

Estatística

Aplicação do modelo SARIMAX para modelar e prever a concentração de material particulado inalável, no Espírito Santo, Brasil

Application of SARIMAX model to model and forecast the concentration of inhalable particulate matter, in Espírito Santo, Brazil

Jaqueline Knaak^I, Wanderson de Paula Pinto^{II}

^I Universidade Federal do Espírito Santo, Vitória, ES, Brasil

^{II} Faculdade da Região Serrana, Santa Maria de Jetibá, ES, Brasil

RESUMO

Este trabalho teve como objetivo modelar e prever a concentração média diária de material particulado inalável (PM₁₀) utilizando o modelo SARIMAX, na Região da Grande Vitória (RGV), ES, Brasil, para o período de 01/01/2008 a 31/12/2018. Para isso, utilizaram-se séries temporais de concentrações de PM₁₀ e de variáveis meteorológicas velocidade do vento (V), umidade relativa (U), precipitação pluviométrica (PP), temperatura (T), radiação solar (I) e pressão atmosférica (P) obtidas junto ao Instituto Estadual de Meio Ambiente e Recursos Hídricos (IEMA), sendo escolhidas as estações Laranjeiras, Carapina, Jardim Camburi, Enseada do Suá, Vitória (Centro), Ibes e Vila Capixaba, para fazer o estudo de predição e previsão. Conforme os indicadores de desempenho, os modelos SARIMAX para a maioria das estações, apresentaram como bons modelos para realizar predições e previsões da qualidade do ar nas localidades. Em relação à predição de eventos de qualidade do ar regular, de forma geral, os modelos SARIMAX se sobressaíram quando comparados com os modelos SARIMA e ARMA. Entre as variáveis meteorológicas avaliadas, a V, U, PP e T destacam-se como variáveis preditoras das concentrações de PM₁₀ e assumiram papel determinante na melhoria do desempenho dos modelos de previsão.

Palavras-chave: PM₁₀; SARIMAX; Variáveis meteorológicas; Poluição do ar

ABSTRACT

This work aimed to model and forecast the average daily concentration of inhalable particulate matter (PM₁₀) using the SARIMAX model, in the Greater Vitória Region (RGV), ES, Brazil, for the period from January 1st, 2008 to December 31th, 2018. For this, time series of PM₁₀ concentration and meteorological parameters wind speed (V), relative humidity (U), precipitation (PP), temperature (T), solar radiation (I) and atmospheric pressure (P) were considered. These parameters were obtained from the State

Environmental Institute (IEMA), being chosen the Laranjeiras, Carapina, Jardim Camburi, Enseada do Suá, Vitória (Centro), Ibes and Vila Capixaba stations to the study of prediction and forecasting. According to performance indicators, SARIMAX models, for most seasons, have been presented as good models for making predictions and forecasts of air quality in the localities. Regarding the prediction of regular air quality events, in general, the SARIMAX models stood out when compared to the SARIMA and ARMA models. Among the meteorological variables evaluated, V, U, PP and T stand out as predictor variables of PM₁₀ concentrations and assumed a decisive role in improving the performance of the prediction models.

Keywords: PM₁₀; SARIMAX; Meteorological variables; Air pollution

1 INTRODUÇÃO

O ar, necessário para a sobrevivência de todos os seres vivos da Terra, tem sido um dos elementos mais agredidos pelo homem. O crescimento populacional, o aumento da frota motorizada e a expansão das atividades industriais são os principais fatores que conduziram à multiplicação das fontes de emissão de poluentes comprometendo a salubridade do ar (LIRA, 2009).

Entre os poluentes atmosféricos, o material particulado (PM) se destaca devido à sua complexidade em termos de composição química e propriedades físicas, visto que é uma classe de poluentes constituído de poeira, fumaça e todo tipo de partículas sólidas e líquidas suspensas no ar originadas de diferentes fontes, como combustão de combustíveis fósseis e reações químicas de gases na atmosfera (ARAUJO e NEL, 2009; SANTIAGO *et al.*, 2015). Além disso, possui associação intrínseca com a saúde em razão do tamanho das partículas, principalmente as partículas com diâmetro igual ou inferior a 10 microns (PM₁₀), pois são capazes de penetrar profundamente no sistema respiratório chegando no pulmão, onde se depositam nas regiões alveolares durante a respiração e podem ser absorvidas pela corrente sanguínea através dos capilares alveolares, afetando a função de vários outros órgãos, além do sistema respiratório (FIORDELISI *et al.*, 2017).

Em vista disso, vários estudos epidemiológicos associam o PM₁₀ com os diferentes danos à saúde, como o aumento de hospitalização devido morbididades respiratórias e cardiovasculares, principalmente de crianças e idosos (GOUVEIA *et al.*, 2003; NASCIMENTO *et al.*, 2007, FREITAS *et al.*, 2016), maiores chances de uma criança ter

Transtorno do Espectro do Autismo (RAZ *et al.*, 2015), risco aumentado de incidência de diabetes mellitus (BOWE *et al.*, 2018), alterações no desempenho cognitivo humano (ZHANG, CHEN e ZHANG, 2018), mortalidade cardiovascular, especialmente em idosos (YAP *et al.*, 2019), entre outros efeitos que destacam a emergência em adotar medidas de controle da poluição do ar.

Diante esse cenário, o conhecimento prévio dos níveis de poluentes na atmosfera de uma região pode ser utilizado para alertar concentrações que possam representar risco à saúde pública e permitir a tomada de ações de emergência. Os modelos de previsão de poluentes atmosféricos têm sido propostos como uma ferramenta de ajuda para a gestão da qualidade do ar em diversas cidades em todo mundo, com intuito de prever possíveis picos de concentrações e índices de qualidade do ar indesejáveis (PEREZ e REYS, 2006; GOMES, 2009).

De acordo com Leite *et al.* (2011) os efeitos causados pela emissão dos poluentes atmosféricos, ao meio ambiente e à saúde da população, podem não ser apenas locais, pois dependem do relevo do entorno do ponto de emissão, das condições meteorológicas e da natureza dos poluentes. Em consonância, Lira (2009) descreve que a concentração de um poluente no ar depende de vários fatores, não apenas das emissões das fontes, mas também de suas interações físicas (diluição) e químicas (reações) na atmosfera. Desta maneira, as condições meteorológicas possuem fundamental importância em relação a acumulação e dispersão de poluentes, visto que essas condições atuam por meio da ação de dois fenômenos fundamentais: o transporte e a difusão (MOREIRA, TIRABASSI e MORAES, 2008). Geralmente, a poluição do ar está associada a fatores como temperatura, umidade relativa, velocidade e direção do vento (LIU e JOHNSON, 2002).

Assim, variáveis meteorológicas têm sido incorporadas nos modelos de séries temporais com objetivo de melhorar o desempenho da modelagem e previsão da qualidade do ar. Como exemplo, Agirre-Basurko, Ibarra-Berastegui e Madariaga (2006), Reisen *et al.* (2014) e Pinto, Reisen e Monte (2018)

desenvolveram modelos estatísticos de previsão da qualidade do ar, para a cidade de Bilbao (Espanha) e os municípios de Cariacica, Vitória, Vila Velha e Serra (Espírito Santo, Brasil), respectivamente. De forma geral, estas pesquisas demonstraram que os modelos que consideraram, além da série do poluente estudado, outras séries temporais como variáveis explicativas, apresentaram melhor desempenho em relação à previsão das concentrações desses poluentes.

Além deles, Grippa *et al.* (2012) compararam dois modelos, a saber: um modelo de séries temporais e um modelo de regressão linear múltipla, para previsão das concentrações médias de PM_{10} monitorados na cidade da Serra, Região da Grande Vitória (RGV), com incorporação de variáveis meteorológicas. Os resultados demonstraram que a atribuição da variável explicativa (velocidade do vento) no modelo de regressão permitiu melhorar sua capacidade preditiva, apresentando melhores previsões quando comparado à análise exclusiva das séries temporais da variável sob estudo. De forma semelhante, Memarianfard e Hatami (2017) utilizaram a técnica de rede neural artificial para modelar a dispersão de partículas inaláveis com diâmetro menor ou igual a $2,5 \mu m$ ($PM_{2,5}$) usando dados meteorológicos na cidade de Teerã, Iran. As variáveis exógenas consideradas foram os poluentes: dióxido de enxofre (SO_2), monóxido de carbono (CO), dióxido de nitrogênio (NO_2) e os fatores climáticos: velocidade do vento, umidade relativa e temperatura. De acordo com os resultados obtidos, houve um melhor desempenho quando considerados no modelo as variáveis exógenas, comprovando que os padrões meteorológicos são determinantes na precisão da previsão da qualidade atmosférica local.

Nesse contexto, este trabalho teve como objetivo modelar e prever a concentração média diária de PM_{10} utilizando o Modelo Autorregressivo Integrado e de Médias Móveis Sazonal Multiplicativo com variáveis exógenas (SARIMAX), na Região da Grande Vitória (RGV), ES, Brasil, para o período de 01/01/2008 a 31/12/2018, sob justificativa de que com a atribuição de variáveis explicativas nos modelos de séries temporais é possível melhorar seu desempenho para fazer

predições e previsões da qualidade do ar da Região da Grande Vitória e, assim, este pode ser utilizado como uma ferramenta eficiente de alerta sobre a concentração de PM₁₀ na atmosfera dos municípios da localidade, proporcionando fornecer dados para ativar ações de emergência durante períodos de estagnação atmosférica, quando os níveis de poluentes possam representar risco à saúde da população. Além disso, pode ser utilizado como informação para os gestores corroborando a preparação de planos para redução de emissões e gerenciamento da qualidade do ar da região.

Vale ressaltar que o trabalho se trata de uma extensão do estudo desenvolvido por Pinto, Reisen e Monte (2018), no qual foi avaliado um maior número de estações e observações referentes ao PM₁₀ e as variáveis meteorológicas, permitindo considerar uma variação climática de tempo maior, que pode afetar a qualidade do ar em uma determinada região. Sob essas considerações, os resultados obtidos nesse trabalho tendem proporcionar informações mais reais de qualidade do ar para a RGV.

2 METODOLOGIA

2.1 Caracterização da área de estudo

A RGV, localiza-se na costa sul do estado do Espírito Santo sendo composta pelos municípios de Vitória, Vila Velha, Cariacica, Serra e Viana. Segundo o Instituto Brasileiro de Geografia e Estatística (IBGE, 2019), a RGV possui uma área de cerca de 1.456 km² com uma população estimada de aproximadamente 1.832.969 habitantes o que representa 45,61% da população total do estado.

Além disso, apresenta clima Aw (tropical quente) de acordo com a classificação de Köppen (KÖPPEN, 1900), com estações de estiagem bem definida no inverno e estação chuvosa de verão, com chuvas convectivas. Segundo IEMA (2018), as temperaturas não variam muito, concentrando-se entre 24° a 30°C. Em média, a precipitação pluvial anual total é de 1.318,6 mm, cujo período chuvoso

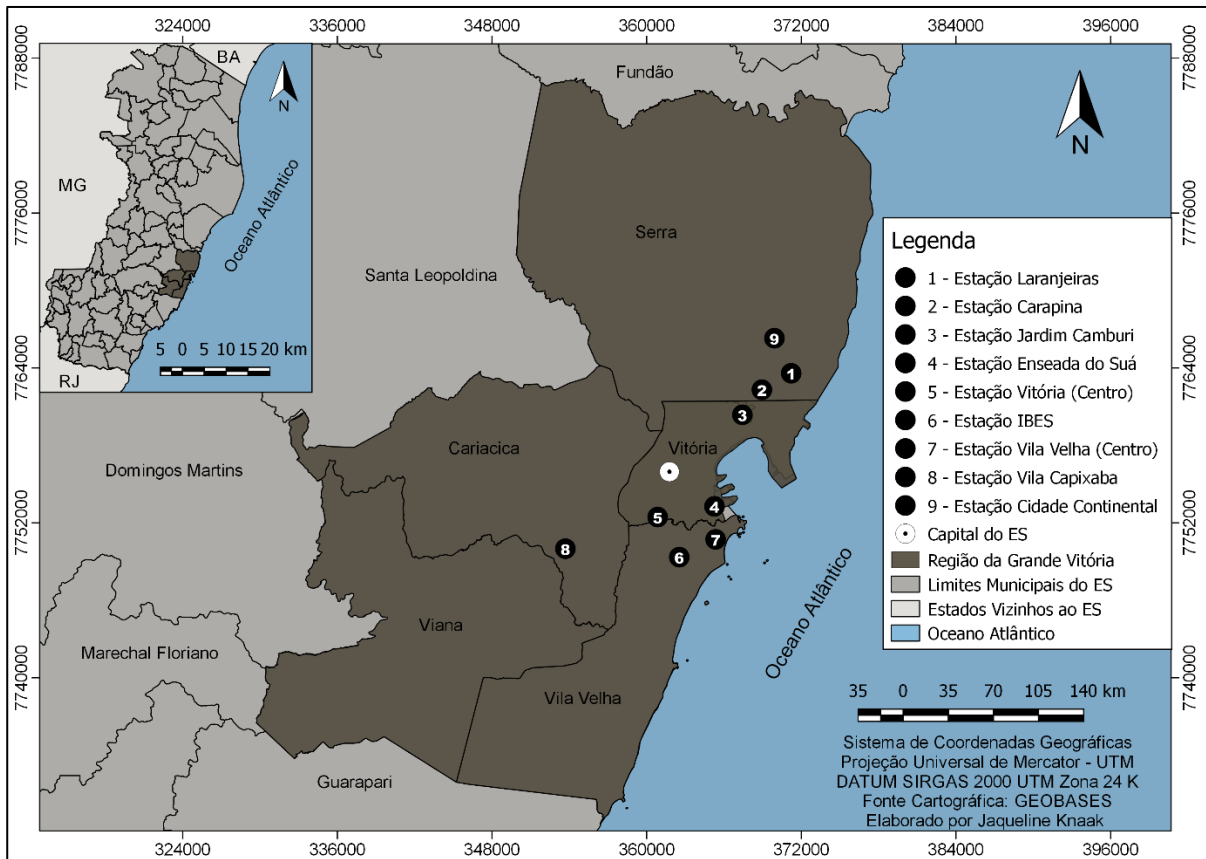
inicia-se em outubro e se estende até a metade do mês de abril. Em relação ao regime de vento, as localidades da RGV são influenciadas por brisas marinhas e terrestres - em função da proximidade com o oceano e brisas de vale montanha - em razão da topografia acidentada.

A região é caracterizada por ser uma das principais áreas de desenvolvimento urbano e industrial do estado. Devido a isso, a qualidade do ar tem sido diretamente influenciada pelas emissões de poluentes atmosféricos provenientes, principalmente, da atividade industrial, da frota veicular e da ressuspensão do solo causado pelo vento e tráfego veicular. Além desses fatores, as condições meteorológicas e da topografia dos municípios são determinantes para a salubridade do ar na região, pois atuam na acumulação e dispersão desses poluentes na atmosfera (IEMA, 2018).

Diante dessas características, em junho do ano de 2000, foi inaugurada na RGV a Rede Automática de Monitoramento da Qualidade do Ar (RAMQAr) de propriedade do Instituto Estadual de Meio Ambiente e Recursos Hídricos (IEMA). A RAMQAr é composta por nove estações distribuídas por quatro municípios da RGV, são elas: Estação Laranjeiras (E1), Estação Carapina (E2), Estação Jardim Camburi (E3), Estação Enseada do Suá (E4), Estação Vitória (Centro) (E5), Estação Ibes (E6), Estação Vila Velha (Centro) (E7), Estação Vila Capixaba (E8) e Estação Cidade Continental (E9). A Figura 1, apresenta a localização espacial das estações de monitoramento da RAMQAr.

A RAMQAr monitora os seguintes poluentes atmosféricos: $PM_{2,5}$; PM_{10} ; partículas totais em suspensão (PTS); SO_2 ; monóxido de nitrogênio (NO); NO_2 ; óxidos de nitrogênio (NO_x); CO; ozônio (O_3); metano (CH_4); hidrocarbonetos não-Metano (HCnM) e hidrocarbonetos totais (HCT). E, ainda realiza, o monitoramento dos seguintes parâmetros meteorológicos: direção dos ventos (DV); velocidade dos ventos (V); umidade relativa (U); precipitação pluviométrica (PP); temperatura (T); pressão atmosférica (P); e a radiação solar (I). As variáveis monitoradas por cada estação da RAMQAr estão apresentados na Tabela 1.

Figura 1 – Localização das estações da RAMQAr na RGV, Espírito Santo



Fonte: Autores (2020)

Tabela 1 – Estações e variáveis atmosféricas monitoradas pela RAMQAr

Estações	Poluentes Monitorados	Variáveis Meteorológicas
E1	PM ₁₀ , PTS, SO ₂ , NO, NO ₂ , NO _x , O ₃	
E2	PM ₁₀ , PTS	DV, V, U, PP, P, T, I
E3	PM ₁₀ , PTS, SO ₂ , NO, NO ₂ , NO _x	
E4	PM ₁₀ , PM _{2.5} , PTS, SO ₂ , NO, NO ₂ , NO _x , CO, O ₃ , CH ₄ , HCnM, HCT	DV, V
E5	PM ₁₀ , PTS, SO ₂ , NO, NO ₂ , NO _x , CO, CH ₄ , HCnM, HCT	
E6	PM ₁₀ , PM _{2.5} , PTS, SO ₂ , NO, NO ₂ , NO _x , CO, O ₃ , CH ₄ , HCnM, HCT	DV, V
E7	PM ₁₀ , SO ₂	
E8	PM ₁₀ , PTS, SO ₂ , NO, NO ₂ , NO _x , CO, O ₃	DV, V, T
E9	PM ₁₀ , PTS, SO ₂ , NO ₂	DV, V

Fonte: Adaptado de IEMA (2018)

2.2 Dados

Para a realização do estudo foram utilizadas séries temporais referentes à concentração de PM_{10} e as variáveis V, U, PP, P, T e I, fornecidos em médias horárias de 24 horas e coletados através do banco de dados do IEMA (2018), para o período de 01/01/2008 a 31/12/2018.

De acordo com a Companhia Ambiental do Estado de São Paulo (CETESB, 2019) é necessário adotar critérios de representatividade temporal nos dados de monitoramento da qualidade do ar para que não seja comprometida a interpretação do resultado obtido. A CETESB determina que os dados médios diários da estação devem conter 2/3 das medidas horárias válidas no dia. Seguindo as orientações do órgão e considerando que algumas estações da RAMQAr possuem uma porcentagem alta de dados faltantes, para determinar as estações representativas do estudo foi realizado uma análise dos dados brutos de todas as estações da RAMQAr, sendo considerada apenas as estações que apresentaram porcentagem de dados faltantes de sua série igual ou inferior a 34%, como disposto na Tabela 2. Assim, foram definidas as seguintes estações a serem utilizadas, considerando a série do poluente PM_{10} : E1, E2, E3, E4, E5, E6 e E8.

Tabela 2 – Porcentagem de observações faltantes referente as medições médias horárias das estações da RAMQAr

Estação	Porcentagem de dados faltantes (%)
E1	13
E2	15
E3	13
E4	11
E5	10
E6	13
E7	62
E8	29
E9	66

Fonte: Autores (2020)

Com relação à determinação das variáveis meteorológicas utilizadas neste trabalho, foi seguida a mesma metodologia descrita anteriormente para escolha das estações. Sendo assim, foram empregadas as séries de dados referentes a V, U, PP, T, I e P conforme a descrição da Tabela 3.

Tabela 3 – Descrição das variáveis meteorológicas

Variáveis	Unidades	Descrição
V	$m.s^{-1}$	Dado que a estação de Cidade Continental apresentou muitos dados faltantes, adotou-se uma média aritmética entre as estações de Carapina, Enseada do Suá, IBES e de Cariacica.
U	%	Média aritmética entre as estações de Carapina e Cariacica, as únicas que medem tal variável.
PP	mm	Valores medidos na estação de Carapina, pois é a única que possui medição para tal variável.
P	$mbar$	Valores medidos na estação de Carapina, pois é a única que possui dados para tal variável.
T	$^{\circ}C$	Média aritmética entre as estações de Carapina e Cariacica.
I	$W.m^2$	Valores medidos na estação de Carapina, única que realiza tal medição.

Fonte: Adaptado de Pinto, Reisen e Monte (2018)

Em razão da presença de dados faltantes nas séries temporais foi adotada a metodologia de imputação via algoritmo EM (*expectation-maximisation*), por meio da plataforma *mstdi* (*multivariate time-series data imputation*) proposta por Junger e Leon (2015) e implementada na biblioteca do *software* R (JUNGER e LEON, 2018). Após a imputação dos dados faltantes, calculou-se as médias diárias das concentrações do poluente PM_{10} e as médias diárias das variáveis meteorológicas adotadas, sendo considerados, assim, para o período analisado, 4.015 observações tanto na série de PM_{10} quanto das variáveis explicativas.

2.3 Métodos

Para a predição e previsão das concentrações de PM₁₀ para cada estação da RGV, utilizou-se a metodologia proposta por Box e Jenkins (1970), que consiste na ideia de que a série temporal em estudo seja gerada por um processo estocástico, cuja natureza pode ser representada a partir de um modelo matemático (MORETTIN e TOLOI, 2006).

Os chamados modelos Autorregressivos Integrados e de Médias Móveis Sazonal Multiplicativo (SARIMA) destacam-se por serem uma ampliação dos modelos Autorregressivos Integrados e de Médias Móveis (ARIMA), por incluírem a característica de autocorrelação sazonal. O modelo SARIMA é geralmente descrito como SARIMA $(p, d, q) \times (P, D, Q)$, em que p, d, q e P, D, Q são inteiros não negativos que se referem a ordem polinomial autorregressiva (AR), integrada (I), e média móvel (MA) de partes não sazonais e sazonais do modelo, respectivamente. Logo, este modelo pode ser representado pela seguinte expressão (Equação 1):

$$\varphi_p(B) \Phi_P(B^S) \nabla^d \nabla_S^D Y_t = \theta_q(B) \Theta_Q(B^S) \varepsilon_t \quad (1)$$

em que Y_t é a variável de previsão; $\varphi_p(B)$ é o polinômio de AR regular de ordem p ; $\theta_q(B)$ é o polinômio de MA regular de ordem q ; $\Phi_P(B^S)$ é o polinômio de AR sazonal de ordem P ; $\Theta_Q(B^S)$ é o polinômio de MA sazonal de ordem Q e ε_t é ruído branco, definido como uma sequência de variáveis aleatórias não correlacionadas com média zero e variância constante ao longo do tempo (WEI, 2006; VANGROPOULOS *et al.*, 2016).

O operador de diferenciação ∇^d e o operador de diferenciação sazonal ∇_S^D eliminam a não-sazonalidade e a não-estacionariedade sazonal, respectivamente. Tem-se que B é o operador de defasagem definido como $B^k(Y_t) = Y_{t-k}$, $k \in \mathbb{N}$. Os polinômios e os operadores são definidos, matematicamente como $\varphi_p(B) = 1 - \sum_{i=1}^p \varphi_i B^i$, $\Phi_P(B^S) = 1 - \sum_{i=1}^P \Phi_i B^{S,i}$, $\theta_q(B) = 1 - \sum_{i=1}^q \theta_i B^i$, $\Theta_Q(B^S) = 1 - \sum_{i=1}^Q \Theta_i B^{S,i}$, $\nabla^d = (1 - B)^d$, e $\nabla_S^D = (1 - B^S)^D$.

Neste estudo foi aplicado o modelo SARIMAX, que é uma extensão do modelo SARIMA, com capacidade de integrar variáveis explicativas, processo no qual possibilita aumentar o desempenho da previsão. De acordo Vagropoulos *et al.* (2016), esse modelo pode ser representado pela Equação 2:

$$\varphi_p(B)\Phi_p(B^S)\nabla^d\nabla_S^D Y_t = \beta x'_t + \theta_q(B)\Theta_q(B^S)\varepsilon_t \quad (2)$$

em que x'_t é o vetor que inclui as variáveis de entrada exógenas k no tempo t e β refere-se ao valor do coeficiente da variável de entrada exógena k .

Segundo Wei (2006), antes de se proceder a modelagem, o primeiro passo na análise de séries temporais é identificar se elas são estacionárias, ou seja, se possuem média, variância e covariância constantes ao longo do tempo. Para isso, foi aplicado aos dados o teste de raiz unitária de Dickey-Fuller Aumentado (*Argumented Dickey-Fuller* ou ADF) (DICKEY e FULLER, 1981). A avaliação da existência de periodicidade, também denominada sazonalidade, nas séries de concentração de PM₁₀ foi realizada pela análise espectral com a construção do periodograma e, além disso, aplicou-se o teste G de Fisher aos dados transformados (WEI, 2006). A transformação dos dados da série temporal foi utilizada para estabilizar a variância e aproximar de uma distribuição normal. Para isso, foi considerada a transformação sugerida por Box e Cox (1964), no qual se estima o λ e baseada nessa estimativa, define-se o tipo de transformação. Assim, a série transformada é dada por:

$$T(Z_t) = \begin{cases} Z_t^\lambda & \text{se } \lambda \neq 0 \\ \ln(Z_t) & \text{se } \lambda = 0 \end{cases} \quad (3)$$

Em que λ é o parâmetro de transformação e escolhido no intervalo $[-1, +1]$ e os valores mais correntes correspondem às transformações propostas por Box e Cox (1964). Por fim, o estabelecimento do modelo de previsão apropriado que descreva o fenômeno gerador de cada série estudada foi definido através das quatro etapas contidas na metodologia de Box e Jenkins (1970), as quais são descritas como: (i) identificação; (ii) estimação; (iii) diagnóstico; e (iv) previsão.

2.4 Indicadores estatísticos

Na Tabela 4 estão apresentadas as equações referentes aos indicadores estatísticos utilizados para realizar a identificação e avaliação da qualidade de ajuste e desempenho do modelo de previsão das concentrações de PM₁₀, a saber: os critérios de seleção Akaike Information Criteria (AIC) (AKAIKE, 1973) e Bayesian Information Criterion (BIC) (SCHAWAZ; AKAIKE, 1978), raiz do erro quadrático médio (REQM), erro absoluto médio (EAM) e as estatísticas de avaliação propostas por Ryan (1995) e Liu e Johnson (2003) - probabilidade de detecção (POD), razão de alarme falso (FAR), escore de ameaças (EA) e taxa de perda (MISS), respectivamente. O melhor modelo para representar a série é aquele que obtêm os menores valores para os critérios de informação e para as medidas de qualidade.

Tabela 4 – Fórmulas dos indicadores estatísticos de qualidade de ajuste e desempenho do modelo

Indicador Estatístico	Fórmula
AIC	$-2\ell(\hat{\xi}) + 2(K)$
BIC	$-2\ell(\hat{\xi}) + (K)\log(n)$
REQM	$\sqrt{\frac{1}{N} \sum_{i=1}^N (Y_i - \hat{Y}_i)^2}$
EAM	$\frac{1}{N} \sum_{i=1}^N Y_i - \hat{Y}_i $
POD	$\frac{A}{(A + B)}$
FAR	$\frac{C}{(C + A)}$
EA	$\frac{A}{(A + B + C)}$
MISS	$1 - POD$

Legenda: $\ell(\hat{\xi})$ é a função de log-verossimilhança maximizada; K refere-se ao número de parâmetros do modelo; n é o número de observações da amostra; Y_i e \hat{Y}_i são os valores observados e previsto no instante i ; N é o número período de tempos; A é o número de eventos observados e preditos; B é o número de eventos observados, mas não preditos; e C é o número de eventos estimados, mas não observados.

3 RESULTADOS E DISCUSSÃO

Para um entendimento preliminar das variáveis em estudo, estão apresentadas na Tabela 5 medidas descritivas básicas. Observa-se que a maior concentração média de PM_{10} foi registrada na E8 ($38,84 \mu g.m^{-3}$) seguida pela E1 ($32,82 \mu g.m^{-3}$), e o menor valor médio foi encontrado na E2 ($20,35 \mu g.m^{-3}$). Em média, as concentrações não ultrapassaram a diretriz estabelecida pela Organização Mundial da Saúde (OMS) (WHO, 2006) ($50 \mu g.m^{-3}$), o Padrão Intermediário 1 (PI1) estabelecido pela Resolução CONAMA 491/2018 (CONAMA, 2018) ($120 \mu g.m^{-3}$) e a Meta Intermediária 1 (MI1) determinada pelo Decreto Estadual nº 3463 – R/2013 (ESPÍRITO SANTO, 2013) ($120 \mu g.m^{-3}$). Porém, nota-se que todas as estações apresentam alto desvio-padrão e coeficiente de variação, sugerindo que a média dos dados é pouco representativa e que existe uma grande variabilidade deles. Os valores dos coeficientes de assimetria e curtose encontrados indicam que as séries em estudo não são normalmente distribuídas.

Com relação à análise das medidas descritivas das variáveis meteorológicas (Tabela 5) é possível notar que os dados meteorológicos também apresentam grande variabilidade, com exceção da variável temperatura que, de acordo com o IEMA (2018), apresenta pouca variabilidade climatológica na região.

Tabela 5 – Medidas descritivas das variáveis em estudo

Estações e Variáveis	Medidas Descritivas							
	μ	M	σ	CV	Máx.	Mín.	Assimetria	Curtose
PM_{10}	E1	31,82	30,25	13,38	42,03	118,8	5,93	0,96
	E2	20,41	19,23	7,26	35,55	88,25	4,41	1,79
	E3	22,59	21,83	7,58	33,56	66,86	3,54	0,94
	E4	27,17	26,33	8,94	32,92	83,58	8,33	0,91
	E5	24,96	23,83	8,07	32,35	83,12	6,06	1,03
	E6	26,21	25,16	9,56	36,47	88,12	5	0,97
	E8	38,84	36,88	15,27	39,31	120,83	5,5	1,20

Continua...

Tabela 5 – Medidas descritivas das variáveis em estudo

Estações e Variáveis	Medidas Descritivas								Conclusão
	μ	M	σ	CV	Máx.	Mín.	Assimetria	Curtose	
Variáveis meteorológicas	V	2,01	1,92	0,40	31,62	9,42	0,75	2,22	
	U	76,01	75,72	6,59	8,67	98,3	55,25	0,24	
	PP	0,14	0,01	0,45	313,26	12,83	0	9,99	
	T	24,73	24,77	2,50	10,12	30,69	17,81	-0,09	
	I	209,24	205,8	72,6	34,7	396,54	22,57	-0,04	
	P	1010,8	1010,7	5,07	0,5	1026,52	994,3	0,01	

Legenda: Unidade de Medida: μ , M, σ , Máx (máxima)., Mín.(mínima) = $\mu g. m^{-3}$, CV (coeficiente de variação) = %.

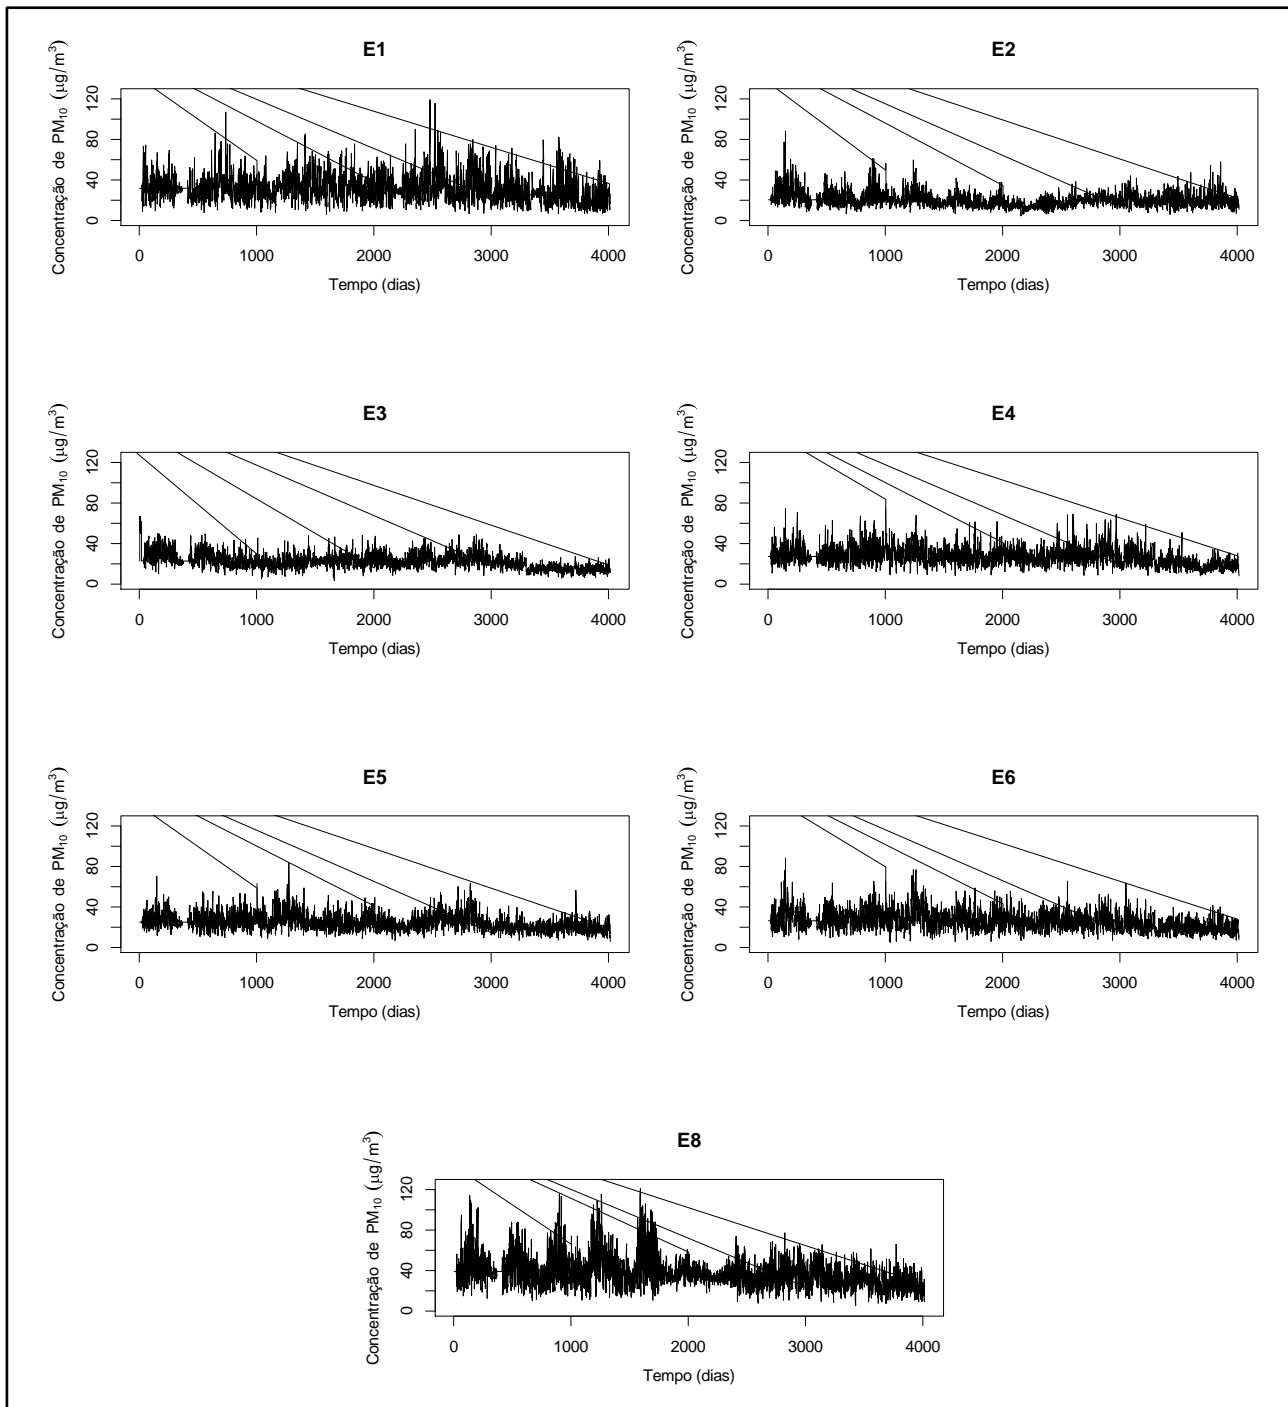
Fonte: Autores (2020)

Para complementar a avaliação comportamental do poluente e dos elementos climatológicos, as Figuras 2 e 3 apresentam as séries temporais das concentrações de PM_{10} e das variáveis meteorológicas, respectivamente, no período de estudo.

Do total de observações, sem exceção, todas estações apresentaram valores diários que ultrapassaram a diretriz estabelecida pela OMS (WHO, 2006) para o PM_{10} , sendo que as concentrações monitoradas nas estações E1 e E8 foram as que mais superaram o valor de $50 \mu g. m^{-3}$, correspondente a 401 ultrapassagens na primeira e 716 ultrapassagens na estação de Cariacica. A diretriz da OMS é baseada em extensas evidências científicas sobre a poluição do ar referente ao PM_{10} e suas consequências para a saúde. Conforme os achados, o valor de $50 \mu g. m^{-3}$ é o valor mínimo de exposição diária ao poluente encontrado, que apresenta mais segurança aos expostos, porém não garante uma proteção completa contra os efeitos adversos do material particulado à saúde, uma vez que os limites não foram identificados devido a existência de pouca evidência para sugerir um limite abaixo do qual nenhum efeito adverso à saúde seria previsto. De acordo com o Guia de Qualidade do Ar da OMS, a diretriz de $50 \mu g. m^{-3}$ proporciona a redução de cerca

de 1,2%, 2,5% e 5% na mortalidade de curto prazo em relação aos limites de 75, 100 e 150 $\mu\text{g}\cdot\text{m}^{-3}$, respectivamente, com base nos coeficientes de risco publicados em estudos multicêntricos e metanálises (WHO, 2006).

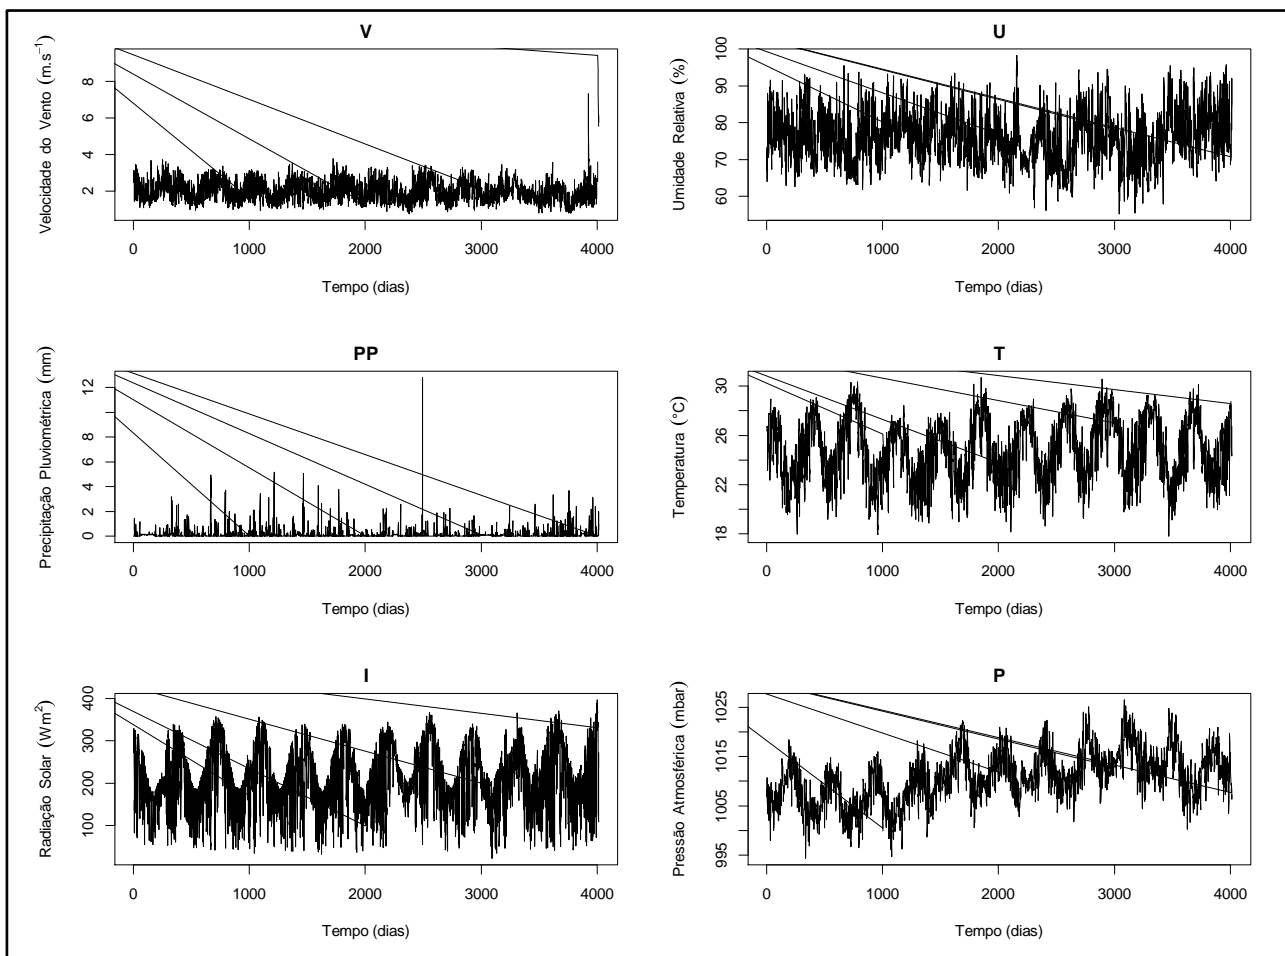
Figura 2 – Evolução temporal das séries de PM_{10} em cada estação da RGV



Fonte: Autores (2020)

Em comparação com a legislação brasileira, a estação E8 foi a única que excedeu o padrão PI1 da Resolução do CONAMA nº 491/2018 (CONAMA, 2018) e a meta MI1 do Decreto Estadual nº 3463 – R/2013 (ESPÍRITO SANTO, 2013), contudo, esses resultados são preocupantes, pois mesmo em níveis abaixo do estabelecido pela legislação são observados efeitos adversos à saúde da população e ao meio ambiente em geral, como demonstrado na pesquisa de Freitas *et al.* (2016) em que mesmo as concentrações anuais do poluente estudado (PM_{10}) terem permanecido em torno de $27 \mu g.m^{-3}$, valor bem abaixo do estabelecido pela Resolução do CONAMA nº 491/2018 ($40 \mu g.m^{-3}$), houve associação consistente entre as concentrações de PM_{10} e problemas respiratórios na cidade de Vitória.

Figura 3 – Evolução temporal das séries das variáveis meteorológicas



Fonte: Autores (2020)

A Tabela 6 contém a quantidade de vezes que as concentrações de PM₁₀ ultrapassaram a diretriz estabelecida pela OMS (WHO, 2005), o padrão PI1 estabelecido pela Resolução do CONAMA nº 491/2018 e a meta MI1 do Decreto Estadual nº 3463 – R/2013 em cada ano do período estudado. A estação E8, no ano de 2011, foi a que registrou maior número de concentrações acima de 50 $\mu\text{g}\cdot\text{m}^{-3}$.

Tabela 6 – Quantidade de vezes que as concentrações de PM₁₀ ultrapassaram o padrão estadual, o padrão nacional e a diretriz da OMS

Estações	Legislação	Anos											Total
		2008	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	
E1	OMS	10	5	18	38	54	24	50	69	39	31	18	356
	CONAMA e Decreto	0	0	0	0	0	0	0	0	0	0	0	-
E2	OMS	10	0	6	3	0	0	0	0	0	0	2	21
	CONAMA e Decreto	0	0	0	0	0	0	0	0	0	0	0	-
E3	OMS	16	0	0	0	0	0	0	0	0	0	0	16
	CONAMA e Decreto	0	0	0	0	0	0	0	0	0	0	0	-
E4	OMS	10	5	18	7	4	2	4	10	4	1	0	65
	CONAMA e Decreto	0	0	0	0	0	0	0	0	0	0	0	-
E5	OMS	2	4	5	11	1	0	0	9	0	0	1	33
	CONAMA e Decreto	0	0	0	0	0	0	0	0	0	0	0	-
E6	OMS	15	2	17	24	5	4	2	2	1	0	0	72
	CONAMA e Decreto	0	0	0	0	0	0	0	0	0	0	0	-
E8	OMS	120	94	111	131	118	18	24	38	46	10	4	714
	CONAMA e Decreto	0	0	0	0	1	0	0	0	0	0	0	1

Fonte: Autores (2020)

Na Tabela 7 estão apresentadas as matrizes de correlação entre as variáveis meteorológicas e o poluente PM₁₀, correspondente, às estações E1, E2, E3, E4, E5, E6 e E8, contendo os seus respectivos coeficientes de correlação de Pearson. Os

coeficientes de correlação que não apresentaram significância estatística estão em negrito, sendo considerado o nível de significância de 5%. De forma geral, observa-se que as variáveis meteorológicas apresentam relação linear com as concentrações de material particulado inalável.

Tabela 7 – Matriz de correlação entre PM₁₀ e as variáveis meteorológicas

Continua...

	PM ₁₀	V	U	PP	T	I	P
E1							
PM ₁₀	1						
V	0,3742	1					
U	-0,3898	-0,4421	1				
PP	-0,2059	-0,0882	0,3675	1			
T	0,3520	0,3865	-0,3994	-0,1435	1		
I	0,2587	0,4013	-0,4874	-0,2521	0,6185	1	
P	-0,2664	-0,2425	0,0308	-0,0728	-0,4702	-0,2033	1
E2							
PM ₁₀	1						
V	-0,1851	1					
U	-0,0255	-0,4421	1				
PP	-0,1545	-0,0882	0,3675	1			
T	-0,1019	0,3865	-0,3994	-0,1435	1		
I	-0,1227	0,4013	-0,4874	-0,2521	0,6185	1	
P	-0,0484	-0,2425	0,0308	-0,0728	-0,4702	-0,2033	1
E3							
PM ₁₀	1						
V	-0,0737	1					
U	-0,1041	-0,4421	1				
PP	-0,08	-0,0882	0,3675	1			
T	-0,0392	0,3865	-0,3994	-0,1435	1		
I	-0,0712	0,4013	-0,4874	-0,2521	0,6185	1	
P	-0,0697	-0,2425	0,0308	-0,0728	-0,4702	-0,2033	1

Tabela 7 – Matriz de correlação entre PM₁₀ e as variáveis meteorológicas

Continua...

	PM ₁₀	V	U	PP	T	I	P
E4							
PM ₁₀	1						
V	0,1325	1					
U	-0,2583	-0,4421	1				
PP	-0,1734	-0,0882	0,3675	1			
T	0,0847	0,3865	-0,3994	-0,1435	1		
I	0,0585	0,4013	-0,4874	-0,2521	0,6185	1	
P	-0,16	-0,2425	0,0308	-0,0728	-0,4702	-0,2033	1
E5							
PM ₁₀	1						
V	-0,0872	1					
U	-0,1128	-0,4421	1				
PP	-0,1623	-0,0882	0,3675	1			
T	0,01	0,3865	-0,3994	-0,1435	1		
I	0,0107	0,4013	-0,4874	-0,2521	0,6185	1	
P	-0,1399	-0,2425	0,0308	-0,0728	-0,4702	-0,2033	1
E6							
PM ₁₀	1						
V	0,0485	1					
U	-0,2482	-0,4421	1				
PP	-0,2189	-0,0882	0,3675	1			
T	0,003	0,3865	-0,3994	-0,1435	1		
I	0,0385	0,4013	-0,4874	-0,2521	0,6185	1	
P	-0,1889	-0,2425	0,0308	-0,0728	-0,4702	-0,2033	1

Tabela 7 – Matriz de correlação entre PM₁₀ e as variáveis meteorológicas

conclusão

	PM ₁₀	V	U	PP	T	I	P
	E8						
PM ₁₀	1						
V	-0,1446	1					
U	-0,0921	-0,4421	1				
PP	-0,1732	-0,0882	0,3675	1			
T	-0,1382	0,3865	-0,3994	-0,1435	1		
I	-0,1035	0,4013	-0,4874	-0,2521	0,6185	1	
P	-0,0576	-0,2425	0,0308	-0,0728	-0,4702	-0,2033	1

Fonte: Autores (2020)

Assim, como esperado, as concentrações de PM₁₀ na RGV estão associadas às mudanças dessas variáveis, ou seja, constata-se a partir dos resultados (Tabela 7) que o aumento da V acarreta aumento nas concentrações de PM₁₀ nas estações E1, E4 e a redução dos níveis do poluente monitorado nas estações E2 e E8; já o aumento da U e PP contribui para diminuição nas concentrações de PM₁₀ nas estações E1, E3, E4, E5, E6 e E8. Em contrapartida, o aumento de T acarreta tanto o aumento dos níveis de material particulado inalável monitorados na estação E1, quanto a sua redução nas estações E2 e E8; da mesma forma, a I apresenta correlação positiva com o poluente estudado na estação E1 e correlação negativa nas estações E2 e E8; e, por fim, o aumento da P leva a diminuição dos níveis de PM₁₀ nas estações E1, E4, E5 e E6. É importante ressaltar que algumas combinações não foram estatisticamente significativas, pois os dados não foram validados, seja na análise da estatística do teste de significância ou na análise dos valores dos coeficientes de correlação, o que pode ser explicado visto a quantidade de dados faltantes das séries temporais, pelos dados meteorológicos utilizados serem uma média para todas as estações ou até mesmo pela inexistência de relação entre as variáveis estudadas.

As disparidades encontradas nos resultados da correlação entre as variáveis meteorológicas e o material particulado inalável monitorado nas estações da RGV deve as características específicas de cada localidade estudada e, também, foi encontrada por Santos, Reboita e Carvalho (2018), os quais relataram que a influência dos fatores meteorológicos nos níveis de poluentes na atmosfera está relacionada com as características locais e específicas da região. A exemplo, citam que a velocidade do vento pode promover a ressuspensão de partículas e, conseqüentemente, levar o aumento da concentração de PM_{10} , ou sua dispersão, como também, de acordo com a direção deste em relação à fonte emissora e a estação, pode dispersar as partículas para outra direção ou contribuir para seu aumento na estação de monitoramento.

A análise das séries temporais é realizada por meio de várias etapas com objetivo de identificar as principais dependências existentes temporalmente nos dados e com base nelas descrever o seu comportamento (WEI, 2006). Desse modo, o primeiro passo na análise dessas séries consiste em identificar se elas são estacionárias. Por meio da aplicação do teste de Dickey-Fuller aumentado (DICKEY e FULLER, 1981), os resultados obtidos revelaram que as séries em estudo não são estacionárias na média e, por isso, foi aplicada uma diferença estacionária de ordem 1 para eliminar a componente tendência de cada série temporal e torná-las estacionárias na média. Em seguida, observou-se que a série não é estacionária na variância. Dessa maneira, para estabilizar o aumento da variância das observações e melhorar na aproximação da distribuição dos dados para a distribuição normal, foi aplicado o logaritmo natural na série temporal.

A análise das funções de autocorrelação indica a presença de sazonalidade nos dados com periodicidade de sete dias. Assim, para a confirmação da presença dessa característica e verificação da necessidade de aplicação de diferenças sazonais foi realizada a decomposição espectral das séries de PM_{10} de acordo com a Figura 4. Os periodogramas das estações E1, E2, E4, E5, E6 e E8 demonstraram

que o maior pico está associado à frequência de 0,1429, e da estação E3, à frequência de 0,1432, o que implica em $s = \frac{1}{0,1429} = 6,99$ e $s = \frac{1}{0,1432} = 6,98$, ou seja, todas estações apresentam componente sazonal com periodicidade de sete dias. E, conforme os resultados do teste de Fisher, para todas as estações o valor de G foi superior ao de Z, deste modo, aceita-se a hipótese H1 da existência de sazonalidade, confirmando a existência da componente sazonalidade para períodos de sete dias, ao nível de significância de 5%. Por fim, a aplicação do teste de Kruskal-Wallis também corrobora com a existência de sazonalidade na série (MORETTIN e TOLOI, 2006), considerando que o valor de p é menor do que 0,05, rejeita-se a hipótese nula de que não existe sazonalidade, conforme Tabela 8.

Tabela 8 – Teste de Kruskal-Wallis aplicado aos dados da série de PM₁₀

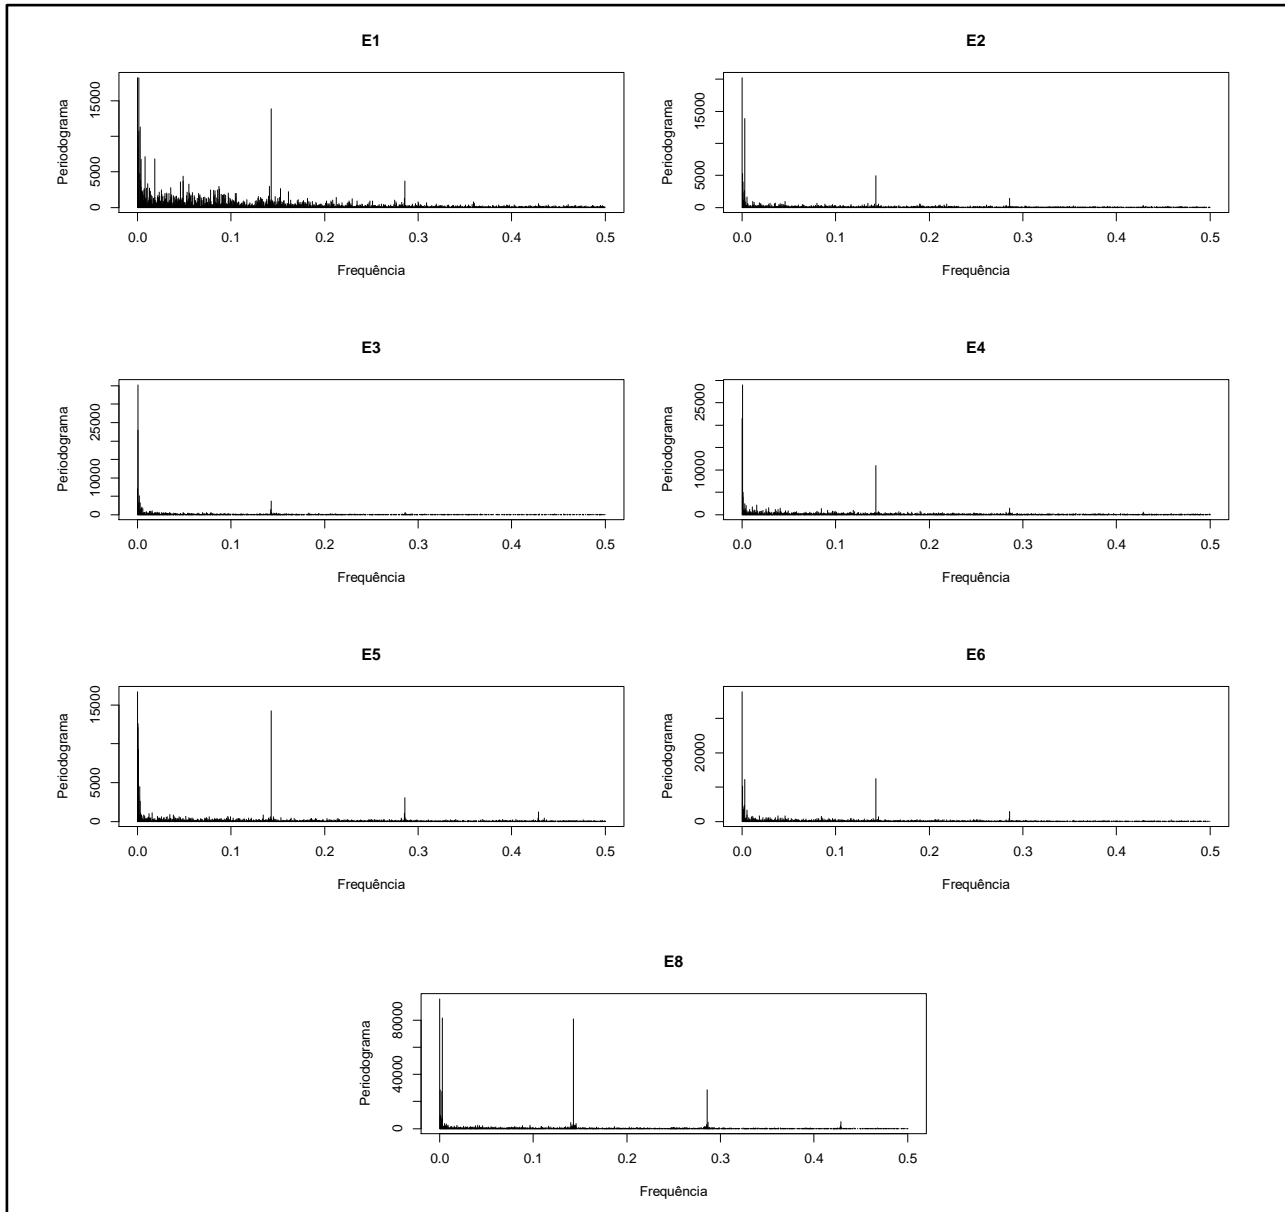
Estação	Estatística	Valor p
E1	679,08	< 0,0001
E2	86,294	< 0,0001
E3	64,983	0,0002
E4	165,64	< 0,0001
E5	153,1	< 0,0001
E6	251,45	< 0,0001
E8	168	< 0,0001

Fonte: Autores (2020)

Tal comportamento é esperado em séries de PM₁₀, pois conforme o Inventário de Emissões Atmosféricas na Região da Grande Vitória (ECOSOFT, 2019), dispõe o processo de emissão dominante para partículas é a ressuspensão nas vias primárias e secundárias da região provocada, principalmente, pelo deslocamento de veículos automotores. Em razão disso, a variação sazonal apresentada pode ser explicada pelo ritmo de movimentação dos transportes, ou seja, as maiores concentrações de PM₁₀ ocorrem durante os dias úteis, quando o fluxo de veículos é maior, e o oposto ocorre nos finais de semana, devido à redução da circulação

veicular nas ruas. Logo, foi aplicada uma diferença sazonal de ordem $s = 7$ para eliminar a sazonalidade presente nas séries das estações.

Figura 4 – Periodograma das séries temporais de material particulado inalável



Fonte: Autores (2020)

O próximo passo consiste em realizar os procedimentos de identificação e estimação dos parâmetros do modelo SARIMAX para cada estação de monitoramento do poluente PM_{10} . A identificação preliminar das ordens autorregressivas e de médias móveis não sazonal e sazonal (p e q e P e Q) dos modelos deram-se por meio da análise do comportamento das funções de

autocorrelação (FAC) e das funções de autocorrelação parcial (FACP) e o melhor modelo para representar os dados, baseou-se nos critérios de informação AIC, BIC, nos valores de REQM e EAM e na qualidade de ajuste à série original. Como foi realizada uma diferença estacionária nas séries e se fez necessária a aplicação de uma diferença sazonal, tem-se $d = 1$ e $D = 1$. Assim, entre todos os modelos testados e estimados, os modelos com melhores ajustes para as estações E1, E2, E3, E4, E5, E6 e E8 foram, respectivamente, SARIMAX (1,1,2) (0,1,1)₇; SARIMAX (1,1,1) (0,1,1)₇; SARIMAX (1,1,1) (0,1,1)₇; SARIMAX (3,1,1) (0,1,1)₇; SARIMAX (1,1,1) (0,1,0)₇; SARIMAX (1,1,2) (0,1,1)₇ e SARIMAX (1,1,3) (0,1,1)₇.

Na Tabela 9 são apresentados os resultados das estatísticas dos testes Shapiro e Wilk, Jarque e Bera, Ljung e Box e Box e Pierce, para verificar a adequação do modelo por meio da normalidade e a não autocorrelação dos resíduos. Conforme os dois primeiros testes, os resíduos das séries temporais de todas as estações não são normalmente distribuídos, por se tratar uma variável ambiental. Entretanto, conforme Monte, Albuquerque e Reisen (2015), assumiu-se, pela teoria assintótica sobre as médias das distribuições de probabilidade a suposição de que os resíduos são normais. Na Figura 5 são apresentados os gráficos da FAC e FACP dos resíduos dos modelos SARIMAX ajustados para cada estação. Não se rejeita a hipótese nula de erros não correlacionados, considerando os valores p superiores ao nível de significância de 5%. Por conseguinte, conclui-se que os modelos ajustados são adequados para fazer previsões.

Tabela 9 – Testes estatísticos de normalidade e correlação dos resíduos dos modelos escolhidos

MODELOS	Testes de normalidade		Testes de correlação	
	Shapiro-Wilk	Jarque-Bera	Box-Ljung	Box-Pierce
E1 SARIMAX (1,1,2) (0,1,1) ₇	<0,0001	<0,0001	0,6514	0,6521
E2 SARIMAX (1,1,1) (0,1,1) ₇	<0,0001	<0,0001	0,0573	0,0583
E3 SARIMAX (1,1,1) (0,1,1) ₇	<0,0001	<0,0001	0,0943	0,0956
E4 SARIMAX (3,1,1) (0,1,1) ₇	<0,0001	<0,0001	0,4931	0,4959
E5 SARIMAX (1,1,1) (0,1,0) ₇	<0,0001	<0,0001	0,3244	0,3254
E6 SARIMAX (1,1,2) (0,1,1) ₇	<0,0001	<0,0001	0,1003	0,1018
E8 SARIMAX (1,1,3) (0,1,1) ₇	<0,0001	<0,0001	0,6767	0,6793

Fonte: Autores (2020)

As estimativas dos parâmetros dos modelos selecionados, calculados por máxima verossimilhança e seus respectivos erros padrão, valores de z e p , são apresentados na Tabela 10. De acordo com os resultados obtidos para o teste z , todos os coeficientes dos modelos são significativos. As variáveis I e P não foram estatisticamente significativas, por isso não foram incorporadas no ajuste final dos modelos das estações de monitoramento. Nos modelos ajustados para as estações E2, E4, E5 foram consideradas como variáveis explicativas V e PP. Já no modelo estimado para a estação E3 foi incorporada apenas a variável PP. Na estação E6, além da variável V, foi considerada também a U como variável preditora. Por fim, para as estações E1 e E8, o melhor modelo ajustado considerou como variáveis explicativas a V, PP e T.

Tabela 10 – Estimativa dos parâmetros dos modelos ajustados para as estações de PM₁₀ sob estudo

Estações	Parâmetro	Estimativa	Erro padrão	Valor de z	Continua...
					Valor de p
E1	V	0,09028	0,0105	8,6209	<0,0001
	PP	-0,0501	0,0098	-5,0629	<0,0001
	T	0,1355	0,004	33,8699	<0,0001

Tabela 10 – Estimativa dos parâmetros dos modelos ajustados para as estações de PM₁₀ sob estudo

					Continua...
Estações	Parâmetro	Estimativa	Erro padrão	Valor de z	Valor de p
E1	φ_1	0,3447	0,0388	8,8783	<0,0001
	θ_1	-0,7884	0,0405	-19,4320	<0,0001
	θ_2	-0,1198	0,0343	-3,4903	0,0004
	Φ_1	-0,9718	0,0045	-215,0002	<0,0001
E2	V	-0,1139	0,0086	-13,264	<0,0001
	PP	-0,1189	0,009	-13,090	<0,0001
	φ_1	0,3706	0,017	21,763	<0,0001
	θ_1	-0,9608	0,0058	-164,593	<0,0001
	Φ_1	-0,9764	0,0038	-256,479	<0,0001
E3	PP	-0,0328	0,0083	-3,986	<0,0001
	φ_1	0,4071	0,0173	23,486	<0,0001
	θ_1	-0,9582	0,007	-136,446	<0,0001
	Φ_1	-0,9603	0,0056	-193,008	<0,0001
E4	V	0,0468	0,0084	5,5387	<0,0001
	PP	-0,1055	0,0088	-11,8881	<0,0001
	φ_1	0,4353	0,0169	25,6156	<0,0001
	φ_2	-0,044	0,0175	-2,5106	0,012
	φ_3	0,0655	0,0167	3,9199	<0,0001
	θ_1	-0,9812	0,0057	-172,4301	<0,0001
	Φ_1	-0,9716	0,0042	-232,1971	<0,0001
E5	V	-0,1024	0,0083	-12,222	<0,0001
	PP	-0,1243	0,0086	-14,385	<0,0001
	φ_1	0,3421	0,0152	22,5	<0,0001
	Φ_1	-0,9999	0,0008	-132,981	<0,0001
E6	U	-0,0202	0,0101	-22,1889	<0,0001
	PP	-0,0893	0,0101	-8,8211	<0,0001
	φ_1	0,2706	0,0525	5,1531	<0,0001
	θ_1	-0,8105	0,0547	-14,8305	<0,0001
	θ_2	-0,1025	0,0471	-2,1774	0,0294

Tabela 10 – Estimativa dos parâmetros dos modelos ajustados para as estações de PM₁₀ sob estudo

Estações	Parâmetro	Estimativa	Erro padrão	Valor de z	Conclusão
					Valor de p
E6	Φ_1	-0,9750	0,0038	-257,2294	<0,0001
	V	-0,114	0,0095	-11,9930	<0,0001
	PP	-0,1275	0,0095	-13,3938	<0,0001
	T	0,0514	0,0036	14,2817	<0,0001
E8	φ_1	0,6752	0,0831	8,1162	<0,0001
	θ_1	0,2458	0,0861	-14,4608	<0,0001
	θ_2	0,1558	0,0516	3,0177	0,002
	θ_3	0,1178	0,0355	3,3218	0,0008
	Φ_1	-0,8887	0,01	-88,8394	<0,0001

Fonte: Autores (2020)

Zhang *et al.* (2018) produziram um modelo Land-use Regression (LUR) para estimar a média mensal de PM_{2,5}, PM₁₀ e NO₂ de 2014 a 2016 na China. Os autores observaram que a umidade relativa, temperatura da atmosfera e a velocidade do vento são os principais fatores meteorológicos que explicam a variação dos três poluentes estudados sendo utilizados como preditores no modelo desenvolvido. Em consonância, Lyra, Oda - Souza e Viola (2011) observaram que a precipitação pluviométrica e a umidade relativa foram as variáveis mais significativas para explicar a variabilidade do material particulado inalável na cidade do Rio de Janeiro, Brasil. Ambos os estudos corroboram aos resultados apresentados no presente trabalho, confirmando a dependência entre as concentrações de PM₁₀ e fatores climáticos e a importância de se avaliar em conjunto essas duas variáveis.

Gocheva-Ilieva, Ivanov e Iliev (2019) afirmam que para uma previsão realista dos valores de PM₁₀, é necessário ter conhecimento das variáveis precursoras do poluente como as variáveis meteorológicas, dos quais dependem suas concentrações. Portanto, para efeitos de comparação e mostrar a significância de

incorporar nos modelos de predição e previsão de concentração de material particulado através de variáveis meteorológicas, realizou-se estimativas para os modelos ARMA e SARIMA e verificou-se qual o melhor modelo para fazer previsões de PM_{10} nos municípios da RGV. Para isso, foram determinados dois horizontes de previsão (h), sendo um para calcular as estimações do período de 01/01/2008 a 31/12/2018 ($h = 0$) e outro para realizar a previsão referente ao período de 01/01/2019 a 07/01/2019 ($h = 7$).

Na Tabela 11 são apresentados os resultados estimados de REQM e EAM para os modelos ajustados. Observa-se que, de forma geral, os modelos SARIMAX apresentaram um aumento da precisão das previsões nos horizontes. Para todas as estações, exceto a estação E3 e E5, os resultados da comparação das medidas de qualidade mostraram que, para $h = 0$ e $h = 7$, o modelo SARIMAX foi o que obteve melhores resultados, sendo o mais adequado para realizar previsões nessas estações, assemelhando aos resultados obtidos por Pinto, Reisen e Monte (2018) quando avaliaram a predição e previsão do modelo SARIMAX com as variáveis meteorológicas V e PP, utilizando séries temporais de concentração de PM_{10} monitorados na estação de Enseada do Suá.

Tabela 11 – Medidas de avaliação da qualidade de previsão obtidas a partir de modelos ajustados

		Continua...					
Estação	Medida	Modelos					
		$h = 0$			$h = 7$		
		ARMA	SARIMA	SARIMAX	ARMA	SARIMA	SARIMAX
E1	REQM	10,5767	10,3209	8,7479	10,4844	10,2621	8,8210
	EAM	7,6940	7,4901	6,4345	7,7472	7,5358	6,6049
		Modelos					
Estação	Medida	$h = 0$			$h = 7$		
		ARMA	SARIMA	SARIMAX	ARMA	SARIMA	SARIMAX
E2	REQM	6,1094	5,7240	5,4650	5,8309	5,7391	5,5388
	EAM	4,2084	3,9936	3,8348	4,1203	4,0601	3,9465

Tabela 11 – Medidas de avaliação da qualidade de previsão obtidas a partir de modelos ajustados

Estação	Medida	Modelos						Conclusão
		$h = 0$			$h = 0$			
		ARMA	SARIMA	SARIMAX	ARMA	SARIMA	SARIMAX	
E3	REQM	5,3037	5,2005	5,2020	13,0584	12,6985	12,7093	
	EAM	3,9091	3,8127	3,8162	9,6820	13,0584	9,4483	
E4	REQM	7,1396	6,9244	6,7975	14,8237	14,5869	14,4608	
	EAM	5,2327	5,0874	5,0024	10,9828	10,8003	10,6762	
E5	REQM	6,9397	8,5116	8,1937	12,6696	13,1578	12,9338	
	EAM	5,0944	6,3038	6,0890	9,2360	9,7276	9,5843	
E6	REQM	7,6890	7,4215	7,0537	14,4268	14,0942	13,5385	
	EAM	5,7233	5,5103	5,2464	10,8609	10,6130	10,0512	
E8	REQM	12,1396	10,5950	9,9978	29,368	26,7762	26,4073	
	EAM	8,8232	7,5867	7,2022	22,214	20,6618	20,3882	

Fonte: Autores (2020)

Além disso, os autores supracitados ajustaram o modelo SARIMAX (1,0,2) (0,1,1)₇ para a estação E4 avaliando o período de 01/01/2012 a 30/04/2015. Quando comparado o modelo obtido para a estação nesse trabalho com a referência, verifica-se que as estimativas de $h = 0$ foram quase duas vezes melhores (Pinto, Reisen e Monte (2018): REQM = 12,85 e EAM = 9,34) e a qualidade de previsão de sete dias ficou próxima ao obtido no estudo de referência, que foi igual a 12,92 para o REQM e 9,35 para o EAM. Outra consideração que pode ser feita é que a pesquisa se apresenta como uma extensão de Pinto, Reisen e Monte (2018) e os resultados obtidos no trabalho em função do maior número de estações avaliadas e observações, proporcionam informações mais reais de qualidade do ar para a RGV.

Para estação E3, o modelo SARIMA apresentou as menores medidas de avaliação para ambos os horizontes de previsão, que se deve ao fato de que apesar

do modelo SARIMAX ajustado ter considerado como variável preditiva a PP, esse não foi capaz de contribuir nas predições e previsões do modelo, pois como disposto na Tabela 9, as concentrações medidas nessa estação apresentam relações baixas com as variáveis meteorológicas, uma vez que não existe medição dessas variáveis nessa estação. Além disso, a estação está localizada em um bairro residencial, onde o predomínio de prédios atua como uma barreira na circulação dos ventos. No que se refere aos resultados obtidos para estação E5, o modelo ARMA foi o melhor modelo para predição e previsão das concentrações de PM_{10} monitoradas, tal efeito pode ser atribuído a característica de estacionariedade desse modelo que tende a produzir previsões que oscilam em torno do valor médio de longo prazo (MORETTIN e TOLOI, 2006).

Figura 5 – Funções amostrais de autocorrelação (FAC) e autocorrelação parcial (FACP) dos resíduos dos modelos SARIMAX ajustados para cada estação

Continua...

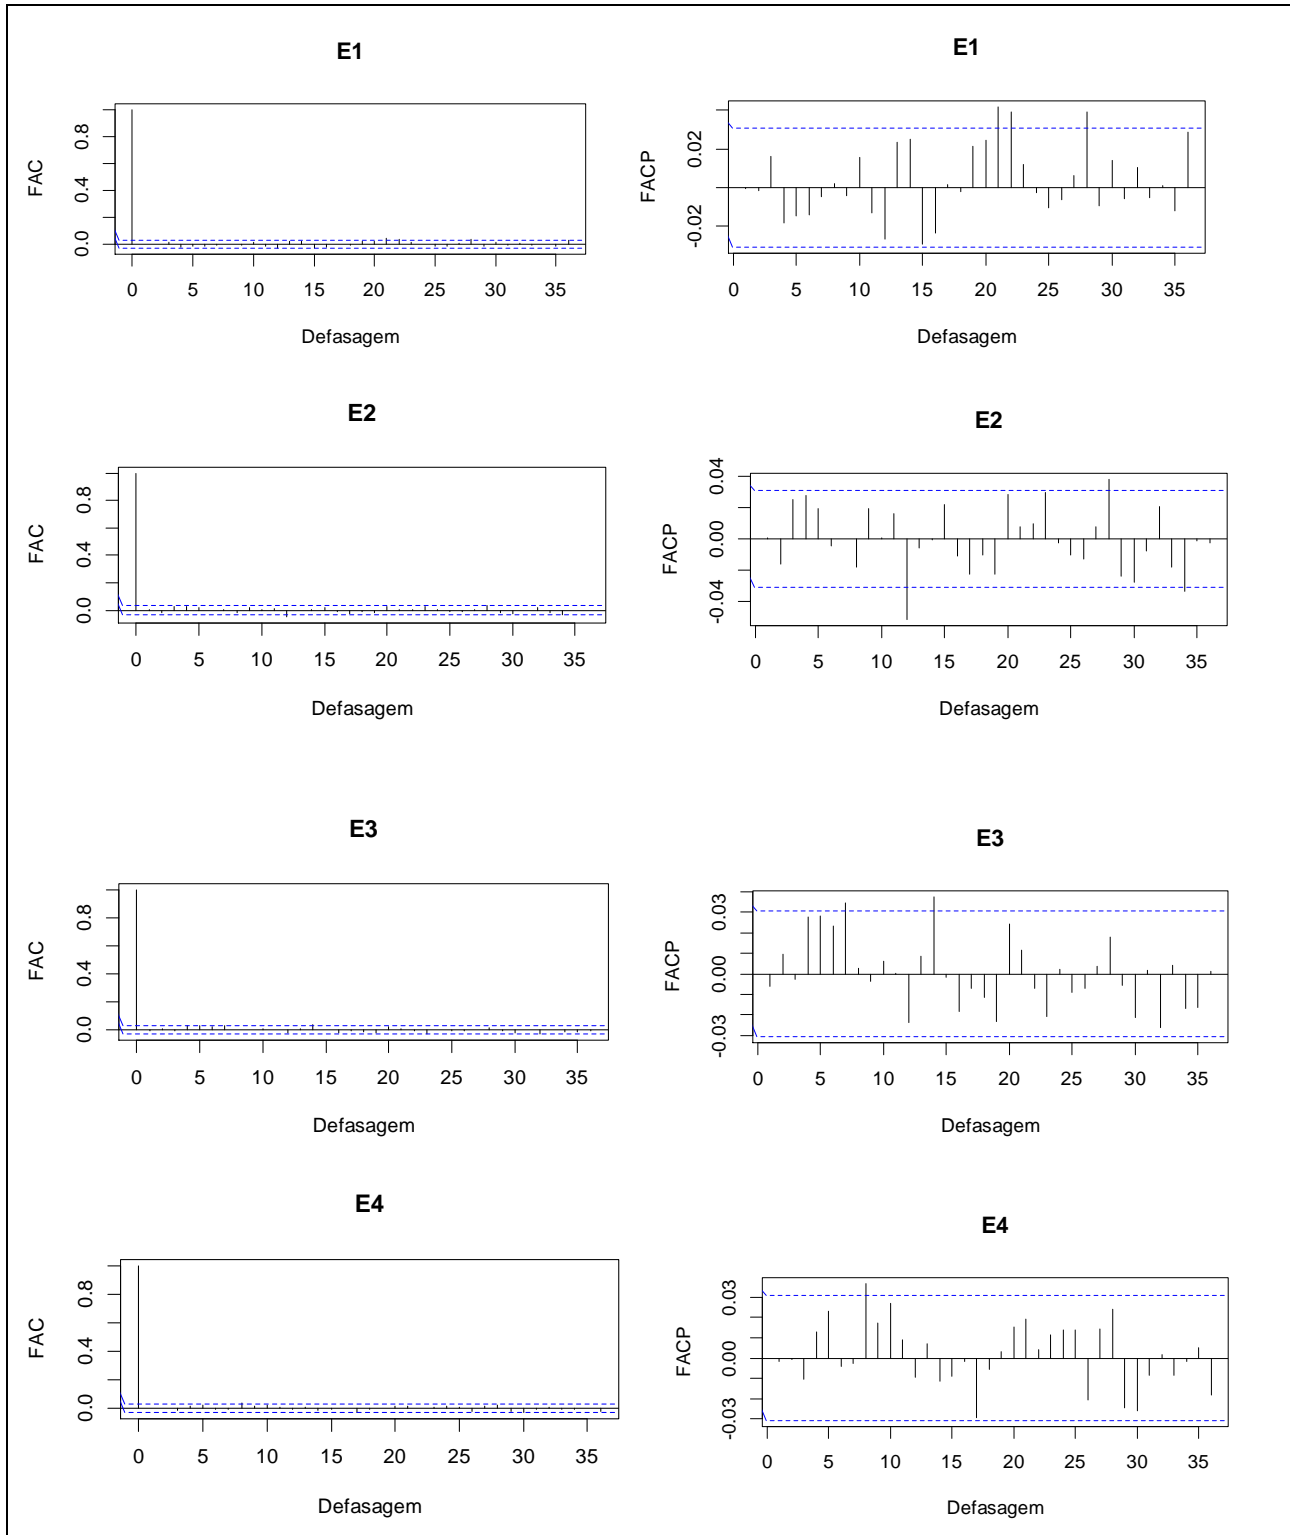
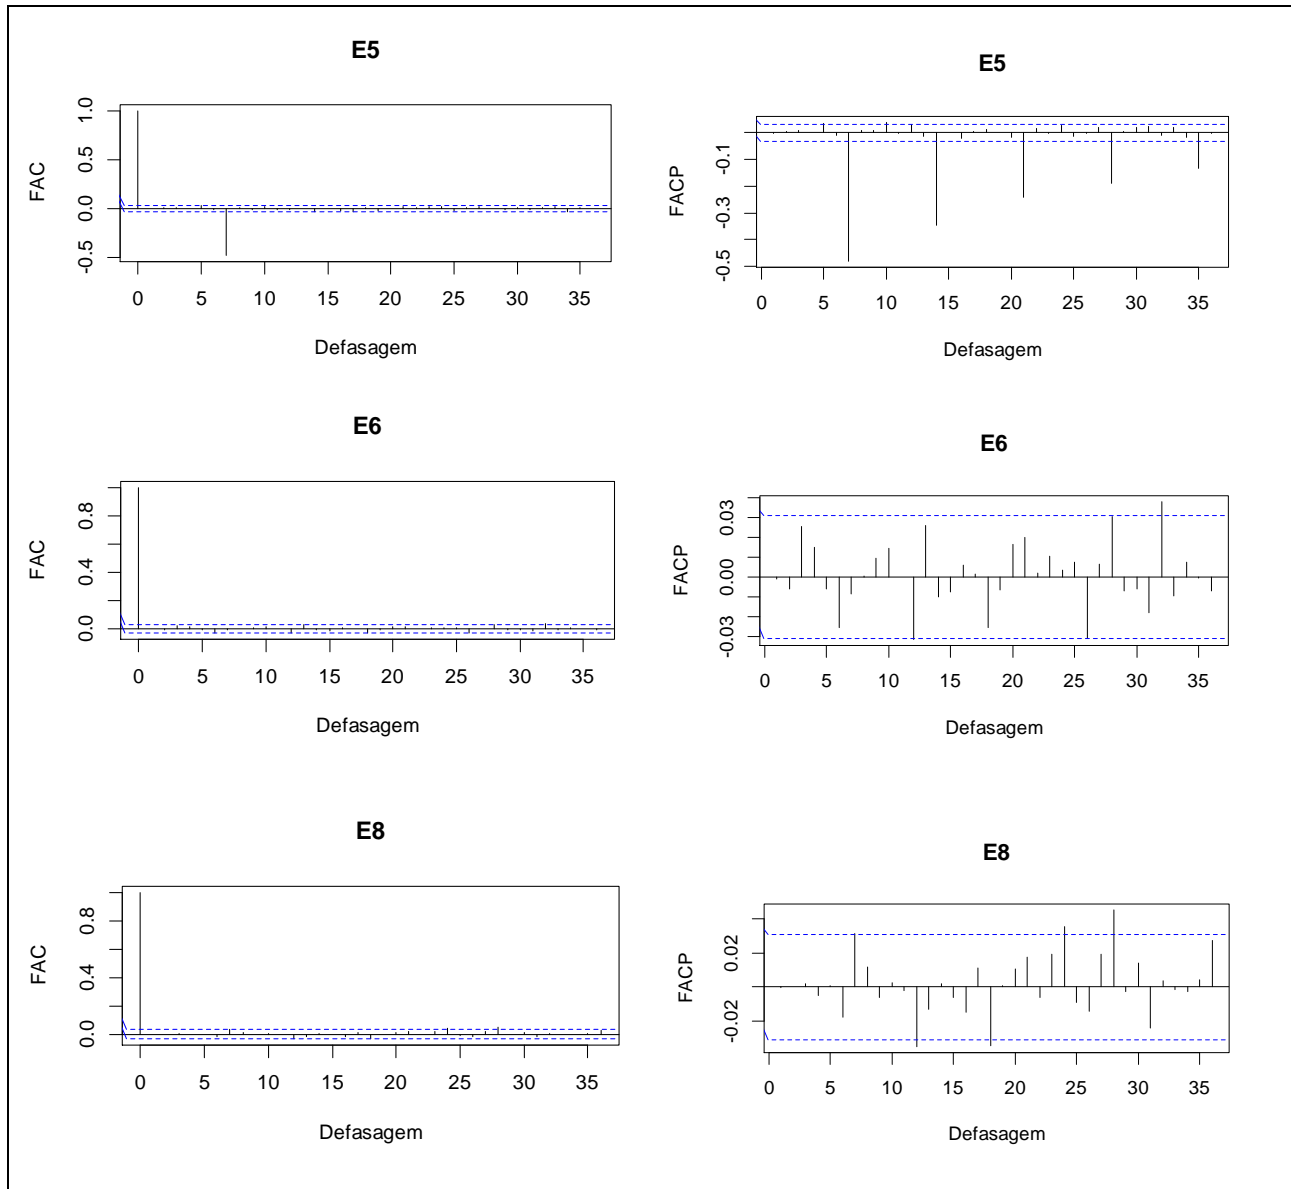


Figura 5 – Funções amostrais de autocorrelação (FAC) e autocorrelação parcial (FACP) dos resíduos dos modelos SARIMAX ajustados para cada estação

Conclusão



Fonte: Autores (2020)

É desejável que o modelo de previsão seja capaz de captar concentrações as quais possam ser prejudiciais à saúde pública. Assim, a fim de avaliar a eficiência e comparar os três modelos em prever eventos iguais ou superiores a $46 \mu g.m^{-3}$ (qualidade do ar regular), foram calculadas as estatísticas de avaliação POD, FAR, EA e MISS, cujos resultados encontram-se descritos na Tabela 12. É possível

observar que o modelo SARIMAX apresentou como o melhor modelo para realizar predições de eventos com níveis iguais ou superiores a $46 \mu\text{g.m}^{-3}$, dentre eles destacam-se os modelos determinados para as estações E1 e E8 os quais, das vezes que foram observados eventos de qualidade do ar regular, estimaram corretamente, 50,09% (E1) e 64,46% (E8) desses eventos. Tais resultados vão de encontro com os trabalhos de Monte, Albuquerque e Reisen (2015) e Pinto, Reisen e Monte (2018) em que os modelos adotados pelos autores considerando as variáveis velocidade do vento, temperatura, umidade relativa e precipitação pluviométrica se sobressaíram na predição de concentrações de ozônio acima de $80 \mu\text{g.m}^{-3}$ e de concentrações de material particulado inalável superiores a $46 \mu\text{g.m}^{-3}$, respectivamente.

Tabela 12 – Resultados das estatísticas de avaliação da eficiência do modelo em prever eventos classificados como regular

Estatística	Modelos	Estações						
		E1	E2	E3	E4	E5	E6	E8
POD	SARIMAX	0,5009	0	0,3571	0,0347	0,1798	0,1429	0,6446
	SARIMA	0,2555	0	0,3571	0,0347	0,1685	0,1039	0,585
	ARMA	0,1908	0	0,2857	0,0139	0	0,026	0,4179
FAR	SARIMAX	0,3836	1	0,0625	0,2857	0,8	0,4762	0,2944
	SARIMA	0,3902	1	0,0625	0,4444	0,8193	0,3333	0,3056
	ARMA	0,3412	0	0,0769	0	0	0,3333	0,3409
EA	SARIMAX	0,3818	0	0,3488	0,0342	0,1046	0,1264	0,5079
	SARIMA	0,2196	0	0,3488	0,0338	0,0955	0,0988	0,4652
	ARMA	0,1736	0	0,2791	0,0139	0	0,0256	0,3436
MISS	SARIMAX	0,4991	1	0,6429	0,9653	0,8202	0,8571	0,3554
	SARIMA	0,7445	1	0,6429	0,9653	0,8315	0,8961	0,415
	ARMA	0,8092	1	0,7143	0,9861	1	0,974	0,5821

Fonte: Autores (2020)

Ng e Awang (2018) também avaliaram modelos de previsão de concentrações médias diárias de PM_{10} monitoradas em cinco estações localizadas em diferentes

ambientes da Malásia, com base em variáveis preditivas, incluindo parâmetros meteorológicos e poluentes gasosos. Os resultados obtidos demonstram que os três modelos de regressão linear múltipla (MLR) apresentaram melhor desempenho conforme a variação das concentrações medidas em cada estação. Assim, o modelo de regressão linear múltipla com variáveis preditivas e concentrações de PM_{10} defasadas (MLR1) atuou bem em cenários em que as concentrações de material particulado apresentam grande variação. Em contrapartida, o modelo de regressão com erro de série temporal (RTSE) apresentou um bom desempenho nos casos em que as concentrações de PM_{10} variam com pequenas alterações.

Tal análise explica as diferenças encontradas na qualidade de predição e previsão dos modelos para cada estação da RGV. Para aquelas estações que apresentaram maior variação temporal (E1, E4, E6 e E8), o modelo SARIMAX mostrou-se mais eficaz comparado aos modelos ARMA e SARIMA. Logo, o modelo SARIMA com atribuição de variáveis exógenas pode ser considerado como um bom modelo de previsão de concentrações de PM_{10} mais elevadas, que possam representar risco a saúde da população.

Os resultados obtidos com a modelagem das séries temporais de concentração de PM_{10} com o modelo SARIMAX, tanto na previsão quanto na predição de eventos de qualidade do ar, demonstram que estes são considerados bons, posto que os modelos ajustados apresentaram resultados satisfatórios em relação à termos estatísticos, portanto, podem ser utilizados como ferramenta de previsão da qualidade do ar nos municípios da RGV para alertar previamente níveis prejudiciais à saúde pública e permitir adaptação de comportamentos adequados pela população e, principalmente, grupos de risco como crianças, idosos e pessoas com problemas respiratórios.

Tal análise explica as diferenças encontradas na qualidade de predição e previsão dos modelos para cada estação da RGV. Para aquelas estações que apresentaram maior variação temporal (E1, E4, E6 e E8), o modelo SARIMAX

mostrou-se mais eficaz comparado aos modelos ARMA e SARIMA. Logo, o modelo SARIMA com atribuição de variáveis exógenas pode ser considerado como um bom modelo de previsão de concentrações de PM₁₀ mais elevadas, que possam representar risco a saúde da população.

Os resultados obtidos com a modelagem das séries temporais de concentração de PM₁₀ com o modelo SARIMAX, tanto na previsão quanto na predição de eventos de qualidade do ar, demonstram que estes são considerados bons, posto que os modelos ajustados apresentaram resultados satisfatórios em relação à termos estatísticos, portanto, podem ser utilizados como ferramenta de previsão da qualidade do ar nos municípios da RGV para alertar previamente níveis prejudiciais à saúde pública e permitir adaptação de comportamentos adequados pela população e, principalmente, grupos de risco como crianças, idosos e pessoas com problemas respiratórios.

4 CONCLUSÕES

Este trabalho objetivou modelar e prever a concentração média diária de material particulado inalável utilizando o modelo SARIMAX, na Região da Grande Vitória (RGV), ES, Brasil, para o período de 01/01/2008 a 31/12/2018. Os resultados obtidos para os indicadores de desempenho demonstraram que os modelos SARIMAX ajustados para as estações E1, E2, E4, E6 e E8 são os mais minuciosos entre os estudados, para realizar predições e previsões da qualidade do ar na RGV. Para as estações E3 e E5 os modelos SARIMA e ARMA, respectivamente, superaram o desempenho do modelo SARIMAX devido a nula ou baixa correlação com as variáveis meteorológicas e pelas concentrações de PM₁₀ variarem próximos a média.

Com relação à predição de eventos de qualidade do ar regular para todas estações, com exceção da estação E2 e E3, o desempenho estatístico dos modelos SARIMAX foram superiores quando comparado aos demais. Dentre as variáveis

meteorológicas avaliadas, foram significativas e melhoraram o ajuste dos modelos as variáveis V, U, PP e T. Além disso, é importante destacar que a influência dos fatores meteorológicos sob os níveis de PM₁₀ está relacionada com as características locais e específicas de cada região.

Ressalta-se que estudos dessa natureza são importantes visto que, ao analisar o comportamento do poluente (PM₁₀) juntamente com as variáveis meteorológicas, permitem traçar um perfil mais preciso e eficaz na previsão dos índices de qualidade do ar com a capacidade de prever os picos de concentração, podendo auxiliar na tomada de decisões dos agentes públicos em relação ao planejamento e controle da qualidade do ar com vistas em minimizar os efeitos adversos provocados, especialmente, por episódios críticos de poluição atmosférica.

REFERÊNCIAS

AGIRRE-BASURKO, E.; IBARRA-BERASTEGUI, G.; MADARIAGA, I. Regression and multilayer perceptron-based models to forecast hourly O₃ and NO₂ levels in the Bilbao area.

Environmental Modelling and Software, v. 21, p. 430-446, 2006.

AKAIKE, H. A Bayesian analysis of the minimum AIC procedure. **Annals of the Institute of Statistical Mathematics**, v. 30, n. 1, p. 9-14, 1978.

AKAIKE, H. Information theory and an extension of the maximum likelihood principle. In: PETROV, B.N.; CSAKI, F. (Eds.). **Proceedings of the Second International Symposium on Information Theory**. Budapeste: Akademiai Kiado. 1973, p. 267-281.

ARAUJO, J. A.; NEL, A. E. Particulate matter and atherosclerosis: role of particle size, composition and oxidative stress. **Particle and Fibre Toxicology**, v. 6, n. 24, 2009.

BERA, A.K.; JARQUE, C.M. Efficient tests for normality, homoscedasticity and serial independence of regression residuals: Monte Carlo evidence. **Economics Letters**, v. 7, n. 4, p. 313-318, 1981.

BOX, G.; JENKINS, G. M. **Time Series Analysis: Forecasting and Control**. San Francisco, CA: Holden - Day, 1970, 500 p.

BOX, G.; PIERCE, D.A. Distribution of residual autocorrelations in autorregressive integrated moving average time series models. **Journal of the American Statistical Association**, v. 65, n. 332, p. 1509-1526, 1970.

BOX, G., COX, D. An analysis of transformations. **Journal of the Royal Statistical Society**, v. 26, p. 211-252, 1964.

BOWE, B.; XIE, Y.; LI, T.; YAN, Y.; XIAN, H.; AL-ALY, Z. The 2016 global and national burden of diabetes mellitus attributable to PM_{2,5} air pollution. **The Lancet Planetary Health**, v. 2, n. 7, p. e301-e312, 2018.

CETESB - Companhia Ambiental do Estado de São Paulo. **Relatório de qualidade do ar no Estado de São Paulo 2018**. São Paulo: CETESB, 2019. Disponível em: <https://cetesb.sp.gov.br/ar/publicacoes-relatorios/>. Acesso em: 07 jul. 2021.

CONAMA – Conselho Nacional de Meio Ambiente. **Resolução nº 491**, de 19 de novembro de 2018. Dispõe sobre padrões de qualidade do ar. Diário Oficial da União: seção 1, Brasília, DF, p. 155. Disponível em: <http://www2.mma.gov.br/port/conama/legiabre.cfm?codlegi=740>. Acesso em: 13 ago. 2019.

DICKEY, D. A.; FULLER, W. A. Likelihood ratio statistics for autoregressive time series with a unit root. **Econometrica**, Chicago, v. 49, p. 1057-1072, 1981.

ECOSOFT – Ecosoft Consultoria e Softwares Ambientais. **Inventário de emissões atmosféricas da Região da Grande Vitória**: ano base – 2015. Vitória, 2019. Disponível em: <https://iema.es.gov.br/qualidadedoar/inventariodefuentes/2015>. Acesso em: 24 ago. 2019.

ESPÍRITO SANTO (Estado). **Decreto nº 3463-R**, de 16 de dezembro de 2013. Estabelece novos padrões de qualidade do ar e dá providências correlatas. Diário Oficial do Estado do Espírito Santo, Vitória, ES, p. 9-11, 17 dez. 2013. Disponível em: https://iema.es.gov.br/Media/iema/CQAI/Documentos/DECRETO_N%C2%BA_3463_2013.pdf. Acesso em: 13 ago. 2019.

FIORDELISI, A.; PISCITELLI, P.; TRIMARCO, B.; COSCIONI, E.; IACCARINO, G.; SORRIENTO, D. The mechanisms of air pollution and particulate matter in cardiovascular diseases. **Heart Failure Reviews**, v. 22, p. 337-347, 2017.

FREITAS, C. U.; LEON, A. P.; JUNGER, W. GOUVEIA, N. Air pollution and its impacts on health in Vitoria, Espirito Santo, Brazil. **Revista de Saúde Pública**, v. 50, n. 4, p. 1-9, 2016.

GOMES, K.S. **Modelagem INAR(p) para a previsão de índices de qualidade do ar**. 71 f. Dissertação (Mestrado em Engenharia Ambiental) – Programa de Pós-Graduação em Engenharia Ambiental, Centro Tecnológico, Universidade Federal do Espírito Santo, Vitória, 2009.

GOUVEIA, N.; MENDONÇA, G. A. e S.; LEON, A. P.; CORREIA, J. E. M.; JUNGER, W. L.; FREITAS, C. U.; DAUMAS, R. P.; MARTINS, L. C.; GIUSSEPE, L.; CONCEIÇÃO, G. M.S.; MANERICH, A.; CUNHA-CRUZ, J. Poluição do ar e efeitos na saúde nas populações de duas grandes metrópoles brasileiras. **Epidemiologia e Serviços de Saúde**, v. 12, p. 29-40, 2003.

GOCHEVA-ILIEVA, S.; IVANOV, A.; ILIEV, I. **Exploring key air pollutants and forecasting particulate matter PM10 by a two-step SARIMA approach**. In: Aip Conference Proceedings. AIP Publishing, 2019, p. 1-10.

GRIPA, W.R.; REISEN, V.A.; FAJARDO, F.A.; REIS JUNIOR, N.C. Análise de predição e previsão das concentrações de material particulado inalável (PM10) na cidade de Cariacica, ES. **Revista Brasileira de Estatística**, v. 73, n. 237, p. 37-57, 2012.

IBGE – Instituto Brasileiro de Geografia e Estatística. **Estimativa da população**. 2019. Disponível em: <https://www.ibge.gov.br/estatisticas/sociais/populacao/9103-estimativas-de-populacao.html>. Acesso em: 15 out. 2019.

IEMA – Instituto Estadual de Meio Ambiente e Recursos Hídricos do Estado do Espírito Santo, **Relatório da qualidade do ar da Região da Grande Vitória – 2016**. Vitória. 2018. Disponível em: https://iema.es.gov.br/Media/iema/CQAI/Relatorios_anuais/Relat%C3%B3rio_Anual_de_Qualidade_do_Ar_2016.pdf. Acesso em: 03 mar. 2019.

JUNGER, W.L.; LEON, A.P. Imputation of missing data in time series for air pollutants. **Atmospheric Environment**, v. 102, p. 96-104, 2015.

JUNGER, W.L.; LEON, A.P. **mstdi: Multivariate Time Series Data Imputation**. R package version 0.3.5, 2018. Disponível em: <https://CRAN.R-project.org/package=mtsdi>. Acesso em: 01 maio 2020.

KÖPPEN, W. Versuch einer klassifikation der klimate, vorzugsweise nach ihren beziehungen zur pflanzenweltl. **Geogr Zeitschr**, v. 6, p. 596-611, 1900.

LEITE, R. C. M.; GUIMARÃES, E. C.; LIMA, E. A. P.; BARROZO, M. A. S.; TAVARES, M. Utilização de regressão logística simples na verificação da qualidade do ar atmosférico de Uberlândia. **Engenharia Sanitária e Ambiental**, v. 16, n.1, p. 175-180, 2011.

LIRA, T. S. **Modelagem e previsão da qualidade do ar na cidade de Uberlândia – MG**. 180 f. Tese (Doutorado em Engenharia Química) - Programa de Pós-graduação em Engenharia Química, Universidade Federal de Uberlândia, Uberlândia, 2009.

LIU, P. W.G.; JOHNSON, R. Forecasting peak daily ozone levels: part 2. A regression with time series errors model having a principal component trigger to forecast 1999 and 2002 ozone levels. **Journal of the Air & Waste Management Association**, v. 52, n. 9, p.1064-1074, 2002.

LIU, P.W.G.; JOHNSON, R. Forecasting peak daily ozone levels: part 2. A regression with time series errors model having a principal component trigger to forecast 1999 and 2002 ozone levels. **Journal of the Air & Waste Management Association**, v. 53, n. 12, p.1472-1489, 2003.

LJUNG, G.M.; BOX, G.E.P. On a measure of lack of fit in time series models. **Biometrika**, v. 65, n. 2, p. 297-303, 1978.

LYRA, G.B.; ODA-SOUZA, M.; VIOLA, D.N. Modelos lineares aplicados à estimativa da concentração do material particulado (PM10) na cidade do Rio de Janeiro, RJ. **Revista Brasileira de Meteorologia**, v. 26, n. 3, p. 392-400, 2011.

MEMARIANFARD, M.; HATAMI, A. M. Artificial neural network forecast application for fine particulate matter concentration using meteorological data. **Global Journal of Environmental Science and Management**, v. 3, n. 11, p. 333-340, 2017.

MONTE, E. Z.; ALBUQUERQUE, T. T. A.; REISEN, V. A. Previsão da concentração de ozônio na Região da Grande Vitória, ES, Brasil, utilizando o modelo ARMAX-GARCH. **Revista Brasileira de Meteorologia**, v. 30, n. 3, p. 285-294, 2015.

MOREIRA, D. M.; TIRABASSI, T.; MORAES, M. R. Meteorologia e poluição atmosférica. **Ambiente e Sociedade**, v. 11, n. 1, p. 1-13, 2008.

MORETTIN, P. A.; TOLOI, C. M. C. **Análise de séries temporais**. 2 ed. São Paulo: Edgard Blücher, 2006.

NASCIMENTO, L. F. C.; PEREIRA, L. A. P.; BRAGA, A. L. F.; MÓDOLO, M. C. C.; CARVALHO JUNIOR, J. A. Efeitos da poluição atmosférica na saúde infantil em São José dos Campos, SP. **Revista de Saúde Pública**, v. 40, p. 77- 82, 2006.

NG, K. Y.; AWANG, N. Multiple linear regression and regression with time series error models in forecasting PM10 concentrations in Peninsular Malaysia. **Environmental Monitoring and Assessment**, v. 190, n. 2, p. 1-11, 2018.

PEREZ, P.; REYES, J. An integrated neural network model for PM₁₀ forecasting. **Atmospheric Environment**, v. 40, p. 2845–2851, 2006.

PINTO, W. P.; REISEN, V. A.; MONTE, E. Z. Previsão da concentração de material particulado inalável, na Região da Grande Vitória, ES, Brasil, utilizando o modelo SARIMAX. **Engenharia Sanitária e Ambiental**, v. 23, n. 2, p. 307-318, 2018.

R CORE TEAM (2019). **R: A language and environment for statistical computing**, R Foundation for Statistical Computing, Vienna, Austria, 2019. Disponível em: <https://www.R-project.org/>.

RAZ, R.; ROBERTS, A. L.; LYALL, K.; HART, J. E.; JUST, A. C.; LADEN, F.; WEISSKOPF, M. G. Autism spectrum disorder and particulate matter air pollution before, during, and after pregnancy: a nested case-control analysis within the Nurses' Health Study II cohort. **Environmental Health Perspectives**, v.123, p. 264-270, 2015.

REISEN, V.A.; SARNAGLIA, A.J.Q.; REIS JR, N.C.; LÉVY-LEDUC, C. SANTOS, J.M. Modeling and forecasting daily average PM10 concentrations by a seasonal long-memory model with volatility. **Environmental Modelling & Software**, v. 51, p. 286-295, 2014.

RYAN, W. F. Forecasting severe ozone episodes in the Baltimore metropolitan area. **Atmospheric Environment**, v. 29, n. 17, p. 2387-2398, 1995.

SANTIAGO, A.; PRADO, R. J.; FILHO, P. M.; ALONSO, R. V. Caracterização do material particulado suspenso no ar de Cuiabá-MT no período de queimadas. **Revista Matéria**, v. 20, p. 273-283, 2015.

SANTOS, T. C.; REBOITA, M. S.; CARVALHO, V. S. B. Investigação da Relação entre Variáveis Atmosféricas e a Concentração de MP10 E O3 no Estado de São Paulo. **Revista Brasileira de Meteorologia**, v. 33, p. 631-645, 2018.

SCHWARZ, G. Estimating the dimension of a model. **Ann. Stat.**, Haward, v.6, p.461-464, 1978.

SHAPIRO, S.S.; WILK, M.B. An analysis of variance test for normality (complete samples). **Biometrika**, v. 52, n. 3-4, p. 591-611, 1965.

SNEDECOR, W.; COCHRAN, W. G. **Statistical Methods**. 8 ed., Ames: Iowa State University Press, 1989.

SOUZA, J. B.D.; REISEN, V. A.; SANTOS, J.M.; FRANCO, G.C. Componentes principais e modelagem linear generalizada na associação entre atendimento hospitalar e poluição do ar. **Revista de Saúde Pública**, v. 48, n. 3, p. 451-458, 2014.

VAGROPOULOS, S. I.; VAGROPOULOS, S. I.; CHOULIARAS, G. I.; KARDAKOS, E. G.; SIMOGLU, C. K. BAKIRTZIS, A. G. Comparison of SARIMAX, SARIMA, modified SARIMA and ANN-based models for short-term PV generation forecasting. In: **2016 IEEE International Energy Conference (Energycon)**. IEEE, Bélgica, 2016.

WEI, W. **Time Series Analysis: Univariate and Multivariate Methods**. Nova York: Addison Wesley, 2006.

WHO – World Health Organization. **WHO air quality guidelines global update 2005**. 2005. Disponível em: http://www.euro.who.int/__data/assets/pdf_file/0008/147851/E87950.pdf. Acesso em: 13 ago. 2019.

WUERTZ, D.; SETZ, T.; CHALABI, Y. **fBasics: Rmetrics - Markets and Basic Statistics**. R package version 3042.89.1, 2020. Disponível em: <https://CRAN.R-project.org/package=fBasics>. Acesso em: 01 maio 2020.

YAP, J.; NG, Y.; YEO, K. K.; SAHLÉN, A.; LAM, C. S. P.; LEE, V.; MA, S. Particulate air pollution on cardiovascular mortality in the tropics: impact on the elderly. **Environmental Health**, v. 18, p. 34, 2019.

ZHANG, X.; CHEN, X.; ZHANG, X. The impact of exposure to air pollution on cognitive performance. **Proceedings of the National Academy of Sciences**, v. 115, p. 9193-9197, 2018.

ZHANG, Z.; WANG, J.; HART, J. E.; LADEN, F.; ZHAO, C.; LI, T.; ZHEN, P.; LI, D.; YE, Z.; CHEN, K. National scale spatiotemporal land-use regression model for PM_{2.5}, PM₁₀ and NO₂ concentration in China. **Atmospheric Environment**, v. 192, p. 48-54, 2018.

Contribuição de autoria

1 – Jaqueline Knaak (Autor correspondente)

Engenheira Sanitarista e Ambiental, Mestranda em Engenharia Ambiental,
<https://orcid.org/0000-0001-8980-7289> - jaquelineknaak@gmail.com

Contribuição: Curadoria de dados, investigação, análise formal, metodologia, software, visualização de dados, escrita – primeira redação, escrita – revisão e edição.

2 – Wanderson de Paula Pinto

Matemático, Mestre e Doutor em Engenharia Ambiental, Professor do Curso de Engenharia Ambiental e Sanitária da FARESE

<https://orcid.org/0000-0001-5267-227X> - wandersondpp@gmail.com

Contribuição: investigação, administração do projeto, escrita – revisão e edição, metodologia.

Como citar este artigo

KNAAK, J.; PINTO, W. de P. Aplicação do Modelo SARIMAX para Modelar e Prever a Concentração de Material Particulado Inalável, no Espírito Santo, Brasil. **Ciência e Natura**, Santa Maria, v. 44, e9, 2022. DOI 10.5902/2179460X63466. Disponível em: <https://doi.org/10.5902/2179460X63466>.