

Spectral analysis of time series: an application for air pollution in the city of Vitória, Espírito Santo, Brazil

Análise espectral de séries temporais: uma aplicação para a poluição do ar, na cidade de Vitória, Espírito Santo, Brasil

Article Info:

Article history: Received 2022-01-03 / Accepted 2022-03-02 / Available online 2022-03-10

doi: 10.18540/jcecv18iss2pp13892-01e

Geisely do Espírito Santo

ORCID: <https://orcid.org/0000-0002-6381-3290>

Faculdade da Região Serrana - FARESE, Brasil

E-mail: geiselyes@gmail.com

Wanderson de Paula Pinto

ORCID: <https://orcid.org/0000-0001-5267-227X>

Faculdade da Região Serrana - FARESE, Brasil

E-mail: wandersonpdp@gmail.com

Resumo

A poluição atmosférica é um fator causador do aumento da taxa de mortalidade, aumento da taxa de doenças crônicas, aumento no custo das despesas com saúde, diminuição da produtividade e da qualidade de vida de uma forma geral. Vale lembrar que os efeitos causados pela poluição do ar podem não ser apenas locais, isso significa que esses poluentes podem viajar milhares de quilômetros pela atmosfera, atingindo, assim, comunidades distantes do ponto de emissão. Baseado nos riscos que esses poluentes podem causar esse trabalho objetivou analisar as séries temporais de concentrações de poluentes atmosféricos de PM₁₀, PM_{2,5} e SO₂, monitorados na RGV, Espírito Santo, Brasil, utilizando as técnicas da análise espectral. Os dados utilizados nesta pesquisa foram medidos nas estações da Rede Automática de Monitoramento da Qualidade do Ar (RAMQAr) e coletados através do banco de dados do IEMA. Através da análise espectral da série temporal, foi possível observar que as concentrações dos poluentes PM₁₀ e PM_{2,5} apresentaram sazonalidade com período de sete dias, e para o poluente SO₂, não houve presença de sazonalidade. Dessa forma, a variação sazonal apresentada pode ser explicada principalmente pelo ritmo de movimentação dos transportes na RGV, ou seja, as maiores concentrações medidas de PM_{2,5} e PM₁₀, ocorrem durante os dias úteis, quando o fluxo de veículos é maior, e o oposto ocorre nos fins de semana. Já para o SO₂, por não apresentar variação sazonal, não possui um período fixo de repetição.

Palavras-chave: Análise espectral. Séries temporais. Teste G de Fisher.

Abstract

Air pollution is a factor causing an increase in the mortality rate, an increase in the rate of chronic diseases, an increase in the cost of healthcare expenses, a decrease in productivity and quality of life in general. It is worth remembering that the effects caused by air pollution may not only be local, it means that these pollutants can travel thousands of kilometers through the atmosphere, thus reaching communities far from the point of emission. Based on the risks that these pollutants can cause, this study aimed to analyze the time series of concentrations of atmospheric pollutants of PM₁₀, PM_{2,5} and SO₂, monitored at RGV, Espírito Santo, Brazil, using spectral analysis techniques. The data used in this research were measured at the stations of the Automatic Air Quality Monitoring Network (RAMQAr) and collected through the IEMA database. Through the spectral analysis of the time series, it was possible to observe that the concentrations of the pollutants PM₁₀ and PM_{2,5} presented seasonality with a period of seven days, and for the pollutant SO₂, there was no presence of seasonality. Thus, the seasonal variation presented can be explained mainly by the pace of

transport movement in the RGV, that is, the highest measured concentrations of $PM_{2.5}$ and PM_{10} , occur during weekdays, when the flow of vehicles is greater, and the opposite occurs on weekends. As for SO_2 , as it does not present seasonal variation, it does not have a fixed repetition period.

Keywords: Spectral analysis. Time series. Fisher's G test.

1. Introdução

O estudo da qualidade do ar envolve diferentes aspectos, como as emissões por fontes pontuais ou difusas e a relação entre as condições geomorfológicas e meteorológicas. As atividades exercidas pela humanidade, desde o início da era industrial, promoveram benefícios econômicos e sociais, contudo provocaram grandes alterações na composição química da troposfera, por meio da emissão de poluentes, sobretudo nos ambientes urbanos e industriais (ORLANDO et al., 2010).

A poluição atmosférica é um fator causador do aumento da taxa de mortalidade, aumento da taxa de doenças crônicas, aumento no custo das despesas com saúde, diminuição da produtividade e da qualidade de vida de uma forma geral (MIHRLCIC, ZIMMERMAN e AUER, 2014; DERISIO, 2016). Estudos realizados por Abbey et al., 1995; Martins et al., 2002; Liu et al., 2003; Souza et al., 2014; Tibuakuu et al., 2018; Bowe et al., 2018; Wang et al., 2020; e outros têm mostrado que a poluição atmosférica é um fator causador de doenças cardiovasculares, doenças neurológicas e principalmente doenças do aparelho respiratório.

Na literatura diversos autores (LATORRE e CARDOSO, 2001; JUNGER, 2008; ANDREÃO e PIMASSONI, 2013; PEREIRA et al., 2015; TIBULO, 2020, entre outros) utilizam técnicas estatísticas para analisar dados de poluição do ar e fazer associação com problemas de saúde, porém, a maioria dos autores analisam dados no domínio do tempo. As séries temporais ambientais são frequentemente de grande dimensão devido ao grande número de medições registradas em muitos locais diferentes. Esses dados também podem apresentar fenômenos interessantes a serem considerados do ponto de vista teórico e aplicado (REISEN et al. 2019). De forma geral, uma série temporal é composta por três componentes não observáveis, a saber: tendência, sazonalidade e aleatoriedade (PINTO, REISEN e MONTE 2018a). Um fenômeno sazonal é definido como aquele que ocorre regularmente em períodos fixos de tempo. Para descobrir se existe sazonalidade na série de valores e verificar qual o seu ritmo é importante realizar uma análise espectral. Com este tipo de análise é possível identificar um padrão sazonal, mesmo dentro de uma variabilidade aleatória (LATORRE & CARDOSO, 2001).

Reisen *et al.* (2014), modelaram a média diária de concentração de material particulado inalável, na cidade de Cariacica, Espírito Santo, Brasil, utilizando um processo integrado fracionado sazonal, com volatilidade. Os autores relataram que as estimativas fracionárias mostraram que a série é estacionária na média e apresentou o fenômeno de memória longa a longo prazo e, também, nos períodos sazonais. Sendo assim, foi considerado pelos autores o modelo SARFIMA (modelo autoregressivo sazonal fracionário integrado de média móvel) com inovação do tipo GARCH para modelagem de previsão de PM_{10} . As estimativas do estudo evidenciaram que o modelo SARFIMA-GARCH apresentou um alto nível de precisão e capturou bem a dinâmica da série.

Pinto, Reisen e Lima (2018a), realizaram um estudo cujo objetivo consistiu em modelar e prever a concentração média diária de material particulado inalável (PM_{10}), na Região da Grande Vitória, Espírito Santo, Brasil, utilizando o modelo SARIMAX. Os dados desta pesquisa foram do tipo séries temporais de concentrações de PM_{10} e de variáveis meteorológicas. Os resultados apontam que o modelo SARIMAX é o mais acurado, entre os estudados, para fazer previsões e previsões da qualidade ar da região.

Reisen *et al.* (2019) realizaram um estudo na Região da Grande Vitória onde foi considerado a modelagem de fatores para séries temporais de alta dimensão contaminadas por outliers aditivos. A metodologia proposta foi utilizada para identificar o comportamento poluente do poluente PM_{10} , que pode ser muito útil para a gestão da rede da qualidade do ar. Os autores investigaram o desempenho do método de Monte Carlo por meio de simulações, as quais são realizadas para

analisar o desempenho do tamanho da amostra finita do estimador robusto do número de fatores sob os cenários de séries temporais multivariadas com e sem outliers. Os resultados apresentados revelam que outliers aditivos reduzem a dimensão clássica do fator estimado.

Gonzaga e Freitas (2020), produziram um trabalho cujo objetivo consistiu em analisar a influência da qualidade do ar e dos parâmetros meteorológicos na transmissão e órbitos causados pelo COVID-19 na região metropolitana de São Paulo. Para isso foram empregados dados meteorológicos e de qualidade do ar fornecidos pela Companhia Ambiental do Estado de São Paulo. Além disso, utilizou-se um modelo de regressão múltipla pelo método de stepwise. Os resultados mostraram que estes preditores são: ozônio, monóxido de carbono, umidade relativa do ar, pressão atmosférica, radiação ultravioleta e temperatura do ar.

São poucos os trabalhos desenvolvidos no domínio da frequência. Rao, Samson e Peddada (1976), realizaram uma comparação entre as características espectrais da concentração de SO_2 e a velocidade do vento no domínio da frequência aplicado em Long Island, Nova York. Os resultados apontam que, durante o inverno, ambos os espectros têm um pico dominante correspondente a escala de tempo sinótico, indicando que as variações climáticas sinóticas são responsáveis pelas oscilações de longo período do poluente. Porém, durante o verão, os espectros do poluente e a velocidade do vento apresentaram picos diurnos e semi-diurnos significativos, além do pico sinótico.

Hies *et al.* (2000), trataram um método eficaz para analisar diferentes fontes de poluição do ar em uma série temporal de Carbono Elementar (CE) em quatro locais de Berlim. Um dos métodos empregado pelos autores foi a análise espectral, o qual pode detectar periodicidades típicas para a contribuição de fontes como o aquecimento doméstico por carvão e transporte de longo alcance. Além disso, foi mostrado que o aquecimento doméstico por combustão de carvão aparece como uma periodicidade de 365 dias e o CE elevado de longo alcance pode ser identificado como picos característicos com periodicidades na faixa de 13 a 42 dias.

Tchepel *et al.* (2010), propuseram uma abordagem para a estimativa de concentrações de fundo usando dados decompostos de qualidade do ar medidos em componentes de linha de base e de curto prazo na zona urbana de Lisboa (Portugal). Para tanto, a densidade espectral foi obtida para dados de monitoramento da qualidade do ar com base na análise da série de Fourier. Os resultados obtidos, apresentaram um melhor desempenho para o modelo em microescala quando inicializado por séries temporais decompostas e demonstraram a importância da metodologia proposta na redução da incerteza das previsões do modelo.

Kandlikar (2007) aplicou métodos espectrais para analisar mudanças na qualidade do ar em um único local de monitoramento em Delhi, Índia, de 2000 a 2006. Através dos cálculos de densidade espectral de potência de dados de concentração diária de PM_{10} , CO, NO_x e SO_x os autores revelam a presença de tendências e oscilações periódicas para todos os poluentes. Além disso, foi aplicado a Análise do Espectro Singular (SSA) para decompor os dados diários em tendências não lineares, estatisticamente significativas, ciclos sazonais e outras oscilações. Por fim, os resultados apontam que períodos de reduções acentuadas foram observados para as concentrações de SO_x em 2001 e CO em 2002. Além disso, observaram que as mudanças nas concentrações de SO_x e PM_{10} , provavelmente, não foram causadas por fontes relacionadas ao tráfego veicular.

Fajardo *et al.* (2018) sugeriram um periodograma alternativo, denominado M-periodograma, que é obtido relacionando o periodograma a um problema de regressão e usando um M-estimador para os coeficientes do modelo de regressão. Segundo os autores, além de ser um periodograma alternativo atraente para séries temporais de memória longa, ele também é resistente a outliers aditivos. Através de simulação de Monte Carlo foi investigado o desempenho de robustez do estimador e como uma aplicação prática, investigaram o efeito de observações atípicas em dados de poluição do ar, PM_{10} . Os resultados mostram que o M-periodograma demonstrou ser melhor do que os outros estimadores espectrais estudados, especialmente quando a série está contaminada com outliers.

Na Região da Grande Vitória (RGV), nos últimos anos aconteceram muitas mudanças, como a implantação e ampliação de grandes projetos industriais, aumento dos empreendimentos

imobiliários, aumento do consumo de energia e o aumento da frota veicular, o que conduziu na elevação dos índices de poluição atmosférica, mesmo existindo diversas regulamentações impostas pelos órgãos de controle ambiental (MONTE, 2016). Dessa forma, este trabalho objetivou analisar as séries temporais de concentrações de poluentes atmosféricos de PM_{10} , $PM_{2,5}$ e SO_2 , monitorados na RGV, Espírito Santo, Brasil, utilizando técnicas da análise espectral.

2. Materiais e Métodos

2.1 Caracterização da área de estudo

A área de estudo compreendeu a RGV, Espírito Santo, Brasil, que é constituída pelos municípios de Vitória, Vila Velha, Cariacica, Serra e Viana. Segundo o Instituto Brasileiro de Geografia e Estatística (IBGE, 2021), a RGV abrange uma área de 1.461 Km², com aproximadamente 1.882.184 habitantes, sendo um dos principais polos de desenvolvimento urbano e industrial do Estado. Por estar situada na região litorânea, a RGV apresenta clima tropical quente (Aw), possuindo inverno ameno e seco, e verão chuvoso e quente. As temperaturas médias variam entre 24 °C (Celsius) e 30 °C (IEMA, 2013). A região sofre com diversos tipos de problemas ambientais, entre os quais está a deterioração da qualidade do ar, devido às emissões atmosféricas por indústrias, pela frota veicular e pela ressuspensão do solo causada pelo vento e pelo tráfego veicular (PINTO, REISEN e MONTE, 2018b).

Vale lembrar que a RGV possui uma Rede Automática de Monitoramento da Qualidade do Ar (RAMQAR) inaugurada em julho de 2000, de propriedade do IEMA. Essa rede é distribuída em oito estações, a saber: Laranjeiras; Carapina; Jardim Camburi; Enseada do Suá; Vitória – Centro; Vila Velha – Ibes; Vila Velha – Centro; e, Cariacica (PINTO, REISEN e MONTE, 2018a). A localização espacial das estações de monitoramento da RAMQAR está ilustrada na Figura 1.

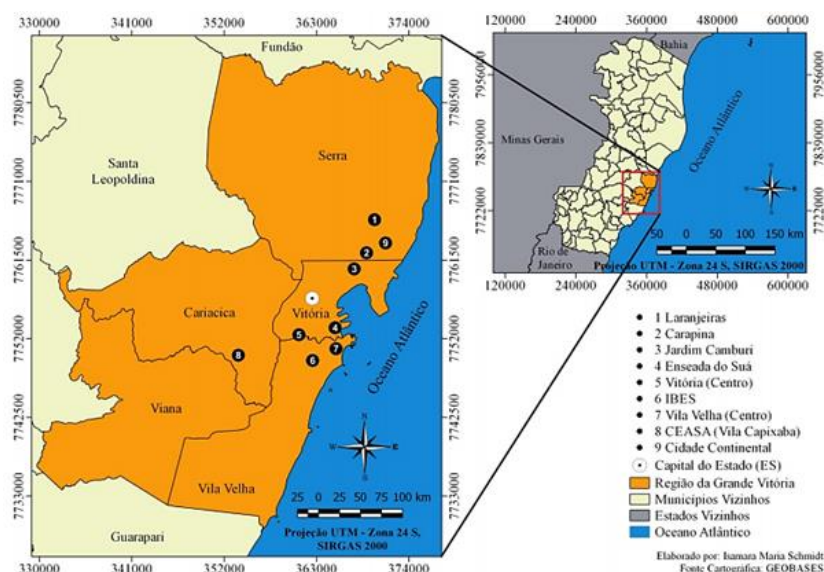


Figura 1 - Localização espacial das estações de monitoramento da qualidade do ar da RGV (SCHMIDT et al, 2019).

2.2 Dados

Os dados utilizados nesta pesquisa foram medidos nas estações da RAMQAR, fornecidos em médias horárias de 24 horas, e coletados através do banco de dados do IEMA, compreendendo o período de 01 de janeiro de 2016 a 31 de dezembro de 2020. Para esse artigo, foi utilizado apenas a estação Enseada de Suá e como a sazonalidade é um fenômeno característico de alguns poluentes atmosféricos, o enfoque foi nos poluentes PM_{10} , $PM_{2,5}$ e SO_2 . Além disso, toda análise e tratamento estatístico foi realizado utilizando o software R versão 4.0.2 (R CORE TEAM, 2020).

2.2 Análise espectral

Na literatura, a análise espectral de séries temporais ambientais, baseia-se na avaliação de dados de médias horárias, diárias ou mensais como única ferramenta para investigar as periodicidades dos mesmos (PINTO, 2019). Com base na série de Fourier, este método permite determinar a contribuição de diferentes frequências para a variância dos dados e, portanto, para analisar a contradição de vários processos subjacentes à flutuação de concentrações (PERCIVAL e WALDEN, 1998 apud TCHEPEL et al, 2010).

Segundo Brockwell e Davis (2002), a decomposição espectral é análoga aos processos estacionários da representação de Fourier de funções determinísticas. A análise dos processos estacionários por meio de sua representação espectral é muitas vezes referida como "análise de domínio de frequência" de séries temporais ou "análise espectral". É equivalente a análise no domínio do tempo que utiliza a função de autocovariância, mas fornece uma forma alternativa de visualização do processo, o que para algumas aplicações pode ser mais esclarecedora.

Em estudos realizados por Morettin e Tolo (2006), a expressão $E \left| d_j^{(N)} \right|^2 \cong f(\lambda_j), \lambda_j = \frac{2\pi j}{N}$ sugere que, dada uma realização $\{Z_t, t = 1, \dots, N\}$ do processo estacionário, um estimador para $f(\lambda_j)$ é denominado periodograma (Equação 1).

$$I_j^{(N)}(\lambda) = \left| d_j^{(N)} \right|^2 = \frac{1}{2\pi N} \left| \sum_{t=1}^N Z_t e^{-i\lambda_j t} \right|^2 \quad (1)$$

O qual pode também ser definido para qualquer frequência $\lambda \in [-\pi, \pi]$, ou seja, $I^{(N)}(\lambda) = \left| d^{(N)}(\lambda) \right|^2$, mas na prática só poderá ser calculado para um número finito de frequências. Pode-se demonstrar que a equação anterior é completamente determinada por seus valores nas frequências $\lambda_j = 2\pi j/N$.

Para Morettin e Tolo (2006) considera-se dois testes que utilizam as ordenadas do periodograma em testes para periodicidades. Suponha que um modelo adequado para a série temporal observada seja a Equação 2, em que K, R_i e $\omega_i, i = 1, \dots, K$, são constantes, $\phi_i \sim \mathcal{U}(-\pi, \pi)$ independentes, $\{\varepsilon_t\}$ sequência de ruídos brancos independentes de Z_t , com média zero e variância σ_ε^2 .

$$Z_t = \sum_{i=1}^K R_i \cos(\omega_i t + \phi_i) + \varepsilon_t, \quad t = 1, \dots, N \quad (2)$$

Utilizando uma amostra Z_1, Z_2, \dots, Z_N podemos calcular o periodograma $I_j^{(N)}, j = 1, \dots, \left[\frac{N}{2} \right]$. Mesmo que $R_i = 0$, todo i , é possível que ocorram picos nas ordenadas do periodograma devido a flutuação aleatórias. Em resumo, mesmo que o periodograma apresente vários picos, não podemos concluir, a priori, que cada um dos picos corresponda a uma componente periódica da série Z_t .

Supondo que o processo Z_t seja Gaussiano, Fisher (1929) apresenta um procedimento para testar a hipótese $H_0: R_i \equiv 0$, todo i (não existe periodicidade). Baseado na estatística da Equação 3.

$$g = \frac{\max_j I_j^{(N)}}{\sum_{j=1}^{\left[\frac{N}{2} \right]} I_j^{(N)}} = \frac{I^{(1)}}{\sum_{j=1}^{\left[\frac{N}{2} \right]} I_j^{(N)}} \quad (3)$$

Fisher mostrou que, para N ímpar, a distribuição exata de g , sob H_0 , é dada pela Equação 4, em que, $n = \left[\frac{N}{2} \right]$ e x é maior inteiro menor que $\frac{1}{a}$ ($x = \left[\frac{1}{a} \right]$). Para mais detalhes ver em Morettin e Tolo (2006).

$$P(g > a) = n(1-a)^{n-1} - \binom{n}{2}(1-2a)^{n-1} + \dots + (-1)^z \binom{n}{x}(1-xa)^{n-1} \quad (4)$$

Para esse estudo, foi utilizada várias ferramentas com intuito de identificar sazonalidade através da análise espectral, sendo essas a análise estatística, testes de normalidade, testes de tendência, Análise de Variância e principalmente, o teste G de Fisher, que é uma ferramenta útil para verificar períodos de repetição em uma série temporal, sendo muito utilizada por outros autores como Bleidorn (2019); Pinto, Reisen e Monte (2018a); Pereira (2015); entre outros.

3. Resultados e discussão

Para um entendimento prévio das variáveis estudadas, são apresentadas algumas estatísticas descritivas nas Tabelas 1, 2 e 3. As análises correspondem aos dados de 24 horas dos poluentes $PM_{2,5}$, PM_{10} e SO_2 , para o período de 01/01/2016 a 31/12/2020, perfazendo um total de 43.800 observações. A presença de dados faltantes nas séries motivou o uso da metodologia proposta por Junger e Leon (2015) e implementada na biblioteca do Software R Multivariate Time Series Data Imputation (mtsdi) (JUNGER e LEON, 2018).

Tabela 1 – Análise descritiva da RGV, para $PM_{2,5}$, em $\mu g/m^3$.

	2016	2017	2018	2019	2020
Mínimo	1,00	1,00	1,00	1,00	1,00
Máximo	217,00	75,00	80,00	69,00	121,00
1º Quartil	8,00	7,00	8,54	9,78	6,00
3º Quartil	15,00	12,03	14,00	12,83	13,00
Média	11,99	10,41	11,58	11,56	9,98
Mediana	11,00	9,87	11,00	11,18	9,00
Coefficiente de variação - CV (%)	59,93	48,56	44,04	41,12	54,51
Variância	51,64	25,56	26,00	22,61	29,59
Desvio Padrão	7,19	5,06	5,09	4,75	5,44
Assimetria	4,18	1,82	1,59	2,56	1,80
Curtose	80,23	8,06	8,80	15,63	21,18

Observa-se, Tabela 01, que a média de $PM_{2,5}$ nos anos de 2016 a 2020 são bem próximas, porém houve um pequeno decréscimo no ano de 2020. O menor valor encontrado para a média da RGV foi de $9,98014 \mu g/m^3$ no ano de 2020, e o máximo de $11,99156 \mu g/m^3$ em 2016. A maior variação observada foi a de 2016, com coeficiente de variação de 59,93%.

Como mostra a Tabela 2, em 2016, para o poluente PM_{10} , as médias também apresentaram valores próximos às medianas, porém a maior diferença encontrada entre as duas medidas ($4,11235 \mu g/m^3$) ocorreu em 2016, indicando que a média foi influenciada por altas taxas de deposição. O menor valor encontrado foi de $1,0 \mu g/m^3$ para todos os anos estudados, e o maior foi de $449 \mu g/m^3$, em 2019. O ano de 2016 teve a maior média ($27,11235 \mu g/m^3$) e maior variabilidade dos dados (CV = 74,17841%). Além disso, o ano de 2020 teve o menor coeficiente de variação, com 52,81693%.

Tabela 2 – Análise descritiva da RGV, para PM₁₀, em µg/m³

	2016	2017	2018	2019	2020
Mínimo	1,00	1,00	1,00	1,00	1,00
Máximo	286,00	247,00	139,00	449,00	181,00
1º Quartil	15,00	12,00	11,00	14,00	12,00
3º Quartil	33,00	26,00	22,00	30,00	22,00
Média	27,11	20,81	17,93	24,59	18,52
Mediana	23,00	18,00	16,00	21,00	16,19
Coefficiente de variação - CV (%)	74,18	67,03	58,58	68,58	52,82
Variância	404,47	194,68	110,39	284,48	95,64
Desvio Padrão	20,11	13,95	10,51	16,87	9,78
Assimetria	2,97	2,65	2,19	4,21	2,20
Curtose	17,36	15,95	9,28	56,90	13,37

Conforme Tabela 3, para o poluente SO₂, médias e medianas obtiveram valores próximos com menores valores em 2020. O menor valor encontrado no ponto de monitoramento foi de 0,01 µg/m³, em 2018, 2019 e 2020, e o maior, de 763,34 µg/m³, em 2017. O valor mais elevado apresentado no coeficiente de variação foi em 2017, com 271,10008%, devido ao maior máximo.

Tabela 3 – Análise descritiva da RGV, para SO₂, em µg/m³

	2016	2017	2018	2019	2020
Mínimo	1,65	0,02	0,01	0,01	0,01
Máximo	249,15	763,34	134,47	163,17	168,07
1º Quartil	3,87	3,26	2,15	1,95	1,28
3º Quartil	6,86	6,07	4,79	5,10	3,15
Média	7,35	7,69	5,13	6,45	5,09
Mediana	4,93	4,16	3,81	2,88	2,28
Coefficiente de variação - CV (%)	153,85	271,10	150,49	181,75	227,94
Variância	127,97	435,13	59,72	137,37	135,06
Desvio Padrão	11,31	20,86	7,73	11,72	11,62
Assimetria	8,81	21,47	6,19	4,81	5,78
Curtose	106,55	643,35	53,48	30,32	42,78

No geral, a maioria dos poluentes tiveram valores menores no ano de 2020, isso pode ser relacionado à pandemia de COVID-19 que ocorreu nesse período, já que, com o isolamento social, muitas pessoas tiveram que trabalhar de casa, estudantes também tiveram aulas remotas, o que influenciou então, à diminuição da frota de veículos, por exemplo, reduzindo as taxas de emissão de poluentes atmosféricos. Cabe ressaltar que, o estudo realizado por Freitas et al. (2020) corrobora tal afirmação, os autores realizaram uma pesquisa no estado de São Paulo e observou uma queda dos poluentes atmosféricos desde o início da quarentena, na primeira semana do distanciamento social, as principais reduções analisadas foram nas concentrações dos poluentes CO, NO_x, PM_{2,5} e PM₁₀.

Afim de descobrir se as séries apresentam normalidade, foram desenvolvidos alguns Testes de Normalidade dos poluentes, sendo esses testes o de Jarque Bera; One-sample Kolmogorov-

Smirnov; Lilliefors (Kolmogorov-Smirnov); Cramer-von Mises; Shapiro-Wilk; Shapiro-Francia e Anderson-Darling. Após análise dos resultados desses testes, observou-se que as séries de $PM_{2,5}$, PM_{10} e SO_2 não apresentam normalidade, pois o p-valor encontrado em cada teste de normalidade e poluente, são inferiores ao nível de significância de 5%, resultado que já era esperado por se tratar de uma variável ambiental.

Para analisar a tendência foram utilizados três testes, sendo o de Cox-Stuart, Mann-Kendall e Wald-Wolfowitz, os quais demonstram o aumento ou a diminuição gradual das observações ao longo do tempo. Na Tabela 4 apresenta-se os Testes de Tendência para os poluentes $PM_{2,5}$, PM_{10} e SO_2 , no período entre 2016 e 2020. O teste de Cox-Stuart, para o poluente $PM_{2,5}$, mostrou que a série não possui tendência no ano de 2016, 2017 e 2020. Ainda é exibido pelo teste de Mann-Kendall que em 2017 e 2019, que a série também não possui tendência. Mas, para o teste de Wald-Wolfowitz, todos os anos apresentaram tendência.

Para o poluente PM_{10} , através dos p-valores obtidos, percebe-se que para quase todos os anos e testes, a série apresenta tendência, sendo que o teste de Cox-Stuart no ano de 2016, foi o único que apontou um resultado de 0,2667, indicando não possuir tendência. Já para o poluente SO_2 , por meio dos p-valores encontrados, pode-se dizer que a série exibe tendência em todos os anos e testes, já que os resultados são significativamente menores que 5%.

Tabela 4 – Testes de Tendência para poluentes (p-valor) por ano

Poluentes	Anos	Cox-Stuart	Mann-Kendall	Wald-Wolfowitz
$PM_{2,5}$	2016	0,109900	0,008960	2,2E-16
	2017	0,075820	0,088930	2,2E-16
	2018	8,513E-10	1,913E-04	2,2E-16
	2019	0,0004039	0,485400	2,2E-16
	2020	0,4965000	2,792E-09	2,2E-16
PM_{10}	2016	0,266700	0,002034	2,2E-16
	2017	0,013280	1,56E-05	2,2E-16
	2018	8,66E-10	1,38E-13	2,2E-16
	2019	2,20E-16	2,20E-16	2,2E-16
	2020	6,22E-15	3,07E-07	2,2E-16
SO_2	2016	2,2E-16	2,2E-16	2,2E-16
	2017	2,2E-16	2,2E-16	2,2E-16
	2018	8,3E-16	2,2E-16	2,2E-16
	2019	2,2E-16	2,2E-16	2,2E-16
	2020	2,2E-16	0,007138	2,2E-16

Foi realizado também a Análise de Variância (ANOVA) para cada poluente que é um modelo de regressão simples que observa o desvio em relação à média, além de ser decomposta e ajustada pela regressão, e somada ao desvio do valor ajustado em relação à média. Os resultados obtidos nessa análise mostraram que as diferenças entre as médias são altamente significativas, já que o p-valor encontrado foi menor que 0,05. Além disso, esse resultado nos diz que para cada poluente, existe um par de média que se difere, porém não se sabe qual.

Aplicou-se, então, o Teste de Tukey HSD para determinar em quais períodos as alterações nas médias foram significantes, analisando os dados entre dois anos distintos do período, afim de identificar em qual que a média se difere. Vale lembrar que a diferença ocorre quando o p-valor é menor que 5%. No teste realizado para o poluente $PM_{2,5}$ de dez comparações feitas, seis apresentaram médias significativas diferentes, sendo essas ocorridas nos anos de 2017-2016, 2020-2016, 2018-2017, 2019-2017, 2020-2018 e 2020-2019. No que se refere ao poluente PM_{10} foi apontado que somente uma comparação não mostraram diferenças significativas ao nível de 5% de

confiança, sendo essa a de 2020-2018. E para o SO_2 sete comparações tiveram nível de significância menor que 0,05, sendo essas exibidas nos anos de 2018-2016, 2020-2016, 2018-2017, 2019-2017, 2020-2017, 2019-2018, 2020-2019.

Pode-se dizer que as diferenças apresentadas em sua maioria são do ano de 2020 aos demais anos. Esse fato comprova o que foi visto anteriormente nas tabelas 1, 2 e 3, que possivelmente estão relacionados à pandemia do COVID-19 e o isolamento social. Para uma melhor visualização das comparações de anos tem-se a Figura 2 que é a representação gráfica do Teste de Tukey HSD para cada poluente.

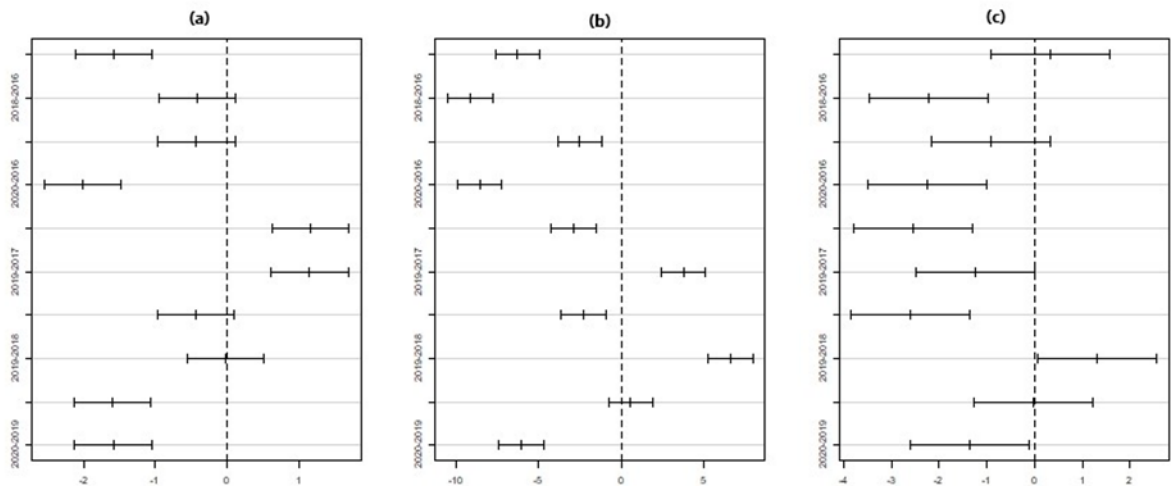


Figura 2 – Gráfico do Teste de Tukey HSD dos poluentes: $\text{PM}_{2,5}$ (a), PM_{10} (b) e SO_2 (c)

A Figura 3 apresenta a evolução temporal das concentrações dos poluentes $\text{PM}_{2,5}$, PM_{10} e SO_2 , no período de estudo.

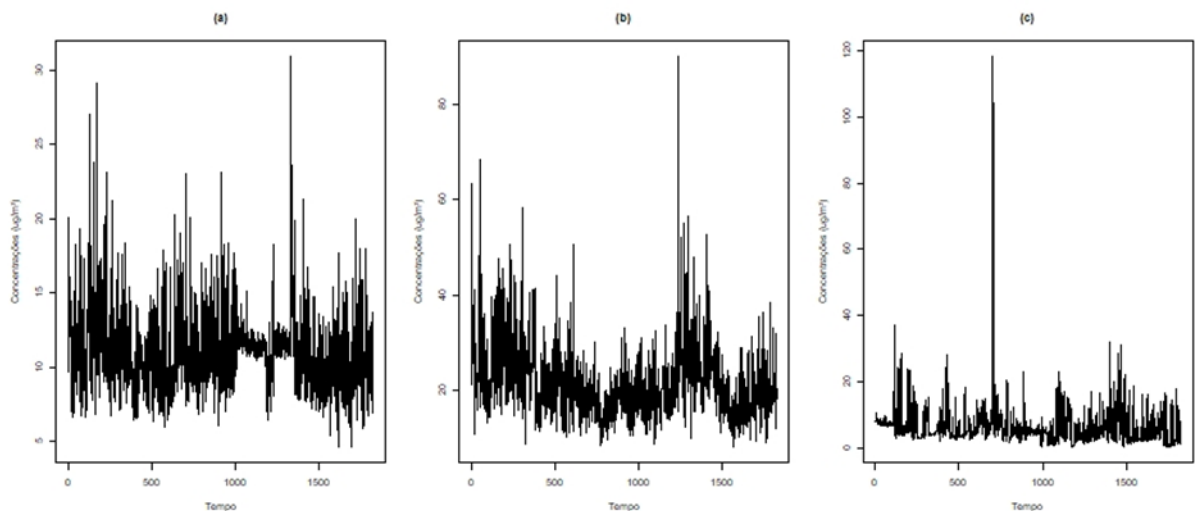


Figura 3 – Gráfico da série temporal dos poluentes: $\text{PM}_{2,5}$ (a), PM_{10} (b) e SO_2 (c)

A Figura 4 exibe o histograma dos poluentes $\text{PM}_{2,5}$, PM_{10} e SO_2 , no período de 2016 a 2020. Observa-se algo em comum nesses gráficos, que seriam os histogramas assimétrico à direita. Isso também é visto nas tabelas 1, 2 e 3, onde todos os valores de assimetria e curtose apresentam um valor maior que zero, o que significa que possui uma assimetria positiva e uma distribuição não normal.

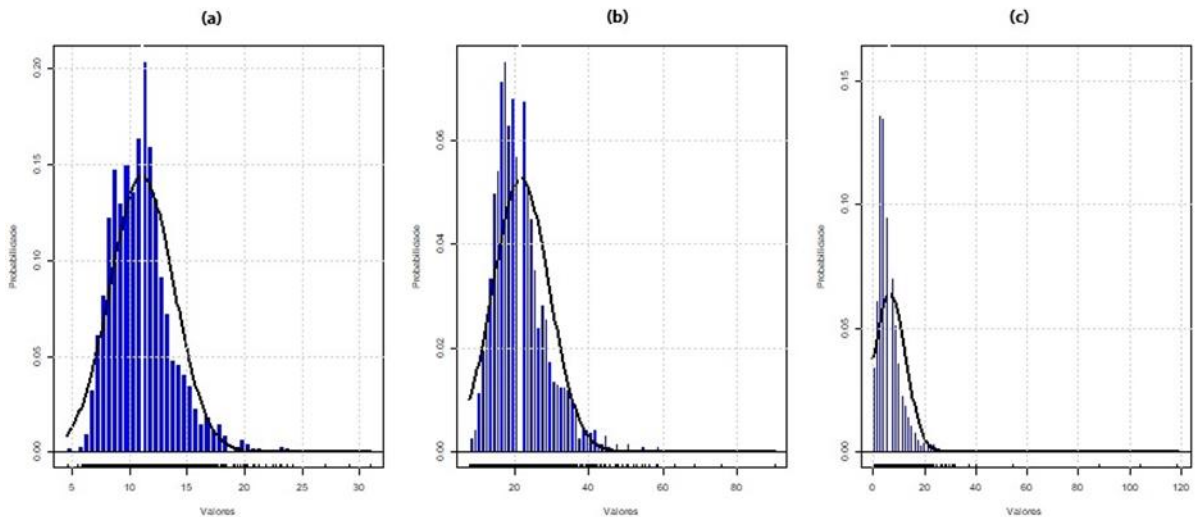


Figura 4 – Histograma dos poluentes: PM_{2,5} (a), PM₁₀ (b) e SO₂ (c)

A Figura 5 apresenta o periodograma dos poluentes PM_{2,5}, PM₁₀ e SO₂, no período de estudo, que foram realizados considerando o log dos dados para estabilizar a variância. Verifica-se, na Figura 5 (a), que o maior pico do periodograma está associado à frequência 0,1429333, demonstrando uma componente sazonal com periodicidade de $s = 1/0,1429333 = 6,996269$, ou seja, uma componente sazonal com periodicidade de sete dias. Para confirmar a presença de sazonalidade foi utilizado o teste G de Fisher, onde foram obtidos os valores das estatísticas $G = 0,01070686$ e $g = 0,04271456$. Como o valor de g é superior ao de G , confirma-se a presença de sazonalidade na série temporal das concentrações de PM_{2,5} para períodos de 7 dias ao nível nominal de significância de 5%.

Na Figura 5 (b), nota-se que o maior pico do periodograma está associado à frequência 0,1429333, demonstrando uma componente sazonal com periodicidade de $s = 1/0,1429333 = 6,996269$. A presença de sazonalidade foi comprovada novamente utilizando o teste G de Fisher, onde os valores obtidos das estatísticas foi $G = 0,01070686$ e $g = 0,1655065$. Como o valor de g também é superior ao de G , confirmou-se a presença de sazonalidade na série temporal das concentrações de PM₁₀ para períodos de 7 dias ao nível nominal de significância de 5%.

A sazonalidade em séries de PM₁₀ e PM_{2,5} já é esperada, pois a principal fonte emissora de partículas na RGV são veículos automotores, representando mais de 60% das emissões de partículas que estão ligados à ressuspensão de partículas em vias (IEMA, 2013). Sendo assim, as concentrações medidas nos dias úteis e finais de semana, possuem variação, já que, o fluxo de veículos é maior durante os dias da semana. Logo, uma diferença sazonal de ordem $s = 7$ foi aplicada para eliminar a sazonalidade presente na série.

Percebe-se, na Figura 5 (c), que o maior pico do periodograma está associado à frequência 0,005333333 e que sua componente sazonal é de $s = 1/0,005333333 = 187,5$, demonstrando não possuir sazonalidade. Assim, para o poluente SO₂ em questão, é dito periódico, ou seja, o período de repetição varia.

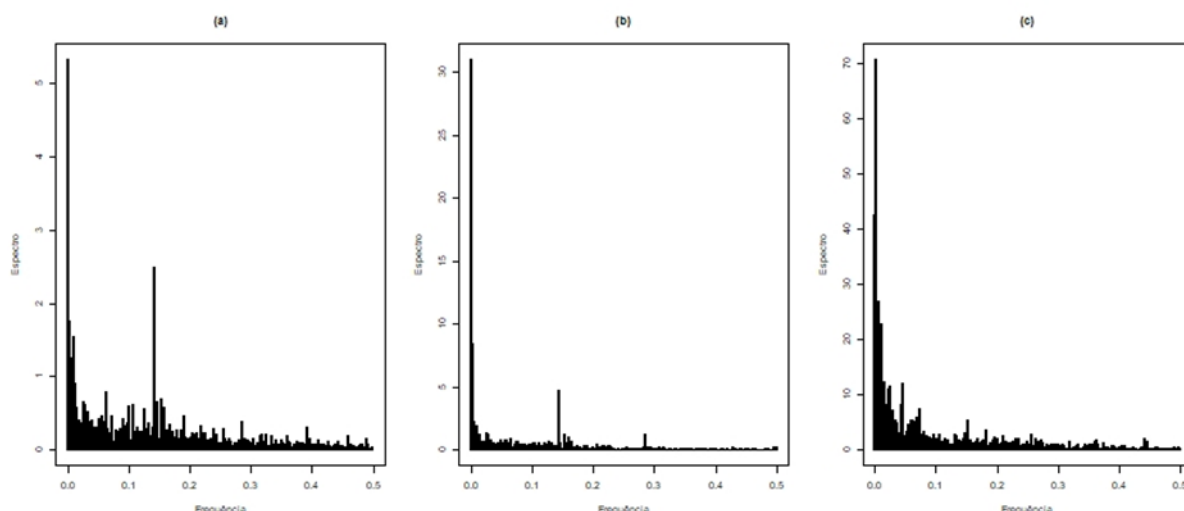


Figura 4 – Periodograma dos poluentes: PM_{2,5} (a), PM₁₀ (b) e SO₂ (c)

De maneira geral, os resultados obtidos mostraram que na RGV os poluentes PM_{2,5} e PM₁₀ apresentaram sazonalidade, para os anos entre 2016 a 2020. Esse comportamento apresentado pelos poluentes é esperado pois, conforme o inventário de emissões atmosféricas da RGV, a principal fonte emissora de material particulado na região são os veículos automotores, representando aproximadamente 70% das emissões, decorrentes da ressuspensão de partículas em vias (ECOSOFT, 2011).

O causador principal das emissões de SO₂ são as indústrias minero-siderúrgicas, sendo que essas emissões estão concentradas principalmente na Ponta de Tubarão, o que constitui um problema relevante para algumas zonas da RGV quando é considerada a direção predominante Norte-Noroeste dos ventos. O setor industrial minero-siderúrgico é responsável por 75,5% das emissões, principalmente pelo uso de carvão mineral e outros combustíveis fósseis com elevado teor de enxofre como insumos de produção. O segundo maior contribuinte é o setor de logística (portos e aeroportos), mais notadamente as operações portuárias, que operam com combustíveis fósseis com elevado teor de enxofre (GOVERNO DO ESTADO DO ESPÍRITO SANTO, 2014).

Para o poluente SO₂, os resultados obtidos mostraram que não houve a presença de sazonalidade, diferentemente das emissões de partículas para a atmosfera, isso pode ser explicado pelo fato da Ponta de Tubarão não estar localizada perto da estação de monitoramento da Enseada do Suá, sendo mais de seis quilômetros de distância de diferença.

Dessa forma, a variação sazonal apresentada pode ser explicada principalmente pelo ritmo de movimentação dos transportes na RGV, ou seja, as maiores concentrações medidas de PM_{2,5} e PM₁₀, ocorrem durante os dias úteis, quando o fluxo de veículos é maior, e o oposto ocorre nos fins de semana. Já para o SO₂, por não apresentar variação sazonal, não possui um período fixo de repetição.

Resultados semelhantes foram encontrados no estudo de Pinto, Reisen e Monte (2018a), o qual encontra para o poluente MP₁₀ uma sazonalidade de sete dias. Ainda em outros estudos (CELIS et al., 2007; LEITE et al., 2011; REINA e OLAYA, 2012; MONTE, ALBURQUERQUE e REISEN, 2016; LORIATO et al., 2018; OLIVARES, 2020) os autores também argumentam que os dias úteis da semana proporcionam maiores concentrações de material particulado na atmosfera e, ainda, apontam que este fato está relacionado ao tráfego de veículos automotores.

Resultados encontrados por Vieira et al. (2020) apontam que para o SO₂ foi verificado um aumento 31% nas concentrações avaliadas, enquanto que para o MP₁₀ foi constatada uma redução de 23%. Apesar da diferença numérica nas medianas avaliadas para estes poluentes, estas medições estão dentro da incerteza admitida para os analisadores utilizados na medição. Tanto para o MP₁₀ quanto para o SO₂ a redução no tráfego de veículo e atividades industriais, respectivamente, resultaram numa menor variabilidade no registro das concentrações.

4. Conclusões

A partir dos resultados encontrados neste trabalho, pode-se concluir que os dados das séries de ambos os poluentes não apresentam normalidade e que possuem tendência. Além disso, através da análise espectral da série temporal, foi possível observar que as concentrações dos poluentes PM_{10} e $PM_{2,5}$ apresentaram sazonalidade com período de sete dias, a qual foi comprovada pelo teste G de Fisher, que por sua vez, é uma ferramenta útil para verificar períodos de repetição em uma série temporal. Já para o poluente SO_2 , não houve presença de sazonalidade.

Além disso, durante o isolamento social motivado pela COVID-19 observou-se melhora da qualidade do ar na RGV, para alguns poluentes, em razão dos impactos positivos causados pelas mudanças na forma de trabalho, redução nas necessidades de deslocamento e adaptações no comportamento dos habitantes. Isso significa que existem alternativas viáveis para o problema da poluição atmosférica na região.

Dessa forma, este estudo visa contribuir como uma ferramenta para os órgãos regulamentadores na discussão de atividades de controle da poluição atmosférica e também como deve ser levado em correlação com a saúde da população da RGV. Como parte de um estudo posterior, sugere-se a utilização de um modelo de imputação de dados faltantes, para obtenção de resultados ainda mais próximos da realidade.

5. Agradecimentos

Agradecemos a FAPES por ter concedido a bolsa de Iniciação Científica. O primeiro autor agradece ao coordenador de curso de Engenharia ambiental e Sanitária da FARESE e ao orientador de Iniciação Científica que ajudaram no desenvolvimento desta pesquisa.

Referências

- Abbey, D.E., Ostro, B.E., Petersen, F., & Burchette, RJ (1995). Sintomas respiratórios crônicos associados a concentrações ambientais de longo prazo estimadas de partículas finas com menos de 2,5 microns de diâmetro aerodinâmico ($PM_{2,5}$) e outros poluentes do ar. *Jornal de análise de exposição e epidemiologia ambiental*, 5 (2), 137-159.
- Aguirre, A. (1995). Uma introdução à análise espectral de séries temporais econômicas. *Nova Economia*, 5(1).
- Andreão, W.L.; Pimassoni, L.H.S. (2013). Análise estatística da poeira sedimentável da região da Grande Vitória para os anos de 2010, 2011 e 2012. *Revista Científica FAESA*, 9 (1), 7-18.
- Bleidorn, M.T., Pinto, W.P., Braum, E. S., Lima, G.B., & Montebeller, C.A. (2019). Modelagem e previsão de vazões médias mensais do rio Jucu, ES, utilizando o modelo SARIMA. *IRRIGA*, 24 (2), 320-335. <https://doi.org/10.15809/irriga.2019v24n2p320-335>
- Bowe, B., Xie, Y., Li, T., Yan, Y., Xian, H., & Al-Aly, Z. (2018). The 2016 global and national burden of diabetes mellitus attributable to $PM_{2,5}$ air pollution. *The Lancet Planetary Health*, 2(7), e301-e312. [https://doi.org/10.1016/S2542-5196\(18\)30140-2](https://doi.org/10.1016/S2542-5196(18)30140-2)
- Ecosoft Consultoria e Softwares Ambientais (ECOSOFT). (2011). *Inventário de emissões atmosféricas da Região da Grande Vitória*. Acordo de Cooperação Técnica IEMA & EcoSoft nº 010/2009.
- Freitas, E. D., Ibarra-Espinosa, S. A., Gavidia-Calderón, M. E., Rehbein, A., Abou Rafee, S. A., Martins, J. A., ... & Trindade, R. I. (2020). Mobility restrictions and air quality under COVID-19 pandemic in São Paulo, Brazil. <https://doi.org/10.20944/preprints202004.0515.v1>
- Gonzaga, A. C., & Freitas, A. C. V. (2020). Análise da relação entre condições meteorológicas, poluição atmosférica e infecções respiratórias virais: o caso COVID-19. *Research, Society and Development*, 9(8), e591985942-e591985942. <https://doi.org/10.33448/rsd-v9i8.5942>

- Gouveia, N., Mendonça, G. A., Leon, A. P. D., Correia, J. E. D. M., Junger, W. L., Freitas, C. U. D., ... & Cunha-Cruz, J. (2003). Poluição do ar e efeitos na saúde nas populações de duas grandes metrópoles brasileiras. *Epidemiologia e Serviços de saúde*, 12(1), 29-40. <http://dx.doi.org/10.5123/S1679-49742003000100004>
- Governo do Estado do Espírito Santo. (2014). *Plano Estratégico de Qualidade do Ar*. Disponível em: https://iema.es.gov.br/Media/iema/COAI/Documentos/PEQAR_Final.pdf
- Gripa, W.R.; Reisen, V.A.; Fajardo, F.A.; Reis Junior, N.C. (2012). Análise de predição e previsão das concentrações de material particulado inalável (PM_{10}) na cidade de Carapina, ES. *Revista Brasileira de Estatística*, 73 (237), 37-57.
- Hies, T., Treffeisen, R., Sebal, L., & Reimer, E. (2000). Spectral analysis of air pollutants. Part 1: elemental carbon time series. *Atmospheric Environment*, 34(21), 3495-3502. [https://doi.org/10.1016/S1352-2310\(00\)00146-1](https://doi.org/10.1016/S1352-2310(00)00146-1)
- Instituto Brasileiro de Geografia e Estatística (IBGE). (2020). *Banco de dados. Cidades@*. Recuperado em 19 abril, 2020 de <http://www.cidades.ibge.gov.br/xtras/home.php>.
- Instituto Estadual de Meio Ambiente e Recursos Hídricos do Estado do Espírito Santo (IEMA). (2013). *Relatório da qualidade do ar da Região da Grande Vitória*. Recuperado em 19 abril, 2020 de <http://www.meioambiente.es.gov.br>.
- Junger, W. L., & De Leon, A. P. (2015). Imputation of missing data in time series for air pollutants. *Atmospheric Environment*, 102, 96-104. <https://doi.org/10.1016/j.atmosenv.2014.11.049>
- Junger, W.L. (2008). *Análise, imputação de dados e interfaces computacionais em estudos de séries temporais epidemiológicas*. Tese doutorado, Universidade do Estado do Rio de Janeiro, Instituto de Medicina Social.
- Kandlikar, M. (2007). Air pollution at a hotspot location in Delhi: detecting trends, seasonal cycles and oscillations. *Atmospheric Environment*, 41(28), 5934-5947. <https://doi.org/10.1016/j.atmosenv.2007.03.044>
- Latorre, M. D. R. D. D. O., & Cardoso, M. R. A. (2001). Análise de séries temporais em epidemiologia: uma introdução sobre os aspectos metodológicos. *Revista Brasileira de Epidemiologia*, 4, 145-152. <https://doi.org/10.1590/S1415-790X2001000300002>
- Leite, R. C. M., Guimarães, E. C., Lima, E. A. P. D., Barrozo, M. A. D. S., & Tavares, M. (2011). Utilização de regressão logística simples na verificação da qualidade do ar atmosférico de Uberlândia. *Engenharia Sanitária e Ambiental*, 16(2), 175-180.
- Liu, P. W. G., & Johnson, R. (2003). 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*, 53(12), 1472-1489. <https://doi.org/10.1080/10473289.2003.10466321>
- Loriato, A. G., Salvador, N., Loriato, A. A. B., Sokolov, A., Nascimento, A. P., Ynoue, R. Y., ... & Albuquerque, T. T. D. A. (2018). Inventário de emissões com alta resolução para a região da grande Vitória utilizando o Sistema de Modelagem Integrada WRF-SMOKE-CMAQ. *Revista Brasileira de Meteorologia*, 33, 521-536. <https://doi.org/10.1590/0102-7786333011>
- Martins, L. C., Latorre, M. D. R. D. D. O., Cardoso, M. R. A., Gonçalves, F. L. T., Saldiva, P. H. N., & Braga, A. L. F. (2002). Poluição atmosférica e atendimentos por pneumonia e gripe em São Paulo, Brasil. *Revista de Saúde Pública*, 36(1), 88-94.
- Monte, E. Z., Albuquerque, T. T. D. A., & Reisen, V. A. (2016). Impactos das variáveis meteorológicas na qualidade do ar da Região da Grande Vitória, Espírito Santo, Brasil. *Revista Brasileira de Meteorologia*, 31, 546-554. <https://doi.org/10.1590/0102-7786312314b20150100>
- Monte, E. Z., Albuquerque, T. T. D. A., & Reisen, V. A. (2017). Inter-relações entre as concentrações de ozônio e de dióxido de nitrogênio na região da Grande Vitória, Espírito Santo, Brasil. *Engenharia Sanitaria e Ambiental*, 22(4), 679-690. <https://doi.org/10.1590/S1413-41522017140796>

- Monte, E. Z., ALBUQUERQUE, T. T. D. A., & Reisen, V. A. (2015). Previsão da concentração de ozônio na Região da Grande Vitória, Espírito Santo, Brasil, utilizando o modelo ARMAX-GARCH. *Revista Brasileira de Meteorologia*, 30(3), 285-294. <https://doi.org/10.1590/0102-10.1590/0102-778620140060>
- Morettin, P. A., & Toloi, C. M. C. (2006). *Análise de Séries Temporais. 2a. Edição, São Paulo: Blucher.*
- Olivares, L. B. C. (2020). *Caracterização e análise de tendências a longo prazo de poluentes atmosféricos na região metropolitana de Curitiba, Brasil* (Master's thesis, Universidade Tecnológica Federal do Paraná).
- Orlando, J. P., Alvim, D. S., Yamazaki, A., Corrêa, S. M., & Gatti, L. V. (2010). Ozone precursors for the São Paulo metropolitan area. *Science of the total environment*, 408(7), 1612-1620. <https://doi.org/10.1016/j.scitotenv.2009.11.060>
- Pereira, A. R., de Souza Costa, A., de Oliveira, V. G., de Farias Borges, P., & Ismael Filho, A. (2015). Análise do comportamento das médias anuais da precipitação pluvial e temperatura da cidade de Areia, Paraíba. *Gaia Scientia*, 9(1).
- Pinto, W. P. (2019). *Análise espectral de séries temporais de concentrações de poluentes atmosféricos com dados faltantes*. Tese de Doutorado. Universidade Federal do Espírito Santo (UFES).
- Pinto, W. P., Reisen, V. A., & Monte, E. Z. (2018a). Previsão da concentração de material particulado inalável, na Região da Grande Vitória, ES, Brasil, utilizando o modelo SARIMAX. *Engenharia Sanitária e Ambiental*, 23, 307-318. <https://doi.org/10.1590/S1413-41522018168758>
- Pinto, W. P., Reisen, V. A., & Monte, E. Z. (2018b). Picos de concentração de poluição atmosférica na Região da Grande Vitória, ES, Brasil: uma aplicação da regressão logística. *Sociedade & Natureza*, 30(3), 159-184. <https://doi.org/10.14393/SN-v30n3-2018-9>
- Reina, J., & Olaya, J. (2012). Curve fitting nonparametric methods for studying behavior from air pollution pm10. *Revista EIA*, (18), 19-31.
- Reisen, V. A., Sgrancio, A. M., Lévy-Leduc, C., Bondon, P., Monte, E. Z., Cotta, H. H. A., & Ziegelmann, F. A. (2019). Robust factor modelling for high-dimensional time series: An application to air pollution data. *Applied Mathematics and Computation*, 346, 842-852. <https://doi.org/10.1016/j.amc.2018.09.062>
- Ribeiro, J. C. J., Custódio, M. M., & Praça, D. H. P. (2020). COVID-19: Reflexões sobre seus impactos na qualidade do ar e nas modificações climáticas. *Veredas do Direito: Direito Ambiental e Desenvolvimento Sustentável*, 17(39).
- Schmidt, I. M., Knaak, J., de Paula Pinto, W., & Lima, G. B. (2019) Análise comparativa das séries temporais de material particulado PTS e PM10 da região da Grande Vitória, entre os anos de 2008 a 2017 e suas compatibilidades com os principais padrões legais vigentes. *Associação Brasileira de Engenharia Sanitária e Ambiental (ABES)*, 30º Congresso Brasileiro de Engenharia Sanitária e Ambiental.
- Souza, J. B. D., Reisen, V. A., Santos, J. M., & Franco, G. C. (2014). Componentes principais e modelagem linear generalizada na associação entre atendimento hospitalar e poluição do ar. *Revista de Saúde Pública*, 48, 451-458. <https://doi.org/10.1590/S0034-8910.2014048005078>
- Tchepel, O., Costa, A. M., Martins, H., Ferreira, J., Monteiro, A., Miranda, A. I., & Borrego, C. (2010). Determination of background concentrations for air quality models using spectral analysis and filtering of monitoring data. *Atmospheric Environment*, 44(1), 106-114. <https://doi.org/10.1016/j.atmosenv.2009.08.038>
- Tibuakuu, M., Michos, E. D., Navas-Acien, A., & Jones, M. R. (2018). Air pollution and cardiovascular disease: a focus on vulnerable populations worldwide. *Current epidemiology reports*, 5(4), 370-378.

- Tibulo, C., Zanini, R. R., Ferraz, S. E. T., Boiaski, N. T., & Tibulo, V. D. C. (2020). A relação entre a poluição do ar e as principais variáveis climatológicas no município de Canoas-RS. *Revista Brasileira de Climatologia*, 26. <http://dx.doi.org/10.5380/abclima.v26i0.65560>
- Vieira, A. B., Cola, I. T. B., Lougon, D. R., & Ronchi, P. (2020). Efeitos das medidas de afastamento social sobre a qualidade do ar na Região Grande Vitória (Espírito Santo). *Revista Brasileira de Meio Ambiente*, 8(4).
- Wang, C., Wolters, P. J., Calfee, C. S., Liu, S., Balmes, J. R., Zhao, Z., ... & Ware, L. B. (2020). Long-term ozone exposure is positively associated with telomere length in critically ill patients. *Environment international*, 141, 105780. <https://doi.org/10.1016/j.envint.2020.105780>