

Crise Recorde de Qualidade do Ar em Porto Velho/RO: Modelagem Preditiva do Índice de Qualidade do Ar (AQI) e Riscos Futuros para a Saúde na Amazônia Brasileira

Record Air Quality Crisis in Porto Velho, Rondônia (Brazil): Predictive Modeling of the Air Quality Index (AQI) and Future Health Risks in the Brazilian Amazon

Crisis Récord de Calidad del Aire en Porto Velho, Rondônia (Brasil): Modelización Predictiva del Índice de Calidad del Aire (AQI) y Riesgos Futuros para la Salud en la Amazonía Brasileña

Grupo temático GT08 - Governo e administração pública para a gestão climática e ambiental

Darcy Ramos da Silva Neto, Universidade Federal de Lavras (UFLA)

RESUMO

A qualidade do ar afeta diretamente a saúde pública e a qualidade de vida. Em agosto de 2024, Porto Velho (RO) registrou a pior qualidade do ar já observada no Brasil, com níveis comparáveis aos de grandes centros da Índia e da China. Este estudo estima e prevê o Índice de Qualidade do Ar (AQI) e analisa sua relação com internações por doenças respiratórias, utilizando série mensal de 2014 a 2024. Para a modelagem preditiva do AQI, aplicaram-se modelos ARIMA e GARCH; o GARCH apresentou melhor ajuste, especialmente ao capturar o pico extremo de agosto de 2024 ($AQI = 430$; $PM_{2.5} = 277,4 \mu g/m^3$). As projeções indicam tendência de piora do AQI nos próximos anos, com potenciais repercussões adversas para a saúde da população. A correlação entre AQI e internações foi positiva, porém fraca, sugerindo que o aumento da poluição pode contribuir para maior demanda hospitalar, ainda que de forma limitada nos dados analisados. Os resultados reforçam a necessidade de políticas públicas preventivas e de mitigação da poluição do ar em Porto Velho.

Palavras-chave: Qualidade do ar; Saúde pública; Modelagem preditiva.

ABSTRACT

Air quality directly affects public health and quality of life. In August 2024, Porto Velho (Rondônia, Brazil) recorded the worst air quality ever observed in the country, reaching levels comparable to major cities in India and China. This study estimates and forecasts the Air Quality Index (AQI) and examines its relationship with hospitalizations for respiratory diseases using monthly data from 2014 to 2024. AQI forecasting was conducted using ARIMA and GARCH time-series models; GARCH provided the best fit, particularly in capturing the extreme peak recorded in August 2024 ($AQI = 430$; $PM_{2.5} = 277.4 \mu g/m^3$). Projections indicate a worsening AQI trend in the coming years, with potentially adverse implications for population health. The correlation between AQI and hospitalizations was positive but weak, suggesting that higher pollution may contribute to increased hospital demand, albeit modestly in the analyzed data. These findings underscore the need for preventive and mitigation public policies to reduce air pollution in Porto Velho.

Keywords: Air quality; Public health; Predictive modeling.

RESUMEN

La calidad del aire afecta directamente la salud pública y la calidad de vida. En agosto de 2024, Porto Velho (Rondônia, Brasil) registró la peor calidad del aire observada hasta la fecha en el país, alcanzando niveles comparables a los de grandes ciudades de India y China. Este estudio estima y pronostica el Índice de Calidad del Aire (AQI) y analiza su relación con las hospitalizaciones por enfermedades respiratorias, utilizando una serie mensual de 2014 a 2024. Para la predicción del AQI se aplicaron modelos de series temporales ARIMA y GARCH; el GARCH mostró el mejor ajuste, especialmente al capturar el pico extremo de agosto de 2024 ($AQI = 430$; $PM_{2.5} = 277,4 \mu g/m^3$). Las proyecciones indican una tendencia de deterioro del AQI en los próximos años, con posibles impactos adversos en la salud de la población. La correlación entre el AQI y las hospitalizaciones fue positiva pero débil, lo que sugiere que el aumento de la contaminación podría contribuir a una mayor demanda hospitalaria, aunque de forma limitada en los datos analizados. Los resultados refuerzan la necesidad de políticas públicas preventivas y de mitigación para reducir la contaminación del aire en Porto Velho.

Palabras clave: Calidad del aire; Salud pública; Modelización predictiva.

1. Introdução

A qualidade do ar é um problema público ambiental de alta relevância, com efeitos diretos sobre a saúde coletiva e consequências para a qualidade de vida e para a demanda por serviços de saúde. Nas últimas décadas, a intensificação da urbanização, de atividades industriais e agropecuárias e o avanço do desmatamento têm contribuído para a deterioração da qualidade do ar em diversas regiões. Na Amazônia brasileira, esses vetores se combinam de forma particularmente sensível, o que torna a gestão ambiental e a proteção à saúde pública desafios recorrentes para governos e administrações locais.

Nesse contexto, Porto Velho, capital do estado de Rondônia, tem enfrentado episódios graves de poluição atmosférica, sobretudo durante a temporada anual de queimadas. Em agosto de 2024, o município registrou um Índice de Qualidade do Ar (AQI) de 430, classificado como “Perigoso” segundo padrões internacionais. Episódios dessa magnitude evidenciam a necessidade de instrumentos de monitoramento, análise e antecipação que apoiem a ação pública em tempo oportuno, favorecendo respostas preventivas e mitigatórias tanto no campo ambiental quanto no campo da saúde.

Diante desse problema, o objetivo geral deste estudo é modelar e prever a evolução do AQI em Porto Velho. Como objetivos específicos, pretende-se: (i) estimar previsões do AQI por meio de modelos estatísticos de séries temporais, com destaque para ARIMA e GARCH, avaliando sua adequação diante de tendências, sazonalidade e eventos extremos; e (ii) examinar a relação entre a dinâmica do AQI e as internações hospitalares por doenças respiratórias no município. A premissa central é que a deterioração da qualidade do ar pode se associar ao aumento das taxas de internação por agravos respiratórios, produzindo riscos relevantes para a população e implicações para o planejamento e a gestão de políticas públicas. Ao gerar previsões e explorar vínculos entre variáveis ambientais e sanitárias, o trabalho contribui para discutir como evidências quantitativas podem apoiar estratégias de vigilância, planejamento e intervenção governamental em períodos críticos.

Trata-se de uma pesquisa empírica baseada em uma série histórica mensal de 2014 a 2024, combinando dados de AQI e indicadores de internações por doenças respiratórias para Porto Velho. Para a modelagem preditiva do AQI, empregam-se modelos ARIMA, adequados para capturar dependência temporal e tendência, e modelos GARCH, apropriados quando há variação de volatilidade ao longo do tempo e ocorrência de choques. Para analisar a relação entre AQI e internações em uma perspectiva dinâmica, utiliza-se um modelo de Vetor Autorregressivo (VAR), que permite considerar interações temporais e defasagens entre as variáveis, reconhecendo que a relação entre poluição atmosférica e saúde pode envolver mecanismos complexos e respostas não imediatas.

Por fim, o estudo reforça a importância do monitoramento contínuo da qualidade do ar e da adoção de intervenções preventivas para mitigar impactos negativos sobre a saúde, especialmente em cidades onde episódios de poluição atingem níveis excepcionalmente elevados em determinados períodos do ano. Nessa direção, políticas públicas orientadas por evidências e sustentadas por capacidades institucionais de resposta tornam-se essenciais para reduzir exposição, proteger grupos vulneráveis e promover um ambiente mais saudável para as gerações futuras.

2. Referencial Teórico e Empírico

A qualidade do ar é um dos fatores ambientais mais estudados nas últimas décadas, devido ao seu impacto direto e significativo na saúde pública e na qualidade de vida das populações. A poluição atmosférica, frequentemente medida através do Índice de Qualidade do Ar (AQI), tem sido associada a um aumento substancial em doenças respiratórias, cardiovasculares e até mesmo transtornos mentais (Dockery et al., 1993; Pope et al., 2002).

Os primeiros estudos sistemáticos sobre a qualidade do ar e seus impactos na saúde remontam à década de 1950. Meade (1952) e Haagen-Smit (1952) foram pioneiros em estabelecer a relação entre níveis elevados de poluentes, como dióxido de enxofre (SO_2) e material particulado (PM), e o aumento da mortalidade nas grandes cidades industriais. Esses estudos abriram caminho para uma maior compreensão dos efeitos da poluição atmosférica, que foi aprofundada por Lave e Seskin (1970) ao quantificarem os custos econômicos da poluição, demonstrando a relação direta entre a degradação da qualidade do ar e o aumento nos gastos com saúde pública e a redução da produtividade laboral.

Nas últimas décadas, o avanço das tecnologias de monitoramento da qualidade do ar e a disponibilidade de grandes volumes de dados permitiram uma análise mais detalhada dos impactos da poluição. Dockery et al. (1993) foram fundamentais ao demonstrar, em cidades dos Estados Unidos, a associação entre exposição crônica

a partículas finas (PM2.5) e a maior mortalidade por doenças cardíacas e pulmonares. Posteriormente, Pope et al. (2002) reforçaram a relação entre exposição a longo prazo a partículas finas e a redução da expectativa de vida.

A relevância global deste tema também se reflete em estudos como o de Jerrett et al. (2009), que demonstraram que pequenas reduções nos níveis de poluição podem levar a ganhos significativos em termos de saúde pública. Zhang et al. (2018), utilizando dados da organização IQAir Earth, mostraram que a poluição atmosférica afeta não só a saúde física, mas também o bem-estar mental, aumentando a incidência de depressão e ansiedade em populações urbanas.

No contexto brasileiro, a Amazônia destaca-se como uma região particularmente vulnerável à poluição atmosférica devido às queimadas sazonais e ao desmatamento, que liberam grandes quantidades de material particulado fino (PM2.5) e outros poluentes. Estudos como o de Artaxo et al. (2013) sublinham os impactos diretos dessas emissões na saúde humana, exacerbando crises respiratórias e aumentando a mortalidade em curto prazo.

Porto Velho, capital de Rondônia, é um caso emblemático, frequentemente apresentando níveis alarmantes de poluição durante a temporada de queimadas. O AQI na cidade atingiu níveis críticos, como em agosto de 2024, quando o índice chegou a 430, considerado "Perigoso" segundo os padrões internacionais (World IQ Ranking, 2024). Essa situação evidencia a necessidade urgente de políticas públicas eficazes e modelos preditivos que possam mitigar os impactos da poluição.

Estudos internacionais também reforçam a importância dessas políticas. Lelieveld et al. (2015) estimaram que mais de três milhões de mortes prematuras por ano podem ser atribuídas à poluição do ar, um número que pode dobrar até 2050 se nenhuma ação for tomada. Burnett e Cohen (2020) discutem a evolução dos modelos de risco relativo, como o Modelo de Resposta de Exposição Integrada (IER), que tem sido amplamente utilizado para estimar a carga global de doenças atribuíveis ao PM2.5. Esses modelos são fundamentais para compreender os riscos à saúde associados à poluição, especialmente em áreas como Porto Velho, onde a situação é agravada por fatores locais como as queimadas.

A evidência de que o PM2.5 é um fator de risco significativo para a mortalidade, mesmo em exposições de curto prazo (Kloog et al., 2013), reforça a urgência de medidas preventivas em Porto Velho. A continuidade das pesquisas nesta área, com ênfase em modelos preditivos e políticas públicas específicas, é essencial para mitigar os impactos da poluição do ar na saúde pública.

3. Dados

Este estudo se baseia na análise da qualidade do ar na cidade de Porto Velho, capital do estado de Rondônia, Brasil, onde foram registrados níveis alarmantes de poluição atmosférica nos últimos dias. Especificamente, no período de 14 a 15 de agosto de 2024, Porto Velho atingiu um Índice de Qualidade do Ar (AQI) de 430, classificado como "Perigoso" segundo os padrões internacionais. Este índice foi acompanhado por uma concentração de material particulado fino (PM2.5) de 277 µg/m³ (correspondendo a 55 vezes maior que a média aceitável), níveis extremamente elevados que representam sérios riscos à saúde pública.


Quadro 1 – Nível de poluição (AQI) encontrados e previsto em sete dias no município de Porto Velho

Dia/mês/ano	AQI	Status
12 de agosto de 2024	158	Insalubre
13 de agosto de 2024	243	Muito Insalubre
14 de agosto de 2024	430	Perigoso
15 de agosto de 2024	404	Perigoso
16 de agosto de 2024	178	Insalubre
17 de agosto de 2024	172	Insalubre
18 de agosto de 2024	171	Insalubre

Nota: World IQ Ranking (Dados do site em Agosto de 2024).

Os dados utilizados neste estudo foram extraídos da plataforma IQAir, que monitora a qualidade do ar em tempo real em diversas localidades ao redor do mundo. A IQAir utiliza uma rede global de estações de monitoramento, combinada com dados de satélite e modelos de previsão para calcular o AQI e as concentrações de PM2.5. As leituras específicas para Porto Velho foram obtidas diretamente das estações de monitoramento localizadas na cidade, complementadas por estimativas modeladas que abrangem áreas onde a cobertura de sensores é limitada. A próxima figura mostra a concentração de PM2.5:

Figura 1 – AQI e Concentração de PM2.5 para o dia 15 de agosto de 2024 em Porto Velho




Nota: World IQ Ranking (Registro do site de 15 de Agosto de 2024).

A concentração de PM2.5, que representa partículas com diâmetro aerodinâmico inferior a 2,5 micrômetros, é um dos principais componentes do AQI. Essas partículas são particularmente perigosas porque podem penetrar profundamente nos pulmões e até mesmo entrar na corrente sanguínea, causando uma variedade de problemas de saúde, incluindo doenças respiratórias e cardiovasculares.

O registro de um AQI de 430 em Porto Velho não é apenas o mais alto já observado na cidade, mas também um dos maiores já documentados no Brasil. Esses níveis extraordinariamente elevados de poluição atmosférica são alarmantes e justificam a necessidade urgente de uma análise aprofundada e sistemática. A pesquisa visa não apenas entender as causas e a dinâmica desses picos extremos de poluição, mas também desenvolver modelos preditivos que possam ajudar na mitigação de seus impactos.

A escolha de Porto Velho como objeto de estudo é estratégica devido ao seu histórico de problemas relacionados à qualidade do ar, especialmente durante a temporada de queimadas na Amazônia. A cidade, frequentemente exposta a altos níveis de poluição devido às queimadas e ao desmatamento, serve como um exemplo crítico das consequências ambientais e de saúde pública que podem resultar da degradação ambiental. A próxima figura mostra um mapa e calor do país para o AQI de 15 de setembro de 2024 e os pontos de queimada encontrados:

Figura 2 – Mapa de calor do Brasil para os AQI e pontos de queimada




Nota: World IQ Ranking (Registro do site de 15 de Agosto de 2024).

Além disso, este estudo busca correlacionar esses picos de AQI com os dados de internações por doenças respiratórias na cidade, fornecendo uma base empírica para políticas públicas voltadas à proteção da saúde da população. A análise dos dados de AQI e PM2.5, combinada com os registros de saúde pública, permitirá uma compreensão mais clara dos riscos e das medidas necessárias para mitigá-los.

Sobre os dados de internações hospitalares, eles foram coletados no TABNET (DATASUS) para o período entre janeiro de 2014 a junho de 2024 (mês a mês), sendo junho o último registro encontrado. Os filtros de coleta foram para morbidade hospitalar do SUS por local de internação para o município de Porto Velho considerando o capítulo CID-10 item *X. Doenças do aparelho respiratório*. O gráfico abaixo apresenta a quantidade de internações por ano:

Figura 3 – Quantitativo de internações por doenças respiratórias entre 2014 e 2024 no município de Porto Velho



Nota: Elaboração própria a partir dos dados do DATASUS (dados de janeiro de 2014 a junho de 2024).

A taxa de internação estava com uma tendência de queda de 2014 a 2021, mas reverteu e iniciou uma escalada positiva a partir de então. No ano de 2023 atingiu seu pico, sendo o segundo maior valor (atrás apenas das internações de 2014). Para 2024, os dados só estão atualizados até junho, então ainda não são valores do ano completo.

4. Metodologia e Estratégia Empírica

Os dados foram organizados em um formato de série temporal, com períodos mensais entre janeiro de 2014 e junho de 2024. Para melhores ajustes do modelo, foram testados os modelos ARIMA, GARCH, modelo de regressão simples e correlação e, por fim, o modelo de vetores autorregressivos (VAR). A estratégia empírica se compreende em duas partes: (i) estimar um modelo de predição de tendência de AQI para o município (ARIMA e GARCH); (ii) relacionar a evolução do AQI com as taxas de internações hospitalares por doença respiratória (MQO e VAR).

4.1 Modelagem e Análise de Séries Temporais

4.1.1 Modelo ARIMA

O modelo ARIMA (AutoRegressive Integrated Moving Average) é uma abordagem estatística amplamente utilizada para modelar séries temporais, especialmente aquelas que apresentam padrões sazonais e não estacionários. O modelo ARIMA pode ser descrito pela seguinte equação:

$$Y_t = c + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \theta_1 \epsilon_{t-1} + \theta_2 \epsilon_{t-2} + \dots + \theta_q \epsilon_{t-q} + \epsilon_t \quad (1)$$

Onde:

Y_t é o valor da série temporal no tempo t .



$\phi_1, \dots, \phi_p$ são os coeficientes autorregressivos.

$\theta_1, \dots, \theta_q$ são os coeficientes da média móvel.

ϵ_t é o termo de erro (ruído branco).

p é a ordem da parte autorregressiva.

q é a ordem da parte de média móvel.

d é o número de diferenças necessárias para tornar a série estacionária.

Neste estudo, foi ajustado automaticamente um modelo ARIMA aos dados de AQI, capturando tanto as tendências sazonais quanto a componente de ruído na série temporal. O modelo foi validado através de uma análise dos resíduos, garantindo a adequação do ajuste.

4.1.2 Modelo GARCH

O modelo GARCH (Generalized Autoregressive Conditional Heteroskedasticity) é utilizado para modelar séries temporais que apresentam variabilidade na volatilidade ao longo do tempo. Esse modelo é particularmente adequado para séries que exibem períodos de alta e baixa volatilidade, como o AQI, que apresenta picos extremos de poluição. O modelo GARCH(1,1) pode ser descrito pelas seguintes equações:

Equação da média (ARMA)

$$Y_t = \mu + \phi Y_{t-1} + \theta \epsilon_{t-1} + \epsilon_t \quad (2)$$

Equação da variância condicional

$$\sigma_t^2 = \alpha_0 + \alpha_1 \epsilon_{t-1}^2 + \beta_1 \sigma_{t-1}^2 \quad (3)$$

Onde:

σ_t^2 é a variância condicional no tempo t .

α_0 é o termo constante da variância.

α_1 é o coeficiente que captura o efeito do choque passado (ϵ_{t-1}^2).

β_1 é o coeficiente que captura o efeito da variância condicional passada.

O modelo GARCH foi ajustado e diferentes distribuições (normal, t-Student, t-Student assimétrica) foram testadas para capturar a estrutura de volatilidade dos dados do AQI. O modelo GARCH apresentou um ajuste superior ao ARIMA para capturar os picos extremos do AQI em Porto Velho.

4.1.3 Análise de Correlação e Regressão

Para investigar a relação entre a qualidade do ar e as internações por problemas respiratórios, foi calculada a correlação entre o AQI e a taxa bruta de internação, considerando apenas os dados completos e não faltantes. Apesar da correlação encontrada ser fraca, ela foi significativa e positiva, sugerindo que o aumento no AQI está associado ao aumento nas internações. Foi também ajustado um modelo de regressão linear simples para estimar o efeito do AQI sobre a taxa de internação:

$$\text{Taxa de internação}_t = \beta_0 + \beta_1 \text{AQI}_t + \epsilon_t \quad (4)$$

Onde:

$\text{Taxa de internação}_t$ é a taxa de internação no tempo t .

AQI_t é o AQI no tempo t .

β_0 é o intercepto.

β_1 é o coeficiente de regressão que captura o efeito do AQI na taxa de internação.

ϵ_t é o termo de erro.

Os resultados deste modelo confirmaram a significância estatística da relação, embora a magnitude do efeito seja moderada.

4.1.4 Modelo VAR

Por fim, foi utilizado o modelo VAR (Vetores Autorregressivos) para capturar as interações dinâmicas entre o AQI e a taxa de internação. O modelo VAR pode ser descrito pela seguinte equação matricial:

$$Y_t = c + A_1 Y_{t-1} + A_2 Y_{t-2} + \dots + A_p Y_{t-p} + \epsilon_t \quad (5)$$

Onde:

Y_t é o vetor de variáveis endógenas (neste caso, AQI e taxa de internação).

$A_1, A_2, \dots, A_p$ são matrizes de coeficientes.

p é a ordem do modelo.

ϵ_t é o vetor de termos de erro.


O modelo VAR foi ajustado para prever tanto o AQI quanto a taxa de internação com base em suas próprias passadas, oferecendo uma visão integrada das interações entre essas variáveis ao longo do tempo. As previsões do modelo VAR foram utilizadas para antecipar as tendências futuras das internações, com base nas previsões do AQI.

A metodologia aplicada neste estudo combina técnicas avançadas de modelagem de séries temporais e análise econométrica para fornecer uma visão detalhada da evolução da qualidade do ar em Porto Velho e seus impactos na saúde pública. Os modelos ARIMA e GARCH capturam diferentes aspectos das variações no AQI, enquanto a análise de correlação, regressão linear e o modelo VAR ajudam a entender e prever os impactos na saúde pública.

5. Resultados

Seguindo a metodologia e estratégia empírica, é necessário verificar a série temporal original e sua composição em componentes principais de tendência, sazonalidade e resíduos. Esse procedimento serve para ver o comportamento geral do AQI ao longo do tempo e é útil para entender melhor os componentes subjacentes da série e para prever futuros comportamentos, considerando tanto a tendência quanto a sazonalidade, conforme imagem abaixo:

Figura 4 – Decomposição da Série Temporal de AQI em tendência, sazonalidade e resíduos



Nota: Elaboração própria a partir da base de dados.

É possível verificar picos significativos (data), especialmente para o aumento em agosto de 2024, refletindo na situação crítica da qualidade do ar em Porto Velho. Na parte de tendência (trend), essa linha captura a tendência de longo prazo na série, mostrando a direção geral dos dados, ignorando flutuações de curto prazo e sazonalidades. A tendência mostra como o AQI aumentou gradualmente ao longo dos anos.

Sobre a sazonalidade (seasonal), ela reflete padrões sazonais repetitivos na série, que ocorrem em intervalos regulares. Essa componente mostra que há uma flutuação sazonal clara, com picos em certos meses do

ARTIGO

ano, como nas épocas de queimada e clima seco entre agosto e outubro. Por fim, os resíduos (remainder) é a parte da série que sobre após a remoção da tendência e sazonalidade. Os resíduos parecem relativamente estáveis, o que indica que a decomposição capturou bem a tendência e a sazonalidade da série.

Conforme a descrição do método e estratégia empírica, segue a tabela de resultados do modelo ARIMA:

Tabela 1 – Resultados do modelo ARIMA para a série temporal de AQI


Modelo ARIMA	Estimação
Coeficientes	
ar1	1.0584 (0.190)
ar2	-0.6450 (0.202)
drift	0.6734 (0.290)
σ^2	484.1
Log likelihood	-522.46
AIC	1052.92
AICc	1053.28
BIC	1063.93
Medidas de Erro o Conjunto de Treinamento	
ME	-0.007
RMSE	20.673
MAE	9.924
MPE	-3.869
MAPE	11.454
MASE	0.6357
ACF1	0.0073

Nota: Elaboração própria a partir da base de dados.
Os valores dentro os parênteses são os desvio-padrão.

O modelo ARIMA com drift (deriva) ajustado para a série temporal do AQI capturou bem a estrutura dos dados, incluindo tanto a tendência linear ascendente (capturada pela deriva), quanto o componente autorregressivo que considera os valores passados do AQI. A presença do drift indica uma tendência ascendente contínua no AQI, o que pode ser motivo de preocupação, especialmente dado o contexto ambiental. Sobre as medidas de erro, dado que são todas relativamente baixas, sugere que o modelo está ajustado adequadamente aos dados. Estes resultados indicam que o modelo é confiável para prever o futuro comportamento do AQI.

A figura abaixo mostra a previsão do AQI usando o modelo ARIMA que foi ajustado à série temporal:

Figura 5 – Previsão do AQI pelo modelo ARIMA



Nota: Elaboração própria a partir da base de dados.

O modelo ARIMA ajustou adequadamente aos dados históricos, com a linha ajustada (vermelha) seguindo próximo à trajetória original (azul claro). Os resultados indicam que o AQI pode continuar aumentando, embora o intervalo de confiança (faixa azul escuro) sugira incerteza (o que é um caso típico após grandes eventos anômalos – como o pico de AQI em agosto de 2024, onde o comportamento futuro pode ser difícil de prever com precisão. A tendência do AQI continua e elevação no futuro, mas existe incerteza sobre a precisão desses índices.

O teste de Ljung-Box é um teste estatístico utilizado para verificar se os resíduos de um modelo de séries temporais são independentes, ou seja, se não há autocorrelação significativa entre eles. Ele é útil para validar a adequação do modelo ARIMA utilizado, conforme tabela abaixo:


Tabela 2 – Resultados do teste de Ljung-Box

Ljung-Box Test	
Q*	9.3487
Graus de liberdade (df)	22
P-valor	0.9913
Lags totais usados	24

Nota: Elaboração própria a partir da base de dados.

Não há autocorrelação nos resíduos até a defasagem considerada, ou seja, os resíduos são independentes e não apresentam padrões que o modelo ARIMA não capturou. Neste caso, os resíduos podem ser considerados como ruído branco, o que é desejável, indicando que o modelo capturou bem a estrutura da série. A partir deste resultado, é importante analisar como o ruído branco está se comportando, na figura abaixo:

Figura 6 – Análise dos Resíduos do Modelo ARIMA



Nota: Elaboração própria a partir da base de dados.

A figura acima apresenta os resíduos ao longo do tempo, a imagem inferior esquerda é a autocorrelação dos resíduos (ACF) e a da direita é um histograma dos resíduos com a curva de densidade. Como pode ser visto, os resíduos se comportam bem ao longo da série, mas sofre o pico em agosto de 2024 (devido ao AQI anômalo). Sobre a ACF, ele está dentro dos limites do intervalo de confiança, capturando as dependências temporais, embora o modelo ainda possa ser mais refinado futuramente com a inclusão de outras variáveis. Uma limitação observada é que a distribuição dos resíduos não seguem uma distribuição normal (cauda direita acentuada), mas é esperado dado o efeito do AQI atual.

Dado o grande pico do AQI em agosto de 2024, é necessário considerar modelos mais robustos a outliers ou que capturem melhor eventos externos, como o modelo de heterocedasticidade condicional – GARCH, que já havia sido considerado na estratégia empírica dado os valores anômalos do AQI no final da série.

O modelo GARCH (Generalized Autoregressive Conditional Heteroskedasticity) é uma escolha apropriada quando se está lidando com séries temporais que têm variância não constante ao longo do tempo, como é o caso extremo de agosto de 2024. O GARCH modela a volatilidade no tempo, o que torna útil capturar períodos de alta e baixa variabilidade, como observado no final da série. A tabela abaixo apresenta os resultados do modelo GARCH:

Tabela 3 – Resultados do Modelo GARCH

Parâmetro	Estimação	D.P.	D.P. Robusto	Estat. t	P-valor
μ	82.958	7.66	8.076	10.829	0.000***
$ar1$	1.564	0.090	0.115	17.325	0.000***
$ar2$	-0.869	0.090	0.098	-9.382	0.000***
Ω	29.883	22.525	57.294	1.326	0.184
α_1	0.074	0.019	0.028	3.787	0.000***
β_1	0.924	0.012	0.020	74.217	0.000***
LogLikelihood			-615.784		
Akaike (AIC)			9.715		
Bayes (BIC)			9.849		
Shibata			9.711		
Hannan-Quinn			9.769		

Nota: Elaboração própria a partir da base de dados. Os símbolos *, ** e *** são, respectivamente, significâncias de 10%, 5% e 1%.

A soma de α_1 e β_1 é muito próxima a 1, indicando uma alta persistência da volatilidade. Isso indica que choques de volatilidade podem ter efeitos prolongados, o que é consistente com a alta volatilidade do AQI observado em 2024. Todos os parâmetros estimados deram significância estatística a 1%, exceto o Ω , sugerindo que o termo constante na equação de variância condicional pode não ser necessário.


Sobre os critérios de informação (AIC, BIC, Shibata e Hannan-Quinn), eles ajudam a comparar diferentes modelos. Menores valores destes critérios são preferidos por indicar um melhor equilíbrio entre o ajuste do modelo e a complexidade. Esses resultados podem ser comparados com outros modelos para avaliar qual ajusta melhor os dados.

Os testes de adequação, estabilidade e viés referentes a estes resultados do modelo GARCH (apêndice A) mostram que não há autocorrelação significativa nos resíduos (p-valor alto), o que é um bom sinal de que o modelo capturou as dependências temporais nos dados. Também, a verificação de autocorrelação nos resíduos quadrados com p-valores altos indicam que não há evidência de autocorrelação na variância dos resíduos, o que sugere que o modelo GARCH estimado tenha ajustado adequadamente a heterocedasticidade dos dados. Apesar de uma leve estabilidade em Ω , o modelo é estável em sua maior parte.

Sobre a adequação geral, o modelo GARCH ajustado parece capturar bem a volatilidade de AQI, especialmente em torno do pico de agosto de 2024. A maioria dos testes de diagnóstico mostra que o modelo é adequado, com resíduos sem autocorrelação e pouca evidência de efeitos ARCH não capturados. A título de informação, também foram testados os modelos GARCH com distribuição t-student e distribuição assimétrica t-student para a compreensão do pico negativo do AQI em 2025, mas estes modelos não capturaram diferenças significativas nos resultados e foram removidos do texto.

Com base nos resultados encontrados, foi estimada a variância condicional ao longo do tempo usando o GARCH. Ela é uma medida de volatilidade que o modelo prevê a série temporal ao longo do tempo.

Figura 7 – Previsão da Variância Condicional com o GARCH




Nota: Elaboração própria a partir da base de dados.

A linha vermelha mostra uma tendência ascendente na variância condicional prevista ao longo do tempo. Isso indica que o modelo GARCH espera que a volatilidade da série temporal aumente de maneira contínua no tempo, ou seja, conforme avançamos para 2025, o modelo prevê que o AQI pode se tornar ainda mais incerto e volátil, com picos anômalos mais constantes e uma maior dispersão esperada em torno da média. O modelo prevê que, a partir do pico de AQI de agosto de 2024, novos períodos anômalos podem surgir com mais frequência. Contudo, é necessário considerar que essas estimações é um valor modelado e não uma medida observada diretamente. Se a volatilidade continuar a crescer, isso pode levar a desafios na previsão e na estabilidade do modelo.

A partir dos resultados apresentados, serão inseridos os dados de internação hospitalar no município de Porto Velho (para o mesmo período da série AQI) para verificar relações entre eles. A figura abaixo apresenta os valores de AQI e as internações (absoluto e taxa por 100 mil habitantes) para o município de Porto Velho de 2014 a 2024:

Figura 8 – Valores de AQI e internações e taxas por 100 mil habitantes de 2014 a 2024



Nota: Elaboração própria a partir da base de dados.

As figuras apresentam (figura 8), respectivamente, a evolução do AQI por mês com o número absoluto de internações por doenças respiratórias e também pela taxa e internação por cem mil habitantes com os dados do CENSO e as estimativas do IBGE. Esses resultados apresentam tanto uma evolução positiva no AQI quanto uma redução das internações (absoluto e taxa) até 2021 e um processo de aumento novamente. Conforme os dados apresentados, o AQI nas datas de 14 e 15 de agosto de 2024 atingiu, respectivamente, os valores de 430 e 404, sendo considerados os maiores da série histórica brasileira.

O primeiro teste foi uma regressão linear simples para verificar a força e a direção da relação linear entre as variáveis. A correlação entre AQI e a taxa bruta de internação por doenças respiratórias foi significativa a 5% no teste e hipótese e apresentou um valor de correlação positiva de 0.2044. Embora seja considerada uma correlação linear fraca, ainda é positiva e significativa. Contudo, a relação entre o AQI e as internações pode não ser linear ou dinâmica, sendo necessário considerar outros modelos.

A tabela abaixo faz uma estimação a partir do modelo de Vetor Autorregressivo (VAR). Apesar do modelo VAR ser linear, cada variável é modelada como uma função linear de suas próprias defasagens e das defasagens de outras variáveis, importante para compreender as relações dinâmicas entre as variáveis, o que um modelo de regressão simples não consegue capturar.

Tabela 4 – Estimação entre AQI e internações hospitalares pelo Modelo VAR

Equação	Parâmetro	Estimação	D.P.	Estat. t	P-valor
AQI	AQI_def1	1.468	0.060	24.315	0.000***
	Tx_intern_def1	0.363	0.213	1.704	0.091*
	AQI_def2	-0.740	0.059	-12.416	0.000***
	Tx_intern_def2	-0.220	0.214	-1.031	0.304
	Constante	21.988	5.400	4.071	0.000***
Tx_internação	AQI_def1	-0.019	0.025	-0.025	0.435
	Tx_intern_def1	0.618	0.089	6.919	0.000***
	AQI_def2	-0.019	0.024	-0.800	0.425
	Tx_intern_def2	0.251	0.089	2.798	0.006**
	Constante	8.172	2.260	3.616	0.000***
LogLikelihood		-973.561			
Multiple R-Squared (AQI)	0.883			Multiple R-Squared (Tx_int)	0.701
Adjusted R-Squared (AQI)	0.879			Adjusted R-Squared (Tx_int)	0.691
F-statistic (AQI)	223.8			F-statistic (Tx_int)	69.25
P-valor (AQI)	0.000***			P-valor (Tx_int)	0.000***
Raízes do Polinômio característico		0.883; 0.872; 0.872; 0.282			

Nota: Elaboração própria a partir da base de dados. Os símbolos *, ** e *** são, respectivamente, significâncias de 10%, 5% e 1%.


Na equação de AQI, os valores de AQI defasados de períodos passados (AQI_def1 e AQI_def2) possuem coeficientes altamente significativos, o que indica que valores anteriores de AQI são fortes preditores do valor atual. A taxa de internação no primeiro período defasado (Tx_intern_def1) tem um coeficiente positivo e significativo a 10%, sugerindo uma possível associação com o AQI atual, apesar de fraca.

Na equação da taxa e internação, o primeiro período defasado (Tx_intern_def1) também é significativo, indicando que valores anteriores à taxa de internação são bons preditores dos valores atuais. Todos os valores das raízes dos polinômios característicos estão dentro do círculo unitário, o que sugere que o modelo é estacionário, ou seja, os processos não explodem ao longo do tempo.

No geral, o modelo VAR mostrou que o AQI é fortemente influenciado por seus próprios valores passados, mas apenas marginalmente pelas internações passadas. Esse resultado pode funcionar como robustez o que foi feito anteriormente, considerando uma relação positiva entre AQI e as internações, mesmo que fraca. Isso sugere que existem outros fatores que são preditores das internações hospitalares que não estão sendo considerados neste estudo. Apesar disso, a relação positiva e fraca do AQI sobre as internações é um resultado importante que

deve ser considerado em análises futuras, bem como estratégias de melhoria da qualidade do ar e ações de políticas públicas. A figura 9 representa a previsão dos valores de AQI e as internações futuramente.

Figura 9 – Previsão da variação do AQI e da taxa de internação por doenças respiratórias



Nota: Elaboração própria a partir da base de dados.

A imagem superior se refere à previsão dos valores de AQI ao longo do tempo. É possível notar que os valores de AQI mostram uma certa sazonalidade, com padrões repetitivos ao longo do tempo e a previsão sugere que essa tendência e aumento continuará acontecendo. Na imagem inferior, temos a previsão da taxa e internação. Neste caso, a variação é mais irregular ao longo do tempo, o que sugere um aumento esperado, porém menor. Em ambos os casos, a incerteza ainda é grande pelo fato do AQI extremamente elevado no final da série de tempo.

6. Discussão

6.1 Dinâmica do AQI, sazonalidade e utilidade da previsão

Os resultados indicam que a série de AQI em Porto Velho apresenta tendência de elevação e sazonalidade recorrente, com picos concentrados em períodos compatíveis com a estação seca e maior ocorrência de queimadas. Do ponto de vista substantivo, isso é importante porque desloca a qualidade do ar de um fenômeno meramente episódico para um risco com regularidade temporal, o que permite planejamento preventivo. Evidências epidemiológicas e de saúde ambiental mostram que tanto a exposição crônica quanto variações de curto prazo em poluentes atmosféricos estão associadas a desfechos adversos, inclusive respiratórios, e que diretrizes de qualidade do ar enfatizam a necessidade de monitoramento e comunicação de risco baseada em evidências (Pope & Dockery, 2006; Brook et al., 2010; World Health Organization, 2021).

Assim, a capacidade preditiva obtida com ARIMA (com drift capturando tendência ascendente) é especialmente relevante como instrumento de apoio ao planejamento público, pois permite antecipar janelas de maior risco e orientar medidas de preparação (por exemplo, protocolos de alerta, intensificação de vigilância e ações de mitigação em meses críticos), mesmo reconhecendo a incerteza inerente a choques extremos (World Health Organization, 2021).

6.2 Choques extremos, volatilidade e gestão sob incerteza

O pico observado ao final da série (agosto de 2024) evidencia que a trajetória do AQI não se resume a flutuações regulares: há eventos extremos capazes de elevar abruptamente o nível do índice e, sobretudo, aumentar a incerteza sobre o comportamento futuro. Nesse sentido, a modelagem com GARCH é coerente com séries em que a variância é não constante e “aglomerada” no tempo, permitindo capturar períodos de maior e menor volatilidade. A alta persistência estimada na volatilidade ($\alpha_1 + \beta_1$ próxima de 1) sugere que choques podem produzir efeitos prolongados na incerteza, o que tem leitura direta para a administração pública: além de “prever o nível”, é crucial monitorar o regime de volatilidade para definir quando acionar respostas mais intensas.

A literatura sobre episódios de fumaça e incêndios florestais destaca que eventos agudos podem gerar impactos relevantes sobre saúde e demanda por serviços, exigindo protocolos de contingência e comunicação rápida, frequentemente sob condições de incerteza e rápida mudança (Johnston et al., 2012; Reid et al., 2016). Assim, o componente de volatilidade não é apenas um detalhe estatístico: ele pode ser interpretado como um indicador para planejamento de prontidão, definindo gatilhos de ação e escalonamento de resposta quando a instabilidade aumenta (World Health Organization, 2021).

6.3 Associação com internações e contribuição para políticas públicas e gestão

Na segunda parte do estudo, a correlação entre AQI e taxa de internações respiratórias é positiva e significativa, porém fraca, e o VAR sugere que o AQI é fortemente explicado por suas próprias defasagens, enquanto a contribuição das internações defasadas para o AQI é marginal — padrão compatível com a direção causal esperada (poluição → saúde). Uma associação fraca, contudo, não implica irrelevância: a literatura de séries temporais em epidemiologia ambiental encontra efeitos estatisticamente detectáveis, mas muitas vezes modestos, de poluentes sobre admissões hospitalares, variando por local, composição dos poluentes, características populacionais e qualidade de mensuração de exposição (Dominici et al., 2006; Atkinson et al., 2014).

Além disso, quando a exposição é representada por medidas agregadas (como um índice) e quando há heterogeneidade espacial relevante dentro do município, o erro de mensuração pode atenuar estimativas, reduzindo a magnitude observada (Kloog et al., 2013). Em paralelo, estudos de carga global e funções de risco para PM_{2.5} reforçam que a relação entre poluição e desfechos é complexa e pode exigir ajustes contextuais, especialmente em cenários de alta exposição e fontes específicas como fumaça de queimadas (Burnett et al., 2014; Burnett et al., 2018; Burnett & Cohen, 2020).

Dessa forma, a principal contribuição aplicada do trabalho está menos em afirmar uma relação linear “forte” e mais em oferecer uma base quantitativa integrada para organização da resposta pública: (i) a previsão do AQI, sustentada por tendência e sazonalidade, apoia ações preventivas e planejamento sazonal; (ii) o diagnóstico de volatilidade e persistência do risco apoia desenho de planos de contingência e gatilhos de escalonamento; e (iii) a evidência de associação positiva, mesmo que modesta, reforça a necessidade de coordenação entre políticas ambientais e estratégias de vigilância em saúde, conforme orientações internacionais de proteção à saúde frente à poluição do ar (World Health Organization, 2021).

Em síntese, os resultados sustentam uma abordagem de gestão baseada em evidências para reduzir exposição, mitigar impactos e orientar medidas de proteção em períodos críticos, sem depender exclusivamente de um único parâmetro estatístico como critério para ação (Pope & Dockery, 2006; Atkinson et al., 2014; World Health Organization, 2021).

7. Considerações Finais

As estimativas e previsões realizadas indicam uma tendência preocupante de aumento do Índice de Qualidade do Ar (AQI) em Porto Velho, sugerindo piora das condições atmosféricas no médio prazo. Esse resultado é particularmente relevante para a saúde pública, considerando o histórico de episódios críticos associados ao período seco e às queimadas no município. Em paralelo, a análise empírica apontou que a relação entre o AQI e a taxa de internações por doenças respiratórias é positiva, porém fraca. Assim, embora a deterioração do AQI represente um risco plausível à saúde, os dados e os modelos empregados não indicam uma associação linear forte o suficiente para explicar, isoladamente, a variação das internações ao longo do período analisado.

A magnitude reduzida dessa associação sugere que as internações respiratórias respondem a um conjunto mais amplo de determinantes, além do AQI. Entre eles, destacam-se a sazonalidade de doenças respiratórias (com picos em períodos específicos do ano), condições socioeconômicas e barreiras de acesso ao cuidado, campanhas e políticas de saúde pública (como vacinação), variáveis meteorológicas (umidade, temperatura e precipitação) e diferenças na disponibilidade e qualidade dos serviços de saúde. Esses fatores podem atuar simultaneamente, interagir entre si e produzir efeitos com defasagens temporais, o que dificulta que uma medida agregada como o AQI capture plenamente os mecanismos que levam ao adoecimento e à hospitalização.

Apesar disso, a tendência de piora na qualidade do ar não deve ser relativizada. A poluição atmosférica é um fator de risco relevante e pode produzir efeitos adversos diretos, cumulativos e/ou interativos com outras vulnerabilidades, afetando principalmente grupos mais sensíveis e ampliando pressões sobre o sistema de saúde em períodos críticos. Dessa forma, o monitoramento contínuo do AQI e a adoção de ações preventivas para reduzir

a exposição populacional permanecem medidas prioritárias, especialmente durante a estação seca e em momentos de maior risco de eventos extremos.

Como agenda de continuidade, recomenda-se ampliar o conjunto de variáveis incorporadas às análises, com inclusão de indicadores climáticos e meteorológicos, variáveis sociodemográficas e informações sobre políticas e serviços de saúde, de modo a reduzir omissões relevantes e melhorar a capacidade explicativa dos modelos. Também é desejável avançar na investigação de causalidade por meio de especificações mais flexíveis (por exemplo, modelos com defasagens distribuídas, não linearidades e controles adicionais) e, quando viável, por estratégias de identificação baseadas em choques exógenos ou experimentos naturais. Ademais, a incorporação explícita da sazonalidade e a melhoria da mensuração de exposição (incluindo, quando possível, poluentes específicos e maior granularidade espacial) podem produzir estimativas mais informativas sobre os mecanismos pelos quais episódios de piora do AQI se relacionam a desfechos respiratórios.

Por fim, este estudo contribui para a Administração Pública ao demonstrar como ferramentas de modelagem e previsão podem apoiar decisões em gestão ambiental e sanitária, especialmente em contextos de queimadas e risco climático. As evidências produzidas podem subsidiar a estruturação de rotinas de monitoramento e alerta precoce, o planejamento sazonal de ações preventivas e a coordenação intersetorial entre políticas ambientais e de saúde, com foco na proteção de grupos vulneráveis e na preparação do sistema de saúde para períodos críticos. O principal público-alvo do trabalho inclui gestores municipais e estaduais das áreas de meio ambiente, saúde e defesa civil, bem como equipes de vigilância em saúde e serviços de saúde responsáveis pela organização da resposta e mitigação de impactos associados à poluição do ar.

8. Referências bibliográficas

- Atkinson, R. W., Kang, S., Anderson, H. R., Mills, I. C., & Walton, H. A. (2014). Epidemiological time series studies of PM_{2.5} and daily mortality and hospital admissions: A systematic review and meta-analysis. *Thorax*, 69(7), 660-665. <https://doi.org/10.1136/thoraxjnl-2013-204492>
- Artaxo, P., Rizzo, L. V., Brito, J. F., Barbosa, H. M. J., Arana, A., Sena, E. T., ... & Bastos, W. R. (2013). Atmospheric aerosols in Amazonia and land use change: From natural biogenic to biomass burning conditions. *Faraday Discussions*, 165, 203-235. <https://doi.org/10.1039/C3FD00052D>
- Brook, R. D., Rajagopalan, S., Pope, C. A., III, Brook, J. R., Bhatnagar, A., Diez-Roux, A. V., Holguin, F., Hong, Y., Luepker, R. V., Mittleman, M. A., Peters, A., Siscovick, D., Smith, S. C., Jr., Whitsel, L., Kaufman, J. D., & American Heart Association Council on Epidemiology and Prevention, Council on the Kidney in Cardiovascular Disease, and Council on Nutrition, Physical Activity and Metabolism. (2010). Particulate matter air pollution and cardiovascular disease: An update to the scientific statement from the American Heart Association. *Circulation*, 121(21), 2331-2378. <https://doi.org/10.1161/CIR.0b013e3181dbecel>
- Burnett, R., Chen, H., Szyszkowicz, M., Fann, N., Hubbell, B., Pope, C. A., Apte, J. S., Brauer, M., Cohen, A., Weichenthal, S., Coggins, J., Di, Q., Brunekreef, B., Frostad, J., Lim, S. S., Kan, H., Walker, K. D., Thurston, G. D., Hayes, R. B., ... Spadaro, J. V. (2018). Global estimates of mortality associated with long-term exposure to outdoor fine particulate matter. *Proceedings of the National Academy of Sciences of the United States of America*, 115(38), 9592-9597. <https://doi.org/10.1073/pnas.1803222115>
- Burnett, R. T., Pope, C. A., III, Ezzati, M., Olives, C., Lim, S. S., Mehta, S., Shin, H. H., Singh, G., Hubbell, B., Brauer, M., Anderson, H. R., Smith, K. R., Balmes, J. R., Bruce, N. G., Kan, H., Laden, F., Prüss-Ustün, A., Turner, M. C., Gapstur, S. M., ... Cohen, A. (2014). An integrated risk function for estimating the global burden of disease attributable to ambient fine particulate matter exposure. *Environmental Health Perspectives*, 122(4), 397-403. <https://doi.org/10.1289/ehp.1307049>
- Burnett, R., & Cohen, A. (2020). Relative risk functions for estimating excess mortality attributable to outdoor PM_{2.5} air pollution: Evolution and state-of-the-art. *Atmosphere*, 11(6), 589. <https://doi.org/10.3390/atmos11060589>

ARTIGO

- Dockery, D. W., Pope, C. A., Xu, X., Spengler, J. D., Ware, J. H., Fay, M. E., ... & Speizer, F. E. (1993). An association between air pollution and mortality in six U.S. cities. *New England Journal of Medicine*, 329(24), 1753-1759. <https://doi.org/10.1056/NEJM199312093292401>
- Dominici, F., Peng, R. D., Bell, M. L., Pham, L., McDermott, A., Zeger, S. L., & Samet, J. M. (2006). Fine particulate air pollution and hospital admission for cardiovascular and respiratory diseases. *JAMA*, 295(10), 1127-1134. <https://doi.org/10.1001/jama.295.10.1127>
- Haagen-Smit, A. J. (1952). The chemistry and physiology of Los Angeles smog. *Industrial & Engineering Chemistry*, 44(6), 1342-1346. <https://doi.org/10.1021/ie50510a045>
- Jerrett, M., Burnett, R. T., Pope, C. A., Ito, K., Thurston, G., Krewski, D., ... & Thun, M. (2009). Long-term ozone exposure and mortality. *New England Journal of Medicine*, 360(11), 1085-1095. <https://doi.org/10.1056/NEJMoa0803894>
- Johnston, F. H., Henderson, S. B., Chen, Y., Randerson, J. T., Marlier, M., DeFries, R. S., Kinney, P., Bowman, D. M. J. S., & Brauer, M. (2012). Estimated global mortality attributable to smoke from landscape fires. *Environmental Health Perspectives*, 120(5), 695-701. <https://doi.org/10.1289/ehp.1104422>
- Kloog, I., Ridgway, B., Koutrakis, P., Coull, B. A., & Schwartz, J. D. (2013). Long- and short-term exposure to PM_{2.5} and mortality: Using novel exposure models. *Epidemiology*, 24(4), 555-561. <https://doi.org/10.1097/EDE.0b013e318294beaa>
- Lave, L. B., & Seskin, E. P. (1970). Air pollution and human health. *Science*, 169(3947), 723-733. <https://doi.org/10.1126/science.169.3947.723>
- Lelieveld, J., Evans, J. S., Fnais, M., Giannadaki, D., & Pozzer, A. (2015). The contribution of outdoor air pollution sources to premature mortality on a global scale. *Nature*, 525(7569), 367-371. <https://doi.org/10.1038/nature15371>
- Meade, P. C. (1952). "Air Pollution and Its Impact on Human Health." *Journal of Public Health*.
- Ministério da Saúde. (n.d.). Sistema de Informações Hospitalares do SUS (SIH/SUS). Departamento de Informática do SUS (DataSUS). Recuperado em 15 de agosto de 2024, de <http://tabnet.datasus.gov.br/cgi/tabcgi.exe?sih/cnv/niro.def>
- Pope, C. A., Burnett, R. T., Thun, M. J., Calle, E. E., Krewski, D., Ito, K., & Thurston, G. D. (2002). Lung cancer, cardiopulmonary mortality, and long-term exposure to fine particulate air pollution. *Journal of the American Medical Association*, 287(9), 1132-1141. <https://doi.org/10.1001/jama.287.9.1132>
- Pope, C. A., III, & Dockery, D. W. (2006). Health effects of fine particulate air pollution: Lines that connect. *Journal of the Air & Waste Management Association*, 56(6), 709-742. <https://doi.org/10.1080/10473289.2006.10464485>
- Reid, C. E., Brauer, M., Johnston, F. H., Jerrett, M., Balmes, J. R., & Elliott, C. T. (2016). Critical review of health impacts of wildfire smoke exposure. *Environmental Health Perspectives*, 124(9), 1334-1343. <https://doi.org/10.1289/ehp.1409277>
- Zhang, X., Chen, X., Zhang, X., & Wang, L. (2018). The psychological impact of air pollution in urban China: Evidence from the pollutant standard index. *Journal of Environmental Economics and Management*, 92, 353-375. <https://doi.org/10.1016/j.jeem.2018.10.001>
- World Health Organization. (2021). *WHO global air quality guidelines: Particulate matter (PM_{2.5} and PM₁₀), ozone, nitrogen dioxide, sulfur dioxide and carbon monoxide*. World Health Organization. <https://www.who.int/publications/i/item/9789240034228>

World IQ Ranking. (2024). *Air quality data for August 2024*. Recuperado de <https://www.iqair.com/air-quality-map>

Apêndice A

Testes de Adequação – Modelo GARCH

Teste	Lag	Estatística	P-valor
Ljung-Box Residuals	1	0.028	0.865
Ljung-Box Residuals	5	2.087	0.939
Ljung-Box Residuals	9	5.410	0.365
Ljung-Box Squared Residuals	1	0.001	0.980
Ljung-Box Squared Residuals	5	0.014	1.000
Ljung-Box Squared Residuals	9	0.040	1.000
Weighted ARCH LM Test	Lag[3]	0.006	0.934
Weighted ARCH LM Test	Lag[5]	0.011	0.999
Weighted ARCH LM Test	Lag[7]	0.019	1.000

Nota: Elaboração própria a partir da base de dados.

Teste de Estabilidade e Viés – Modelo GARCH

Teste	Estatística	Valor
Nyblom Stability Test	Joint Statistic	22.111
um	0.641	-
ar1	0.035	-
ar2	0.104	-
Ω	0.384	-
α_1	0.123	-
β_1	0.222	-
Sign Bias Test		
Sign Bias	0.764	0.446
Negative Sign Bias	0.182	0.855
Positive Sign Bias	0.241	0.809
Joint Effect	1.080	0.781

Nota: Elaboração própria a partir da base de dados.