



UNIVERSIDADE FEDERAL DE OURO PRETO
INSTITUTO DE CIÊNCIAS EXATAS E BIOLÓGICAS
DEPARTAMENTO DE ESTATÍSTICA
BACHARELADO EM ESTATÍSTICA



**Roubos Consumados em Ouro Preto segundo os métodos
Alisamento Exponencial e SARIMA, um estudo do desempenho de
previsões**

Rogéria Lúcia Gerçóssimo Figueiredo

**Ouro Preto-MG
2022**

Rogéria Lúcia Gerçóssimo Figueiredo

Roubos Consumados em Ouro Preto segundo os métodos Alisamento Exponencial e SARIMA, um estudo do desempenho de previsões

Monografia de Graduação apresentada ao Departamento de Estatística do Instituto de Ciências Exatas e Biológicas da Universidade Federal de Ouro Preto como requisito parcial para a obtenção do grau de Bacharel em Estatística.

Orientador: Prof. Dr. Ivair Ramos Silva

Universidade Federal de Ouro Preto – UFOP

Departamento de Estatística – DEEST

**Ouro Preto-MG
2022**

SISBIN - SISTEMA DE BIBLIOTECAS E INFORMAÇÃO

F475r Figueiredo, Rogeria Lucia Gercossimo.
Roubos consumados em Ouro Preto segundo os métodos Alisamento Exponencial e SARIMA [manuscrito]: um estudo do desempenho de previsões. / Rogeria Lucia Gercossimo Figueiredo. - 2022.
45 f.: il.: color., gráf., tab..

Orientador: Prof. Dr. Ivair Ramos Silva.
Monografia (Bacharelado). Universidade Federal de Ouro Preto.
Instituto de Ciências Exatas e Biológicas. Graduação em Estatística .

1. Séries Temporais. 2. Previsões. 3. Alisamento Exponencial. 4. SARIMA. 5. Sazonalidade. I. Silva, Ivair Ramos. II. Universidade Federal de Ouro Preto. III. Título.

CDU 31

Bibliotecário(a) Responsável: Luciana De Oliveira - SIAPE: 1.937.800



FOLHA DE APROVAÇÃO

Rogéria Lúcia Gercóssimo Figueiredo

Roubos Consumados em Ouro Preto segundo os métodos Alisamento Exponencial, Regressão e sARIMA: um estudo do desempenho de previsões

Monografia apresentada ao Curso de Estatística da Universidade Federal de Ouro Preto como requisito parcial para obtenção do título de Bacharel em Estatística

Aprovada em 20 de outubro de 2022

Membros da banca

Dr Ivair Ramos Silva - Orientador (Universidade Federal de Ouro Preto)
Dr Fernando Luiz Pereira de Oliveira (Universidade Federal de Ouro Preto)
Dr Rivert Paulo Braga Oliveira (Universidade Federal de Ouro Preto)

Professor Dr. Ivair Ramos Silva, orientador do trabalho, aprovou a versão final e autorizou seu depósito na Biblioteca Digital de Trabalhos de Conclusão de Curso da UFOP em 20/10/2022



Documento assinado eletronicamente por **Ivair Ramos Silva, PROFESSOR DE MAGISTERIO SUPERIOR**, em 12/11/2022, às 01:07, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Flavio dos Reis Moura, PROFESSOR DE MAGISTERIO SUPERIOR**, em 29/11/2022, às 19:10, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **0413435** e o código CRC **CB7A7FC5**.

*"Dizem que antes de um rio entrar no mar,
ele treme de medo.*

*Olha para trás, para toda jornada que percorreu,
para os cumes, as montanhas, para o longo caminho
sinuoso que trilhou através de florestas e povoados,
e vê à sua frente um oceano tão vasto, que entrar nele
nada mais é do que desaparecer para sempre.*

Mas não há outra maneira.

O rio não pode voltar. Ninguém pode voltar.

Voltar é impossível na existência.

O rio precisa se arriscar e entrar no oceano.

*Somente ao entrar no oceano o medo irá desaparecer,
porque apenas então o rio saberá que não se trata de desaparecer no oceano,
mas de tornar-se oceano".*

(Osho, citando Khalil Gilbran)

Agradecimentos

Agradeço a mim, por, apesar de TUDO, não ter desistido! A todo o sagrado, por iluminar minha sabedoria e conduzir minha jornada. Aos meus ascendentes, Therezinha Álvaro Figueiredo e Pedro do Carmo Figueiredo, Maria Francisca Gerçóssimo Dutra e Mario de Magalhães Dutra, Maria de Lourdes Dutra Figueiredo e José Raimundo Figueiredo, que sempre me estimularam o aprendizado, me nutrindo e inspirando com garra e sabedorias multidisciplinares.

Fundamentais para que este sonho se tornasse realidade, foram os meus queridos amigos de jornada Luiz Claudio Diniz, Ronan David Souza Abreu, Jussara Pereira, Vinícius Starlino Rolim Ferreira, Milele Cássia, Andressa Freitas, que durante estes longos anos eu vivenciei a UFOP, tiveram papel fundamental para o meu crescimento enquanto profissional da estatística, bem como para me tornar um ser humano melhor para o mundo. Sou imensamente grata por ter convivido com cada um de vocês.

Aos professores do departamento de Estatística da UFOP, sou grata por toda referência, incentivo, compreensão e benevolência. Agradeço ao professor Ivair pela humanidade e profissionalismo transmitidos em sala de aula, desde o primeiro período, e principalmente ao longo da orientação deste trabalho.

Agradeço a todos os envolvidos na minha trajetória, em especial, ao meu prezado comandante Joilson Fernandes Bittencourt, quem me inspirou a trilhar pelos caminhos da estatística, ainda em meados de 2015, bem como, agradeço carinhosamente a todos os envolvidos na minha experiência na seção de Planejamento e Controle Operacional, em especial aos “melhores P3 do Brasil” o Sr. Major Giovanni Sebastião Mendes, Sr. Cap Patrício Santos de Oliveira, Sr. Sargento Marcos Barbosa e Sra Cb Sabrina Marcia Sena de Araújo, que foram fundamentais para a execução deste trabalho, assim como agradeço o apoio genuíno da minha amiga Priscilla Margareth Moreira Almeida em todo o processo.

Finalizo, agradecendo ao trabalho impecável da psicóloga Tânia Ferreira que semanalmente vem me ajudando a alinhar minhas condutas e a conduzir os meus pensamentos me baseando em dados e fatos, conduzindo o meu tratamento de forma concisa, com resultados surpreendentes e fundamentais para a conclusão deste ciclo.

Agradeço a todos os que acreditaram!

“Sem dados você é apenas mais uma pessoa com uma opinião.”

William Edwards Deming

Roubos Consumados em Ouro Preto segundo os métodos Alisamento Exponencial e SARIMA, um estudo do desempenho de previsões

Autor: Rogéria Lúcia Gerçóssimo Figueiredo Orientador: Dr. Ivair Ramos Silva

RESUMO

Realizar previsões é apenas uma dentre as diversas formas de utilização dos modelos ajustado à série temporal, permitindo o fornecimento de informações para tomadas de decisão, no estudo em questão direcionado especificamente para ações em Segurança Pública, a qual já tem por rotina, o acompanhamento da evolução das naturezas criminais ao longo dos anos. Entretanto, o aprimoramento das previsões proposto por este estudo oferece melhoria de informações, possibilitando, assim, melhoria de gestão, abrindo caminhos para novas estratégias e ações para controle dos roubos consumados na cidade, que possui características atípicas e instigantes.

A escolha do melhor modelo, entretanto, não é trivial, dadas as peculiaridades da série e existem várias formas de se verificar se modelo se adequa aos dados, baseadas nos erros de previsão.

Uma opção é combinar previsões feitas por modelos distintos; acredita-se que, retirando informações de vários modelos de previsão e Técnicas Descritivas combinando-os, podem-se compensar as fraquezas de cada um e assim obter uma melhor previsão, ou seja, menores erros de previsão [Lemke e Gabrys, 2010].

A partir do detalhamento das especificidades de cada um dos métodos Alisamento Exponencial e SARIMA, verificaremos qual deles apresenta melhor desempenho para a Série de Dados analisada .

Palavras-chave: Séries Temporais, Previsões, Alisamento Exponencial, SARIMA, Roubos Consumados, Sazonalidade, Ouro Preto

1. SUMÁRIO

1.	SUMÁRIO	16
2.	INDICE DE FIGURAS	17
3.	INTRODUÇÃO	19
3.1	Roubo Consumado	20
3.2	Análise Descritiva	21
3.3	Motivação	23
3.4	Objetivos	23
3.5	Contribuições	23
4.	FUNDAMENTAÇÃO TEÓRICA	24
5.	METODO ALISAMENTO EXPONENCIAL	30
5.1	MODELO DE HOLT-WINTERS	31
5.1.1	MODELO 1 – NÍVEL	31
5.1.2	MODELO 2 – NÍVEL E TENDÊNCIA	33
5.1.3	MODELO 3 – NÍVEL, TENDÊNCIA E SAZONALIDADE ADITIVA	36
5.1.4	MODELO 4 NÍVEL, TENDÊNCIA E SAZONALIDADE MULTIPLICATIVA	39
6.	METODO SARIMA	41
7.	RESULTADOS	49
8.	CONSIDERAÇÕES FINAIS	51

2. INDICE DE FIGURAS

Figura 1 Roubo Consumado em Ouro Preto 2012 a 2022	20
Figura 2 Gráfico de Correlação Série Roubo Consumado	21
Figura 3 Histograma da Série Roubo Consumado	21
Figura 4 Gráfico BoxPlot Série Roubo Consumado	22
Figura 5 Gráficos separado por anos	22
Figura 6 Gráficos Boxplot por anos	22
Figura 7 Gráficos Boxplot por meses	26
Figura 8 Gráfico de Dispersão - Sazonalidade da Série Roubo Consumados	26
Figura 9 - Saída do Software R referente ao Teste de Sazonalidade do Método de Morray	27
Figura 10 Processo de Diferenciação da Série	28
Figura 11 Gráfico Radar	29
Figura 12 Modelo Holt-Winters	32
Figura 13 Previsões Modelo Holt-Winters (Nível)	32
Figura 14 Gráfico Linha Resíduos Modelo Holt-Winters (Nível)	33
Figura 15 Gráfico Dispersão Resíduos Modelo Holt-Winters (Nível)	33
Figura 16 Modelo Holt-Winters (Nível e Tendência)	34
Figura 17 Previsões Modelo Holt-Winters (Nível e Tendência)	34
Figura 18 Gráfico Linha dos Resíduos Modelo Holt-Winters (Nível e Tendência)	35
Figura 19 Gráfico Dispersão Resíduos Modelo Holt-Winters (Nível e Tendência)	35
Figura 20 Histograma Resíduos Modelo Holt-Winters (Nível e Tendência)	35
Figura 21 Modelo Holt-Winters (Nível, Tendência e Sazonalidade Aditiva)	36
Figura 22 Previsões do Modelo Holt-Winters (Nível, Tendência e Sazonalidade Aditiva)	37
Figura 23 Gráfico Linha dos Resíduos Modelo Holt-Winters (Nível, Tendência e Sazonalidade Aditiva)	37
Figura 24 Gráfico Dispersão dos Resíduos Modelo Holt-Winters (Nível, Tendência e Sazonalidade Aditiva)	38
Figura 25 Histograma dos Resíduos Modelo Holt-Winters (Nível, Tendência e Sazonalidade Aditiva)	38
Figura 26 Modelo Holt-Winters (Nível, Tendência e Sazonalidade Multiplicativa)	39
Figura 27 Previsões do Modelo Holt-Winters (Nível, Tendência e Sazonalidade Multiplicativa)	40
Figura 28 Gráfico Dispersão dos Resíduos Modelo Holt-Winters (Nível, Tendência e Sazonalidade Multiplicativa)	40

Figura 29 Histograma Resíduos do Modelo Holt-Winters (Nível, Tendência e Sazonalidade Multiplicativa)	41
Figura 30 Gráfico Boxcox Série Roubo Consumado	42
Figura 31 Série Transformada (Estacionarizada)	43
Figura 32 Gráfico Boxcox Série Transformada	43
Figura 33 Saída Software R Estacionaridade – SARIMA	44
Figura 34 Função autocorrelação	45
Figura 35 Função autocorrelação parcial	45
Figura 36 Gráficos de Resíduos SARIMA	46
Figura 37 Periodograma	46
Figura 38 Saída do Software R Modelo SARIMA (0,1,1)(1,0,0) ₁₂	47
Figura 39 Funções autocorrelação e Autocorrelação parcial do Modelo SARIMA (0,1,1)(1,0,0) ₁₂	47
Figura 40 Previsões do Modelo SARIMA (0,1,1)(1,0,0) ₁₂	48
Figura 41 Gráfico de Resíduos SARIMA(0,1,1)(1,0,0) ₁₂	48
Figura 42 Saída do Software R Modelo AUTO ARIMA	49
Figura 43 Resumo - Resultados dos Métodos Alisamento Exponencial	49
Figura 44 Método Alisamento Exponencial – NÍVEL, TENDÊNCIA E SAZONALIDADE ADITIVA	50
Figura 45 Método SARIMA - Modelo proposto: SARIMA(0,1,1)(1,0,0) ₁₂	50
Figura 46 Série de Roubo Consumado em Ouro Preto atualizado até agosto 2022	51

3. INTRODUÇÃO

Analisar empiricamente fenômenos criminais, através de indicadores de desempenho e procedimentos padrões para controle e acompanhamento, bem como de análises de evoluções ao longo de períodos pré-determinados e de setores específicos que apresentavam suas particularidades socio-econômicas e culturais através dos gráficos fazia parte da minha rotina, até que o meu superior imediato, na época Cap PM Joilson, hoje Tenente Coronel, e atual comandante desta mesma unidade militar em que trabalho, em oportuno momento me orientou a olhar com mais carinho para o curso de estatística ofertado pela UFOP, em detrimento da Engenharia de Produção que era a opção que eu cogitava no momento.

Sou Servidora Pública do Estado, atuo no 52º Batalhão da Polícia Militar desde 2015, e mediante o tempo em que trabalhei empiricamente com os dados da segurança pública fui verificando algumas naturezas de ocorrências criminais que considerei de maior significância e interesse para a confecção de estudos ao longo da minha graduação, inclusive para a confecção deste trabalho.

A série analisada faz referência aos Roubos Consumados na Cidade de Ouro Preto, extraída do portal Dados Abertos da Secretaria de Segurança Pública e Justiça de Minas Gerais, onde são computados todas as ocorrências das esferas policiais de forma geral, e não somente os dados registrados pela Polícia Militar e dentre os dados de criminalidade violenta foram filtrados somente os dados da natureza do crime de Roubo na modalidade Consumado ocorridos no município de Ouro Preto no Período de janeiro de 2012 a fevereiro de 2022, agrupados por meses, totalizando 123 registros.

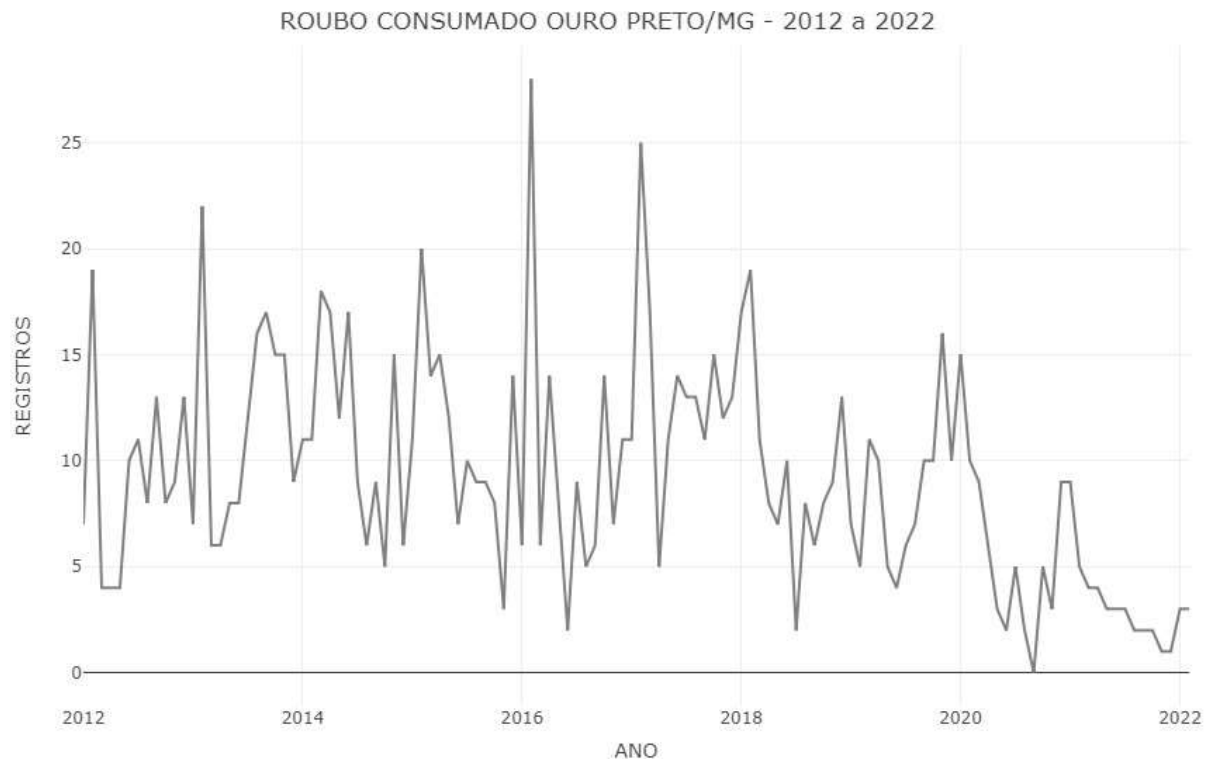


Figura 1 Roubo Consumado em Ouro Preto 2012 a 2022

Analisando apenas visualmente o gráfico, aparentemente trata-se de uma série estacionária, entretanto, há uma tendência de redução significativa de 2020 até 2022, com índices nunca registrados entre os anos 2012 até o ano de 2020. Cabendo, entretanto, ressaltar tratar-se evidentemente de uma quebra estrutural de dados em virtude da Pandemia.

3.1 Roubo Consumado

Contextualizando, brevemente, o crime de Roubo, conhecido “artigo 157” do Código Penal Brasileiro, é definido pelo ato de subtrair coisa móvel alheia, para si ou para outrem, mediante grave ameaça ou violência a pessoa, ou depois de havê-la, por qualquer meio, reduzido à impossibilidade de resistência cuja pena é a detenção, de 1 (um) a 4 (quatro) anos, e multa. (Incluído pela Lei nº 9.983, de 2000). Quanto a opção de análise somente pela modalidade de roubo consumado, me baseio na súmula 582 do STJ, que esclarece sobre as tratativas de inversão de posse, ainda que por breve tempo e em seguida à perseguição imediata ao agente e recuperação da coisa roubada, sendo prescindível a posse mansa e pacífica ou desvigiada, se configuram como crime de Roubo Consumado, sendo suficiente para a intencionalidade com esta pesquisa.

3.2 Análise Descritiva

A série analisada apresenta média e mediana de 9 registros, com um desvio padrão de 5,3039 e um p-valor de 0,001442., e, portanto, apesar de muito aproximar-se, assume-se que os dados não são normalmente distribuídos. A diferença entre a amostra de dados e a distribuição normal é grande o suficiente para ser estatisticamente significativa. O valor máximo foram 28 registros de roubo no mês, enquanto o valor mínimo foi nenhum registro. Esta nulidade de registro corroborou para alguns problemas em aplicação de fórmulas, necessitando portanto, substituir o valor “0” por “ 10^{-10} ” a fim de possibilitar a modelagem




Figura 2 Gráfico de Correlação Série Roubo Consumado

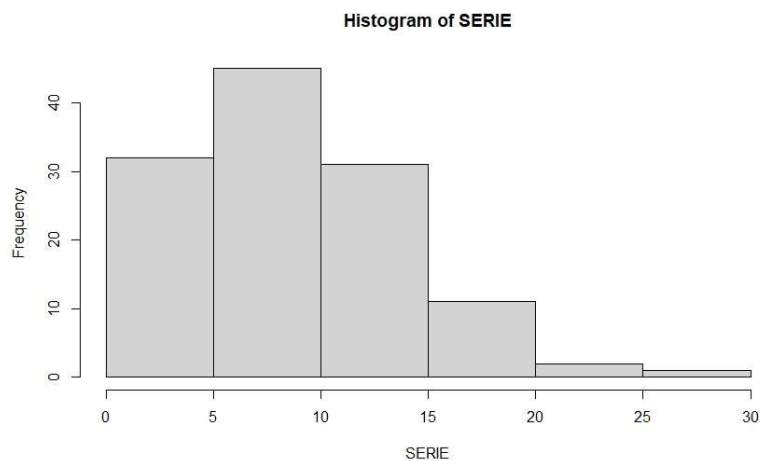


Figura 3 Histograma da Série Roubo Consumado




Figura 4 Gráfico BoxPlot Série Roubo Consumado

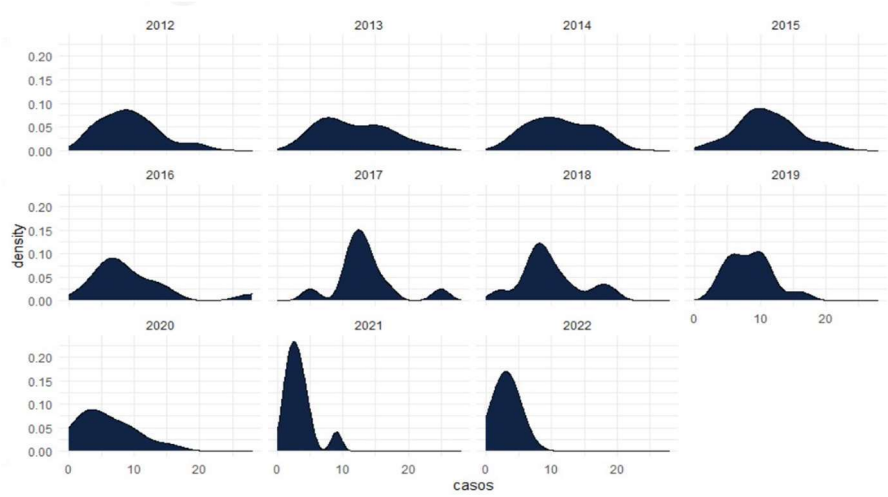


Figura 5 Gráficos separado por anos




Figura 6 Gráficos Boxplot por anos

3.3 Motivação

Aplicação de análises e técnicas para verificar o modelo que melhor se adequa a série de Roubos Consumados da Cidade Ouro Preto, que conta com uma população de aproximadamente 1 245,865 km² e 75 mil habitantes distribuídos em seus 12 distritos marcadamente definidos por suas características interioranas é a motivação principal deste estudo. O aprimoramento das previsões proposto por este estudo oferece melhoria de informações, possibilitando, assim, melhoria de gestão, abrindo caminhos para novas estratégias e ações para controle do fenômeno em questão.

3.4 Objetivos

3.4.1 Objetivo Geral

Verificar dentre os métodos propostos o que melhor se aplica para se realizar previsões para a série temporal de Roubo Consumado em Ouro Preto

3.4.2 Objetivo Específico

Detalhar as especificidades dos métodos Alisamento Exponencial, e SARIMA e verificar qual deles apresenta melhor desempenho para se realizar previsões de acordo com as peculiaridades da Série de Roubo Consumado em Ouro Preto.

3.5 Contribuições

Aprimorar técnicas de controle de previsões, a princípio, no âmbito da unidade em que trabalho, uma vez que, a realidade enfrentada pela segurança pública na cidade é bem diferente da teórica, dado que somente a Universidade Federal de Ouro Preto corrobora com a vivência de uma quantidade significativa de moradores na sede do município, sendo importante ressaltar também as características patrimoniais, culturais e turísticas da cidade que atraem um perfil de população flutuante diário e sazonal, não contabilizado no IBGE, significativo nas parametrizações deste estudo de forma geral, dentre eles, por exemplo,

posso citar o evento do Carnaval. Ensejo também colaborar com o desenvolvimento das pesquisas na comunidade científica e com o desenvolvimento de ações no âmbito da segurança pública de maneira geral.

4. FUNDAMENTAÇÃO TEÓRICA

Conjuntos de dados ordenados no tempo constituem uma série temporal, que é um campo de estudo que desenvolve técnicas específicas, que levam em consideração esta especificidade dos dados. Analisar previamente algumas características são imprescindíveis para a correta modelagem da série, dentre elas temos os critérios de normalidade, estacionaridade, tendência, sazonalidade ou ciclos, que são padrões que podem, inclusive, ser encontrados de forma combinada em uma série. Para otimizar o desenvolvimento deste estudo, vou me concentrar somente nas características alusivas a série em questão.

Dado o caráter comparativo do trabalho em questão, esclareço previamente que o critério estabelecido para mensurar o desempenho das previsões, conforme proposto como objetivo desta pesquisa será a avaliação da medida de Erro Quadrático Médio (MSE), mediante avaliação empírica da acurácia dos modelos propostos.

1. Normalidade

Pressupondo que a maioria dos modelos de série temporais existentes se fundamentam em distribuição Normal, é de suma importância compreender subjetivamente o contexto e a fonte dos dados analisados, pensar em transformações, para reduzir, por exemplo, assimetrias. A distribuição Normal caracteriza-se por possuir média, mediana e moda iguais, bem como, possui gráfico em forma de sino e é simétrica em torno da média, cabendo ressaltar que a curvatura distribuição do gráfico muda a medida que a média mais ou menos o desvio padrão forem modificados.

Para casos em que a distribuição assimétrica positiva ou a variação da série cresce com a média, ambos visualizados graficamente, por histograma e por gráficos de linha, uma alternativa amplamente utilizada é a transformação logarítmica $\log(.)$

2. Estacionaridade

Diz-se de uma série temporal estacionária, aquela que se desenvolve no tempo aleatoriamente ao redor de uma média constante, refletindo alguma forma de

equilíbrio estável. A maior parte das séries, entretanto, apresentam alguma forma de não-estacionaridade, assim como a série apresentada neste estudo, uma vez que visualmente já nota-se uma tendência de redução.

O uso de séries não estacionárias pode resultar em regressões lineares aparentemente muito bem ajustadas, mas que, para mencionar um dos problemas, possuem resíduos altamente correlacionados, o que viola as hipóteses do modelo clássico ... Tais valores, em sua grande maioria, são obtidos pelo método de Monte Carlo, que grosso modo, se resume na geração de cenários aleatórios em grande número para através destes gerar intervalos de confiança ou estimativas pontuais. (FGV)

3. Sazonalidade

Fenômenos que ocorrem regularmente de ano para ano, como pode ser facilmente identificado nesta série, são considerados como eventos sazonais. Empiricamente, analisando visualmente o gráfico, é possível identificar picos de registros de ocorrências de Roubo Consumados na cidade sempre nos mesmos períodos, evidenciando a sua característica sazonal bem determinada. Entretanto, existem procedimentos tal finalidade, sendo o método de Regressão e o Método de Médias Móveis, os mais usuais para se estimar com precisão a existência de sazonalidade. Uma outra alternativa amplamente utilizada é incorporar a variação sazonal e a tendência em um modelo ARIMA.

Sazonalidade é qualquer tipo de comportamento recorrente no qual a frequência é estável. Pode ocorrer em muitas frequências diferentes e ao mesmo tempo. AILEEN

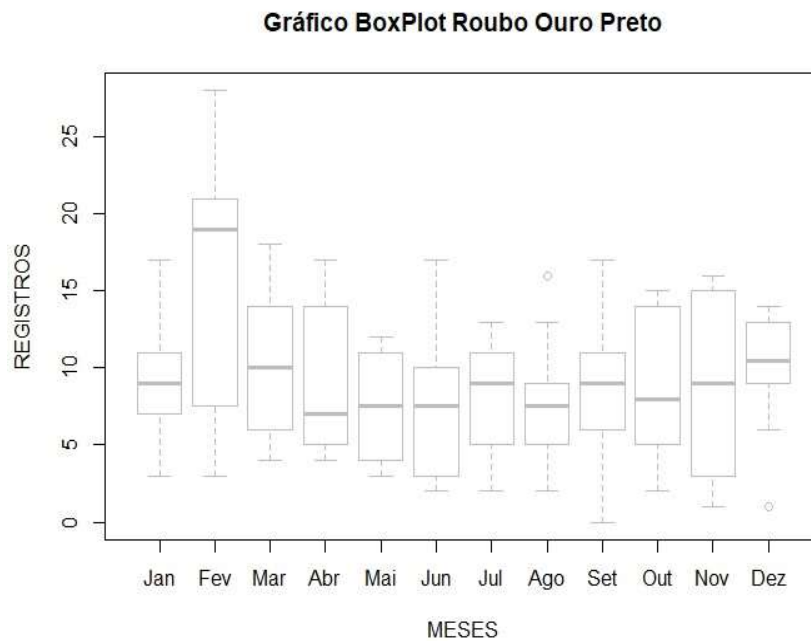


Figura 7 Gráficos Boxplot por meses




Figura 8 Gráfico de Dispersão - Sazonalidade da Série Roubo Consumados

De acordo com o gráfico box plot, existem fortes indícios de sazonalidade no mês de fevereiro, e o gráfico de dispersão, a julgar visualmente, demonstra que a serie apresenta uma sazonalidade do tipo aditiva. Com base no teste de Morry não existe evidências significativas para rejeitarmos H_0 . Logo, pode-se afirmar que a série possui uma sazonalidade aditiva.

método de Morray (1975)

Para este teste consideramos:

H0:A série temporal possui sazonalidade aditiva

H1:A série temporal não possui sazonalidade aditiva

```
mod1<- lm(si~ti)
```

```
summary(mod1)
```

```
Call:
lm(formula = si ~ ti)

Residuals:
    Min       1Q   Median       3Q      Max
-0.9623 -0.4808 -0.2271  0.4120  2.1332

Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept)  0.74887    0.80122   0.935   0.3744
ti           0.26714    0.08537   3.129   0.0121 *
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.9144 on 9 degrees of freedom
Multiple R-squared:  0.5211,    Adjusted R-squared:  0.4678
F-statistic: 9.791 on 1 and 9 DF,  p-value: 0.01214
```

Figura 9 - Saída do Software R referente ao Teste de Sazonalidade do Método de Morray

4. Diferenciação

Diferenciação é a conversão de uma série temporal de valores em uma série temporal de mudanças nos valores ao longo do tempo. Na maioria das vezes, isso é feito calculando as diferenças de pares de pontos adjacentes no tempo, de modo que o valor da série diferenciada em um tempo t é o valor no tempo t menos o valor no tempo $t - 1$. No entanto, a diferenciação também pode ser realizada em diferentes janelas de lag, conforme conveniente.

AILEEN

```
#1 DIFERENCIAÇÃO
```

```
x1 = diff(SERIE,lag = 1 , differences = 1)
```

```
ts_plot(x1,
```

```
  title = "1ª DIFERENÇA ROUBO OURO PRETO",
```

```
  Xtitle = "ANO",
```

```
  Ytitle = "REGISTROS",
```

```
  slider = FALSE,
```

```
  color = "GRAY",
```

```
  Xgrid = TRUE, Ygrid = TRUE,
```

```
  line.mode = "lines")
```



```
#2 DIFERENCIAÇÃO
```

```
x2 = diff(SERIE,lag = 1 , differences = 2)
```

```
ts_plot(x2,
```

```
  title = "2ª DIFERENÇA ROUBO OURO PRETO",
```

```
  Xtitle = "ANO",
```

```
  Ytitle = "REGISTROS",
```

```
  slider = FALSE,
```

```
  color = "GRAY",
```

```
  Xgrid = TRUE, Ygrid = TRUE,
```

```
  line.mode = "lines")
```



Figura 10 Processo de Diferenciação da Série

Aparentemente trata-se de uma série estacionária, conforme verificação visual em ambos os gráficos.

Todavia, a diferenciação da série é uma transformação forte do processo que, se feito sem necessidade, induz a análises e modelagens equivocadas. FGV

5. Heterocedasticidade

A heterocedasticidade indica que os erros de previsão são diferentes para diferentes amplitudes de valores previstos, e pode sugerir um modelo incompleto. Por exemplo, a heteroscedasticidade em Im_98105 pode indicar que a regressão deixou algo não contabilizado para casas em amplitudes baixas e altas. Capítulo 4 – Testado as suposições: Diagnóstico de Regressão Estatística Prática para Cientista de Dados Peter Bruce & Andrew Bruce]

6. Processo Estocástico

Um processo estocástico $Z = (Z(t) : t \in T)$ é estacionário no sentido amplo ou estacionário de segunda ordem se e somente se:

- $E\{Z_t\} = E_t = \mu$, constante, para todo $t \in T$;
- $E\{Z^2_t\} = C < \infty$, para todo $t \in T$;
- $\gamma(t_1, t_2) = \text{Cov}\{Z_{t_1}, Z_{t_2}\}$ é uma função de $|t_1 - t_2|$,

Leiliane da Silva Oliveira Um Estudo Empírico do Desempenho de Combinações de Previsões

Ainda, segundo os autores Morettin, Pedro e Toloi, Celia, para séries cuja sazonalidade é estocástica, ou seja, o componente sazonal varia com o tempo, o método de análise mais apropriado é o Método de Médias Móveis. Sendo válido ressaltar que trata-se de um procedimento usualmente aplicado para padrões sazonais constantes. [Pag 70 livro novo morettin~]




Figura 11 Gráfico Radar

7. Ruído Branco

Trata-se de uma série residual que surge posteriormente ao ajuste de um modelo de uma série temporal estacionária, desde que as variáveis aleatórias sejam independentes e identicamente distribuídas (iid) com média zero,

$$X_t = f(\cdot) + \varepsilon$$

8. Autocorrelação

Autocorrelação varia entre -1 e 1 para uma perfeita correlação linear negativa e positiva respectivamente, e caso seja igual a zero, significa que as variáveis são independentes. Coeficiente de Correlação é parâmetro “h” para os valores de autocorrelação. O coeficiente de Determinação é equivalente ao quadrado do coeficiente de correlação, R^2 ou Coeficiente de Pearson.

5. METODO ALISAMENTO EXPONENCIAL

Através do método de Alisamento Exponencial é possível determinar um padrão de comportamento esperado para a série por meio da suavização dos extremos, uma vez que este pertence a classe dos métodos de previsão que reconhecem um padrão de fenômenos por meio da suavização das flutuações. Em sua maioria, os métodos de previsão fundamentam-se na ideia de que os dados obtidos no passado explicam o padrão comportamental da série, permitindo, portanto, fazer desta forma inferências futuras. Para tanto, é preciso supor uma série sem tendência e sem sazonalidade.

O modelo de amortecimento exponencial simples pode, ainda, ser interpretado como uma correção da previsão, a cada passo, pela parcela do último erro observado. Em outras palavras, se o último erro de previsão foi positivo (ou seja, o valor observado foi maior do que o previsto), a próxima previsão será aumentada de uma parcela deste erro; se o erro foi negativo (ou seja, o valor observado foi menor que o previsto), a próxima previsão será reduzida de uma parcela deste erro, [Hippert, 2010].

Nos modelos de previsão de amortecimento exponencial adota-se a suposição de que as observações são independentes, mas na prática a maioria das séries temporais apresentam dependência entre seus valores observados, e conseqüentemente os erros não serão independentes.

O parâmetro alpha determina o NÍVEL de suavização da série temporal. Portanto, o trabalho fundamental para ajustar o modelo de suavização exponencial simples é calibrar o alpha, reduzindo os erros da série. Se alpha tende a 1, existirá pouca suavização e o nível at seguirá “de perto” a série temporal x_t , entretanto, se alpha tende a 0, existirá muita suavização, ou pouca influência da corrente observação na estimativa da média.

Como α pode assumir qualquer valor entre 0 e 1, é interessante conhecer seu efeito. Se o valor de α é pequeno, o decaimento dos pesos ϕ_k é lento, ou seja, a observação mais recente não recebe muito mais peso que as observações mais antigas; se α é grande, a observação mais recente recebe muito peso, e as antigas pouco [Barros, 2011]

Entretanto, o Modelo de Alisamento Exponencial simples trata-se de um modelo que despreza a tendência e o efeito sazonal, o que não corrobora, portanto, para que seja apropriado para análise da série de Roubo consumado em questão. Mas, têm-se nesta mesma linha de estudos um modelo desenvolvido que torna possível esta análise, o Modelo de Holt- Winters.

5.1 MODELO DE HOLT-WINTERS

O modelo de Holt Winters trata-se de uma forma de expansão do modelo de alisamento exponencial simples o qual desenvolveu uma forma de acrescentar a tendência, ou, inclinação, e o efeito de sazonalidade, possuindo, portanto, três parâmetros de suavização (α , β e γ) e não somente α , como no alisamento exponencial simples. Em que b é chamado de inclinação e s é o efeito sazonal. O índice p associado ao efeito sazonal indica o tamanho da estação.

5.1.1 MODELO 1 – NÍVEL

O Comando utilizado no software `r` para realizar o alisamento exponencial simples, adequados para séries estacionárias sem sazonalidade foi o `HoltWinters(SERIE, beta=FALSE, gamma=FALSE)`. O nível de suavização da série temporal, estimado pelo modelo foi α : 0.1691362, o que induz existirá muita suavização, ou pouca influência da corrente observação na estimativa da média.

Holt-Winters exponential smoothing without trend and without seasonal component.

Call: `HoltWinters(x = SERIE, beta = FALSE, gamma = FALSE)`

Smoothing parameters: α : 0.1691362 β : FALSE γ : FALSE

Coefficients: [,1] a 2.726531

Valor estimado para o α : 0.1691362




Figura 12 Modelo Holt-Winters

A soma dos erros quadráticos entre valores observados e valores ajustados foi realizada através do comando “fit1\$SSE” do software r , retornando o valor 2695.544.

Para o cálculo de previsões para um horizonte de 12 meses, foi utilizado o pacote forecast(fit1, h=12), ressaltando que a função retorna não apenas a previsão pontual, mas também os

intervalos de confiança para as previsões de confiança 80% e 95%.




Figura 13 Previsões Modelo Holt-Winters (Nível)




Figura 14 Gráfico Linha Resíduos Modelo Holt-Winters (Nível)




Figura 15 Gráfico Dispersão Resíduos Modelo Holt-Winters (Nível)

5.1.2 MODELO 2 – NÍVEL E TENDÊNCIA

O Comando utilizado no software r para realizar o alisamento exponencial simples, adequado para séries estacionárias com tendência, mas sem sazonalidade foi “HoltWinters(SERIE, gamma=FALSE)”, onde a mesma função é utilizada novamente, entretanto apenas o input "gamma" é colocado como "FALSE". O nível de suavização

da série temporal, estimado pelo modelo foi α : 0.6395145 e β : 0.2561438, o que induz existirá menor suavização, ou maior influência da corrente observação na estimativa da média. Coefficients: [,1] a 2.695327 b 0.174337

No gráfico, podem ser visualizados os valores ajustados frente aos valores observados, ajustado em vermelho. Soma dos erros quadráticos entre valores observados e valores ajustados, 4603.912.




Figura 16 Modelo Holt-Winters (Nível e Tendência)

Para as previsões em um horizonte de 12 meses, utilizando o comando `forecast(fit2, h=12)` a função retorna não apenas a previsão pontual, mas também os intervalos de confiança para as previsões de confiança 80% e 95%, obtivemos




Figura 17 Previsões Modelo Holt-Winters (Nível e Tendência)




Figura 18 Gráfico Linha dos Resíduos Modelo Holt-Winters (Nível e Tendência)




Figura 19 Gráfico Dispersão Resíduos Modelo Holt-Winters (Nível e Tendência)

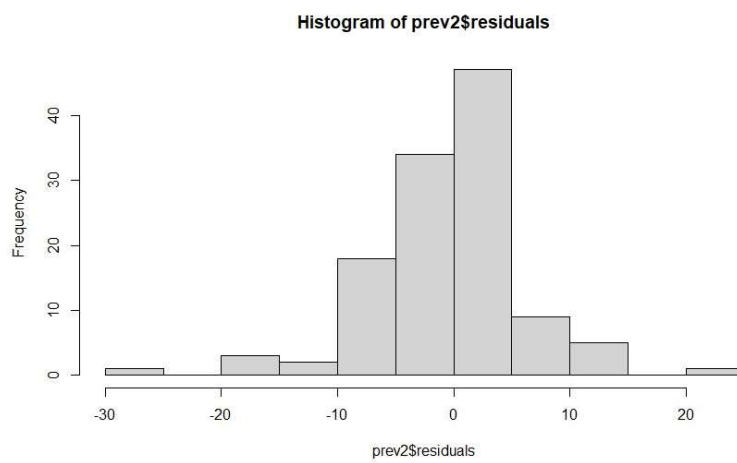


Figura 20 Histograma Resíduos Modelo Holt-Winters (Nível e Tendência)

5.1.3 MODELO 3 – NÍVEL, TENDÊNCIA E SAZONALIDADE ADITIVA

O Comando utilizado no software r para realizar o alisamento exponencial simples, adequado para séries estacionárias com tendência e sazonalidade do tipo aditiva foi “HoltWinters(SERIE)”, onde a mesma função é utilizada novamente, entretanto todos os parâmetros são colocado como "VERDADEIROS", implicitamente. O nível de suavização da série temporal, estimado pelo modelo parameters: alpha: 0.1806263 beta : 0.03683584 e gamma: 0.3383343, o que induz existirá elevada suavização, ou seja, menor influência da corrente observação na estimativa da média. Coefficients: [,1] a 2.2178821 b -0.2025339




Figura 21 Modelo Holt-Winters (Nível, Tendência e Sazonalidade Aditiva)

No gráfico, podem ser visualizados os valores ajustados frente aos valores observados, ajustado em vermelho. Soma dos erros quadráticos entre valores observados e valores ajustados, 2530.603.

Previsões para um horizonte de 12 meses, comando “forecast(fit3, h=12)”, onde a função retorna não apenas a previsão pontual, mas também os intervalos de confiança para as previsões de confiança 80% e 95%.

Forecasts from HoltWinters




Figura 22 Previsões do Modelo Holt-Winters (Nível, Tendência e Sazonalidade Aditiva)




Figura 23 Gráfico Linha dos Resíduos Modelo Holt-Winters (Nível, Tendência e Sazonalidade Aditiva)




Figura 24 Gráfico Dispersão dos Resíduos Modelo Holt-Winters (Nível, Tendência e Sazonalidade Aditiva)




Figura 25 Histograma dos Resíduos Modelo Holt-Winters (Nível, Tendência e Sazonalidade Aditiva)

shapiro.test(prev3\$residuals) # H0: os dados seguem uma distribuição normal
 data: prev3\$residuals W = 0.98584, p-value = 0.2994

5.1.4 MODELO 4 NÍVEL, TENDÊNCIA E SAZONALIDADE MULTIPLICATIVA

O Comando utilizado no software r para realizar o alisamento exponencia, adequado para séries estacionárias com tendência e sazonalidade do tipo multiplicativa é exatamente o mesmo "HoltWinters(SERIE)", utilizado nas demais alternativas, entretanto, para tratar a especificidade da sazonalidade, é acrescentado o o input "seasonal", que por default vale "additive", mas agora o fixaremos igual a "multiplicative", e, novamente todos os parâmetros são colocado como "VERDADEIROS", implicitamente. O nível de suavização da série temporal, estimado pelo modelo parameters: alpha: 0.1554 beta : 0.0045 e gamma: 1e-04,

No gráfico, podem ser visualizados os valores ajustados frente aos valores observados, ajustado em vermelho. Soma dos erros quadráticos entre valores observados e valores ajustados, 3299,725.

Previsões para um horizonte de 12 meses, comando "forecast(fit4, h=12), onde a função retorna não apenas a previsão pontual, mas também os intervalos de confiança para as previsões de confiança 80% e 95%.

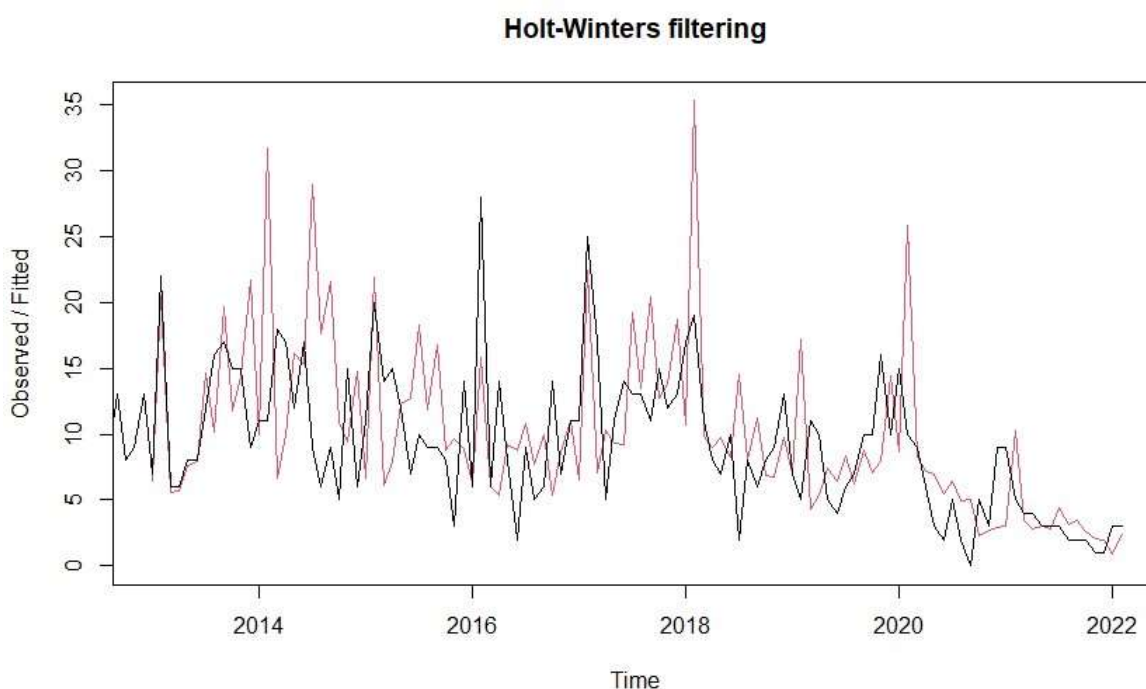


Figura 26 Modelo Holt-Winters (Nível, Tendência e Sazonalidade Multiplicativa)

Onde a mesma função é utilizada novamente, entretanto O nível de suavização da série temporal, estimado pelo modelo parameters: alpha: 0.1806263 beta : 0.03683584 e gamma: 0.3383343, o que induz existirá elevada suavização, ou

seja, menor influência da corrente observação na estimativa da média.
Coefficients: [,1] a 2.2178821 b -0.2025339

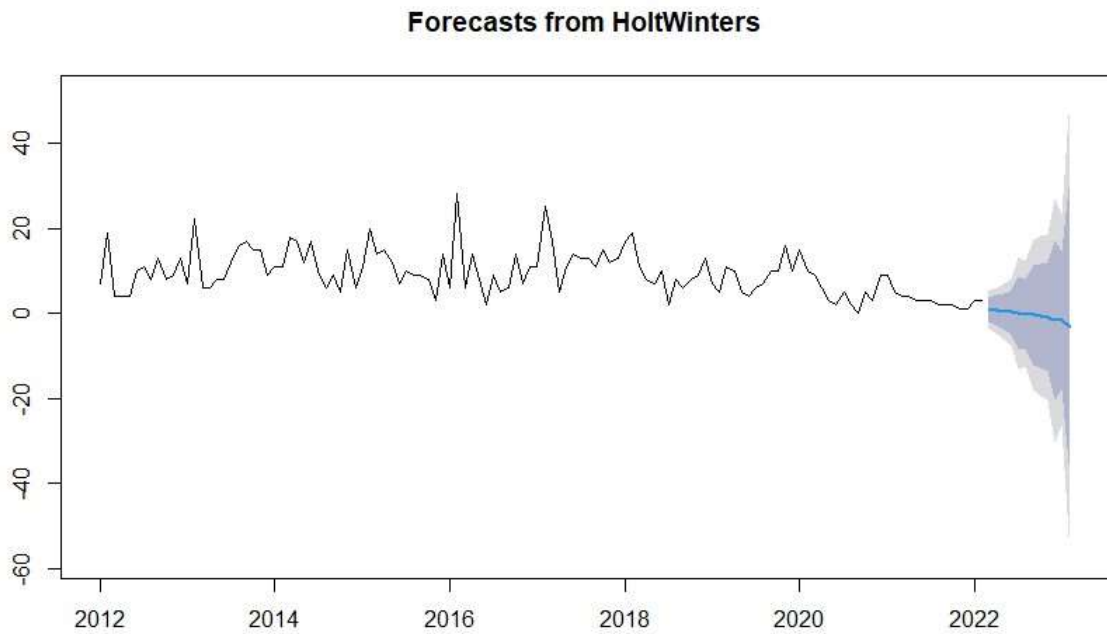


Figura 27 Previsões do Modelo Holt-Winters (Nível, Tendência e Sazonalidade Multiplicativa)




Figura 28 Gráfico Dispersão dos Resíduos Modelo Holt-Winters (Nível, Tendência e Sazonalidade Multiplicativa)




Figura 29 Histograma Resíduos do Modelo Holt-Winters (Nível, Tendência e Sazonalidade Multiplicativa)

6. METODO SARIMA

O modelo SARIMA pertence, na verdade, a uma combinação de modelos da metodologia de Box e Jenkins, 1994, que consiste em ajustar modelos autoregressivos de médias móveis, ou uma combinação de ambos, a séries que podem ser estacionárias (modelo ARMA) ou não (modelo ARIMA), sazonais ou não (modelo SARIMA).

Modelos ARMA são modelos que possuem uma estrutura de dependência tanto em relação às observações como às perturbações ocorridas no passado, portanto, esses modelos misturam os modelos mais simples de Médias Móveis com os modelos, autoregressivos.

ARMA(p,q) = Modelos autoregressivos AR(p) + Modelos Media Móvel MA(q)

$$ARMA(p,q) = \underbrace{\alpha_1 X(t-1) + \dots + \alpha_p X(t-p)}_{\text{Modelos autoregressivos AR(p)}} + \underbrace{E_t + \beta_1 E(t-1) + \dots + E_t + \beta_q E(t-q)}_{\text{Modelos Media Móvel MA(q)}}$$

Consegue simular uma quantidade significativamente maior de estruturas de dependência, e comumente necessita de menos parâmetros que um modelo autoregressivo ou um modelo de média móvel necessitaria sozinho. Baseando-se em critérios de parcimônia, é, portanto, um modelo que se destaca positivamente.




Figura 30 Gráfico Boxcox Série Roubo Consumado

Existe a necessidade de transformar a série afim de se estacionarizar a variância, uma vez que $\lambda = 0.46$, obtida através do comando “bx = boxcox(z~1)” está dentro do intervalo para o verdadeiro valor máximo para log-likelihood, cabe, portanto, fazer tanto uma transformação logarítmica quanto uma raiz quadrada, conforme pode ser verificado no gráfico boxcox acima.

Amplitude da série transformada:




Figura 31 Série Transformada (Estacionarizada)

Após a transformação, realizamos novamente o teste para verificar se a série transformada possui o valor de lambda igual a 1 em seu intervalo de acordo com a transformação boxcox. Caso positivo, nossa série estará com a variancia estabilizada.




Figura 32 Gráfico Boxcox Série Transformada

Dado que a série possui aparente tendência negativa, o procedimento de diferenciações, para verificação de estacionaridade fez-se necessário. Rejeitando-se a hipótese nula de não estacionariedade. A série é estacionária em média sem qualquer diferenciação. Logo, $d=1$.

```
diffs <- c()
test = list('kpss', 'adf', 'pp')
nd = c()

for (i in test) { diffs[i] <- ndiffs(z_dif, test = i)}

diffs

## kpss  adf  pp
##    0    0    0

adf.test(z_dif)

## Warning in adf.test(z_dif): p-value smaller than printed p-value

##
## Augmented Dickey-Fuller Test
##
## data:  z_dif
## Dickey-Fuller = -6.4532, Lag order = 4, p-value = 0.01
## alternative hypothesis: stationary

Box.test(diff(diff(z_transf)), type = "Ljung-Box")

##
## Box-Ljung test
##
## data:  diff(diff(z_transf))
## X-squared = 60.348, df = 1, p-value = 7.994e-15
```

Figura 33 Saída Software R Estacionaridade – SARIMA

Referente ao procedimento para verificação de sazonalidade do método, através dos gráficos de Função de Autocorrelação e Autocorrelação Parcial, verifica-se no gráficos decaimento de forma exponencial nas defasagens sazonais (12,24) . Aparentemente trata-se de de uma parte Auto Regressiva Sazonal de ordem 1.

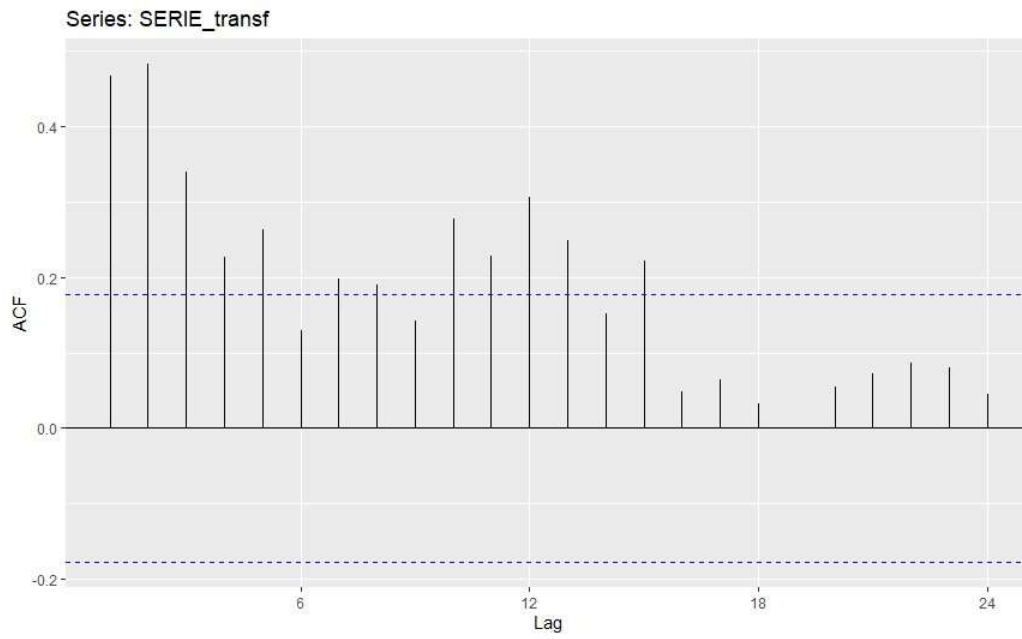


Figura 34 Função autocorrelação




Figura 35 Função autocorrelação parcial




Figura 36 Gráficos de Resíduos SARIMA




Figura 37 Periodograma

1. Modelo: SARIMA(0,1,1)(1,0,0)₁₂

```
> summary(modelo_arima)
Series: SERIE
ARIMA(0,1,1)(1,0,0)[12]

Coefficients:
      ma1      sar1
    -0.8226  0.2834
s.e.   0.0728  0.0868

sigma^2 = 20.58: log likelihood = -354.69
AIC=715.38  AICc=715.58  BIC=723.76

Training set error measures:
              ME      RMSE      MAE      MPE      MAPE      MASE      ACF1
Training set -0.2517926  4.480193  3.41318 -55229413105  55229413126  0.7262084  0.03005654
> |
```

Figura 38 Saída do Software R Modelo SARIMA (0,1,1)(1,0,0)₁₂

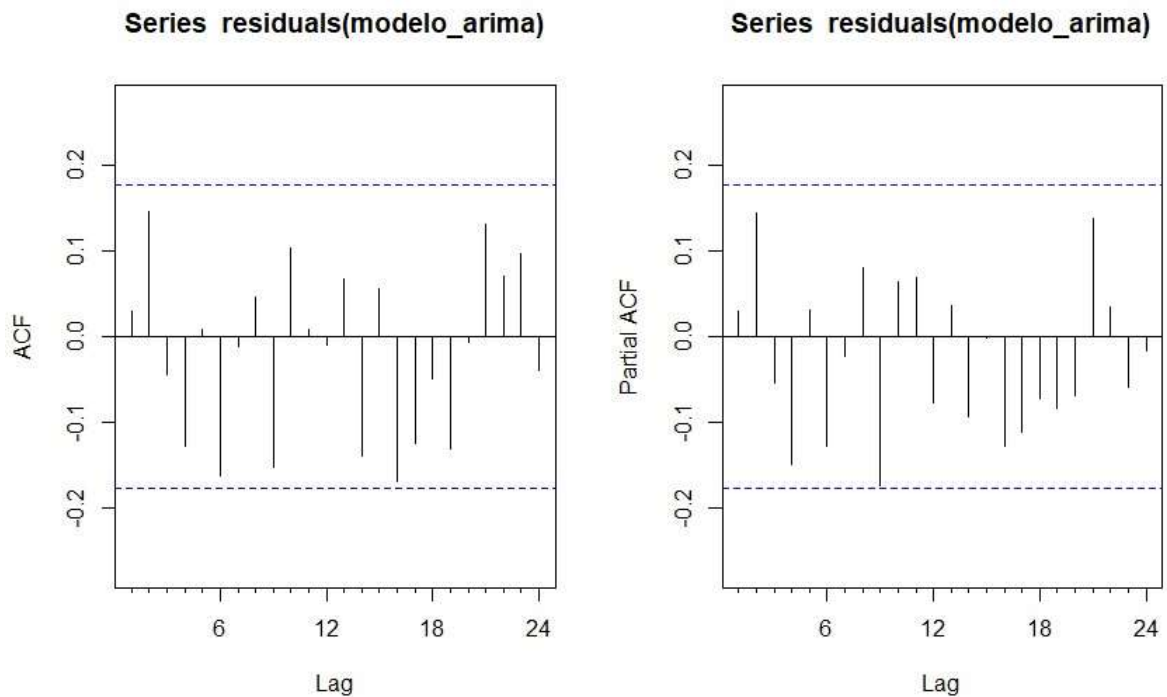


Figura 39 Funções autocorrelação e Autocorrelação parcial do Modelo SARIMA (0,1,1)(1,0,0)₁₂




Figura 40 Previsões do Modelo SARIMA (0,1,1)(1,0,0)12

As autocorrelações estão dentro dos limites com os resíduos se comportando de forma aleatória. Pelo Teste de Ljung-Box, rejeitamos a hipótese nula, indicando que o modelo está bem ajustado, por mais que o intervalo para a predição esteja amplo, podendo variar nessa margem.




Figura 41 Gráfico de Resíduos SARIMA(0,1,1)(1,0,0)12

1. AUTOARIMA

```
> summary(modelo_auto_arima)
Series: SERIE
ARIMA(0,1,1)(1,0,0)[12]

Coefficients:
      ma1      sar1
    -0.8226  0.2834
s.e.   0.0728  0.0868

sigma^2 = 20.58: log likelihood = -354.69
AIC=715.38  AICc=715.58  BIC=723.76

Training set error measures:
              ME      RMSE      MAE      MPE      MAPE      MASE      ACF1
Training set -0.2517926  4.480193  3.41318 -55229413105  55229413126  0.7262084  0.03005654
> |
```

Figura 42 Saída do Software R Modelo AUTO ARIMA

O modelo proposto pela função `auto.arima` foi condizente com a modelagem realizada.
Modelo final: SARIMA(0,1,1)(1,0,0)12

7. RESULTADOS

Realizadas as previsões individuais através dos métodos, é possível se realizar a comparação do Erro Quadrático Médio (MSE), verificando assim o nível de desempenho de cada um. A partir do método do Alisamento Exponencial foi possível obter os resultados inframencionados em tabela, sendo, portanto, o mais adequado o modelo 3, método de NÍVEL, TENDÊNCIA E SAZONALIDADE ADITIVA, o que melhor se adequa à série de dados em questão.

MODELO	AIC	MSE	SSE
1	952.7078	22.23661	2684.537
2	955.9939	22.10471	4585.232
3	947.6264	16.87885	2514.352
4	924.3594	17.07916	3299.725

Figura 43 Resumo - Resultados dos Métodos Alisamento Exponencial

Forecasts from HoltWinters




Figura 44 Método Alisamento Exponencial – NÍVEL, TENDÊNCIA E SAZONALIDADE ADITIVA

Forecasts from ARIMA(0,1,1)(1,0,0)[12]




Figura 45 Método SARIMA - Modelo proposto: SARIMA(0,1,1)(1,0,0)12

O melhor modelo foi aquele que apresentou o menor erro quadrático médio de previsões a um passo, pois esta é uma importante métrica para se evitar um aumento nos roubos em um curto período de tempo.

Dados de Roubo Consumado em Ouro Preto atualizado até agosto 2022, com 6 meses de validação das previsões




Figura 46 Série de Roubo Consumado em Ouro Preto atualizado até agosto 2022

8. CONSIDERAÇÕES FINAIS

Tratam-se de modelos que se aplicam as particularidades de tendência e sazonalidade necessárias para a série desejada, cujos parâmetros podem ser entendidos com clareza.

Cabe ressaltar que um método que certamente traria contribuições significativas para este estudo é a modelagem de dados por meio de regressão linear, pois os modelos mais práticos e populares de descrever as séries temporais são os autoregressivos, que literalmente tratam-se de uma regressão linear dos valores passados das séries estacionárias, onde parte-se do pressuposto que a relação entre a variável resposta e uma variável explicativa é fixada independentemente do indivíduo ou unidade amostral, entretanto, a base de dados utilizada não possui elementos suficientes para que o método fosse desenvolvido, uma vez que não temos uma fonte de variável explicativa.

9. REFERÊNCIAS BIBLIOGRÁFICAS

(SEJUSP - Secretaria de Estado de Justiça e Segurança Pública, 2022)

<http://www.seguranca.mg.gov.br/2018-08-22-13-39-06/dados-abertos>

MORETTIN, P.A.; TOLOI, C.M. Análise de Séries Temporais. São Paulo, Blucher, 2006.

NIELSEN, Aileen; Análise Prática de Séries Temporais: Predição com estatística e aprendizado de máquina, Aileen Nielsen; traduzido por Cibelle Ravaglia – Rio de Janeiro : Alta Books, 2021.

SOUZA, R.C.; CAMARGO, M.E. Análise e Previsão de Séries Temporais: Os modelos ARIMA, Ijuí: SEDIGRAF, 2004.

<https://www.prograd.ufop.br/a-prograd/graduacao-em-numeros>

<https://monografias.brasilecola.uol.com.br/direito/momento-consumativo-crime-roubo.htm>

<https://turismo.ouopreto.mg.gov.br/dados-geograficos>