



**UNIVERSIDADE ESTADUAL DA PARAÍBA  
CAMPUS I  
CENTRO DE CIÊNCIAS E TECNOLOGIA  
DEPARTAMENTO DE ESTATÍSTICA  
CURSO DE BACHARELADO EM ESTATÍSTICA**

**VICENTE JOSÉ DA SILVA NETO**

**Modelagem em Séries Temporais nos Focos de Queimadas na Região do Sertão e  
Precipitações na Região Metropolitana do Estado de Pernambuco.**

**Campina Grande - PB**

**2022**

VICENTE JOSÉ DA SILVA NETO

**MODELAGEM EM SÉRIES TEMPORAIS NOS FOCOS DE QUEIMADAS NA  
REGIÃO DO SERTÃO E PRECIPITAÇÕES NA REGIÃO METROPOLITANA DO  
ESTADO DE PERNAMBUCO.**

Trabalho de Conclusão de Curso apresentado ao curso de Bacharelado em Estatística do Departamento de Estatística do Centro de Ciências e Tecnologia da Universidade Estadual da Paraíba, como requisito parcial à obtenção do título de Bacharel em Estatística.

**Orientador:** Prof. Dr. Ricardo Alves de Olinda

**CAMPINA GRANDE - PB**

**2022**

É expressamente proibido a comercialização deste documento, tanto na forma impressa como eletrônica. Sua reprodução total ou parcial é permitida exclusivamente para fins acadêmicos e científicos, desde que na reprodução figure a identificação do autor, título, instituição e ano do trabalho.

S586m Silva Neto, Vicente Jose da.  
Modelagem em séries temporais nos focos de queimadas na região do sertão e precipitações na região metropolitana do estado de Pernambuco [manuscrito] / Vicente Jose da Silva Neto. - 2022.  
37 p. : il. colorido.

Digitado.

Trabalho de Conclusão de Curso (Graduação em Estatística) - Universidade Estadual da Paraíba, Centro de Ciências e Tecnologia, 2022.

"Orientação : Prof. Dr. Ricardo Alves de Olinda, Coordenação do Curso de Estatística - CCT."

1. Precipitação. 2. Focos de queimadas. 3. Séries temporais. 4. Meio ambiente. I. Título

21. ed. CDD 519.5

VICENTE JOSÉ DA SILVA NETO

MODELAGEM EM SÉRIES TEMPORAIS NOS FOCOS DE QUEIMADAS NA REGIÃO DO SERTÃO E PRECIPITAÇÕES NA REGIÃO METROPOLITANA DO ESTADO DE PERNAMBUCO.

Trabalho de Conclusão de Curso apresentado ao curso de Bacharelado em Estatística do Departamento de Estatística do Centro de Ciências e Tecnologia da Universidade Estadual da Paraíba, como requisito parcial à obtenção do título de Bacharel em Estatística.

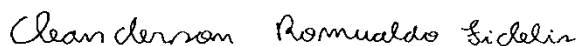
Trabalho aprovado em 18 de Novembro de 2022.

**BANCA EXAMINADORA**



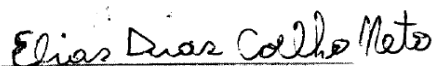
---

Prof. Dr. Ricardo Alves de Olinda (Orientador)  
Universidade Estadual da Paraíba (UEPB)



---

Prof. Me. Cleanderson Romualdo Fidelis  
Universidade Estadual da Paraíba (UEPB)



---

Prof. Dr. Elias Dias Coelho Neto  
Universidade Estadual da Paraíba (UEPB)

A Deus, minha familia, meus professores Dr.  
Ricardo Olinda e Me. Cleanderson Fidelis.

## **AGRADECIMENTOS**

Gostaria de agradecer primeiramente a Deus, minha fonte de energia para chegar até aqui, Aos meus pais Luiz Carlos e Maria Suzicleide que sempre me deram força para estar em Campina Grande, meus dois irmãos, Carlinhos e Silas que sempre tiveram comigo, minha família, que acreditaram e nunca deixaram desistir deste sonho.

Aos Professores, orientador Dr. Ricardo Alves de Olinda e Me. Cleanderson Romualdo Fidelis pelos conhecimentos adquirido, pelo crescimento profissional e principalmente pela paciência.

Aos amigos da UFCG, Helter, Gabriel, Danilo e Paulo Ricardo que durante o período que passei por lá, me ajudaram bastante.

Aos amigos que dividiram apartamento, Lucas, Dimas, Pedro e Higor Felix, Mailson e Robson. Aos amigos do Curso de Estatística e da UEPB, Jéssica Cristina, Jeysiane, Pablo, Fagna, Suziane, Andrezza, Elizandra, Welligton, Adilson e Samuel Smith, nesse longo tempo no curso.

Aos amigos que tive o prazer de passar um ano trabalhando em Paudalho-PE, membros da Escola Municipal Manoel da Rosa, nas pessoas de Marcia Candido, Marcos Kendji, Geysa Correia, Sthelamarys, Dsandro, Edsonia, Tiago, Edson, Amanda, Leonardo Oliveira e todos que fazem parte da escola.

Aos amigos que conquistei durante o estágio no Supermercado Rede Compras, Manoel, Danilo, Thiago, Krislaine, Matheus e todos da Inteligência de Mercado e E-Commerce. Aos amigos do Prédio Edifício Sebastião Severo, Marquinhos, Mane do bar da ladeira, Neca, Saulo, Airton e entre outros.

Aos amigos de farra e das cavalgadas, Lucas da Midia, Luan do bolo, Nathan, Bruno Queixo, Marcelinho, Cristiano, Marllon, James e toda equipe macapazinho que sempre deu uma força e estiveram junto comigo nesta luta.

Aos amigos que conquistei na política, na pessoa do meu vereador Ricardo de Siomara, Vice-Prefeito Giva, Prefeito Paulo Barbosa (Paquinha), Nosso Deputado Estadual Dr. Antônio Moraes, Novinho Gonçalo, Marcos Beira Rio, Zé Dias, Adriano da Fruta que já faz parte da minha família.

E por último, não menos importante, gostaria de agradecer a todos os meus professores da graduação e coordenação. Obrigado por vocês passarem um pouco de seus conhecimentos. Muito obrigado!

“Rendam graças ao senhor, pois ele é bom; o seu amor dura para sempre”.

(Crônicas 16:34)

“A estatística é um ótimo recurso humano para encontrar a prioridade e o tempo é o recurso natural que não falha em revelar a verdade .”

(NeQJau)

## RESUMO

Pesquisadores das áreas de Ciências Climáticas e Meteorologia, observaram que a região metropolitana e a região do sertão, situados no estado de Pernambuco, sofrem com a falta de planejamento e políticas públicas, enquanto o sertão sofre com ondas elevadas de calor, poucas chuvas e estiagem, a região metropolitana sofre com excesso de chuvas e os transtornos que ela causa devidos os problemas na infraestrutura dos municípios. Neste sentido, o aquecimento global, principal fator que contribui para os danos ambientais e mudanças climáticas que foi um dos pilares. Ademais, outro fator que chama atenção são as invasões dos municípios em locais proibido pela defesa civil, que trouxe consigo fatores de riscos, principalmente em tempo chuvoso, com deslizamento de terra. Sendo assim, se faz necessário a aplicação do uso de modelos de séries temporais para avaliar o comportamento das variáveis focos queimadas e precipitação ao longo do tempo, bem como os impactos causados ao meio ambiente. Os dados constituíram uma modelagem entre os anos de 2000 e 2019. Para o estudo dessas séries foram utilizados os testes de sazonalidade, na sequência ajustou-se aos dados os modelos regressivos integrados de médias móveis (ARIMA), adotou-se o critério de escolha de valor AIC (Critério de Informação Akaike). Os gráficos de previsão, permitiu a coerência do comportamento das variáveis. Desta forma, com base nos resultados alcançados, pode-se findar que, o estudo séries temporais nas variáveis focos de queimadas na região do sertão e precipitação na região metropolitana entre os anos de 2000 e 2019, mostra que há presença de sazonalidade nos dados, porém sem tendencia. Desta maneira, o estudo torna-se valoroso com o intuito de auxiliar órgãos competentes, visto que relata duas regiões que sofrem com agravos tanto da seca quanto da chuva.

**Palavras-chave:** Precipitação. Queimadas. Séries Temporais.



## ABSTRACT

Researchers in the areas of Climate Sciences and Meteorology observed that the metropolitan region and the sertão region, located in the state of Pernambuco, suffer from a lack of planning and public policies, while the sertão suffers from high heat waves, little rainfall and drought, the metropolitan region suffers from excessive rainfall and the inconvenience it causes due to problems in the infrastructure of the municipalities. In this sense, global warming, the main factor that contributes to environmental damage and climate change, was one of the pillars. In addition, another factor that draws attention is the invasions of citizens in places prohibited by the civil defense, which brought with it risk factors, especially in rainy weather, with landslides. Therefore, it is necessary to apply the use of time series models to evaluate the behavior of the variables burnt outbreaks and precipitation over time, as well as the impacts caused to the environment. The data constituted a modeling between the years 2000 to 2019. For the study of these series, seasonality tests were used, then the regressive integrated moving average models (ARIMA) were adjusted to the data, the choice criterion was adopted of AIC (Akaike Information Criterion) value. The forecast graphs allowed the coherence of the behavior of the variables. In this way, based on the results achieved, it can be concluded that the study of time series in the variables of fire outbreaks in the sertão region and precipitation in the metropolitan region between the years of 2000 to 2019, shows that there is a seasonality in the data, but without a trend. In this way, the study becomes valuable in order to help competent bodies, since it reports two regions that suffer from both drought and rain.

**Keywords:** Precipitation. fires. Time Series.

## **LISTA DE ABREVIATURAS E SIGLAS**

IBGE	Instituto brasileiro de Geografia e Estatística,
SISAM	Sistema de Informações Ambientais Integrado.
CPRH	Conselho Estadual do Meio Ambiente.
CONAMA	Conselho Nacional do Meio Ambiente.
OMS	Organização Mundial da Saúde.
APAC	Agência Pernambucana de Água e clima.

## SUMÁRIO

1	INTRODUÇÃO.....	10
2	MATERIAL E MÉTODOS ESTATÍSTICOS.....	12
2.1	Local de Estudo e Material .....	12
2.2	Metodologia .....	13
2.3	Processos Estocásticos .....	13
2.4	Sazonalidade.....	13
2.4.1	<i>Teste para Sazonalidade.....</i>	<i>14</i>
2.5	Modelos de Suavização Exponencial.....	15
2.5.1	<i>Método de suavização exponencial Simples.....</i>	<i>15</i>
2.5.2	<i>Função Exponencial de Holt.....</i>	<i>15</i>
2.5.3	<i>Função Exponencial de Holt-Winters.....</i>	<i>16</i>
2.6	Modelagem Box-Jenkins .....	17
2.6.1	<i>Pacote Forecast .....</i>	<i>18</i>
2.6.2	<i>Modelagem ETS.....</i>	<i>18</i>
2.6.3	<i>Modelo Autorregressivo (AR).....</i>	<i>19</i>
2.6.4	<i>Modelo de Médias Móveis (MA).....</i>	<i>19</i>
2.6.5	<i>Modelo Autorregressivo de Médias Móveis (ARMA).....</i>	<i>20</i>
2.6.6	<i>Modelo Autorregressivo Integrado de Médias Móveis (ARIMA).....</i>	<i>20</i>
2.7	Estimação de modelos de Séries temporais .....	21
2.8	Análise de Resíduos.....	21
2.9	Previsão em Série temporal.....	21
3	RESULTADOS E DISCUSSÕES .....	22
3.1	Análise de focos de queimadas na região do sertão.....	22
3.2	Análise da precipitação na região metropolitana.....	28
4	CONCLUSÃO .....	34
	REFERÊNCIAS.....	35

## 1 INTRODUÇÃO

O estado de Pernambuco apresenta um ambiente individualizado em sua paisagem, tendo o clima tropical, situado no nordeste com limitações entre nove estados, tendo suas características geomorfológicas: Planícies (Litoral), Planalto (Zona da Mata e Agreste) e Depressão (Sertão). A partir da revolução industrial de 1840 tem-se observado grandes quantidades de dióxido de carbono na atmosfera, o que levou os cientistas e líderes mundiais, nesses últimos décadas a alertar a população mundial da consequência devastadoras para a vida humana (MAGALHÃES; VENDRAMINI, 2018). Agressões humanas ao meio ambiente teve evolução após a revolução industrial, no século XX, conveniente ao crescimento populacional e aumento no consumo da industrialização. Consequência a isso e a falta de planejamento e políticas públicas voltado ao meio ambiente, a temperatura com o passar dos anos ficando mais quente devido ao desmatamento causado pelos homens, que buscam utilizar de forma ilegal os biomas, causando fenômenos naturais que podem surgir em áreas secas, clima árido e semiárido, que contenham vegetação (GOLDEMBERG; LUCON, 2007) .

Em 1850, Eunice Newton Foote foi a primeira cientista a escrever que aumentos do dióxido na atmosfera poderiam provocar um aquecimento global, afetando diretamente no clima, com ocorrências extremas e de grande magnitude. Segundo Souza e Azevedo (2012), à propensão investigativa de precipitação nas regiões metropolitanas e queimadas na região sertaneja, diagnosticando aumento na frequência de chuvas, atividades industriais, os veículos automotores e as queimadas, dentre as atividades antrópicas, são as maiores produtoras de substâncias poluentes causando mudanças. A impureza atmosférica é globalmente reconhecida como um vultoso problema da saúde pública, tornando-se a matéria produzida do ar impróprio ou infeccioso à saúde, induzindo uma crise sanitária a população, assim como prejuízos a fauna e flora (BRASIL, 2018). Estima-se que todos os anos cerca de sete milhões de pessoas falecem em consequência da poluição ambientais, por esse motivo, em 2019, a impureza do ar é insigne, pela OMS, a maior incisão ambiental para saúde (OPAS, 2019).

Cidades de pequenos e médios portes sofrem com a falta de saneamento básico, infraestrutura e sobretudo, um planejamento adequado. Devido a omissão de seus gestores, as populações dessas localidades ficaram vulneráveis aos principais problemas ocasionado com a falta de chuvas, estiagem e clima seco, ocasionando focos de queimadas na região do sertão, enquanto na região metropolitana o sofrimento da população é os constrangimentos trazido pelas chuvas, alagamento em vias públicas, deslizamento de terra em barreiras que eram para serem preservadas por serem áreas verde. Segundo a Organização Mundial da Saúde (OMS, 2005), a falta de planejamentos variam de acordo com a abordagem adotada para balancear riscos causados pelas mudanças climáticas existente nas duas regiões.

Alguns estados brasileiros sofreram pela falta de planejamentos e políticas públicas, Pernambuco não foi diferente, com avanços acelerados da revolução industrial onde trouxe seus lados benéficos como: desenvolvimento econômico e urbano para os municípios. Maléficos

como: problemas estruturais e ambientais. Segundo Duarte (1999), os estados brasileiros sofrem para se adequar de forma prudente e fiscalizadora para os avanços revolucionários e cidades metropolitanas não conseguiram de uma forma ampla atender o meio empresarial e sua população carente, com isso houve várias invasões em locais considerados de riscos.

No estado de Pernambuco o órgão responsável pela fiscalização que envolve meio ambiente, controle dos avanços do desmantamento e queimadas é o Conselho Estadual de Meio Ambiente e de Recurso Hídricos-CPRH, com o intuito de proteção, conservação e pesquisa aplicada as atividades de controle. Pela resolução Nº 491 de 19/10/2018 do Conselho Nacional do Meio Ambiente (CONAMA), estabeleceu alguns padrões de qualidade do ar devido aos poluentes atmosféricos associado a um período de exposição, para que o meio ambiente. A saúde da população sejam preservados em relação aos riscos de danos causados pelas queimadas nos municípios, enquanto a Agência Pernambucana de Águas e climas-APAC, emite alertas sobre as condições climáticas. possibilitando a adoção e aplicação de medidas preventivas e corretivas de controle (PERNAMBUCO, 2018).

Segundo Silva et al. (2010), analisando séries temporais de precipitação de todo o Brasil para o período de tempo, encontra-se padrões diferenciados e muito regionalizados nas tendências de aumento e diminuição dos índices. Diante ao que foi exibido a nesta introdução, o nosso objetivo neste trabalho é de utilizar modelagem matemática por meio de série temporal para analisar dados de focos de queimadas do sertão pernambucano e das precipitações da região metropolitana

Levando-se em conta as irregularidades existentes nas regiões do sertão e metropolitana de Pernambuco e a inquietude da sociedade no que se expõe diante das necessidades encontradas dessas regiões, se faz preciso o uso de modelos de séries temporais para que seja capaz de quantificar e antever o desempenho das variáveis focos de queimadas e precipitações para os próximos anos. Com avanços computacionais, modelos em séries temporais evoluíram consideravelmente, deste modo favorecendo o uso de diversas áreas de aplicação.

Perante do que foi apresentado este trabalho tem como objetivo: averiguar o comportamento de sazonalidade, suavização exponencial, ajustar modelos de séries temporais às variáveis nos focos de queimadas na região do sertão e precipitação na região metropolitana do estado de Pernambuco; partilhando-se alguns critérios de seleção do modelo. Identificar qual modelo melhor se configura nos dados em estudo e finalmente; efetuar previsões nas variáveis de focos de queimadas e precipitação para futuros anos nas regiões em estudo.

## 2 MATERIAL E MÉTODOS ESTATÍSTICOS

### 2.1 Local de Estudo e Material

Observa-se na Figura 1, o mapa referente ao estado de Pernambuco, região pertencente ao nordeste, contendo 185 municípios, uma extensão territorial de 98.189,119 km<sup>2</sup> com uma população estimada em: 9.616.621 habitante, densidade demográfica: 89,62 hab./km<sup>2</sup> (IBGE,2020)<sup>1</sup>. A região do sertão possui 59 cidades, ocupando 70% do território pernambucano. O sertão está dividido em seis microrregiões, sua economia baseada na culturas de subsistência e pecuária, porém, é uma região castigada pelas secas que atingem o semiárido com precipitação entre 500 e 700 milímetros, muito abaixo em comparação com a região metropolitana que contém uma tendência em torno de 1.000 a 1.500 milímetros, dando continuidade na região metropolitana, onde contém 15 municípios incluindo a capital pernambucana (Recife), sua economia voltado para comércios, serviços e turismo a região metropolitana ocupa 12% da ocupação territorial de Pernambuco.

Figura 1 – Estado de Pernambuco



Fonte: Produzido pelo autor

Os dados utilizados para análise neste trabalho foram recolhidos no SISAM- sistema de Informações Ambientais, estão disponíveis no site: <https://queimadas.dgi.inpe.br/queimadas/sisam/v2/>. Foram acessados e baixados os boletins referentes aos anos de 2000 até 2019, em que quatro dados foram registrados por dia, com o intervalo de seis horas. Cada dado é extraído de análises numéricas de imagens via satélite. O método estatístico empregado é análise de séries temporais e as variáveis precipitação acumulada na região metropolitana e focos de queimadas na região do sertão. Utilizamos o software R (CORE TEAM, 2022) para nos auxiliarem nas análises.

## 2.2 Metodologia

Segundo Fischer, Fuchs e Mansmann (2012), uma série temporal é um conjunto de observações de uma variável, dispostas sequencialmente no tempo. Condizente o conjunto obtido, pode-se categorizar a série em contínua ou discreta. Considera-se que a série é discreta quando os conjuntos de dados observados no tempo for finito ou infinito enumerável. Senão, o conjunto gerado for infinito não enumerável, tem-se uma série contínua. A grande maioria dos estudos ambientais que se coadjuvam do tratamento de séries temporais, utilizam métodos discretos, ao qual as observações são geradas no intervalo de tempo com amplitude constante.

## 2.3 Processos Estocásticos

Segundo Bressan (2004), os modelos usados para descrever séries temporais são processos estocásticos, ou seja, processos regidos por leis de probabilidade. Seja  $T$  um conjunto casual, e o processo aleatório é uma família  $Z = Z_t, t \in T$  é uma variável aleatória. O conjunto  $[T]$  é muitas vezes considerado como o conjunto de inteiros  $Z$ , ou o conjunto de números reais ( $R$ ), e variáveis aleatórias, uniformemente distribuídas no tempo., definido no mesmo espaço de probabilidade  $(\Omega, A, P)$ , onde  $\Omega$  é o espaço amostral,  $A$  é o evento associado ao espaço amostral e  $P$  é a medida de probabilidade.

O conjunto de valores  $Z_t, t \in T$  é denominado espaço nos estados do processo estocástico, e os valores  $Z_t$  são chamados estados, onde  $t$  e  $T$  podem ser distintos ou ligados. Um processo estocástico  $Z = \{Z_t, t \in T\}$  diz-se segunda ordem, somente se:

i)  $\varepsilon(Z_T) = \mu(t) = \mu$ , é contínuo para todo  $t \in T$  ;

ii)  $\varepsilon_t^2 < \infty$ , para qualquer  $t \in T$ ;

iii)  $\gamma_j = cov[Z_t, Z_{t-j}] = E[(Z_t - \mu)(Z_{t-j} - \mu)]$ , depende dos caminhos de : (j)  $\forall t \in T e j \in R$ . Segundo

Morettin (1981), a função definida no tópico (iii) é uma autocovariancia (FACV).

## 2.4 Sazonalidade

Figueredo (2008), estabelece sazonalidade como o conjunto de deslocamentos ou oscilações com o tempo igual ou inferior a um ano, “metódico, mas não indispensavelmente regulares”, que acontecem em uma série temporal. Para Figueredo (2008), estas mobilidades decorrem habitualmente das variações climáticas relativas às estações do ano, ou a motivos culturais relativos a efeitos de calendário.

Essas instabilidades são vistas por muitos autores como ruídos de restrito prazo que devem ser extintos por meio do ajuste sazonal, Lopes (2007). O ajuste sazonal é o procedimento que

avalia e remove os efeitos sazonais de uma série, comumente, pela divisão da série em tendência, ou ciclo de tendência, elemento sazonal e resíduos ou elemento irregulares (FIGUEREDO, 2008). A série consequente de tal método é designada de série dessazonalizada ou série estabelecida sazonalmente.

É considerável identificar a presença do componente sazonal, avaliá-lo e removê-lo (tal procedimento é conhecido como ajustamento sazonal), para logo observar o desempenho da tendência ao longo do período da série. De modo geral, os ensinamentos tradicionais sobre sazonalidade buscam separar o evento em três partes, através de:

$$y_t = \text{tendencia} + \text{sazonalidade} + \text{irregularidade}$$

Onde o componente de tendência simboliza a mobilidade de longo período. A mobilidade irregular espelha movimentos não-sistemáticos e residuais. Decompondo-se os resultados de tendência e dos erros não-sistemáticos, é permitido então captar os resultados sazonais.

#### 2.4.1 Teste para Sazonalidade

De acordo com Morettin e Tolo (1987), dois aspectos devem ser vistos antes da efetuação do teste para sazonalidade, paramétrico e não-paramétrico, e antes de utilizar qualquer um deles é cabível eliminar tendência ou sazonalidade, se ela ficar presente na série.

Se porventura dos testes não-paramétricos, uma viabilidade é usar o teste Kruskal-Wallis, o qual atribui em  $H_0$  a não presença de sazonalidade, que é verificado através da seguinte estatística

$$T_1 = \frac{12}{N(N+1)} \sum_{j=1}^k \frac{R_j^2}{n_j} - 3(N+1).$$

Descarta-se  $H_0$  no momento quando em que essa estatística for superior ou igual ao valor crítico  $T_{1c}$ , no qual  $T_{1c}$  da mesma forma que  $P_H(T_1 > T_{1c}) = \alpha$ ,  $\alpha$  é o grau de significância do teste.

No contexto dos testes paramétricos, é admitido aplicar um teste F regular a uma análise de variância. O modelo contido é

$$Y_{ij} = S_j + e_{ij}, i = 1, \dots, n_j, J = 1, \dots, k,$$

considerando-se que  $e_{ij} \sim N(0, \sigma)$ , autossuficiente. Perante a hipótese nula  $H_0 : S_1 = \dots = S_k$ , a estatística

$$T = \frac{N-k}{k-1} \frac{\sum_{j=1}^k n_j (\hat{Y}_j - \hat{Y})^2}{\sum_{j=1}^k \sum_{i=1}^{n_j} (\hat{Y}_{ij} - \hat{Y}_j)^2}$$

possui distribuição  $F_{(k-1, N-k)}$ .

Os modelos aplicados para detalhar séries temporais são processos estocásticos, ou seja, métodos controlados por regras probabilísticas. Seja qual for a classificação que se realize para



os métodos de séries temporais, é possível ajustar um número admissível de diferentes métodos para descrever o procedimento de uma série peculiar.

## 2.5 Modelos de Suavização Exponencial

A intenção dos métodos é especificar o modelo de qualquer ruído contido nas observações e usar esse padrão para prever valores futuros das séries (MORETTIN; TOLOI, 2006). A suavização é um método para confirmar tal ocorrência nas séries temporais. Os modelos de suavização exponencial, são classes de previsões algoritmos AD HOC (Para este efeito), métodos esses que fazem simples previsões adaptadas, onde ajustam os dados automaticamente para estarem incluídos na série, é importante destacar que mesmo tendo poucas observações, este procedimento consegue apresentar uma previsão eficaz. Pelas incorreções encontradas em previsões passadas, é que as previsões dos modelos de suavização exponencial são obtidas, ou seja,  $Z_1, Z_2, \dots, Z_t$  uma modelagem da série temporal, suas previsões serão produzidas para  $Z_{t+1}, Z_{t+2}, \dots$

### 2.5.1 Método de suavização exponencial Simples

O método de suavização exponencial simples é usado para séries temporais sem tendências ou sazonalidade (EHLERS, 2005), ou seja, é uma série fixa apenas que incluiu níveis aleatórios e ruídos. A série se expande para:

$$Z_t = N_t + \varepsilon_t, \text{ com } t = 1, 2, \dots, n.$$

Onde  $\varepsilon_t$  ( $\theta, \sigma_\varepsilon^2$ ) e  $N_t$  denotam o nível da sequência no instante t. O parâmetro  $N_t$  é apreciado pela média de observações passadas, onde as observações mais recentes têm um peso relativo maior (CHATFIELD, 2003):

$$N_t = \alpha Z_t + \alpha (1 - \alpha) Z_{t-1} + (1 - \alpha)^2 Z_{t-2} + \alpha (1 - \alpha)^3 Z_{t-3} \dots$$

onde  $Z_t$  são as n observações da série e  $\alpha$  é contínuo na suavização com  $0 < \alpha < 1$

### 2.5.2 Função Exponencial de Holt

O método de Holt utiliza dois tipos de coeficientes de suavização: exponencial simples e tendência linear (crescente ou decrescente) (MONTGOMERY; JENNINGS; KULAHCI, 2015). Quando a série mostra uma tendência, o método Exponencial de Holt é utilizado porque a previsão futura através do método de exponencial simples induz erros sistemáticos de previsão devido a através de seguimentos, como se segue.

São estimados os coeficientes da seguinte maneira:

$$N_t = \alpha Z_t + 1(1 - \alpha)(N_{t-1} + T_{t-1})$$

$$T_t = \beta(N_t + N_{t-1}) + (1 - \beta)T_{t-1}$$

onde  $0 < \alpha < 1$  e  $0 < \beta < 1$  com  $\alpha$  e  $\beta$  são suavização constante.

Para indicar os coeficientes de suavização  $\alpha$  e  $\beta$ , em tal forma que reduza os erros de previsão na soma dos quadrados, aplica-se um processo exato ao exponencial simples, todavia o algoritmo começa pela segunda observação, então,  $N_2 = Z_2$  e  $T_2 = Z_2 - Z_1$  (MARTIN et al., 2016). Então, a previsão é dada por:  $Z(h) = N_t + hT_t$ , onde  $h = 1, 2, \dots$ . Os erros numéricos de Holt são feitos na forma análoga da exponencial simples, que resultou em:

$$\begin{aligned} N_t &= N_{t-1} + T_{t-1} + \alpha \varepsilon_t T_t \\ &= T_{t-1} + \beta \varepsilon_t. \end{aligned}$$

### 2.5.3 Função Exponencial de Holt-Winters

Utiliza-se deste método para uma série temporal mais robusta e de comportamento complexo, onde apresentam tendência e/ou sazonalidade (BROCKWELL; DAVIS, 2002). Algoritmos são fragmentados em duas partes: aditivos e multiplicativos. Série Sazonal multiplicativa: É classificado como uma série sazonal com período (s), que podem ser: dia(s), mês(es) ou ano(s). Dispomos  $F_t$  como um fator da variante sazonal multiplicativo, enquanto a tendência variante é aditiva (MORETTIN; TOLOI, 2006). formando recorrências neste algoritmo, que é dada pelas seguintes equações:

$$\begin{aligned} N_t &= \frac{\alpha Z_t}{F_{t-s}} + (1 - \alpha)(N_{t-1} + T_{t-1}) \\ T_t &= \beta(N_t + N_{t-1}) + (1 - \beta)T_{t-1} \\ F_t &= \frac{\gamma Z_t}{N_t} + (1 - \alpha)F_{t-s} \end{aligned}$$

Onde  $0 < \alpha < 1$ ,  $0 < \beta < 1$ ,  $0 < \gamma < 1$  com  $\alpha$ ,  $\beta$  e  $\gamma$  são suavização de algoritmo constante.

As previsões futuras têm valores considerando para cada equação uma sazonalidade contabilizada no período correspondente. A seguir as expressões das previsões (MORETTIN; TOLOI, 2006):

$$\begin{aligned} \hat{Z}_t(h) &= (N_{t+h}T_t)F_{t+h-s}, \text{ onde } h = 1, 2, \dots, s \\ \hat{Z}_t(h) &= (N_{t+h}T_t)F_{t+h-2s}, \text{ onde } h = s + 1, s + 2, \dots, 2s \end{aligned}$$

Utilizando-se procedimentos matemáticos, chegamos a fórmula de correção dos erros:

$$\begin{aligned}
 N_t &= N_{t-1} + T_{t-1} + \frac{\alpha \varepsilon_t}{\varepsilon_{F_{t-s}}} \\
 T_t &= T_{t-1} + \alpha \beta \frac{t}{F_{t-s}} \\
 F_t &= F_{t-s} + \gamma(1-\alpha) \frac{\varepsilon_t}{F_{t-s}}
 \end{aligned}$$

Série Sazonal aditiva: Alterando o processo antecedente em que a situação de fator sazonal passa a ser aditivo, tendo suas expressões atualizadas nos seus dados (MORETTIN; TOLOI, 2006):

$$\begin{aligned}
 N_t &= \alpha(Z_t - F_{t-s}) + (1-\alpha)(N_{t-1} + T_{t-1}) \\
 T_t &= \beta(N_t + N_{t-1}) + (1-\beta)T_{t-1} \\
 F_t &= \gamma(Z_t - N_t) + (1-\gamma)F_{t-s}
 \end{aligned}$$

onde  $0 < \alpha < 1, 0 < \beta < 1, 0 < \gamma < 1$  com  $\alpha, \beta$  e  $\gamma$  são suavização de números constantes.

Com  $h$  passos à frente, as previsões futuras, são representadas pelas seguintes formas (MORETTIN; TOLOI, 2006):

$$\hat{Z}_t(h) = (N_{t+h}T_t)F_{t+h-s},$$

onde  $h = 1, 2, \dots, s$

$$\hat{Z}_t(h) = (N_{t+h}T_t)F_{t+h-2s},$$

onde  $h = s + 1, s + 2, \dots, 2s$ . Utilizando procedimentos matemáticos, chegamos a fórmula de correção dos erros:

$$\begin{aligned}
 N_t &= N_{t-1} + T_{t-1} + \alpha \varepsilon_t T_t \\
 &= t - 1 + \alpha \beta \varepsilon_t \\
 F_t &= F_{t-s} + \gamma(1-\alpha)\varepsilon_t.
 \end{aligned}$$

## 2.6 Modelagem Box-Jenkins

A metodologia Box Jenkins apresenta modelos de séries temporais, os quais podem ser classificados com seus respectivos parâmetros. Estes são considerados como sendo parâmetros, visto que se caracterizam pelos parâmetros de número finitos, e tem suas observações feitas no controle do tempo. Neste trabalho, serão expostos apenas os modelos mais universais. Segundo Fischer (1982), os modelos estudados de séries temporais buscam inferir processos geradores, utilizando métodos estocásticos que seja capaz de retratar as situações específicas que ocorreu. Diante do aspecto de Box e Jenkins, onde a as técnicas desse método de previsão tem sua exploração da correlação temporal que é capaz de encontrar-se entre os valores exibidos pela série.

### 2.6.1 Pacote Forecast

De acordo com Hyndman e Khandakar (2008), o pacote forecast é formado de procedimentos e ferramentas que concedem expor e analisar as previsões univariadas de séries temporais, assim como a suavização exponencial por intermédio de modelos recintos de estados.

No momento em que é feita a previsão com o modelo ARIMA sem regressores, quer dizer, sem dados precedentes, o pacote forecast unicamente usa valores precedentes de sua série histórica para antever valores futuros de forma espontânea. Nesse sentido é plausível especificar o âmbito “h”, que delimita as etapas de previsões. (ROCHA, 2018).

O pacote concede executar previsões e o cálculo das relevantes medidas dos erros de previsões. Para acrescentar é feito uma análise dos resíduos do modelo plotando o gráficos da série primaria com as previsões (HENNING et al., 2009).

Já para previsão no modelo ETS, o pacote forecast concede selecionar o modelo de suavização exponencial os dados são adequados satisfatoriamente. O comando efetua espontaneamente um processo de não linear de minimização do critério de informação adotado, calculando os parâmetros nos quais as previsões serão utilizadas na equação. (CAMPOS, 2009).

### 2.6.2 Modelagem ETS

Os métodos utilizados no modelo ETS de série temporal significa error, trend, seasonal, quer dizer, erro, tendência e sazonalidade. O erro talvez seja multiplicativo (M) ou aditivo (A), a tendência pode não possuir (N), ser multiplicativa (M), multiplicativa amortecida (Md), aditiva (A) ou aditiva amortecida (Ad) e a sazonalidade pode não ocorrer (N). ser multiplicativo (M) ou aditivo (A). Equações do modelo ETS com erros aditivos e multiplicativos podem ser vistos em Hyndman e Khandakar (2008)

Nas equações dos métodos ETS com falhas multiplicativos e aditivos, as imutáveis  $\alpha$ ,  $\beta$  e  $\gamma$  as quais possui dispõe valores introdutivos a 0,1, têm de ser apreciado na conduta de minimizar os erros. Os parâmetros de suavização  $\alpha$ ,  $\beta$  e  $\gamma$  no sentido para cada item da série são regularmente designados no intervalo (0,1) e conseguem ser estimados reduzindo-se a soma dos quadrados dos erros de previsão. Estes parâmetros não se baseiam da escala dos estudos, entretanto dos domínios temporais do nível, tendencia e sazonalidade da série. (SOUZA; PETERNELLI; MELLO, 2014)

Segundo Miranda et al. (2009) utilizar uma metodologia para selecionar o “melhor” modelo acerca de uma classe de modelos é tal maneira importante quanto o procedimento para estimar os parâmetros do modelo. Um método admitido é o critério Akaike (AIC), onde  $\rho$  refere-se o número de parâmetros apreciado do modelo e  $\theta = (\alpha, \beta, \gamma, \varphi)$ .

$$AIC = L * (\theta, x_0) 2\rho$$

A expressão que apresenta o menor AIC é optado como mais apropriado (HYNDMAN; KHANDAKAR, 2008).

### 2.6.3 Modelo Autorregressivo (AR)

Modelo autorregressivo, é modelado como base na média ponderada dos seus valores pre-existente e pelo erro aleatório (ruído branco) (MAKRIDAKIS; HIBON, 1997). Tendo denotação AR (p), modelo de ordem p, dispomos:

$$Z_t = \alpha + \varphi_1 Z_{t-1} + \varphi_2 Z_{t-2} + \dots + \varphi_p Z_{t-p} + u_t$$

onde  $\varphi_1, \varphi_2, \dots, \varphi_p$  parâmetros do modelo e  $u_t$  é o ruído no tempo  $t$ .

Entretanto existe outra maneira de expressar esta modelagem, uma notação alternativa, onde o autorregressivo de ordem p estacionário (BAYER; CASTRO; BAYER, 2012)

$$Z_t = \alpha + \varphi_1 B Z_t + \varphi_2 B^2 Z_t + \dots + \varphi_p B^p Z_t + u_t$$

Tendo  $Z_t$ , a expressão se faz presente na seguinte forma:

$$(1 - \varphi_1 B - \varphi_2 B^2 - \dots - \varphi_p B^p) Z_t = \alpha + u_t$$

Expressão resumida:

$$\varphi(B) Z_t = \alpha + u_t$$

Tendo polinômio de discrepâncias como operador do  $\varphi(B) = 1 - \varphi_1 B - \varphi_2 B^2 - \dots - \varphi_p B^p$ . A variância do modelo autorregressivo é:

$$\gamma_0 = \varphi_1 \gamma_1 - \varphi_2 \gamma_2 - \dots - \varphi_p \gamma_p + \sigma_u^2$$

Tendo que  $\sigma_u^2$  sendo a variância de  $u_t$  (ruído).

A definição da autocovariância é:

$$\gamma_k = \varphi_1 \gamma_{k-1} - \varphi_2 \gamma_{k-2} - \dots - \varphi_p \gamma_{k-p} + \sigma_u^2, K \geq 1$$

Segundo Silva et al. (2021) as equações de autocovariância dados por:  $K = 1, 2, \dots, p$  utilizando  $\gamma_0 = 1$  e  $\gamma_{-k} = \gamma_k$  chegaremos na equação de Yule-Walker.

### 2.6.4 Modelo de Médias Móveis (MA)

Segundo Bayer, Castro e Bayer (2012), as médias móveis são utilizadas, cada vez que o período observado do passado é substituído pelo mais recente, fazendo assim um cálculo mais recente. tendo sua ordem q, classificado como médias móveis (MA), suas características,  $a_t$  é um processo aleatório, sua média  $\mu$  de variância  $\sigma_a^2$ . sendo assim, as médias móveis têm seu modelo representado pela seguinte equação:

$$Z_t = a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q}$$

como ruído da série e  $\theta_j$  é a média móvel.

### 2.6.5 Modelo Autorregressivo de Médias Móveis (ARMA)

Os modelos autorregressivos e de médias móveis é a conjunção de AR(p) e MA(q). Esse modelo tem sua forma de ajustar previsões e modelar o comportamento da série, utilizando os ajuste da função com base nos valores do passado juntamente na média da série, seguindo a norma (p,q) (MORETTIN, 2017). Tendo sua seguinte representação:

$$Z_t = \varphi Z_{t-1} + \dots + \varphi_p Z_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q}$$

onde  $Z_{t-1} + Z_{t-2} + \dots + Z_{t-p}$  são autossuficientes de  $a_t$ .  $Z_{t-1}$  são valores lineares de combinação dos p-valores ascendência de  $a_t$ , onde agregam a tese da série até o tempo t que não é explanado pelos valores passados (MORETTIN, 2017).

### 2.6.6 Modelo Autorregressivo Integrado de Médias Móveis (ARIMA)

Segundo Xavier (2016), ao conceituar um processo estocástico não estacionário, onde sua homogeneidade estacionária apresenta uma transformação com o operador da série, utilizando um processo agregado ao modelo autorregressivo de média móvel, torna-se um processo de ordem d, ou ARIMA(p,d,q). Nos casos que as variáveis não são estagnadas  $Y_t$  (não estacionária), estabelece uma função  $Z(t)$ , tornando-se a primeira diferença de  $Y_t$ , isto é:

$$Z(t) = Y_t - Y_{t-1} = \Delta Y_t$$

nesse sentido, argumentamos que  $Z(t)$  estacionário, portanto, a variável  $Y_t$  é habituada de ordem 1. Tomando d distinções, é lícito dessa forma reformular a equação da seguinte forma:

$$Z(t) = \Delta^d Y_t$$

Prontamente, a nova variável  $Z(t)$  acompanha o processo ARIMA(p,d,q), melhor dizendo:

$$Z(t) = \beta_1 Z_{t-1} + \beta_2 Z_{t-2} + \dots + \beta_p Z_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q}$$

Por fim  $Y_t$ , acompanha um processo ARIMA(p,d,q), em outras palavras,  $Y_t$  é uma variável adaptada de ordem d e sua diferença d-esima permanece no processo autorregressivo de ordem p e q nas médias móveis, sendo caracterizado como:

$$\Delta^d Y_t = \beta_1 \Delta^d Y_{t-1} + \beta_2 \Delta^d Y_{t-2} + \dots + \beta_p \Delta^d Y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q}$$

Segundo Ehlers (2005) no desenvolver da pesquisa, tendo valores pequenos especificamente em d, sendo d = 1 sendo o valor frequente utilizando d = 2. Na aleatoriedade do processo ARIMA tendo (0,1,0).

## 2.7 Estimação de modelos de Séries temporais

Levando em conta os levantamentos do trabalho de Luna, Ballini e Soares (2006) os critérios utilizados para seleção do modelo que mais bem desenvolvido, modificando consideravelmente a necessidade da decisão do analista e ao mesmo tempo conseguindo otimizar nos computadores Os parâmetros autorregressivos são lineares, sendo uma estimativa simples, utilizando o método dos mínimos quadrados, onde consiste na obtenção destes parâmetros que reduza a soma das diferenças entre os pontos destes respectivos parâmetros. O modelo ARIMA (Autorregressivo de médias móveis) são apostos em casos que os dados mostram indicações de não estacionaridade, em que um passo inaugural (corresponde á parte "ambientada" do modelo) pode ser posta uma ou mais para suprimir a não estacionaridade. Já os parâmetros de médias móveis não têm linearidade, tornando custoso a estimação, utilizando assim, o método da máxima verossimilhança.

## 2.8 Análise de Resíduos

A seleção do melhor modelo traduz em ajustar constantes modelos, em ordem crescente, e escolher o modelo que prove o menor valor do critério (AIC- Critério de informação Akaike, BIC- Critério de informação Bayesiana, EQM- Erros Quadráticos Médio). Este método estatístico equivale uma penalidade e outra soma de quadrado dos resíduos, onde as observações é uma função crescente.

## 2.9 Previsão em Série temporal

O último passo a ser executado na modelagem em séries temporais, representa cumprir previsões. Ou seja, gerência a qualidade do modelo em prever valores futuros para os dados estudados. Segundo Morettin e Toloí (1987) a técnica de previsão em séries temporais dispõe de uma aplicação por décadas nas áreas de economia, tratamento digital de sinais, uma previsão precipitada. Em específico, ARMA (Modelo Autorregressivo de Média Móveis) e ARIMA (Modelo Autorregressivo Integrado de médias Móveis) métodos usados em séries temporais.

### 3 RESULTADOS E DISCUSSÕES

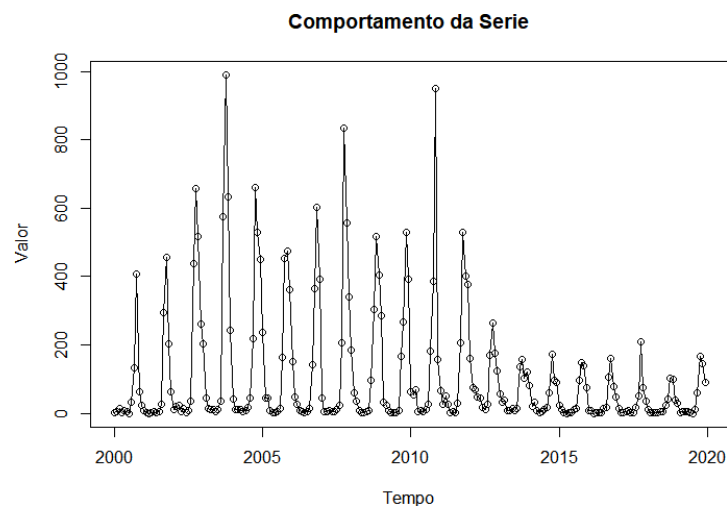
Neste capítulo será apresentado estudo considerando os dados da região do sertão e da região metropolitana de Pernambuco. Tendo o intuito de observar nos municípios da região metropolitana a série das precipitações e nos municípios da região do sertão os focos de queimadas, respectivos, entre os anos de 2000 a 2019. De acordo com Oliveira, Dourado e Mello (2017), ao realizar uma análise em séries temporais é fundamental observar a estacionaridade, tendência e sazonalidade.

#### 3.1 Análise de focos de queimadas na região do sertão

O sertão pernambucano tem uma ocupação de área de cerca de 32,500 km<sup>2</sup> com seu bioma sendo a caatinga, solo arenoso e de baixa fertilidade com ventos forte, sendo assim propício a focos de queimadas. Segundo Tidre, Biase e Silva (2013) primeiro passo para compreender uma série temporal é observar seu comportamento. Análisa-se, inicialmente, os dados numa série temporal compreendida entre os anos de 2000 a 2019, com objetivo de verificar possíveis estruturas de autocorrelações temporal das variáveis em estudo.

Um estudo realizado por Aires et al. (2022), em Rio Verde, interior de Goiás, onde os autores avaliaram a associação de focos de queimadas as condições climáticas e a região seca e solo arenoso, os referidos autores encontraram um maior número de focos nesta região devido ao tempo seco.

Figura 2 – Focos de queimadas no sertão pernambucano entre janeiro de 2000 até dezembro de 2019.



Fonte: Produzido pelo autor


Observa-se a Figura 2 que a fortes indícios de sazonalidade, então para confirmar, aplicou-se o teste de para corroborar a informação, dando sequência, utilizou-se o método de estimação com intuito de verificar os aditivos existentes, onde com o auxílio de software R, foi encontrado



a estimativa: (A.N.A); tendo componente aditivo, não possui tendência e possui sazonalidade aditivo. Observa-se que o valor médio de focos de queimadas na região do sertão foi de 107,6 e sua mediana de 24,5. Já suas margens foram: 00 (valor mínimo) e 989 (máximo). relativo à taxa de focos de queimadas mensal.

Dando sequência utilizou-se o modelo de suavização de Holt Winters, é um método não paramétrico, possuindo a confiabilidade para observar a estabilidade dos dados quando há necessidade de previsões em modelagem de séries temporais que tenham sazonalidade, os dados corroboraram bem ao modelo, mostrando assim, sazonalidade ao longo da série.

Figura 3 – Gráfico dos dados ajustado através do modelo de Holt-Winters em focos de queimadas do sertão pernambucano.



Fonte: Produzido pelo autor

Nota-se na Figura 3 que o ajuste realizado através do método Holt-Winters (azul) que é usado quando há necessidade de determinar previsões de modelagem em séries temporais que tenham sazonalidade, os dados ficaram ajustados, o método utilizado resulta em reproduzir valores exponenciais suavizados coletado no período de tempo. Dessa maneira, esse método é utilizado para prever valores futuros da série.

Tabela 1 – Valores da suavização para modelo de Holt-Winters aditivo em focos de Queimadas no sertão pernambucano.

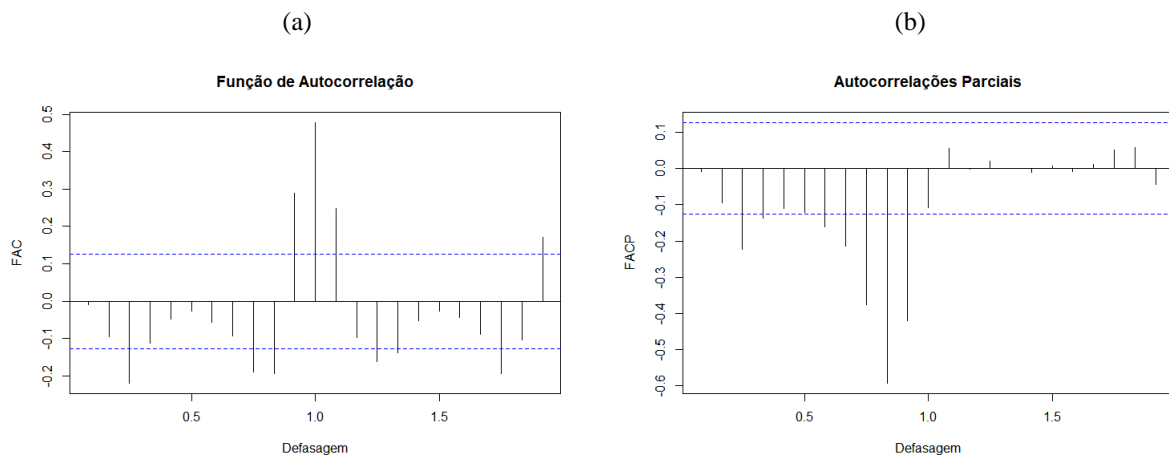
Método	$\alpha$	$\beta$	$\gamma$
HW aditivo	0,04	0,52	99,14

Fonte: Produzido pelo autor

A Tabela 1 demonstra-se que os valores de  $\alpha$  e  $\beta$  variaram entre 0 e 1 mostrando-se constante entre o nível de suavização, entretanto o método  $\gamma$  teve o valor acima da constante comparado aos métodos de  $\alpha$  e  $\beta$ , gerando algoritmos que minimizam o valor do modelo, critério para escolher a suavização.

O Próximo passo é verificar as funções FAC (Função de Autocorrelações) e de FACP (Função de Autocorrelações Parciais) da séries focos de queimadas na região do sertão pernambucano. O comportamento destas funções irá auxiliar na apuração da sazonalidade e na definição da escolha do modelo.

Figura 4 – Funções de autocorrelações e autocorrelações parciais para focos de queimadas no sertão pernambucano.

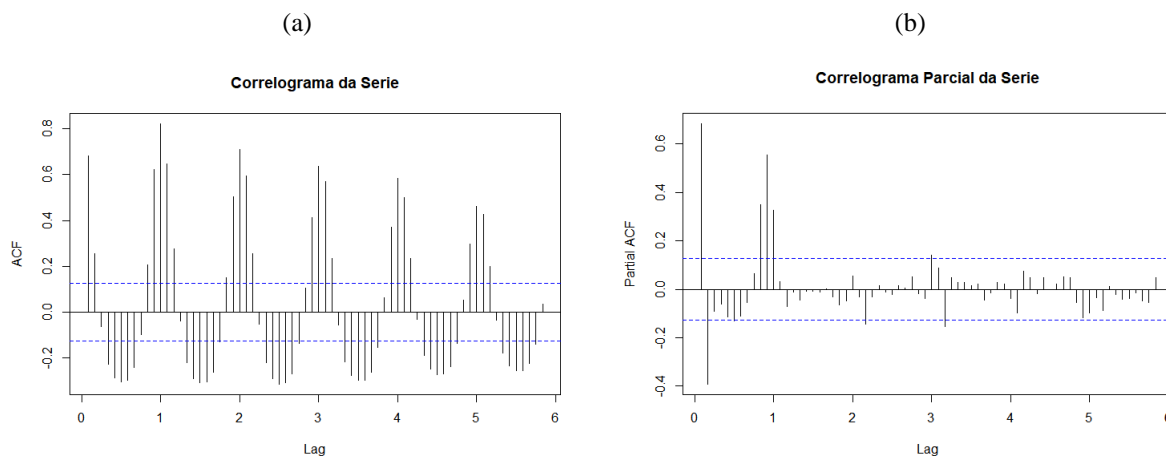


Fonte: Produzido pelo autor

Com base na Figura 4, começa-se o procedimento de reconhecimento da ordem dos modelos que serão ajustados aos dados de queimadas para o sertão de Pernambuco, com intuito de achar um modelo que se adequa aos dados. Desta maneira, foram ponderados modelos com estruturas distintos para séries temporais da região retratado anteriormente. Equiparou-se os resultados e a significância dos parâmetros partilhando alguns fatores de efetividade de modelos.

Logo em seguida, observa-se através do método de correlograma que são utilizados para identificar o modelo e para analisar a autocorrelação em diversas defasagens, tendo em vista se possui alguma tendência ou sazonalidade e analisar os resíduos de um modelo. Autocorrelações têm de ser próximas de zero para todas as distinções de período de tempo.

Figura 5 – Gráficos do correlograma e correlograma parcial nos dados de focos de queimadas no Sertão pernambucano.



Fonte: Produzido pelo autor

Na Figura 5, observa-se que o ACF (Função de Correlograma) mostra umas oscilações amplas com decaimento ultrapassando o limite, evidenciando uma sazonalidade na série. Já o PACF (Função de Correlograma Parcial) apresenta decaimento menores tendo mais pontos positivos fora da série. Aplicou-se a função logaritmo nos dados, mas não observou mudança no comportamento da série temporal.

Observa-se na Tabela 2 os erros de previsões: ME (Erro Médio), RMSE (Erro Quadrático Médio Raiz), MAE (Erro Médio Absoluto), MPE (Erro Percentual Médio), MAPE (Erro Médio de Percentual Absoluto) e MASE (Erro Médio Escalado Absoluto) que são calculados, na grandeza original da série, em atribuição dos parâmetros dos modelos ajustados no âmbito de previsão  $h$  variando de acordo com os meses. Esses erros são contrapostos com as estimativas das variâncias para o mês que está sendo calculado.

Tabela 2- Erros de previsões nos dados de focos de queimadas do sertão pernambucano.

ME	RMSE	MAE	MPE	MAPE	MASE
2,18	88,92	43,94	0,02	0,28	0,88

Fonte: Produzido pelo autor

Segundo Hyndman e Khandakar (2008), o alisamento exponencial executado tem uma linha de algoritmo, está linha usa abordagem de modelagem inovacional nos espaços. Notou-se que a aplicação gerou um erro de 4.15%. Continua-se com o ajuste do modelo aos dados de queimadas no sertão. Observa-se na Tabela 3 (abaixo), que o modelo a ser utilizado é o ARIMA, com parâmetros  $p, d$  e  $q$ , onde  $p$  representa o modelo AR (autorregressivo),  $d$  número de médias moveis (MA). Analisa-se os critérios adotados para os valores AIC (Critério de informação AKAIKE) e BIC (Critério de informação Bayesiana), sendo assim, entrever a variabilidade estimadas entre os modelos.

Dando continuidade no estudo realizado onde observou os alisamentos exponenciais como uma técnica utilizada para previsão, devido aos seus requisitos de armazenamento mínimo dos dados e facilidade de calcular.

Tabela 3- Critérios para escolha do modelo autoregressivo e médias móveis nos dados de focos de queimadas do sertão pernambucano.

Modelos	$\sigma^2$	EQM	AIC	BIC
ARIMA (2.1.2)	12029	1462,06	2934,11	2951,5

Fonte: Produzido pelo autor

O modelo não estacionário ARIMA (Média Móvel Integrado Autorregressivo) (2.1.2) tem seus ajustes os modelos AIC, BIC, EQM e  $\sigma^2$  adotando-se menos valores dos índices. Observou-se que a estimativa ( $\sigma^2$ ) teve uma redução estimativa que os Erros Quadráticos Médio (EQM), tendo o seguinte parâmetros:

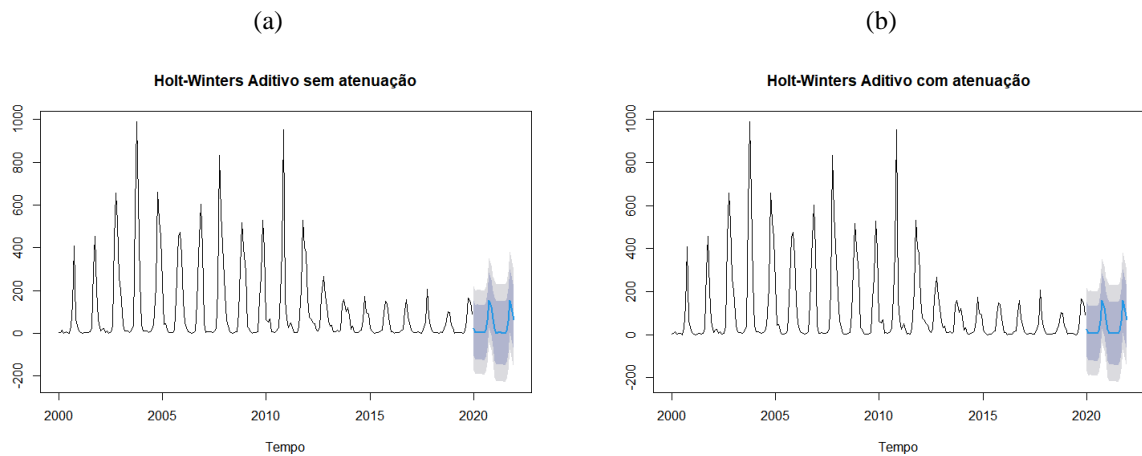
$$\hat{Z}_t = \hat{\phi} \times Z_{t-1} + \hat{\phi} \times Z_{(t-1+1)} - \hat{\theta} \times a_t + a_t$$

$$\hat{Z}_t = 0,0375 \times Z_{t-1} - 1,5999 \times Z_{(t-1)} - 0,8180 \times a_t + a_t$$

Em seguida, apresenta-se um estudo mais aprofundado sobre análise residual. Objetivamos os dados onde forem adequados, os resíduos se distribuem aleatoriamente em volta de zero com variância constante. do mesmo modo, que os resíduos tenham sua independência e possuam, uma distribuição normal. Este ajuste é explicação dos modelos para viabilizar as queimadas na região.

O modelo selecionado, utilizando-se o teste de normalidade Shapiro-Wilk ( $W = 0,40$ ) e seu ( $p$ -valor = 0,52), manter-se assim no patamar apeteável(desejável). Sendo assim, não rejeita-se a hipótese nula da distribuição normal. Seguindo o estudo, disponibiliza-se de modelagem de previsões, onde aplica-se o fator de atenuação.

Figura 6 – Gráficos de previsão sem e com atenuação de sazonalidade nos dados de focos de queimadas do sertão pernambucano.




Fonte: Produzido pelo autor

Objetivamos o modelo que segue a normalidade para prever valores futuros com base nos valores do passado. Observa-se os dados originais da série de focos de queimadas na localidade do sertão de Pernambuco, os valores preditos têm como intervalo de confiança o valor original da série, todavia o comportamento da série expõe uma previsão em volta da média acumulada com uma suavidade pequena. Estes valores estão previstos com a observação da média, mas dentro da sazonalidade e estabilidade da série. Sua fórmula de previsão aditiva para a região do sertão:

$$F_{t+m} = L_t + b_{t-m} + S_{t-s+m}.$$

Observa-se que os valores apresentam uma sazonalidade com índice de queda, é notório também

Figura 7 – Previsão de focos de queimadas anual para os próximos 5 anos na região do sertão pernambucano.



Fonte: Produzido pelo autor

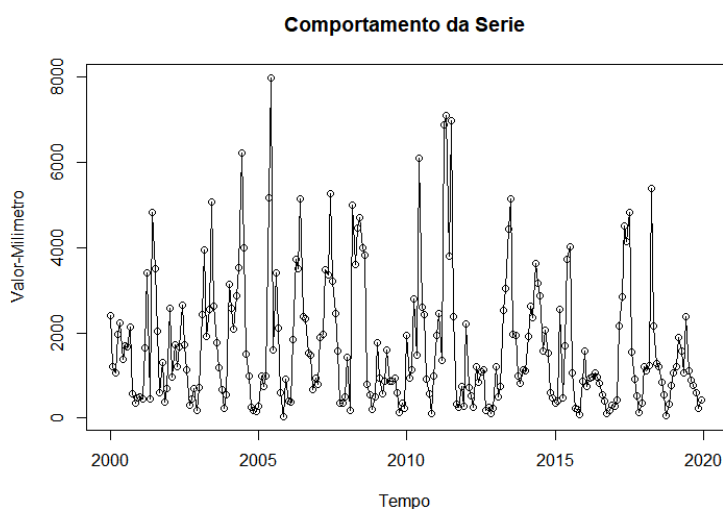
observar que o comportamento é bem descritivo, justificando a menor amplitude. Ao que tudo indica, este fato aparenta ser bem particular na região do sertão pernambucano, pois no estudo de séries temporais, as variações da temperatura para cidade sertanejas no estado de Pernambuco. observa-se na Figura 7 uma tendência na diminuição, a partir do ano de 2012 havendo quedas significativas nos índices de focos de queimadas. Todavia, verificando os índices no estado Pernambuco, observou que as quantidades de meses secos aumentou devido a invernos e outonos menores e com poucas chuvas e verão mais intenso, sendo assim clima mais seco, muito vento e tendência de se criar mais focos de queimadas.

### 3.2 Análise da precipitação na região metropolitana

Segundo Mota e Zipser (2002), a precipitação institui variáveis importantes climatológica. A região metropolitana é contém quatorze municípios, tendo uma abrangência territorial de mais de 2.770,442 km<sup>2</sup>. Essa região é abundante em precipitações devido o estado estar a oito graus abaixo da linha do Equador, sofrendo a influência direta na zona convergência intertropical (ZCIT), onde promove chuvas intensas na capital pernambucana e cidades circunvizinhas. O Primeiro passo é analisar o comportamento dos dados para tomar a decisão dos métodos que iremos utilizar.

Um estudo realizado por Wanderley et al. (2014), em Rio Largo, interior de Alagoas, onde o ator observou através de um estudo em séries temporais as precipitações pluviométricas na temperatura do ar, os dados corroboraram devido a condição da região, principalmente no tempo de inverno, que aumenta os números de chuvas da região.

Figura 8 – Precipitação na região metropolitana de Pernambuco entre janeiro de 2000 até dezembro de 2019.




Fonte: Produzido pelo autor

Na Figura 8 observa-se que a fortes indícios de sazonalidade, então para confirmar, aplicou-se o teste de para corroborar a informação, dando sequência, utilizou-se o método de estimação com intuito de verificar os aditivos existentes, onde com o auxílio de software R, foi encontrado a estimativa: (M. N. M) tendo componente de erro multiplicativo, não existindo tendência e sua sazonalidade é multiplicativa. Constata-se que o valor médio de precipitação de 1692,4 MM (milímetro), já suas margens foram 44 MM (valor mínimo) e 7969 (valor máximo) relativo à taxa mensal.

Dando sequência utilizou-se o modelo de suavização de Holt Winters, é um método não paramétrico, possuindo a confiabilidade para observar a estabilidade dos dados quando há necessidade de previsões em modelagem de séries temporais que tenham sazonalidade, os dados corroboraram bem ao modelo, mostrando assim, sazonalidade ao longo da série.

Figura 9 – Gráfico dos dados ajustados através do método Holt-Winters para os dados da região metropolitana de Pernambuco.



Fonte: Produzido pelo autor

A predição multiplicativa de Holt-Winters é um método bastante popular para previsão, utilizado para dados com ciclos sazonais que aumenta com o tempo, resulta na predição com curva, que descreve alterações nos dados, observa-se na Figura 9 que a sazonalidade teve seus fatores nos anos de 2004 e 2011.

Tabela 4- Valores do modelo de Holt-Whinters multiplicativo para os dados de precipitação para região metropolitana de Pernambuco.

Método	$\alpha$	$\beta$	$\gamma$
HW multiplicativo	0,05	$2e^{-04}$	0,60


Fonte: Produzido pelo autor

A partir da Tabela 4 verifica-se o método de Holt-Winters nos dados que corroboram bem o ajuste. Usando os mesmos índices anteriormente na Tabela 1 em que demonstra-se que os

valores de alfa, beta e gamma estão no nível constante de suavização, a Tabela 4 demonstra todos os valores entre 0 e 1, gerando resultados que minimizam o valor aplicado ao modelo, critério para escolher a suavização.

O próximo passo é verificar as funções FAC (função de autocorrelação) e de FACP (função de autocorrelações parciais) são métodos que observa-se as correlações entre a série anterior (outubro e novembro, por exemplo). As precipitações na região metropolitana, o comportamento das funções para sazonalidade tendem apurar a escolha no modelo.

Figura 10 – Função de autocorrelações e autocorrelações parciais para os dados de precipitação da região metropolitana de Pernambuco.



Fonte: Produzido pelo autor


Na Figura 10, mostra que FAC (Função de Autocorrelações) tem vários picos passando do limite da margem tendo um decaimento forte comparando e ao mesmo tempo um crescimento, digno de uma sazonalidade, picos repetidos, já o FACP (Função de Autocorrelações Parciais) mostrou picos menores comparado ao FAC, mas também segue a sazonalidade com crescimento e decrescimento fora da margem de -0.2 e 0.2.

Observa-se na Figura 11, o procedimento para reconhecer o modelo que serão ajustados aos dados de precipitação na região metropolitana de Pernambuco, com a função de achar um modelo acessível aos dados. Desta maneira, foram adotados modelos com estruturas distintos para séries temporais da região metropolitana. Os resultados e a significância dos parâmetros partilhados para alguns fatores de efetividade do modelo. mantendo-se observações da Figura 11, conclui-se o modelo ARIMA, com parâmetros  $p, d$  e  $q$ , onde  $p$  é o modelo autorregressivo (AR),  $d$  número de médias móveis (MA). Observa-se os critérios adotados para os valores AIC (Critério de Informação AKAIKE) e BIC (Critério de Informação Bayesiana), tendo uma variabilidade estimadas entre os modelos.

Na Tabela 5 observa-se os erros de previsões: ME (Erro Médio), RMSE (Erro Quadrático Médio Raiz), MAE (Erro Médio Absoluto), MPE (Erro Percentual Médio), MAPE (Erro Médio de Percentual Absoluto) e MASE (Erro Médio Escalado Absoluto) que são calculados, na grandeza original da série, em atribuição dos parâmetros dos modelos ajustados no âmbito de



Figura 11 – Gráficos do correlograma e correlograma parcial para os dados de precipitação da região metropolitana de Pernambuco.



Fonte: Produzido pelo autor

Tabela 5- Erros de previsões para os dados de precipitação da região metropolitana de Pernambuco.

ME	RMSE	MAE	MPE	MAPE	MASE
3,69	85,93	44,95	0,03	0,48	0,99

Fonte: Produzido pelo autor

previsão h variando de acordo com os meses. Esses erros são contrapostos com as estimativas das variâncias para o mês que está sendo calculado. Observa-se o alisamento exponencial tem uma linha de algoritmo, essa linha de modelagem notacional nos espaços, notando-se que a aplicação gerou um erro de 4,50%.

Tabela 6- Critérios para escolha do modelo autoregressivo e médias móveis para os dados de precipitação da região metropolitana de Pernambuco.

Modelos	$\sigma^2$	EQM	AIC	BIC
ARIMA (2.0.2)	1399468	172,30	4085,72	4106,6

Fonte: Produzido pelo autor

Ajusta-se o método não estacionário para os dados de previsões em precipitações da região metropolitana foram o modelo ARIMA (Média Móvel Integrado Autorregresivo)(2,0,2), onde possui menores valores, tendo suas estimativas ( $\sigma^2$ ) teve uma redução estimativa que os Erros Quadráticos Médio (EQM), tendo o seguinte parâmetros:

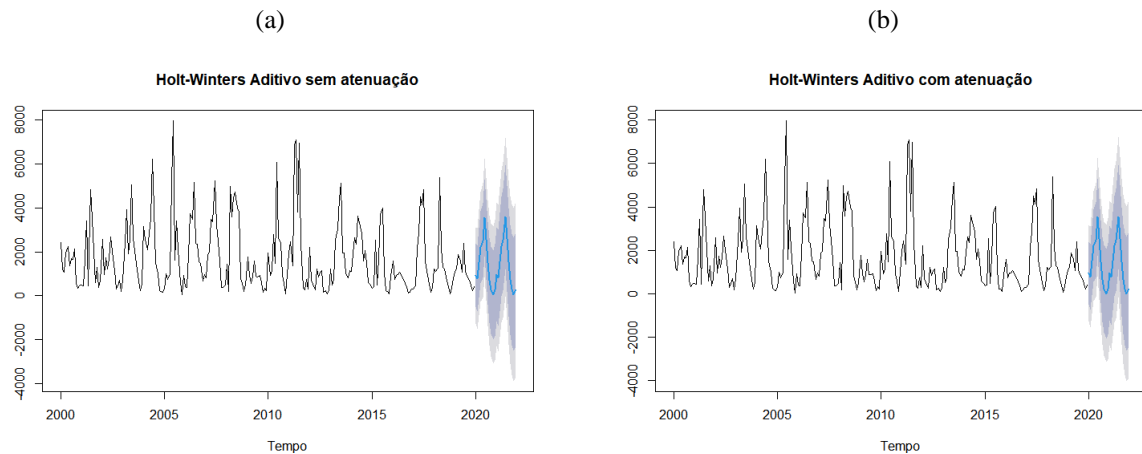
$$\hat{Z}_t = \hat{\phi} \times Z_{t-1} + \hat{\theta} \times Z_{(t-1+1)} - \hat{\theta} \times a_t + a_t$$

$$\hat{Z}_t = 0,0375 \times Z_{t-1} - 0,0067 \times Z_{(t-1)} - 0,9541 \times a_t \times a_t$$

Em seguida, apresenta-se um estudo mais aprofundado sobre análise de resíduos que corroboram os dados na forma adequada, os resíduos se distribuem aleatoriamente em volta de zero

com variância contínua, da mesma forma, que os resíduos tenham sua independência e possui uma distribuição normal. Este ajuste explica os modelos que viabilizaram os dados de precipitação da região metropolitana. O modelo selecionado, utilizando-se o teste de normalidade Shapiro-Wilk ( $W=0,4922$ ) e seu ( $p\text{-valor}=0,5275$ ), manter-se assim no patamar apeteçível(desejável). Sendo assim, não rejeitamos a hipótese nula da distribuição normal.

Figura 12 – Graficos de previsão sem e com atenuação de sazonalidade para os dados de precipitação da região metropolitana de Pernambuco.

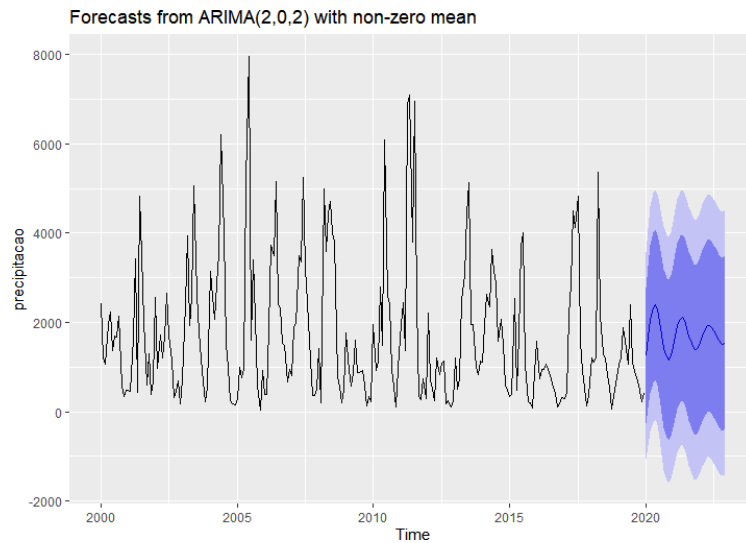


Fonte: Produzido pelo autor

Objetivamos o modelo para prever valores futuros com base nos valores do passado. Observa-se os dados originais da série na localidade da região metropolitana, os valores preditos têm como intervalo de confiança o valor original da série. Todavia o comportamento da série expõe uma previsão em volta da média acumulada com uma suavidade pequena, estes valores estão previstos com a observação da média, mas dentro da sazonalidade da série. Sua fórmula de previsão multiplicativo para região metropolitana:

$$F_{t+m} = (L_t + b_{t-m}) + S_{t-s+m}.$$

Figura 13 – Previsão anual para os próximos 5 anos para os dados de precipitação da região metropolitana de Pernambuco



Fonte: Produzido pelo autor

Observa-se que os valores da sazonalidade tem índice de queda que é notório a observação do comportamento descritivo, justifica-se uma maior amplitude, indicando assim, fatores que aparenta ser bem particular na região metropolitana de Pernambuco, pois na modelagem em séries temporais, as variações da temperatura para cidade como a capital e circunvizinhas do estado de Pernambuco. Observa-se tendência no aumento dos índices de precipitações da região metropolitana de Pernambuco, salienta-se que os valores relevantes, entretanto, o foco analisado tem índices significativos. Todavia, verifica-se que os índices no estado Pernambuco, observou que as precipitações volumosas, nesta região foram devidos a vários aspectos geográficos.

#### 4 CONCLUSÃO

Diante do apresentado, conclui-se que entre os anos 2000 a 2019 houve mudanças relativas das duas regiões estudada, conforme os critérios utilizados: AIC (Critério de informação Akaike), BIC (Critério de informação Bayesiana), EQM (Erros Quadráticos Médio) e  $\sigma^2$  o modelo ARIMA (Autorregressivo integrado de médias móveis) foi o mais adaptável para representar os dados das duas regiões, A região do sertão pernambucano, passou anos com o sofrimento em focos de queimadas acima da média tendo índices altos, mas com início do ano de 2012 teve uma queda drástica, graças a lei 12.651/25 de maio de 2012 onde tornou crime ambiental qualquer tipo de focos de queimadas ou queimadas que não fosse registrada ou liberada pelos órgãos competentes. Na região metropolitana a população sofre com a falta de planejamento para a chegada das chuvas, muitas áreas ocupadas de forma irregular, dragagem não sendo feito em lugares de escoamento das águas, fazendo assim, um constrangimento na estrutura da cidade. Seguindo a seleção dos modelos que teve melhor ajuste nos dados, verifica-se que a previsão no patamar esperado para os próximos cinco anos é de chuvas intensas.

## REFERÊNCIAS

- AIRES, L. S. d. S. et al. Avaliação espaço-temporal dos focos de calor e análise do risco de incêndios no município de rio verde-go. Instituto Federal Goiano, 2022. Citado na página 22.
- BAYER, D. M.; CASTRO, N. M. d. R.; BAYER, F. M. Modelagem e previsão de vazões médias mensais do rio potiribu utilizando modelos de séries temporais. *Rbrh: revista brasileira de recursos hídricos. Porto Alegre, RS. Vol. 17, n. 2 (abr./jun. 2012), p. 229-239*, 2012. Citado na página 19.
- BRASIL, . Ministério do meio ambiente. cidades sustentáveis. 2018. Citado na página 10.
- BRESSAN, A. A. Tomada de decisão em futuros agropecuários com modelos de previsão de séries temporais. *RAE eletrônica, SciELO Brasil*, v. 3, 2004. Citado na página 13.
- BROCKWELL, P. J.; DAVIS, R. A. *Introduction to time series and forecasting*. [S.l.]: Springer, 2002. Citado na página 16.
- CAMPOS, C. V. C. *Previsão da arrecadação de receitas federais: aplicações de modelos de séries temporais para o estado de São Paulo*. Tese (Doutorado) — Universidade de São Paulo, 2009. Citado na página 18.
- CHATFIELD, C. *The analysis of time series: an introduction*. [S.l.]: Chapman and hall/CRC, 2003. Citado na página 15.
- DUARTE, F. *Arquitetura e tecnologias de informação: da revolução industrial à revolução digital*. [S.l.]: Annablume, 1999. v. 97. Citado na página 11.
- EHLERS, R. S. Análise de séries temporais. *Laboratório de Estatística e Geoinformação. Universidade Federal do Paraná*, v. 1, p. 1–118, 2005. Citado 2 vezes nas páginas 15 e 20.
- FIGUEREDO, C. J. Previsão de séries temporais utilizando a metodologia box & jenkins e redes neurais para inicialização de planejamento e controle da produção. *Curitiba: UFPR*, 2008. Citado 2 vezes nas páginas 13 e 14.
- FISCHER, F.; FUCHS, J.; MANSMANN, F. Clockmap: Enhancing circular treemaps with temporal glyphs for time-series data. In: CITESEER. *EuroVis (Short Papers)*. [S.l.], 2012. Citado na página 13.
- FISCHER, S. *Séries univariantes de tempo-metodologia de Box & Jenkins*. [S.l.]: Fundação de Economia e Estatística, 1982. Citado na página 17.
- GOLDEMBERG, J.; LUCON, O. Energia e meio ambiente no brasil. *Estudos avançados, SciELO Brasil*, v. 21, p. 7–20, 2007. Citado na página 10.
- HENNING, E. et al. Uma breve visão sobre aplicações em ambiente r para o ensino de engenharia. In: *37o Congresso Brasileiro de Educação em Engenharia–Cobenge*. [S.l.: s.n.], 2009. Citado na página 18.
- HYNDMAN, R. J.; KHANDAKAR, Y. Automatic time series forecasting: the forecast package for r. *Journal of statistical software*, v. 27, p. 1–22, 2008. Citado 2 vezes nas páginas 18 e 25.
- LOPES, A. C. Sazonalidade em series temporais económicas uma introdução e duas contribuições. ISEG-CEMAPRE, 2007. Citado na página 13.

- LUNA, I.; BALLINI, R.; SOARES, S. Técnica de identificação de modelos lineares e não-lineares de séries temporais. *Sba: Controle & Automação Sociedade Brasileira de Automatica*, SciELO Brasil, v. 17, p. 245–256, 2006. Citado na página 21.
- MAGALHÃES, R.; VENDRAMINI, A. Os impactos da quarta revolução industrial. RAE Publicações, 2018. Citado na página 10.
- MAKRIDAKIS, S.; HIBON, M. Arma models and the box–jenkins methodology. *Journal of forecasting*, Wiley Online Library, v. 16, n. 3, p. 147–163, 1997. Citado na página 19.
- MARTIN, A. C. et al. Análise de séries temporais para previsão da evolução do número de automóveis no município de Joinville. *Revista ESPACIOS/ Vol. 37 (Nº 06) Año 2016*, 2016. Citado na página 16.
- MIRANDA, R. G. d. et al. Espaço admissível para os parâmetros do modelo de suavização exponencial com dupla sazonalidade aditivo. Florianópolis, SC, 2009. Citado na página 18.
- MONTGOMERY, D. C.; JENNINGS, C. L.; KULAHCI, M. *Introduction to time series analysis and forecasting*. [S.l.]: John Wiley & Sons, 2015. Citado na página 15.
- MORETTIN, P.; TOLOI, C. Análise de séries temporais—2ª edição revista e ampliada. *ABE–Projeto Fisher, Editora Edgar Blücher*, 2006. Citado 3 vezes nas páginas 15, 16 e 17.
- MORETTIN, P. A. *Modelos para previsão de séries temporais*. [S.l.]: Instituto de Matemática Pura e Aplicada, 1981. v. 1. Citado na página 13.
- MORETTIN, P. A. *Econometria financeira: um curso em séries temporais financeiras*. [S.l.]: Editora Blucher, 2017. Citado na página 20.
- MORETTIN, P. A.; TOLOI, C. M. *Análise de séries temporais: modelos lineares univariados*. [S.l.]: Editora Blucher, 1987. Citado 2 vezes nas páginas 14 e 21.
- MOTA, G. V.; ZIPSER, E. J. *Rainfall Estimates over South America*. Tese (Doutorado) — Department of Meteorology, University of Utah, 2002. Citado na página 28.
- OLIVEIRA, E. S. de; DOURADO, J. D. de A.; MELLO, J. A. V. B. Aplicação de modelos de previsão de demanda em uma fábrica de embalagens plásticas. *Revista da Universidade Vale do Rio Verde*, v. 15, n. 2, p. 354–373, 2017. Citado na página 22.
- OMS, . [eaax.com.br/qualidade-do-ar-conforme-conama-4912018](http://eaax.com.br/qualidade-do-ar-conforme-conama-4912018). 2005. Citado na página 10.
- OPAS. Organização pan-americana de saúde. *poluição do ar. brasil*, 2019. Citado na página 10.
- PERNAMBUCO, . Agência estadual de meio ambiente - cprh. *monitoramentodaqualidadedoar*. 2018. Citado na página 11.
- ROCHA, V. Modelo arima e previsão no r. disponível em: <https://www.monolitonimbus.com.br/modelo-arima-e-previsao-no-r/>. 2018. Citado na página 18.
- SILVA, A. B. d. S. et al. Modelo autorregressivo integrado de médias móveis (arima): aspectos conceituais e metodológicos e sua aplicabilidade na mortalidade infantil. *Revista Brasileira de Saúde Materno Infantil*, SciELO Brasil, v. 21, p. 647–656, 2021. Citado na página 19.

SILVA, F. d. S. et al. Tendência de alterações climáticas da precipitação observadas no Brasil de 1961 a 2008 utilizando dados gradeados. In: SBMET BELÉM. *XII Congresso Brasileiro de Meteorologia*. [S.l.], 2010. Citado na página 11.

SOUZA, E. F. M. de; PETERNELLI, L. A.; MELLO, M. P. de. Software livre r: aplicação estatística. 2014. Citado na página 18.

SOUZA, W. M.; AZEVEDO, P. V. Índices de detecção de mudanças climáticas derivados da precipitação pluviométrica e das temperaturas em Recife-PE (detection indexes derived from climate change rainfall and temperatures in Recife-PE). *Revista Brasileira de Geografia Física*, v. 5, n. 1, p. 143–159, 2012. Citado na página 10.

TIDRE, P. V.; BIASE, N. G.; SILVA, M. I. de S. Utilização dos modelos de séries temporais na previsão do consumo mensal de energia elétrica da região norte do Brasil. *Matemática e Estatística em Foco*, v. 1, n. 1, p. 57–66, 2013. Citado na página 22.

WANDERLEY, H. S. et al. Mudança no regime temporal da temperatura do ar e precipitação pluviométrica na região de Rio Largo, Alagoas. *Revista Brasileira de Geografia Física*, v. 7, n. 4, p. 662–667, 2014. Citado na página 28.

XAVIER, J. M. N. *Análise e previsão de séries temporais com modelos ARIMA e análise espectral singular*. Tese (Doutorado), 2016. Citado na página 20.