMSE) para o ajuste do Modelo STARMA(2₁₁, 0)

Município	ME	RMSE
Cariacica	0,032	0,504
Guarapari	-0,029	0,902
Serra	-0,050	0,838
Viana	0,092	0,977
Vila Velha	-0,040	0,938
Vitória	-0,006	0,802

3 Conclusões

O presente artigo utiliza uma metodologia baseada no modelo ARMA espaço-temporal (STARMA) com o objetivo de modelar a dinâmica da dengue na RGV por meio das taxas de incidência nos municípios da região. Pode-se concluir que essa incidência possui uma dependência tanto temporal quanto espacial, visto que as correlações são significativas nas funções de autocorrelação e autocorrelação parcial espaço-temporal, nas duas ordens de vizinhança (0 e 1). O modelo ajustado se mostrou apropriado aos dados, sendo que as medidas de precisão indicam que os valores ajustados são muito próximos dos valores reais em todos os municípios. Em outras palavras, os resultados desta pesquisa mostram que a incidência de dengue em uma cidade é influenciada diretamente pela incidência nas cidades mais próximas, assim como pelos índices registrados nos dois meses anteriores.

Agradecimentos

Os autores gostariam de agradecer os revisores e editores pelos comentários e sugestões.

LYRIO, B. C.; MONROY, N. A. J.; MOLINARES, F. A. F. Space-Time modeling of the incidence of dengue fever in Greater Vitória Region, Brazil. *Rev. Bras. Biom.*, Lavras, v.37, n.2, p.135-148, 2019.

- **ABSTRACT:** *The State of Espírito Santo have suffered several dengue breakouts along the last decades, turning this disease into a major public health problem. According to the Brazilian Department of Health, in 2013, the State was fifth among the 11 States with the highest incidences of dengue. In 2016, the State was the third with higher incidence in Brazil. This work presents the space-time ARMA model as an alternative methodology for modeling the dengue incidence using data from the Greater Vitoria Region, Brazil. The model showed to be very suitable for the analyzed data. Spatial and temporal associations were identified, the incidence rates of the cities are directly influenced by the rates observed in the closest neighbors as well as in the same city, until two months earlier.*

■ **KEYWORDS:** *Incidence of dengue; space-time models; STARMA Model.*

Referências

BOX, G. E.; JENKINS, G. M. *Time series analysis: forecasting and control, revised ed.* [S.l.]: Holden-Day, 1976.

BROOMHEAD, D.; JONES, R.; KING, G. P. Topological dimension and local coordinates from time series data. *Journal of Physics A: Mathematical and General*, IOP Publishing, v. 20, n. 9, p. L563, 1987.

BROOMHEAD, D. S.; KING, G. P. Extracting qualitative dynamics from experimental data. *Physica D: Nonlinear Phenomena*, Elsevier, v. 20, n. 2-3, p. 217–236, 1986.

CARDOSO, I. M. *Epidemiologia da dengue em Vitória-ES, 1995-2009*. Dissertação (Mestrado) — Universidade Federal do Espírito Santo, 2010.

COSTA, J. V. *Análise espacial do risco de dengue no município de Campinas: modelagem bayesiana*. Tese (Doutorado) — Universidade Estadual de Campinas, Campinas, 2013.

DEFAVARI, E. R. et al. Análise espacial da incidência da dengue em um município de médio porte do Estado de São Paulo de 2008 a 2015. *Revista de Saúde Coletiva da UEFS*, 2017.

GIACINTO, V. D. A generalized space-time ARMA model with an application to regional unemployment analysis in Italy. *International Regional Science Review*, Sage Publications Sage CA: Thousand Oaks, CA, v. 29, n. 2, p. 159–198, 2006.

GLASBEY, C.; ALLCROFT, D. A spatiotemporal auto-regressive moving average model for solar radiation. *Journal of the Royal Statistical Society: Series C (Applied Statistics)*, Wiley Online Library, v. 57, n. 3, p. 343–355, 2008.

LOWE, R. et al. Quantifying the added value of climate information in a spatio-temporal dengue model. *Stochastic environmental research and risk assessment*, Springer, v. 30, n. 8, p. 2067–2078, 2016.

MARTINEZ, E. Z.; SILVA, E. A. S. d.; FABRO, A. L. D. A SARIMA forecasting model to predict the number of cases of dengue in Campinas, state of São Paulo, Brazil. *Revista da Sociedade Brasileira de Medicina Tropical*, SciELO Brasil, v. 44, n. 4, p. 436–440, 2011.

MARTINS, N. da S.; BIZ, G.; OZAKI, V. A. Modelo autorregressivo de média móvel espaço-temporal aplicado em dados de temperaturas mínimas médias mensais. *Revista Brasileira de Biometria*, v. 32, n. 1, p. 158–169, 2014.

MONSALVE, N.; RUBIO-PALIS, Y.; PÉREZ, M. Modelaje bayesiano espacio-temporal de factores asociados con la incidencia del dengue en el área metropolitana de Maracay, Venezuela. *Bol Mal Salud Amb*, v. 50, n. 2, p. 219–232, 2010.

PFEIFER, P. E.; DEUTSCH, S. J. Identification and interpretation of first order space-time ARMA models. *Technometrics*, Taylor & Francis, v. 22, n. 3, p. 397–408, 1980.

PFEIFER, P. E.; DEUTSCH, S. J. A three-stage iterative procedure for space-time modeling. *Technometrics*, Taylor & Francis, v. 22, n. 1, p. 35–47, 1980.

R Core Team. *R: A Language and Environment for Statistical Computing*. Vienna, Austria, 2018. Disponível em: <https://www.R-project.org/>.

RAO, T. S.; ANTUNES, A. M. C. Spatio-temporal modelling of temperature time series: a comparative study. In: *Time series analysis and applications to geophysical systems*. [S.l.]: Springer, 2004. p. 123–150.

SANTOS, C. A. et al. Epidemiologia espacial para casos de dengue no Estado do Pará. *Anais XVI Simpósio Brasileiro de Sensoriamento Remoto - SBSR*, 2013.

SILVA, F. D. et al. Temporal relationship between rainfall, temperature and occurrence of dengue cases in São Luís, Maranhão, Brazil. *Ciencia & saude coletiva*, SciELO Public Health, v. 21, n. 2, p. 641–646, 2016.

SILVA, R. M. da; SILVA, A. M.; CHAVES, J. J. S. Vulnerabilidade espacial da dengue e sua relação com a variabilidade termoplúviométrica em João Pessoa - PB. *Hygeia: Revista Brasileira de Geografia Médica e da Saúde*, Associação Nacional de Pesquisa e Pós-Graduação em Geografia, Grupo de Trabalho de Geografia da Saúde, v. 10, n. 18, p. 177, 2014.

TAUIL, P. L. Urbanização e ecologia do dengue. *Cadernos de Saúde Pública*, SciELO Public Health, v. 17, p. S99–S102, 2001.

Recebido em 28.02.2018.

Aprovado após revisão em 16.07.2018.