



AVALIAÇÃO DA RELAÇÃO ENTRE A POLUIÇÃO ATMOSFÉRICA E PARÂMETROS CLIMÁTICOS COM A COVID-19 NO GRANDE ABC PAULISTA

*Assessment of the relationship between atmospheric pollution
and climate parameters with Covid-19 in The Great ABC
paulista*

*Evaluación de la relación entre la contaminación atmosférica
y parámetros climáticos con Covid-19 en el Gran ABC paulista*

Viviane Bezerra da Silva  

Pós-Graduanda em Ciência e Tecnologia Ambiental, Universidade Federal do ABC (UFABC) - Centro de Engenharia, Modelagem e Ciências Sociais Aplicadas (CECS)
viviane.b@ufabc.edu.br

María Cleofé Valverde  

Docente no curso de pós-graduação em Ciência e Tecnologia Ambiental, Universidade Federal do ABC (UFABC) - Centro de Engenharia, Modelagem e Ciências Sociais Aplicadas (CECS)
maria.brambila@ufabc.edu.br

Resumo: O novo coronavírus (SARS-CoV-2), com origem no ano de 2019 na cidade de Wuhan, China, já infectou milhares de pessoas e provocou uma resposta acelerada dos governos ao redor do mundo. O objetivo deste estudo foi avaliar a influência de variáveis climáticas e poluentes atmosféricos na disseminação do SARS-CoV-2, na região do Grande ABC paulista, localizada na Região Metropolitana de São Paulo (RMSP). Após a coleta de dados obtidos em fontes oficiais, para o tratamento e a análise foi utilizado o *software* de código aberto *RStudio* para a aplicação do coeficiente de correlação de Spearman e para a aplicação de um modelo de Regressão Linear Múltipla (RLM). Os resultados destacam as correlações negativas dos dados de Covid-19 com as temperaturas mínima e média, em todos os municípios, e as correlações positivas para umidade relativa do ar máxima em Diadema. Os resultados mostram que os compostos O_3 , CO, NO_x , NO e NO_2 são os principais poluentes determinantes da Covid-19 na área de estudo, devido ao maior grau de correlação estatística. Na aplicação da RLM, quatro modelos foram considerados modelos ótimos: para os municípios de Diadema e São Bernardo do Campo, para casos acumulados e para óbitos acumulados. Os resultados da RLM tornam ainda mais evidentes a influência das variáveis climáticas temperatura mínima, umidade relativa mínima e máxima e direção do vento máxima no contágio e óbitos por Covid-19 no Grande ABC paulista.

Palavras-chave: Spearman. Regressão. Pandemia.

Abstract: The new coronavirus (SARS-CoV-2), which originated in the year 2019 in the city of Wuhan, China, has already infected thousands of people and provoked an accelerated response from governments around the world. The objective of this study was to evaluate the influence of climatic variables and atmospheric pollutants on the spread of SARS-CoV-2, in the Great ABC region of São Paulo, located in the Metropolitan Region of São Paulo (MRSP). After collecting data obtained from official sources, the open source software RStudio was used for the treatment and analysis for the application of Spearman's correlation coefficient and for the application of Multiple Linear Regression (MLR). The results highlight the negative correlations of Covid-19 data with minimum and average temperatures, in all municipalities, and the positive correlations for maximum relative humidity in Diadema. The results show that the compounds O_3 , CO, NO_x , NO and NO_2 are the main determinant pollutants of Covid-19 in the study area, due to the higher degree of statistical correlation. In the application of the MLR, four models were considered optimal models: for the municipalities of Diadema and São Bernardo do Campo, for accumulated cases and for accumulated deaths. The MLR results make even more evident the influence of the climatic variables minimum temperature, minimum and maximum relative humidity and maximum wind direction on the contagion and deaths by Covid-19 in the Great ABC region of São Paulo.

Keywords: Spearman. Regression. Pandemic.

Resumen: El nuevo coronavirus (SARS-CoV-2), que se originó en el año 2019 en la ciudad de Wuhan, China, ya infectó a miles de personas y provocó una respuesta acelerada de los gobiernos de todo el mundo. El objetivo de este estudio fue evaluar la influencia de variables climáticas y contaminantes atmosféricos en la propagación del SARS-CoV-2 en la región del Gran ABC paulista, ubicada en la Región Metropolitana de São Paulo (RMSP). Después de recolectar datos obtenidos de fuentes oficiales, para el tratamiento y análisis se utilizó el *software* de código abierto RStudio para la aplicación del coeficiente de correlación de Spearman y para la aplicación de la Regresión Lineal Múltiple (RLM). Los resultados destacan las correlaciones negativas de los datos de Covid-19 con las temperaturas mínimas y medias, en todos los municipios y las correlaciones positivas para la humedad relativa máxima en Diadema. Los resultados muestran que los compuestos O_3 , CO, NO_x , NO y NO_2 son los principales contaminantes determinantes del Covid-19 en la zona de estudio, debido al mayor grado de correlación estadística. En la aplicación del RLM, cuatro modelos fueron considerados modelos óptimos: para los municipios de Diadema y São Bernardo do Campo, para casos acumulados y para muertes acumuladas. Los resultados del RLM hacen aún más evidente la influencia de las variables climáticas temperatura mínima, humedad relativa mínima y máxima y dirección máxima del viento en los contagios y muertes por Covid-19 en la región del Gran ABC de São Paulo.

Palabras clave: Spearman. Regresión. Pandemia.

Submetido em: 24/11/2022

Aceito para publicação em: 04/07/2023

Publicado em: 15/07/2023

1. INTRODUÇÃO

O novo coronavírus (SARS-CoV-2), com origem em 2019 na cidade de Wuhan, China infectou de maneira acelerada milhares de pessoas, causando mortes e provocando uma resposta rápida dos governos ao redor do mundo. A Organização Mundial de Saúde (OMS) declarou a Covid-19 uma pandemia mundial no dia 11 de março de 2020. O Brasil apresentou seu primeiro caso no Estado de São Paulo no dia 26 de fevereiro do mesmo ano.

Estudos têm revelado a influência do clima e da poluição atmosférica (PRATA et al., 2021; WEN E CHEN, 2020; CORRÊA et al., 2021; BILAL et al. 2020) na evolução da Covid-19, por exemplo, casos confirmados e mortes. Wen e Chen (2020) revelaram em seu estudo que casos confirmados mensais aumentam com o aumento da temperatura, precipitação e radiação ultravioleta (UV) em regiões (países e territórios) frias, porém não possuem correlação nas regiões quentes. Bilal et al. (2020) concluíram que o $MP_{2,5}$ (material particulado com diâmetro até 2,5 μm), NO_2 e O_3 possuem correlação significativa para o surto de Covid-19 na Alemanha.

O Estado de São Paulo possuía, até novembro de 2022, 17,6% do total de casos acumulados de Covid-19 no Brasil, representando o epicentro da doença no país, conforme os dados da plataforma oficial do Governo Coronavírus Brasil¹. Estudos tem revelado a correlação negativa da temperatura e da radiação UV na transmissão da Covid-19 na Região Metropolitana de São Paulo (RMSP) (NAKADA E URBAN, 2021).

Um estudo realizado por Ibarra-Espinosa et al. (2021) apresenta a correlação do $MP_{2,5}$ e do O_3 no número de casos e mortes pela Covid-19 na cidade de São Paulo. O estudo revelou que o $MP_{2,5}$ e O_3 têm riscos relativos positivos para casos e óbitos. Os riscos relativos médios para os casos foram 1,140 para $MP_{2,5}$ e 1,075 para O_3 , o que significa que $MP_{2,5}$ aumenta 1,06 vezes mais casos de Covid-19 do que O_3 , enquanto para os óbitos, o risco relativo para O_3 foi de 1,063 e para $MP_{2,5}$ de 1,086.

A área de estudo, a Região do Grande ABC paulista (Figura 1), está localizada na Região Metropolitana de São Paulo (RMSP). É uma região conhecida por possuir diversas indústrias, principalmente do setor automobilístico (SILVA, 2013). Os municípios que compõem o Grande ABC são: São Bernardo do Campo (SBC), Santo André (SA), Diadema

¹ <https://covid.saude.gov.br/>

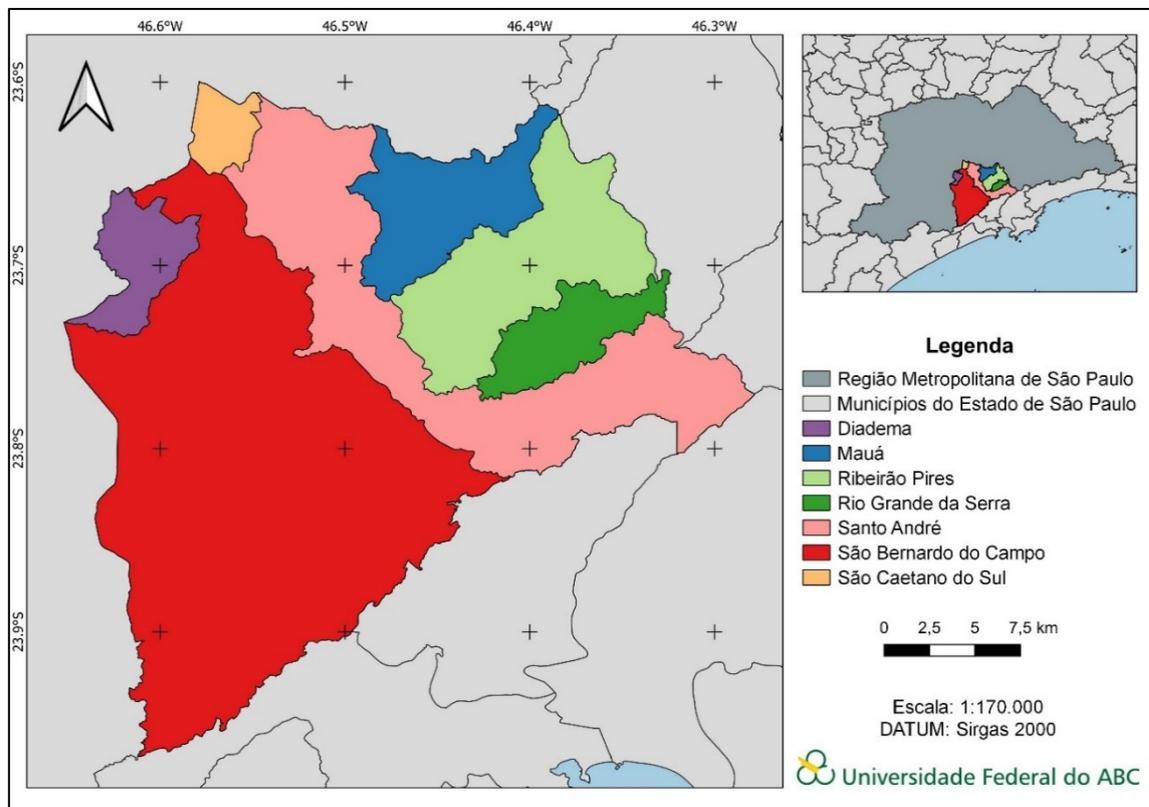
(DA), Mauá (MA), São Caetano do Sul (SCS), Ribeirão Pires (RP) e Rio Grande da Serra (RGS). O Grande ABC representa cerca de 6% da população do Estado de São Paulo (IBGE, 2020). A Tabela 1 apresenta as características demográficas e localização geográfica dos municípios do Grande ABC paulista.

Tabela 1 - Informações demográficas e geográficas da região de estudo.

Município	Acrônimo	Latitude e Longitude	Área (Km ²)	Altitude (m)	População
Santo André	SA	-23.66°; -46.53°	175,782	760	721.368
São Bernardo do Campo	SBC	-23.69°; -46.56°	409,532	762	844.483
Diadema	DA	-23.68°; -46.62°	30,732	780	426.757
São Caetano do Sul	SCS	-23.62°; -46.54°	15,331	744	161.957
Mauá	MA	-23.66°; -46.46°	61,909	818	477.552
Ribeirão Pires	RP	-23.71°; -46.41°	99,075	800	124.159
Rio Grande da Serra	RGS	-23.74°; -46.40°	36,341	780	51.436

Fonte: IBGE Cidades, 2020. Elaboração: própria.

Figura 1 - A Região do Grande ABC paulista.



Fonte: IBGE e DataGeo. Elaboração: própria.

No mês de março de 2021, o Grande ABC paulista apresentou a maior taxa de ocupação dos leitos de Unidade de Terapia Intensiva (UTI) desde o início da pandemia. A região adotou as medidas impostas no Plano São Paulo² para a retomada de forma gradual da economia no Estado e impôs outras medidas como tentativa de conter a disseminação do vírus como, por exemplo, a antecipação de feriados e restrições de circulação no fim de noite e madrugada que ficou conhecido como o “*lockdown* noturno”.

Entender a relação da Covid-19 com o clima e a poluição do ar na região do Grande ABC é urgente e crucial para conduzir mais pesquisas e entender as relações e associações entre a transmissibilidade do SARS-CoV2 e os fatores ambientais. É importante esta análise para estudar o comportamento da doença de acordo com as características atmosféricas específicas do local, como temperaturas, umidade relativa, precipitação, velocidade do vento, e a concentração de poluentes no ar, devido às atividades econômicas e localização geográfica da região.

Portanto, apesar da grande quantidade de estudos que correlacionam as variáveis climatológicas com a Covid-19 (AHMADI et al., 2020; AULER et al. 2020; PRATA; RODRIGUES; BERMEJO, 2020; WANG et al., 2020) há necessidade de estudar além destas variáveis, a correlação com os poluentes emitidos no local, para o entendimento do comportamento da doença com as características de determinada região.

O objetivo deste estudo é avaliar os fatores ambientais, de clima e de poluição atmosférica, que influenciam o contágio e o número de óbitos por Covid-19 na região do Grande ABC paulista através do coeficiente de correlação de Spearman e da Regressão Linear Múltipla (RLM).

2. METODOLOGIA

2.1. Coleta de dados

Na Região do Grande ABC paulista, a Companhia Ambiental do Estado de São Paulo (CETESB) monitora a qualidade do ar em cinco municípios: SA, SBC, DA, SCS e MA. Os municípios de RP e RGS não possuem estações de monitoramento por serem cidades

² <https://www.saopaulo.sp.gov.br/planosp/>

localizadas em áreas de proteção aos mananciais e Mata Atlântica. Os dados coletados nas estações são disponibilizados no sistema QUALAR³, entretanto os dados de poluentes atmosféricos e dados climáticos não são os mesmos para todos os municípios. A coleta de dados para este estudo foi realizada a partir dos primeiros casos de Covid-19 registrados no Grande ABC em 27 de março de 2020, conforme a disponibilidade de dados apresentada na Tabela 2.

Tabela 2 - Dados disponíveis na região de estudo pelo sistema QUALAR.

Municípios	Poluentes Atmosféricos								Variáveis Climáticas		
	MP _{2,5}	MP ₁₀	O ₃	CO	SO ₂	NO ₂	NO	NO _x	VV	T	UR
SA	-	Ok	Ok	-	Ok	Ok	Ok	Ok	Ok	-	-
SBC	Ok	Ok	Ok	Ok	-	Ok	Ok	Ok	Ok	-	-
DA	-	Ok	Ok	-	-	-	-	-	-	-	-
SCS	Ok	Ok	Ok	Ok	Ok	Ok	Ok	Ok	Ok	Ok	Ok
MA	Ok	Ok	Ok	-	-	-	-	-	-	-	-

Legenda: VV – Velocidade do Vento; T- Temperatura; UR – Umidade Relativa.

Fonte: Elaboração própria.

Os dados atmosféricos utilizados para cada município foram a temperatura média (T_{méd}), máxima (T_{máx}) e mínima (T_{mín}), umidade relativa do ar média (UR_{méd}), máxima (UR_{máx}) e mínima (UR_{mín}), velocidade do vento média (V_{méd}) e precipitação (PPP). Para o município de SA também foi utilizada a variável radiação solar média (RAD) e para o município de SBC foi utilizada a variável direção do vento média (D_{méd}), máxima (D_{máx}) e mínima (D_{mín}).

Estas informações foram disponibilizadas pelo banco de dados do Laboratório de Integração de Sistemas Ambientais e Urbanos - Seco (ISAU-Seco)⁴ da Universidade Federal do ABC (UFABC). O banco de dados climáticos possui os dados atmosféricos processados, com controle de qualidade, das estações meteorológicas automáticas da UFABC (SBC e RP), do Serviço Municipal de Saneamento Ambiental de Santo André - SEMASA (SA), do Sistema de Alerta a Inundações de São Paulo – SAISP (MA), do Sistema QUALAR (Tabela 2) e do

³ <https://qualar.cetesb.sp.gov.br/qualar/home.do>

⁴ <https://proppg.ufabc.edu.br/cta/2020/06/09/isau-seco/>

Centro Nacional de Monitoramento e Alertas de Desastres Naturais – CEMADEN (SCS, DA e MA).

A partir da coleta de dados de poluentes atmosféricos e de variáveis climáticas para o período de março de 2020 a dezembro de 2021, se realizou um controle de qualidade dos dados para identificar dados faltantes ou anômalos, entretanto, não foram utilizados métodos para o preenchimento de dados faltantes, apenas foi verificado, de acordo com a metodologia adotada por Chiquetto (2008), se a quantidade de dados disponíveis era suficiente para a aplicação dos métodos de análise estatística, que no caso da média diária, este valor corresponde a no mínimo 16 horas de dados válidos durante o dia, no caso da média mensal, 20 dias no mínimo com dados válidos e na média anual, 8 meses com dados válidos.

Os municípios estudados apresentaram ausência de dados horários, dos poluentes registrados nas estações da CETESB. O único município que não apresentou ausência de dados foi DA, para os dois únicos poluentes MP₁₀ e O₃ monitorados. MA apresentou 12,6% de ausência, SCS 4,3%, SA 5,8% e SBC 3,7%, considerando os dados dos poluentes disponíveis para cada município (Tabela 2).

Da mesma forma, para os dados de variáveis climáticas disponíveis para cada município (temperatura média, máxima e mínima, umidade relativa do ar média, máxima e mínima, velocidade do vento e precipitação), todos os municípios apresentaram ausência de dados. SBC apresentou 15,8%, SA 13,8%, DA 10,3%, SCS 0,3% e MA apresentou o menor percentual de ausência de dados, apenas 0,1%.

Portanto, apesar de todos os municípios apresentarem dados faltantes nas variáveis estudadas durante os anos de 2020 e 2021, a quantidade de dados disponíveis permitiu a análise estatística, respeitando o mínimo estabelecido por Chiquetto (2008).

Os dados de Covid-19 dos municípios do Grande ABC foram coletados na plataforma oficial do Governo Coronavírus Brasil, para as categorias “Casos Novos”, “Óbitos Novos”, “Casos Acumulados” e “Óbitos Acumulados”. Os dados de Covid-19 apresentaram falhas nas categorias “Casos Novos” e “Óbitos Novos”. Foram evidenciados valores negativos que foram substituídos por zero, não impactando no valor das correlações após testes realizados. As categorias “Casos Acumulados” e “Óbitos Acumulados” não apresentaram falhas.

2.2. Análise estatística

Após a coleta e processamento de dados, foi utilizado o RStudio para a análise estatística. O RStudio é um *software* de código aberto que permite a criação de gráficos e a realização de cálculos estatísticos (R CORE TEAM, 2022). Foi calculado o coeficiente de correlação de Spearman, também conhecido como Coeficiente de Correlação por Postos de Spearman (Eq. 1), que permite a análise de relações monótonas, lineares ou não (LIRA, 2004).

$$r_s = 1 - \frac{6 \sum_{i=1}^n d_i^2}{n(n^2 - 1)} \quad (1)$$

Onde: r_s é o Coeficiente de Correlação de Spearman;
 d_i é a diferença entre as ordenações, nesse caso, dos parâmetros ambientais e da Covid-19;
 n é o número de pares de ordenações.

Segundo Callegari-Jacques (2007), o r_s varia entre -1 (correlação perfeita negativa, ou seja, quando uma variável aumenta, influencia no decaimento da outra variável) e +1 (correlação perfeita positiva, ou seja, quando uma variável aumenta, influencia no crescimento da outra variável). Desta forma, a interpretação de r_s é semelhante ao Coeficiente de Correlação de Pearson (Tabela 3).

Tabela 3 - Grau de correlação entre duas variáveis.

$ r_s $	A correlação é dita
0	Nula
0-0,3	Fraca
De 0,3 até 0,6	Regular
De 0,6 até 0,9	Forte
De 0,9 até 1	Muito forte
1	Plena ou perfeita

Fonte: adaptado de Callegari-Jacques (2007).

As correlações de Spearman foram realizadas considerando as variáveis Casos Novos (CN), Óbitos Novos (ON), Casos Acumulados (CA) e Óbitos Acumulados (OA) de Covid-19 e os dados de poluentes atmosféricos e variáveis climáticas disponíveis para os municípios. Todos os dados foram utilizados na escala diária e foram considerados somente os resultados com significância estatística ($p\text{-value} < 0,05$).

A correlação foi aplicada considerando dois arranjos de séries de dados diferentes: (i) compreendendo todo o período de 2020 a 2021 a partir dos primeiros dados de Covid-19 no ABC e (ii) somente no período da quarentena oficial no Estado de São Paulo. Ainda, para este último foram realizadas correlações com lapso de tempo de 5 dias, pois o período de incubação do coronavírus é em torno de 5 dias na média (BACKER; KLINKENBERG; WALLINGA, 2020; GONZAGA E FREITAS, 2020). Portanto, para um dado de Covid-19 iniciado em, por exemplo, 27/03/2020, se realizou as correlações com as outras variáveis (climáticas e de poluição) utilizando os valores destas, 5 dias antes, ou seja, em 22/03/2020.

Por fim, também utilizando o *software* RStudio, foi construído um modelo de Regressão Linear Múltipla (RLM) para a análise de duas ou mais variáveis (independentes, poluentes atmosféricos e variáveis climáticas) influenciando o comportamento da variável resposta (dependente, dados de Covid-19). Segundo Hair et al. (2009), o objetivo da RLM (Eq. 2) é usar as variáveis independentes cujos valores são conhecidos para modelar e prever os valores da variável dependente que foi selecionada.

$$Y_i = \beta_0 + \beta_k V_{ik} + e_i \quad (2)$$

Onde: Y é a variável dependente;

V é a variável independente;

β são os parâmetros a serem estimados;

e é o erro de previsão (resíduo).

O erro de previsão ou resíduo representa a quantidade da variabilidade de Y que o modelo ajustado não consegue explicar. Os resíduos contêm informações sobre o motivo do modelo não ter se ajustado bem aos dados (HAIR et al., 2009).

Para cada município foi construída uma planilha contendo uma variável dependente, por exemplo, CA, OA, CN ou ON, e as demais variáveis independentes (poluentes

atmosféricos e variáveis climáticas) disponíveis. Para isso, foi realizada a normalização dos dados pelo método dos mínimos e máximos (Eq. 3). Este método de normalização consiste em redimensionar cada recurso para o intervalo em [0,1] ou [-1,1] e executa uma transformação linear nos dados, preservando as relações entre os valores de dados originais (HAN et al., 2006).

$$x'_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (3)$$

Onde: x' é a variável normalizada;

x é a variável não normalizada;

x_{\min} valor mínimo da variável não normalizada;

x_{\max} valor máximo da variável não normalizada.

Anteriormente à aplicação do modelo de RLM foi verificado o atendimento aos pressupostos ou hipóteses da RLM. As hipóteses básicas testadas foram: (a) Relação linear nos parâmetros; (b) Normalidade dos erros (resíduos); (c) Homocedasticidade ou variância constante dos erros (resíduos) e (d) Multicolinearidade, ou seja, correlação entre as variáveis independentes (CHEN, 2019; FILHO et al., 2011).

As variáveis que apresentaram multicolinearidade entre si foram removidas e escolhidas aquelas entre as quais apresentaram maior grau de correlação de Spearman. Então, por exemplo, se NO_2 e NO_x apresentaram multicolinearidade, foi escolhida manter a variável que apresentou maior grau de correlação de Spearman para o município analisado. Portanto, todos os municípios atenderam ao pressuposto da não multicolinearidade após a remoção das variáveis que apresentaram alto grau de correlação entre si.

3. RESULTADOS E DISCUSSÕES

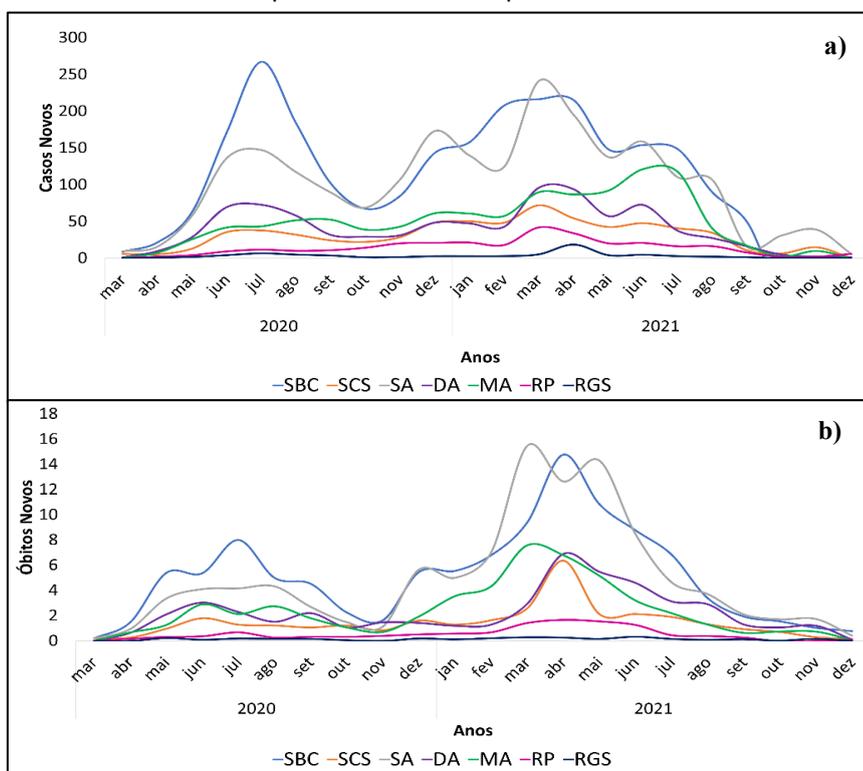
3.1. Análise exploratória dos casos e óbitos de Covid-19

O primeiro caso de Covid-19 em São Paulo foi confirmado pelo Ministério da Saúde no dia 26 de fevereiro de 2020, e a primeira morte no Brasil se registrou no dia 12 de março,

na cidade de São Paulo⁵. No Estado de São Paulo, a quarentena oficial se iniciou em 22 de março de 2020 com o Decreto nº 64.881⁶ pelo prazo de 40 dias. Após este decreto inicial, outros decretos foram prorrogando e flexibilizando o período de quarentena para a retomada das atividades econômicas.

Durante as três primeiras semanas da quarentena (22/03/2020 até 11/04/2020) ocorreram os maiores índices de adesão ao isolamento social, chegando a atingir 71% de adesão na região do Grande ABC paulista, segundo dados do Sistema de Monitoramento Inteligente do Governo de São Paulo⁷. O município de RGS se manteve com a maior adesão ano longo do ano de 2020, enquanto MA e DA foram os municípios com as menores adesões ao isolamento social. Após este período inicial, o índice de isolamento social foi decaindo, devido ao retorno da circulação de pessoas e das medidas de abertura do comércio estabelecidas nos decretos oficiais.

Figura 2 - a) Média de casos novos (CN) de Covid-19 e b) Média de óbitos novos (ON) de Covid-19 para o Grande ABC paulista.



Fonte: Elaboração própria com dados do Ministério da Saúde.

⁵ <https://www.unasus.gov.br/noticia/coronavirus-brasil-confirma-primeiro-caso-da-doenca>

⁶ <https://www.al.sp.gov.br/repositorio/legislacao/decreto/2020/decreto-64881-22.03.2020.html>

⁷ <https://www.saopaulo.sp.gov.br/coronavirus/isolamento/>

Na Figura 2 podem-se observar duas ondas de Covid-19 nos municípios do Grande ABC paulista. A primeira onda para a média de CN (Figura 2a) e para ON (Figura 2b) ocorreu de março a outubro de 2020. Nesta primeira fase, o município de SBC apresentou os maiores picos para ambos casos e óbitos em julho de 2020. A segunda onda, também para casos e óbitos, se iniciou aproximadamente em novembro de 2020, com pico em março de 2021, a partir disso, os casos e óbitos apresentaram queda. Nesta segunda fase, SA ultrapassou SBC nos meses de dezembro de 2020 e março de 2021 para CN (Figura 2a) e em dezembro de 2020, fevereiro, março, maio, agosto e setembro de 2021 para ON (Figura 2b).

3.2. As correlações de Spearman

As correlações realizadas com as variáveis climáticas ($T_{méd}$, $T_{máx}$, $T_{mín}$, $UR_{méd}$, $UR_{máx}$, $UR_{mín}$, PPP e $V_{vméd}$) e as variáveis de Covid-19 (CN, ON, CA, OA) sem lapso de tempo, no período de 2020 a 2021, de maneira geral, os resultados apresentaram correlações “fracas” para todos os municípios e variáveis, ou seja, abaixo de 0,30, ou sem significância estatística ($p\text{-value} > 0,05$). Destaca-se somente a correlação positiva (0,30) OA- $V_{vméd}$ em MA.

As Tabelas 4 e 5 apresentam as correlações para o período da quarentena (27/03/2020 a 31/05/2020). A Tabela 4 apresenta as correlações sem lapso de tempo e a Tabela 6 apresenta as correlações com lapso de tempo de 5 dias.

Na Tabela 4 observa-se que para CA e OA, a $T_{méd}$ e a $T_{mín}$ apresentaram na sua maioria correlações negativas, com classificação de correlação forte ($\geq 0,60$) para a $T_{mín}$, em quase todos os municípios. Os municípios de SA e SCS apresentaram os valores mais altos para a $T_{mín}$. De maneira geral, a maioria das correlações foi negativa, com algumas exceções como, por exemplo, CA- $UR_{máx}$ e OA- $UR_{máx}$ em DA que apresentou correlação positiva de 0,42 e 0,40 respectivamente e CN- $UR_{mín}$ e ON- $UR_{mín}$ em SBC que apresentou correlação positiva de 0,36 e 0,30 respectivamente.

Tabela 4 - Correlações de Spearman com as variáveis climáticas, sem lapso de tempo no período de 27/03/2020 - 31/05/2020. Foram destacadas em vermelho as correlações iguais ou acima de 0,30. O asterisco (*) indica que a correlação não foi estatisticamente significativa (p -value > 0,05).

Municípios	CA-Tméd	CA-Tmáx	CA-Tmín	CA-URméd	CA-URmáx	CA-URmín	CA-PPP	CA-Vvméd
DA	-0,36	0,13*	-0,67	-0,12*	0,42	-0,30*	0,02*	-0,50
MA	-0,58	-0,28	-0,64	-0,31	0,08*	-0,43	-0,03*	-0,04*
SA	-0,56	-0,29	-0,73	-0,29	-0,11*	-0,39	-0,11*	-0,31
SBC	-0,58	-0,32	-0,68	0,17*	-0,16*	0,26	-0,21*	-0,28
SCS	-0,59	-0,38	-0,74	-0,29	-0,10*	-0,37	0,04*	-0,34

Municípios	OA-Tméd	OA-Tmáx	OA-Tmín	OA-URméd	OA-URmáx	OA-URmín	OA-PPP	OA-Vvméd
DA	-0,32	0,18*	-0,63	-0,15*	0,40	-0,33	0,02*	-0,50
MA	-0,53	0,22*	-0,60	0,17	0,08*	-0,43	-0,02*	-0,05*
SA	-0,55	-0,27	-0,73	-0,29	-0,11*	-0,40	-0,12*	-0,32
SBC	-0,58	-0,32	-0,68	0,17*	-0,17*	0,27	-0,21*	-0,27
SCS	-0,57	-0,36	-0,72	-0,29	-0,12*	-0,36	0,04*	-0,33

Fonte: autoras.

Na Tabela 5, que considera o lapso de tempo de 5 dias, se apresentam as correlações para CN, ON, CA e OA. As correlações para CN e ON apresentaram correlações negativas, com destaque também para a Tmín e Tméd. Para os CA e OA, a Tméd e a Tmín para todos os municípios analisados apresentaram correlações negativas, sendo novamente a Tmín a que apresentou os maiores valores. A URmín também apresentou valores acima de 0,3 (CA-URmín e OA-URmín) em DA e MA. A URmáx se destaca somente em DA para ON, CA e OA, bem como as correlações CN/CA/OA-Vvméd.

Tabela 5 - Correlações de Spearman com as variáveis climáticas, com lapso de tempo de 5 dias no período de 27/03/2020 - 31/05/2020. Foram destacadas em vermelho as correlações iguais ou acima de 0,30. O asterisco (*) indica que a correlação não foi estatisticamente significativa ($p\text{-value} > 0,05$).

Municípios	CN-Tméd	CN-Tmáx	CN-Tmín	CN-URméd	CN-URmáx	CN-URmín	CN-PPP	CN-Vvméd
DA	-0,09*	0,16*	-0,24*	0,03*	0,18*	-0,20*	0,09*	-0,43
MA	-0,45	-0,26	-0,46	-0,04*	0,07*	-0,18*	-0,05*	-0,16
SA	-0,29	-0,19*	-0,38	-0,03*	-0,06*	-0,04*	0,06*	-0,10
SBC	-0,45	-0,29	-0,48	-0,03*	-0,26	0,07*	-0,10*	-0,06
SCS	-0,30	-0,25	-0,31	-0,11*	-0,14*	-0,11*	0,11*	-0,06
Municípios	ON-Tméd	ON-Tmáx	ON-Tmín	ON-URméd	ON-URmáx	ON-URmín	ON-PPP	ON-Vvméd
DA	-0,13*	0,16*	-0,36	0,07*	0,32	-0,19*	0,09*	-0,23
MA	-0,30	-0,21*	-0,26	0,20*	0,24*	0,04*	0,06*	-0,34
SA	-0,44	-0,31	-0,52	0,09*	0,09*	0,03*	0,00*	-0,22*
SBC	-0,27	-0,11*	-0,33	0,06*	-0,14*	0,09*	0,03*	-0,21*
SCS	-0,36	-0,18*	-0,38	-0,01*	0,01*	-0,20*	-0,04*	-0,10*
Municípios	CA-Tméd	CA-Tmáx	CA-Tmín	CA-URméd	CA-URmáx	CA-URmín	CA-PPP	CA-Vvméd
DA	-0,30	0,17*	-0,60	-0,03*	0,47	-0,31	0,12*	-0,49
MA	-0,47	-0,22*	-0,53	-0,18*	-0,20*	-0,33	0,07*	-0,12*
SA	-0,43	-0,22*	-0,63	-0,19*	-0,08*	-0,28	0,01*	-0,24*
SBC	-0,45	-0,23*	-0,56	0,00*	-0,17*	0,08*	-0,17*	-0,21
SCS	-0,48	-0,32	-0,65	-0,18*	-0,02*	-0,27	0,14*	-0,28
Municípios	OA-Tméd	OA-Tmáx	OA-Tmín	OA-URméd	OA-URmáx	OA-URmín	OA-PPP	OA-Vvméd
DA	-0,27*	0,20*	-0,57	-0,03*	0,50	-0,30	0,11*	-0,51
MA	-0,47	-0,22*	-0,54	-0,19*	-0,04*	-0,34	0,04*	-0,11*
SA	-0,43	-0,22*	-0,63	-0,18*	-0,07*	-0,27	0,00*	-0,24*
SBC	-0,45	-0,23*	-0,56	-0,01*	-0,18*	0,07*	-0,17*	-0,21
SCS	-0,49	-0,33	-0,66	-0,17*	-0,01*	-0,28	0,14*	-0,28

Fonte: autoras.

No Grande ABC paulista destacam-se as correlações negativas com as temperaturas mínima e média, e as correlações destacadas para umidade relativa variam, sendo positivas ou negativas. Especificamente para o período da quarentena, a URmín foi negativa em alguns municípios. Estes resultados estão de acordo com outros estudos ao redor do mundo (BILAL et al. 2020; MA et al. 2020; OLIVEIROS et al. 2020; LUO et al. 2020; PRATA;

RODRIGUES; BERMEJO, 2020). As correlações significativas para a velocidade média do vento apresentam relação inversa para DA (CN, CA e OA) e MA (ON). Ahmadi et al. (2020) evidenciou que entre as variáveis meteorológicas estudadas no Irã, a velocidade do vento apresentou uma relação significativa e inversa com a taxa de infecção por Covid-19, ou seja, com uma menor velocidade do vento, a taxa de infecção é maior.

De acordo com Oliveiros et al. (2020), a temperatura aumenta o tempo de duplicação do coronavírus, o que significa que atrasa a propagação da Covid-19. Isso pode explicar as correlações negativas. Da mesma forma, para a umidade relativa do ar, foi verificado por Ahmadi et al. (2020) no Irã, que em regiões áridas e semiáridas, as taxas de doenças são maiores em áreas com baixa umidade do que em áreas com alta umidade. Portanto, isso pode significar que, com a primavera e o verão, a taxa de progressão da Covid-19 seja mais devagar, devido ao aumento da umidade. Entretanto, nos resultados da presente pesquisa, em Diadema as correlações foram positivas e significativas para UR_{máx}, considerando CA, OA, ON.

As correlações realizadas entre as variáveis de Covid-19 e os poluentes atmosféricos para todo o período de 2020 a 2021 não apresentaram resultados acima ou igual da classificação “regular”, os resultados obtidos foram abaixo de 0,30. A única exceção foi o município de MA que apresentou 0,33 para CA/OA - MP₁₀ e 0,35 para CA/OA - O₃.

As Tabelas 6 e 7 apresentam os resultados com maior grau de correlação para o período da quarentena (27/03/2020 a 31/05/2020) entre os dados de Covid-19 e os poluentes atmosféricos. Na Tabela 8 são apresentadas as correlações com lapso de tempo de 5 dias, somente entre CA e OA e os poluentes atmosféricos, pois o único destaque nas demais correlações foi MA com resultado de 0,44 para CN-MP₁₀.

Os poluentes MP_{2,5} e MP₁₀, em geral, foram os que apresentaram as correlações mais fracas, enquanto a maioria dos demais poluentes apresentou correlações acima de 0,40. As correlações com O₃ foram negativas em todos os municípios, principalmente quando não foi considerado lapso de tempo (Tabela 6). Os demais poluentes apresentaram em sua maioria correlações positivas e o SO₂ não apresentou correlação significativa em nenhum município.

Tabela 6 - Correlações de Spearman com os poluentes atmosféricos, sem lapso de tempo no período de 27/03/2020 - 31/05/2020. Foram destacadas em vermelho as correlações acima de 0,30. O asterisco (*) indica que a correlação não foi estatisticamente significativa ($p\text{-value} > 0,05$). O traço (-) indica que os dados não estavam disponíveis para a aplicação do teste.

Municípios	CN-MP _{2,5}	CN-MP ₁₀	CN-O ₃	CN-CO	CN-NO ₂	CN-NO _x	CN-NO	CN-SO ₂
DA	-	0,14*	-0,54	-	-	-	-	-
MA	-0,36*	-0,02*	-0,45	-	-	-	-	-
SA	-	0,25	-0,52	-	0,49	0,48	0,44	-0,05*
SBC	0,12*	0,32	-0,53	0,40	0,49	0,52	0,44	-
SCS	0,17*	0,22*	-0,49	0,37	0,38	0,37	0,31	-0,05*
Municípios	ON-MP _{2,5}	ON-MP ₁₀	ON-O ₃	ON-CO	ON-NO ₂	ON-NO _x	ON-NO	ON-SO ₂
DA	-	0,18*	-0,37	-	-	-	-	-
MA	-0,21*	0,05*	-0,22	-	-	-	-	-
SA	-	0,27	-0,48	-	0,47	0,47	0,47	0,00*
SBC	-0,17*	-0,03*	-0,42	0,12	0,16	0,17	0,14	-
SCS	0,10*	0,10*	-0,35	0,20	0,13	0,13	0,09	0,05*
Municípios	CA-MP _{2,5}	CA-MP ₁₀	CA-O ₃	CA-CO	CA-NO ₂	CA-NO _x	CA-NO	CA-SO ₂
DA	-	0,21*	-0,55	-	-	-	-	-
MA	-0,22*	0,26*	-0,45	-	-	-	-	-
SA	-	0,26	-0,44	-	0,55	0,53	0,53	0,12*
SBC	0,10*	0,26	-0,62	0,41	0,49	0,53	0,47	-
SCS	0,20*	0,19*	-0,62	0,50	0,48	0,48	0,43	0,03*
Municípios	OA-MP _{2,5}	OA-MP ₁₀	OA-O ₃	OA-CO	OA-NO ₂	OA-NO _x	OA-NO	OA-SO ₂
DA	-	0,21*	-0,55	-	-	-	-	-
MA	-0,11*	0,31*	-0,46	-	-	-	-	-
SA	-	0,27	-0,44	-	0,56	0,54	0,54	0,13*
SBC	0,10*	0,25	-0,62	0,41	0,48	0,52	0,47	-
SCS	0,20*	0,20*	-0,64	0,51	0,48	0,47	0,43	0,03*

Fonte: autoras.

Tabela 7 - Correlações de Spearman com os poluentes atmosféricos, com lapso de tempo de 5 dias no período de 27/03/2020 - 31/05/2020. Foram destacadas em vermelho as correlações acima de 0,30. O asterisco (*) indica que a correlação não foi estatisticamente significativa ($p\text{-value} > 0,05$). O traço (-) indica que os dados não estavam disponíveis para a aplicação do teste.

Municípios	CA-MP _{2,5}	CA-MP ₁₀	CA-O ₃	CA-CO	CA-NO ₂	CA-NO _x	CA-NO	CA-SO ₂
DA	-	0,19*	-0,47	-	-	-	-	-
MA	0,20*	0,47	-0,24*	-	-	-	-	-
SA	-	0,27	-0,26	-	0,44	0,42	0,41	-0,20*
SBC	-0,01*	0,22*	-0,47	0,45	0,48	0,50	0,38	-
SCS	0,25	0,20*	-0,46	0,53	0,48	0,45	0,31	-0,05*

Municípios	OA-MP _{2,5}	OA-MP ₁₀	OA-O ₃	OA-CO	OA-NO ₂	OA-NO _x	OA-NO	OA-SO ₂
DA	-	0,21*	-0,47	-	-	-	-	-
MA	0,10*	0,41	-0,25*	-	-	-	-	-
SA	-	0,26	-0,28	-	0,45	0,42	0,42	-0,20*
SBC	0,00*	0,22*	-0,47	0,45	0,48	0,51	0,38	-
SCS	0,24*	0,19*	-0,48	0,53	0,47	0,43	0,31	-0,04*

Fonte: autoras.

Um estudo realizado por Bilal et al. (2020) na Alemanha utilizou a correlação de Spearman e indicou que MP_{2,5}, O₃ e NO₂ estão significativamente associados ao total de casos, óbitos e número de recuperados por Covid-19. No presente estudo, se encontrou uma correlação negativa com o O₃.

Gonzaga e Freitas (2020) realizaram as correlações entre variáveis climáticas e poluentes atmosféricos com dados de casos acumulados e óbitos confirmados de Covid-19 para a RMSP. Os resultados mostraram que para os poluentes atmosféricos as correlações foram maiores para lapsos de tempo de 5 e 10 dias. Entretanto, para o Grande ABC, os resultados obtidos apresentaram maiores graus de correlação para o período da quarentena sem lapso de tempo.

Portanto, pode-se afirmar que o O₃, CO, NO_x, NO e NO₂, são os principais poluentes determinantes da Covid-19 no Grande ABC paulista. Deve-se destacar que a exposição à poluição atmosférica impacta a saúde humana e este potencial é determinado pelo grau de exposição e toxicidade do poluente. A exposição à poluição atmosférica pode causar doenças pulmonares, cardiovasculares, acidentes vasculares cerebrais, entre outros. Estes impactos afetam principalmente crianças e idosos (SANT'ANNA et al., 2021).

Diversos estudos (SPERANDIO E GOMES, 2020; SAN MARTIN E SAN MARTIN, 2020; OLIVEIRA et al., 2021; SILVA, 2021; ROCHA et al., 2021) indicam que medidas como o fechamento de aeroportos, fechamento do comércio, pausa no setor industrial e restrições para a circulação de pessoas e veículos com o objetivo de controlar a disseminação da Covid-19 contribuíram para uma diminuição na emissão de poluentes atmosféricos e consequente melhoria nos níveis de qualidade do ar no Brasil (Estado de São Paulo) e no mundo.

No entanto, é claro o entendimento da associação direta entre os períodos de *lockdown* com a poluição atmosférica, uma vez que as fontes emissoras (indústrias e automóveis) durante esse período minimizaram ou até paralisaram as suas emissões. Por outro lado, as correlações encontradas entre Casos Acumulados e de Óbitos com os poluentes atmosféricos (CO, NO₂, NO_x e NO), apesar de se apresentar positivas, se entende que a redução das emissões em termos de saúde da população foi benéfico, pois as concentrações desses poluentes diminuíram como consequência da paralisação das principais fontes de emissão de poluentes no período de *lockdown*.

A partir dos resultados obtidos nesta pesquisa, e de acordo com Gonzaga e Freitas (2020), deve-se ressaltar que as variáveis climáticas e os poluentes atmosféricos não fornecem uma explicação completa para a propagação do vírus, a qual envolve também fatores comportamentais da população. Entretanto, deve ser considerada a relação significativa entre saúde humana, qualidade do ar e fatores climáticos.

3.3. A regressão linear múltipla

Na Tabela 8 observam-se os resultados da aplicação da RLM para poluentes atmosféricos, variáveis climáticas, CN e ON. Não houve modelos ótimos, ou seja, que atenderam todos os pressupostos ou hipóteses básicas testadas e estipuladas na metodologia. Três modelos obtiveram resultados nulos na estatística F ($p\text{-value} > 0,05$): SCS para CN e DA e MA para ON. Todos os modelos apresentaram dados não normais e/ou resíduos padronizados atípicos (*outliers*) ou seja, fora do intervalo [-3, +3] da estatística F.

Na Tabela 9 pode-se observar os resultados da aplicação da RLM para poluentes atmosféricos, variáveis climáticas, CA e OA. Quatro modelos atenderam todos os pressupostos, desta forma podem ser considerados modelos ótimos: DA e SBC para CA e

novamente DA e SBC para OA. Os demais modelos apresentaram dados não normais ou a ausência de homocedasticidade.

As variáveis climáticas significativas (ou seja, $p\text{-value} \leq 0,05$) $T_{\text{mín}}$, $UR_{\text{máx}}$ e $UR_{\text{mín}}$ dos modelos ótimos, tanto para SBC quanto para DA foram as que apresentaram os maiores graus de correlações de Spearman nos testes realizados anteriormente no subitem 5.2.1, (por exemplo, 0,38 para $T_{\text{mín}}\text{-CA}$ e 0,47 $UR_{\text{máx}}$ em DA e -0,68 para $T_{\text{mín}}\text{-CA}$ em SBC) em todos os testes realizados, ou seja, para todo o período de 2020-2021, durante a quarentena e também para a quarentena com o lapso de tempo. Também pode ser verificado que as variáveis significativas $D_{\text{vméd}}$, $D_{\text{vmáx}}$ e $P_{\text{máx}}$ referentes aos modelos ótimos de SBC apresentaram correlações de Spearman acima de 0,3 (regular) e acima de 0,6 (forte) para $D_{\text{vmáx}}$ para o período da quarentena com e sem lapso de tempo.

Para os modelos ótimos, o coeficiente de determinação R^2 ajustado foi acima de 60%, indicando que o modelo explica mais de 60% da variabilidade dos dados de resposta ao redor de sua média. A cada variável adicionada no modelo, o R^2 aumenta, mesmo que a variável não seja relevante, desta forma o R^2 ajustado realiza uma correção para a quantidade de variáveis, permitindo a comparação entre modelos com quantidades de variáveis independentes diferentes (FILHO, 2002).

Os poluentes atmosféricos com significância estatística MP_{10} em DA e NO_x em SBC apresentaram graus de correlação de Spearman, nos testes realizados anteriormente no subitem 5.2.2, fraco em DA ($<0,30$) e regular em SBC ($>0,50$).

A Tabela 8 apresenta a ocorrência de três modelos nulos, ou seja, sem significância estatística: SCS para CN, DA e MA para ON. Somente no modelo nulo de DA houve uma variável significativa ($UR_{\text{máx}}$), entretanto comparando-se com as correlações de Spearman a $UR_{\text{máx}}$ apresentou um grau de correlação fraco ($<0,30$).

Tabela 8 – RLM para poluentes atmosféricos, variáveis climáticas, CN e ON.

Municípios	Formulação	CN-Variáveis Significativas ($p \leq 0,05$)	Atendeu Pressupostos?	R ² Ajustado	Modelo nulo ou não nulo
DA	$CN = -0,14T_{mín} + 0,12UR_{máx} - 0,36UR_{mín} + 0,14PPP - 0,08V_{vméd} + 0,08MP_{10} - 0,37O_3$	O ₃	Dados não normais, há <i>outliers</i>	0,2852	Não nulo
MA	$CN = -0,44T_{máx} - 0,002T_{mín} - 0,26UR_{méd} + 0,19UR_{máx} + 0,02PPP - 0,15V_{vméd} - 0,49O_3$	T _{máx} e O ₃	Dados não normais, há <i>outliers</i>	0,06432	Não nulo
SA	$CN = 0,02T_{mín} + 0,43UR_{méd} - 0,54UR_{mín} + 0,21PPP + 0,08V_{vméd} + 0,03RAD - 0,61O_3 + 0,21NO_2 - 0,13SO_2$	UR _{méd} , UR _{mín} , O ₃	Dados não normais	0,3919	Não nulo
SBC	$CN = -0,20T_{mín} - 0,08PPP + 0,10D_{vméd} + 0,10D_{vmáx} - 0,28V_{vméd} - 0,33O_3 - 0,03NO_x + 0,26P_{amáx}$	O ₃	Dados não normais, há <i>outliers</i>	0,3386	Não nulo
SCS	$CN = 0,07T_{mín} + 0,08UR_{máx} - 0,09UR_{mín} - 0,09PPP + 0,02V_{vméd} - 0,16O_3 + 0,33CO - 0,09SO_2$	Não há	Dados não normais, há <i>outliers</i>	0,02433	Nulo
Municípios	Formulação	ON-Variáveis Significativas ($p \leq 0,05$)	Atendeu Pressupostos?	R ² Ajustado	Modelo nulo ou não nulo
DA	$ON = -0,05T_{mín} + 0,45UR_{máx} - 0,07UR_{mín} - 0,15PPP + 0,04V_{vméd} + 0,12MP_{10} - 0,08O_3$	UR _{máx}	Dados não normais, há <i>outliers</i>	0,09832	Nulo
MA	$ON = -0,21T_{máx} + 0,27T_{mín} - 0,40UR_{méd} + 0,29UR_{máx} - 0,01PPP - 0,03V_{vméd} - 0,06O_3$	Não há	Dados não normais	-0,07075	Nulo
SA	$ON = 0,07T_{mín} + 0,68UR_{méd} - 0,70UR_{mín} - 0,02PPP + 0,22V_{vméd} + 0,14RAD - 0,54O_3 + 0,29NO_2 - 0,23SO_2$	UR _{méd} , UR _{mín} e O ₃	Dados não normais, há <i>outliers</i>	0,2264	Não nulo
SBC	$ON = -0,26T_{mín} - 0,03PPP + 0,41D_{vméd} + 0,07D_{vmáx} + 0,08V_{vméd} - 0,18O_3 - 0,23NO_x + 0,40P_{amáx}$	D _{vméd} e P _{amáx}	Dados não normais, há <i>outliers</i>	0,1267	Não nulo
SCS	$ON = 0,11T_{mín} - 0,03UR_{máx} + 0,05UR_{mín} - 0,07PPP + 0,14V_{vméd} - 0,21O_3 + 0,41CO + 0,02SO_2$	CO	Dados não normais, há <i>outliers</i>	0,05453	Não nulo

Fonte: autoras.

Tabela 9 – RLM para poluentes atmosféricos, variáveis climáticas, CA e OA. Os resultados destacados em azul são os modelos considerados ótimos.

Municípios	Formulação	CA-Variáveis Significativas (p≤0,05)	Atendeu Pressupostos?	R ² Ajustado	Modelo nulo ou não nulo
DA	$CA = -0,44T_{mín} + 0,36UR_{máx} - 0,23UR_{mín} + 0,04PPP + 0,19V_{vméd} + 0,38MP_{10} - 0,18O_3$	T _{mín} , UR _{máx} e MP ₁₀	Sim	0,682	Não nulo
MA	$CA = -0,12T_{máx} - 0,46T_{mín} - 0,17UR_{méd} - 0,24UR_{máx} - 0,05PPP - 0,17V_{vméd} - 0,41O_3$	T _{mín} e O ₃	Dados não normais	0,2248	Não nulo
SA	$CA = -0,58T_{mín} + 0,25UR_{méd} - 0,55UR_{mín} - 0,17PPP + 0,24V_{vméd} - 0,19RAD - 0,27O_3 + 0,31NO_2 - 0,21SO_2$	T _{mín} , UR _{mín} , PPP, O ₃ , NO ₂ e SO ₂	Não há homocedasticidade	0,6958	Não nulo
SBC	$CA = -0,46T_{mín} - 0,01PPP + 0,24D_{vméd} + 0,24D_{vmáx} + 0,09V_{vméd} - 0,14O_3 + 0,20NO_x + 0,26P_{amáx}$	T _{mín} , D _{vméd} , D _{vmáx} , NO _x e P _{amáx}	Sim	0,9201	Não nulo
SCS	$CA = -0,47T_{mín} + 0,01UR_{máx} - 0,12UR_{mín} + 0,01PPP + 0,06V_{vméd} - 0,32O_3 + 0,36CO - 0,11SO_2$	T _{mín} , O ₃ , CO	Não há homocedasticidade	0,7432	Não nulo
Municípios	Formulação	OA-Variáveis Significativas (p≤0,05)	Atendeu Pressupostos?	R ² Ajustado	Modelo nulo ou não nulo
DA	$OA = -0,36T_{mín} + 0,41UR_{máx} - 0,27UR_{mín} + 0,05PPP + 0,23V_{vméd} + 0,38MP_{10} - 0,17O_3$	T _{mín} , UR _{máx} , UR _{mín} , MP ₁₀	Sim	0,6465	Não nulo
MA	$OA = -0,15T_{máx} - 0,41T_{mín} - 0,23UR_{méd} - 0,22UR_{máx} + 0,002PPP - 0,19V_{vméd} - 0,39O_3$	T _{mín} e O ₃	Dados não normais	0,1071	Não nulo
SA	$OA = -0,56T_{mín} + 0,24UR_{méd} - 0,58UR_{mín} - 0,16PPP + 0,27V_{vméd} - 0,18RAD - 0,27O_3 + 0,30NO_2 - 0,21SO_2$	T _{mín} , UR _{mín} , PPP, O ₃ , NO ₂ e SO ₂	Não há homocedasticidade	0,6721	Não nulo
SBC	$OA = -0,50T_{mín} + 0,001PPP + 0,27D_{vméd} + 0,23D_{vmáx} + 0,09V_{vméd} - 0,14O_3 + 0,14NO_x + 0,24P_{amáx}$	T _{mín} , D _{vméd} , D _{vmáx} , P _{amáx}	Sim	0,9339	Não nulo
SCS	$OA = -0,42T_{mín} + 0,01UR_{máx} - 0,12UR_{mín} - 0,01PPP + 0,04V_{vméd} - 0,38O_3 + 0,30CO - 0,04SO_2$	T _{mín} , O ₃ e CO	Não há homocedasticidade	0,6919	Não nulo

Fonte: autoras.

Um estudo realizado por Cruz (2022) em Ponta Grossa - PR no qual utilizou o modelo de RLM para novos casos diários da Covid 19, temperatura mínima e radiação solar, de 13/05 a 10/11/2020, constatou que o coeficiente de determinação R² referente a

temperatura mínima do ar e a radiação solar foi capaz de explicar aproximadamente 22% dos novos casos diários da Covid-19. O estudo ainda sugere que os outros 78% da explicação provavelmente se situa em outros fatores como os relacionados com tamanho e densidade da população, fatores comportamentais da sociedade, com a sazonalidade do clima e outras variáveis climáticas.

O estudo realizado por Oliveiros et al. (2020) em 31 províncias da China com diferentes períodos de amostragem de variáveis meteorológicas e dados de Covid-19, mostra que o R^2 ajustado do modelo de RLM baseado em 12 dias e 3 períodos amostrados é capaz de explicar 18% da variação no tempo de duplicação do vírus, ou seja, apenas a temperatura e umidade podem descrever 18% da variação de infecções confirmadas por Covid-19.

4. CONSIDERAÇÕES FINAIS

As correlações entre os dados de Covid-19 e as variáveis climáticas mostram resultados de correlação negativas com as $T_{mín}$ e $T_{méd}$, e as correlações para UR variam, sendo positivas ou negativas. No que se refere à $T_{mín}$ o resultado sugere que quanto mais baixas sejam as temperaturas, estas contribuem no aumento da disseminação e contágio do vírus, por isso as correlações negativas na maioria dos municípios do Grande ABC paulista. Os resultados das correlações entre os dados de Covid-19 e os poluentes atmosféricos tornam evidentes que os poluentes O_3 , CO, NO_x , NO e NO_2 , são os principais determinantes da Covid-19 no Grande ABC paulista, devido ao maior grau de correlação estatística.

Na aplicação da RLM, quatro modelos atenderam todos os pressupostos, desta forma podem ser considerados modelos ótimos: DA e SBC para CA e novamente DA e SBC para OA. As variáveis climáticas significativas (ou seja, $p\text{-value} \leq 0,05$) $T_{mín}$, $UR_{máx}$ e $UR_{mín}$ dos modelos ótimos, tanto para SBC quanto para DA foram as que apresentaram os maiores graus de correlações de Spearman. Também pode ser verificado que as variáveis significativas $D_{vméd}$, $D_{vmáx}$ e $P_{amáx}$ referentes aos modelos ótimos de SBC apresentaram correlações de Spearman acima de 0,3 (regular) e acima de 0,6 (forte) para $D_{vmáx}$. Com esses resultados torna-se ainda mais evidente a influência das variáveis climáticas $T_{mín}$, $UR_{máx}$, $UR_{mín}$ e $D_{vmáx}$ no contágio e óbitos por Covid-19 no Grande ABC paulista.

Não foram encontrados estudos que realizaram a aplicação do modelo de RLM para a análise conjunta de variáveis climáticas e de poluentes atmosféricos na transmissão e óbitos por Covid-19. Em trabalhos futuros serão aplicados outros testes para poder identificar o problema da condição nula, além de verificar a inclusão e/ou remoção de variáveis para aprimorar e melhorar os modelos.

A partir dos resultados encontrados, ressalta-se que as variáveis climáticas e os poluentes atmosféricos não fornecem uma explicação completa para a propagação do vírus, a qual envolve também fatores comportamentais da população. Torna-se evidente que se faz necessária uma revisão das atuais resoluções e leis brasileiras que tratam dos níveis aceitáveis de emissões de poluentes atmosféricos, para a melhoria da qualidade de vida da população e garantia de uma cidade mais sustentável.

REFERÊNCIAS

AHMADI, M. et al. Investigation of effective climatology parameters on COVID-19 outbreak in Iran. **Science of The Total Environment**, [s.l.], v. 729, 2020.

AULER, A.C. et al. Evidence that high temperatures and intermediate relative humidity might favor the spread of COVID-19 in tropical climate: A case study for the most affected Brazilian cities. **Science of The Total Environment**, [s.l.], v. 729, 2020.

BACKER, J. A.; KLINKENBERG, D.; WALLINGA, J. Incubation period of 2019 novel coronavirus (2019-nCoV) infections among travellers from Wuhan, China 20–28 January 2020. **Euro Surveill**, [s.l.], v. 25, n. 5, 2020.

BILAL et al. Environmental pollution and COVID-19 outbreak: insights from Germany. **Air Quality, Atmosphere & Health**, [s.l.], v. 13, p. 1385–1394, 2020.

CALLEGARI-JACQUES, S. M. **Bioestatística: princípios e aplicações**. 1ª ed. Porto Alegre: Artmed, p. 90, 173-176, 2007.

CHEIN, F. **Introdução aos modelos de regressão linear: um passo inicial para compreensão da econometria como uma ferramenta de avaliação de políticas públicas**. Brasília: Enap, 2019.

CHIQUELTO, J. B. **Padrões atmosféricos associados a concentrações de ozônio troposférico na região metropolitana de São Paulo**. 2008. Dissertação (Mestrado em Geografia Física) - Faculdade de Filosofia, Letras e Ciências Humanas, Universidade de São Paulo, São Paulo, 2008.

CORRÊA, M. P. et al. Are there significant correlations between climate factors and the spread of COVID-19 for less densely populated and less polluted regions? **MedRxiv: The Preprint Server for Health Sciences**, [s.l.], 2021.

CRUZ, G. C. F. Clima e COVID 19: as relações entre a temperatura do ar, radiação solar e os novos casos diários em Ponta Grossa, PR. **Terr@Plural**, Ponta Grossa, v.16, p. 1-15, 2022.

FILHO, F. D. et al. O que Fazer e o que Não Fazer com a Regressão: pressupostos e aplicações do modelo linear de Mínimos Quadrados Ordinários (MQO). **Revista Política Hoje**, [s.l.], v. 20, n. 1, 2011.

FILHO, M. L. O. A Utilização da Regressão Linear Como Ferramenta Estratégica Para a Projeção dos Custos Produção. *In*: CONGRESSO BRASILEIRO DE CUSTOS, 9, 2002, São Paulo. **Anais [...]**. São Paulo, 2002.

GONZAGA, A. C; FREITAS, A. C. V. Análise da relação entre condições meteorológicas, poluição atmosférica e infecções respiratórias virais: o caso COVID-19. **Research, Society and Development**, [s.l.], v. 9, n. 8, 2020.

HAIR, J. F. et al. **Análise Multivariada de Dados**. 6ª ed. São Paulo: Bookman, 2009.

HAN, J. et al. **Data Mining: Concepts and Techniques**. 2ª ed. Illinois: Morgan Kaufmann, 2006.

IBARRA-ESPINOSA, S. et al. Association between COVID-19, mobility and environment in São Paulo, Brazil. **MedRxiv: The Preprint Server for Health Sciences**, [s.l.], 2021.

INSTITUTO BRASILEIRO DE GEOGRAFIA ESTATÍSTICA. **Cidades@**, IBGE, [s.l.], 2020. Disponível em: <https://cidades.ibge.gov.br/>. Acesso em: 08 jul. 2022.

LIRA, S. A. **Análise de Correlação: abordagem teórica e de construção dos coeficientes com aplicações**. 2004. Dissertação (Mestrado em Ciências) - Universidade Federal do Paraná, Curitiba – PR, 2004.

LUO, W. et al. The role of absolute humidity on transmission rates of the COVID-19 outbreak. **MedRxiv: The Preprint Server for Health Sciences**, [s.l.], 2020.

MA, Y. et al. Effects of temperature variation and humidity on the death of COVID-19 in Wuhan, China. **Science of The Total Environment**, [s.l.], v. 724, 2020.

NAKADA, L. Y. K.; URBAN, R. C. COVID-19 pandemic: environmental and social factors influencing the spread of SARS-CoV-2 in São Paulo, Brazil. **Environmental Science and Pollution Research**, [s.l.], v. 28, n. 30, p. 40322–40328, 2021.

OLIVEIRA, E. S. et al. Os impactos ambientais ocasionados pelo isolamento social em decorrência da Covid-19. **Revista Educação Ambiental em Ação**, [s.l.], v. 19, n. 73, 2021.

OLIVEIROS, B. et al. Role of temperature and humidity in the modulation of the doubling time of COVID-19 cases. **MedRxiv: The Preprint Server for Health Sciences**, [s.l.], 2020.

PRATA, D. N. et al. The relationship between (sub)tropical climates and the incidence of COVID-19. **PeerJ**, [s.l.], v. 9, ed. 10655, 2021.

PRATA, D. N.; RODRIGUES, W.; BERMEJO, P. H. Temperature significantly changes COVID-19 transmission in (sub)tropical cities of Brazil. **Science of The Total Environment**, [s.l.], v. 729, 2020.

R CORE TEAM. **R: A language and environment for statistical computing**. R Foundation for Statistical Computing, Vienna, Austria, 2022. Disponível em: <https://www.R-project.org/>. Acesso em: 21 out. 2022.

ROCHA, C. A. A better understanding of air quality resulting from the effects of the 2020 pandemic in a city in the equatorial region (Fortaleza, Brazil). **Environmental Science and Pollution Research**, [s.l.], v. 29, p. 20921–20938, 2022.

SAN MARTIN, M. C.; SAN MARTIN, M. C. Condições atuais das emissões dos poluentes atmosféricos durante a quarentena da Covid-19 e as perspectivas futuras. **Boletim de Conjuntura (BOCA)**, Boa Vista, v. 2, n. 5, p. 85-96, 2020.

SANT'ANNA, A. et al. O estado da qualidade do ar no Brasil. **WRI Brasil**, [s.l.], 2021. Disponível em: <https://www.wribrasil.org.br/publicacoes/o-estado-da-qualidade-do-ar-no-brasil>. Acesso em: 14 nov. 2022.

SILVA, E. C. Grande ABC Paulista: é possível pensar em coesão regional? **Revista de Desenvolvimento Econômico**, [s.l.], v. 15, n. 28, 2013.

SILVA, S. A. R. O impacto do lockdown na qualidade do ar em Campinas e região durante a pandemia de Covid-19 através da análise de dados. **Revista Tecnológica da Fatec Americana**, [s.l.], v. 9, n. 1, 2021.

SPERANDIO, D. G., GOMES, C. H. Variações globais nos níveis de NO₂ durante a pandemia do Covid-19 (Coronavírus): Uma breve discussão sobre geologia e Antropoceno. **Holos**, [s.l.], a. 36, v. 5, p. 1-11, 2020.

WANG, J. et al. High Temperature and High Humidity Reduce the Transmission of COVID-19. **arXiv.org**, [s.l.], 2020.

WEN, M.; CHEN, L. Impacts of regional climate on the COVID-19 pandemic. **MedRxiv: The Preprint Server for Health Sciences**, [s.l.], 2020.