

UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE MATEMÁTICA
CURSO DE GRADUAÇÃO EM ESTATÍSTICA

Katon Oliveira Santos Faria

**ESTUDO DA SÉRIE TEMPORAL DO PREÇO DA ARROBA DO BOI GORDO DA
BM&F PARA O ESTADO DE GOIÁS**

Uberlândia - MG

Novembro - 2015

Katon Oliveira Santos Faria

**ESTUDO DA SÉRIE TEMPORAL DO PREÇO DA ARROBA DO BOI GORDO DA
BM&F PARA O ESTADO DE GOIÁS**

Trabalho de conclusão de curso de graduação apresentado à Faculdade de Matemática da Universidade Federal de Uberlândia como requisito parcial para a obtenção do título de Bacharel(a) em Estatística.

Universidade Federal de Uberlândia - UFU
Faculdade de Matemática
Bacharelado em Estatística

Orientador: Dr. Quintiliano Siqueira Schroden Nomelini

Uberlândia - MG
Novembro - 2015

Katon Oliveira Santos Faria

**ESTUDO DA SÉRIE TEMPORAL DO PREÇO DA ARROBA DO BOI GORDO DA
BM&F PARA O ESTADO DE GOIÁS**

Trabalho de conclusão de curso de graduação apresentado à Faculdade de Matemática da Universidade Federal de Uberlândia como requisito parcial para a obtenção do título de Bacharel(a) em Estatística.

Aprovado em: ____ de _____ de ____.

Prof. Dr. Quintiliano Siqueira Schroden Nomelini
Orientador

Prof. Dr. Janser Moura Pereira
Convidado

Prof. Dr. José Waldemar da Silva
Convidado

Uberlândia - MG
Novembro - 2015

AGRADECIMENTOS

Agradeço, em primeiro lugar, à minha família – Katia, Kadu, Osmar e Vinícius, por toda a educação, respeito e humildade que me ensinaram.

Um agradecimento especial à Mariana Pintar, por todo o suporte e companheirismo, fazendo da graduação um período de estudo e amor.

Um agradecimento também aos professores Edmilson Rodrigues Pinto, Janser Moura Pereira, José Waldemar da Silva, Leandro Alves Pereira, Lúcio Borges de Araújo, Patrícia Viana da Silva, Quintiliano Siqueira Schrodin Nomelini e Rogério de Melo Costa Pinto. Com suas orientações e ensinamentos, fez-se possível uma admiração ainda maior aos seres que vivem em função de transmitir o conhecimento adiante.

Aos meus amigos, um obrigado por todos os momentos descontraídos e puxões de orelha. Sem isto o caminho até aqui não teria valido à pena.

RESUMO

Este trabalho tem por objetivo analisar e fazer previsões, utilizando modelos de séries temporais e Alisamento Exponencial de Holt-Winters (AEHW), da série levantada do preço do boi gordo no mercado futuro da BM&F, junto ao Centro de Estudos Avançados em Economia Aplicada (CEPEA) da Escola Superior de Agricultura Luiz de Queiroz (ESALQ) da Universidade de São Paulo. Os modelos serão testados e comparados, afim de se obter o modelo que tenha o melhor ajuste. A construção dos modelos de séries temporais foi feita via teoria de Box & Jenkins (Morettin & Toloí, 2006). Após a definição do melhor modelo, as previsões se mostraram realistas quanto aos valores da série, mostrando que o estudo de séries temporais é essencial para séries econômicas.

Palavras-chaves: Boi Gordo, Séries Temporais, Previsões, BM&F.

ABSTRACT

This work goal is to analyze and make forecasts, using time series models and Holt-Wintes exponential smoothing (AEHW), from the serie of fat bull prices in the future market of BM&F, obtained from the Center for Advanced Studies in Applied Economics (CEPEA) at the “Luiz de Queiroz” College of Agriculture (ESALQ) from University of São Paulo (USP). The models will be tested and compared, in order to obtain the model having the best fit. The construction of time series models was made by Box & Jenkins theory (Morettin & Toloi, 2006). After defining the best model, the forecasts were realistic about values of the series, showing that the time series study is essential for economic series.

Keywords: Fat Bull, Time Series, Forecasts, BM&F.

LISTA DE FIGURAS

Figura 1. Exemplo de uma série com sazonalidade aditiva.....	17
Figura 2. Exemplo de uma série com sazonalidade multiplicativa.....	17
Figura 3. Representação gráfica da série original (a), gráfico de autocorrelação (b) e gráfico de autocorrelação parcial (c) da série histórica do preço da arroba do boi gordo no mercado futuro da BM&F.....	29
Figura 4. Representação gráfica da série diferenciada (a), gráfico de autocorrelação da série diferenciada (b) e gráfico de autocorrelação parcial da série diferenciada (c) da série histórica do preço da arroba do boi gordo no mercado futuro da BM&F.....	30
Figura 5. Representação gráfica do períodograma da série histórica do preço da arroba do boi gordo no mercado futuro da BM&F.....	33
Figura 6. Representação gráfica da previsão da série pelo modelo SARIMA(0,1,1) × (0,1,1) da série histórica do preço da arroba do boi gordo no mercado futuro da BM&F.....	34

SUMÁRIO

1 INTRODUÇÃO	10
2 MATERIAIS E MÉTODOS	13
2.1 PROCESSOS ESTOCÁSTICOS	13
2.2 SÉRIES TEMPORAIS	14
2.2.1 SAZONALIDADE	15
2.2.2 TENDÊNCIA	16
2.2.3 AUTOCORRELAÇÃO	17
2.3 MODELOS	18
2.4 IDENTIFICAÇÃO DO MELHOR MODELO.....	22
2.5 ANÁLISE DE RESÍDUOS	22
3 RESULTADOS	24
4 CONCLUSÃO.....	31
REFERÊNCIAS	32
APÊNDICE	34

1 INTRODUÇÃO

Organizações públicas e privadas necessitam de rumos bem definidos. Precisam também saber que caminhos traçar para direcionar seus esforços e recursos, num futuro próximo ou de longo prazo. Essa visão prospectiva não é estática e exige redirecionamentos periódicos devido às mudanças no ambiente externo. Essa diretriz aplica-se, também, ao Ministério da Agricultura, Pecuária e Abastecimento, como responsável por políticas públicas e ações de normatização que visam o desenvolvimento sustentável do agronegócio brasileiro (Contini, et al. 2006).

Segundo Contini et al. (2006), o agronegócio deve ser entendido como a cadeia produtiva que envolve desde a fabricação de insumos, passando pela produção nos estabelecimentos agropecuários e pela transformação, até seu consumo. Essa cadeia incorpora todos os serviços de apoio: pesquisa e assistência técnica, processamento, transporte, comercialização, crédito, exportação, serviços portuários, distribuidores, bolsas e o consumidor final.

O Brasil é um grande produtor, consumidor e exportador de carnes. Em relação à carne bovina, atualmente o Brasil é o segundo maior produtor mundial e seu consumo é o terceiro maior do mundo. Sua liderança ocorre, também, nas exportações, ocupando, desde 2004, o primeiro lugar, com 26,4% das exportações mundiais de carne bovina (USDA, 2005).

Tendo em vista a dificuldade dos produtores de bovinos de corte em lidar com cenários incertos de formação de preços no mercado físico nas regiões de produção e comercialização bovina, assim como a necessidade real em se proteger contra as constantes oscilações de preços, é que se revela a importância do estudo das séries de preços para auxiliar nas tomadas de decisões.

O gerenciamento de risco na agropecuária, que tem por objetivo fundamental administrar as potenciais perdas relativas ao processo de negociação nos mais diversos mercados, tem, no estudo com séries temporais, um mecanismo estratégico de gestão dos preços alvo, em ambientes de incerteza na formação os preços de comercialização.

Considerando os riscos envolvidos na produção e comercialização de produtos agrícolas, que vão desde as características técnicas de cada cultura (solo, clima, produtividade, etc.), passando por outros como: qualidade da produção, logística, riscos de desempenho (pragas, doenças, etc.) e exposição ao mercado físico (com 30 dias), é que se revela a importância deste estudo.

Devido a importância do agronegócio na economia do país, justifica-se a aplicação de técnicas estatísticas para o estudo das séries históricas da cotação dos preços da arroba do boi gordo. Assim, ferramentas de modelagem univariada, como a utilização de técnicas de séries temporais, podem ser aplicadas ao banco de dados do preço da arroba do boi gordo, sendo a finalidade a predição do preço da arroba para dar subsídio ao produtor e seus investidores.

Vale ressaltar que esse estudo é motivado pela relevância das informações obtidas para produtores, empresários, comunidade acadêmica e científica, devido sua perspectiva de geração de conhecimento, que é pela carência de pesquisas referentes a essa temática.

Os dados coletados neste trabalho são do preço futuro na BM&F, distribuídos mensalmente entre primeiro trimestre de 1997 ao quarto trimestre de 2014. Os dados relacionados às cotações de preços futuros foram obtidos junto ao Centro de Estudos Avançado em Economia Aplicada (CEPEA) da Escola Superior de Agricultura Luiz de Queiroz (ESALQ) da Universidade do Estado de São Paulo (USP).

Portanto, o objetivo deste trabalho é fazer previsão do preço da arroba do boi gordo no mercado futuro da Bolsa de Mercadorias & Futuros (BM&F) a partir do estudo de séries temporais e comparar com Alisamento Exponencial de Holt (AEH). Identificar características inerentes às séries do preço da arroba do boi gordo, como tendência e sazonalidade, por meio de testes específicos, além de observar a presença e os efeitos de possíveis intervenções. Ajustar modelos que representem os dados adequadamente e fazer previsões do preço da arroba do boi gordo.

2 MATERIAIS E MÉTODOS

A série histórica do preço da arroba do boi gordo no mercado futuro da Bolsa de Mercadorias & Futuros (BM&F) do primeiro trimestre de 1997 ao quarto trimestre de 2014 foi obtida junto ao Centro de Estudos Avançado em Economia Aplicada (CEPEA) da Escola Superior de Agricultura Luiz de Queiroz (ESALQ) da Universidade do Estado de São Paulo (USP) e foi analisada via teoria de Box e Jenkins (Morettin & Toloí, 2006), e também via alisamento exponencial de Holt-Winters (AEHW).

Os testes iniciais foram feitos no software *Microsoft Excel* (2013). Após a verificação inicial da série, todos os outros testes e obtenção dos modelos foram feitos no *Software R*.

Para estudar séries temporais, é importante entender sobre processos estocásticos, visto que um processo estocástico é uma coleção de variáveis aleatórias que, em geral, são utilizadas para estudar a evolução de fenômenos que são observados ao longo do tempo. Assim, ao invés de descrevermos o sistema através de equações determinísticas, que dado uma condição inicial, conhecemos toda a evolução do sistema, utiliza-se processos estocásticos, para o qual, dado uma condição inicial, ainda se tem diversas trajetórias possíveis para a evolução do sistema.

2.1 PROCESSOS ESTOCÁSTICOS

Žitković (2010) diz que, com T sendo um subconjunto de $[0, \infty)$. Uma família de variáveis aleatórias $\{X_t\}_{t \in T}$, indexada por T , é chamada de processo estocástico (ou aleatório). Quando $T = \mathbb{N}$ (ou $T = \mathbb{N}_0$), $\{X_t\}_{t \in T}$ é dito ser um processo de tempo discreto, e quando $T = [0, \infty)$, é chamado de processo de tempo contínuo.

Ainda de acordo com Žitković (2010), quando T é único (diz-se $T = \{1\}$), o processo $\{X_t\}_{t \in T} = X_1$ é realmente apenas uma variável aleatória. Quando T é finito (ou seja, $T = \{1, 2, \dots, n\}$), tem-se um vetor aleatório. Portanto, processos estocásticos são generalizações de vetores aleatórios. A interpretação é, entretanto, diferente. Enquanto os componentes de um vetor aleatório geralmente (nem sempre) representam coordenadas espaciais, o índice $t \in T$ é frequentemente interpretado como tempo. Processos estocásticos usualmente modelam a evolução de um método aleatório no tempo. Quando $T = [0, \infty)$ (processo de tempo contínuo), o valor do processo pode mudar a todo momento. Quando $T = \mathbb{N}$ (processo de tempo discreto), as mudanças ocorrem discretamente.

Para Žitković (2010), todo processo estocástico pode ser visto como uma função de duas variáveis – t e ω . Para cada valor fixado t , $\omega \rightarrow X_t(\omega)$ é uma variáveis aleatória. Entretanto, se for mudado o ponto de vista e manter ω fixado, tem-se que o processo estocástico é uma função que leva ω para o valor real da função $t \rightarrow X_t(\omega)$. Essas funções são chamadas de trajetórias do processo estocástico X .

2.2 SÉRIES TEMPORAIS

Ehlers (2009) explicou que uma série temporal é um conjunto de observações feitas sequencialmente ao longo do tempo. A característica mais importante deste tipo de dado é que as observações vizinhas são dependentes. Com isso, o interesse é de analisar e modelar esta dependência. Enquanto que nos modelos de regressão, a ordem das observações é irrelevante para a análise, em séries temporais a ordem dos dados é extremamente relevante. Vale ressaltar que o tempo pode ser substituído por outra variável como espaço, profundidade, etc.

De acordo com Ehlers (2009), uma série é dita ser contínua quando as observações são feitas continuamente no tempo. Definindo o conjunto $T = \{t: t_1 < t < t_2\}$, a série temporal será denotada por $\{X(t): t \in T\}$. Uma série temporal será discreta quando as observações são feitas em tempos específicos (diariamente, mensalmente, anualmente, etc). Definindo o conjunto $T = \{t_1, \dots, t_2\}$, a série será denotada por $\{X(t): t \in T\}$ ou, para facilitar $T = \{1, 2, \dots, n\}$.

Para Ehlers (2009), de um modo geral, os principais objetivos em se estudar séries temporais são:

1. Descrição. Descrever propriedades da série como padrão de tendência, existência de variação sazonal ou cíclica, observações discrepantes (*outliers*) e alterações estruturais.
2. Explicação. Usar a variação da série para explicar a variação em outra série.
3. Predição. Predizer valores futuros com base em valores passados.
4. Controle. Os valores da série medem a “qualidade” de um processo.

As propriedades de uma série temporal X_t pode ser captada, conforme Ehlers (2009), assumindo-se a seguinte forma de decomposição

$$X_t = T_t + C_t + R_t \quad (1)$$

onde T_t é uma componente de tendência, C_t é uma componente cíclica (ou sazonal) e R_t é uma componentes aleatória ou ruído (a parte não explicada, a qual deverá ser aleatória). A

sazonalidade se repete a cada intervalo fixo s e as variações periódicas podem ser captadas por esta componente.

2.2.1 SAZONALIDADE

As séries temporais exibem comportamento que tendem a se repetir a cada s períodos de tempo. Os tipos de sazonalidade, segundo Ehlers (2009), são:

1. Aditiva: a série apresenta flutuações sazonais mais ou menos constantes, não importando o nível global da série.




Figura 1. Exemplo de uma série com sazonalidade aditiva.

2. Multiplicativa: o tamanho das flutuações varia de acordo com o nível global da série.




Figura 2. Exemplo de uma série com sazonalidade multiplicativa.

É sabido que, para aplicação do modelo de Box & Jenkins, a série deverá ser estacionária e, para verificar isto, é possível efetuar inspeção visual do gráfico de autocorrelação sendo que este gráfico deverá decair rapidamente para zero para que a série seja estacionária. A verificação da periodicidade é feita através da análise espectral do periodograma.

De acordo com Morettin & Toloí (1981), o Teste de Friedman pode ser usado para verificar se há sazonalidade. Neste caso os meses são considerados “tratamentos” e os anos são considerados “blocos”. A ordenação é feita dentro de cada bloco ao invés de ordenar todas as N observações. A estatística de Friedman é

$$T = \frac{12}{pk(k+1)} \sum_{j=1}^k R_j^2 - 3p(k+1), \quad (2)$$

onde p = número de blocos = número de anos, e k = número de tratamentos = número de meses, e R_j denota a soma dos postos na j -ésima coluna, isto é

$$R_j = \sum_{i=1}^p R_{ij}, \quad (3)$$

em que R_{ij} = posto de Y_{ij} dentro do bloco i , de 1 até k . A distribuição de T pode ser aproximada por um χ^2 com $k-1$ graus de liberdade.

Ainda considerando uma série com dados mensais, de acordo com Morettin & Toloí (2006), tomando a média dos meses como

$$\bar{Y}_j = \frac{1}{n_j} \sum_{i=1}^{n_j} Y_{ij}, \quad j = 1, \dots, 12. \quad (4)$$

Como a soma dos \bar{Y}_j em geral não é zero, toma-se como estimativas das constantes sazonais

$$\hat{S}_j = \bar{Y}_j - \bar{Y}, \quad (5)$$

onde

$$\bar{Y} = \frac{1}{12} \sum_{j=1}^{12} \bar{Y}_j. \quad (6)$$

O modelo poderá ser escrito como

$$Z_t = T_t + S_j + a_t, \quad (7)$$

com $t = 12i + j$, $i = 0, 1, \dots, p$, $j = 1, \dots, 12$, havendo $(p + 1)$ anos. Então as médias móveis podem ser escritas da seguinte forma

$$\bar{Y}_j = \frac{1}{p} \sum_{i=1}^p Y_{12i+j}, \quad j = 1, \dots, 6 \quad (8)$$

$$\bar{Y}_j = \frac{1}{p} \sum_{i=0}^{p-1} Y_{12i+j}, \quad j = 7, \dots, 12. \quad (9)$$

A série livre de sazonalidade será

$$Z_t^{SA} = Z_t - \hat{S}_t. \quad (10)$$

2.2.2 TENDÊNCIA

Para Morettin & Tolo (1981), se for considerado as observações $\{X_t, t = 1, \dots, N\}$ de uma série temporal, a decomposição do modelo consiste em escrever X_t como a soma de três componentes não observáveis,

$$X_t = T_t + S_t + a_t, \quad (11)$$

onde T_t e S_t são a tendência e sazonalidade, respectivamente, enquanto a_t é uma componente aleatória, de média zero e variância constante σ_a^2 . Se a_t são observações de um ruído branco (erros independentes e identicamente distribuídos), então $E[a_t a_s] = 0, s \neq t$.

Para verificar se existe tendência na série, é possível fazer inspeção visual das funções de autocorrelação e também o teste do sinal de Cox-Stuart. Vários testes também podem ser adotados, mas trataremos aqui apenas do teste do sinal (Cox-Stuart).

Morettin & Tolo (2006) afirmam que é possível utilizar testes de hipóteses para verificar tendência em uma série. Considerando um conjunto de observações X_1, \dots, X_n . Agrupa-se as observações em pares $(X_1, X_{1+c}), \dots, (X_{n-c}, X_n)$, onde $c = N/2$ se N for par e $c = (N + 1)/2$ se N for ímpar. A cada par de observações, é associado o sinal “+” se $X_i < X_{i+c}$ e o sinal “-” se $X_i > X_{i+c}$, caso $X_i = X_{i+c}$, deve-se eliminar a observação. Considerando n_t o número de pares onde $X_i \neq X_{i+c}$. As hipóteses para o teste são

$$H_0 = P(X_i < X_{i+c}) = P(X_i > X_{i+c}), \text{ ou seja, não existe tendência na série, contra}$$

$$H_1 = P(X_i < X_{i+c}) \neq P(X_i > X_{i+c}), \text{ ou seja, existe tendência na série.}$$

A estatística do teste é dada por $T =$ número de pares com sinal positivo. Para $T > n - t$, rejeita-se a hipótese H_0 e pode-se concluir que há evidência da existência de tendência na série. O valor de t é encontrado na tabela de distribuição binomial, com parâmetros $p = 1/2$ e n para um dado nível α , se $n \leq 20$ e para $n \geq 20$ deve ser usado a distribuição normal, onde n é o número de pares.

2.2.3 AUTOCORRELAÇÃO

Ehlers (2009) diz que uma importante ferramenta para se identificar as propriedades (tendência e sazonalidade) de uma série temporal consiste de uma série de quantidades, chamadas de *coeficientes de autocorrelação amostral*. A idéia é parecida à correlação usual.

A função de autocovariância para X_t é dado por

$$\gamma_k = Cov(X_t, X_{t-k}) = E([X_t - E(X_t)][X_{t-k} - E(X_{t-k})]) \quad (12)$$

com $E(X_t) = E(X_{t-k}) = 0$, tem-se que

$$\gamma_k = E([X_t][X_{t-k}]). \quad (13)$$

A função de autocorrelação (fac) será

$$\rho_k = \frac{\gamma_k}{\gamma_0}, \quad k = 0, 1, 2, \dots \quad (14)$$

com $\gamma_0 = \text{Var}(X_t)$.

Já a função de autocorrelação parcial (facp) será dada como a medida entre a correlação de duas observações seriais, ficando assim

$$\text{Cov}(Y_t, Y_{t-k} | Y_{t-1}, \dots, Y_{t-(k+1)}) \quad (15)$$

O gráfico de autocorrelação é usado também para identificar se uma série é estacionária. Para que esta seja estacionária (livre de tendência e sazonalidade), o gráfico deverá decair rapidamente para zero. Caso isto não ocorra, algum método (normalmente este método é a diferenciação da série) deverá ser feito para transformar a série em uma série estacionária. Feito isso, é possível identificar os parâmetros significativos observando quais passos possuem picos no gráfico, onde cada passo do eixo x do gráfico é chamado de lag. Os lags que contêm picos no gráfico de autocorrelação identificam a ordem da parte de médias móveis do modelo, enquanto que os lags que contêm picos no gráfico de autocorrelação parcial identificam a ordem da parte auto-regressiva.

2.3 MODELOS

Seja um $\{\epsilon_t\}$ um processo puramente aleatório com média zero e variância σ_ϵ^2 . Segundo Ehlers (2009), um processo $\{X_t\}$ é chamado processo autoregressivo de ordem p , ou $\text{AR}(p)$, se

$$X_t = \alpha_1 X_{t-1} + \dots + \alpha_p X_{t-p} + \epsilon_t \quad (16)$$

onde X_t é estacionário, e $\alpha_1, \dots, \alpha_p$ são constantes ($\alpha_p \neq 0$). A média de X_t é zero, se a média μ de X_t não for zero, troque X_t por $X_t - \mu$, dado por Ehlers (2009), o ajuste de um modelo autoregressivo de ordem p , abreviado $\text{AR}(p)$, que tem a forma

$$X_t - \mu = \alpha_1(x_{t-1} - \mu) + \alpha_2(x_{t-2} - \mu) + \dots + \alpha_p(x_{t-p} - \mu) + \epsilon_t \quad (17)$$

e dadas n observações x_1, \dots, x_n , os parâmetros $\mu, \alpha_1, \dots, \alpha_p$ podem ser estimados pelo método de mínimos quadrados minimizando-se a soma de quadrados

$$S = \sum_{t=p+1}^n [(x_t - \mu) - \alpha_1(x_{t-1} - \mu) - \dots - \alpha_p(x_{t-p} - \mu)]^2 \quad (18)$$

com respeito a $\mu, \alpha_1, \dots, \alpha_p$. Note que o somatório é de $t = p + 1$ em diante, porém esta perda de informação não será importante se a série for grande. A função de previsão do modelo autoregressivo $\text{AR}(p)$ será

$$\hat{x}_t(1) = \hat{\alpha}_1 x_t + \dots + \hat{\alpha}_p x_{t-p+1}$$

$$\begin{aligned}\hat{x}_t(2) &= \hat{\alpha}_1 \hat{x}_t + \dots + \hat{\alpha}_p x_{t-p+2} \\ &\dots \\ \hat{x}_t(p+1) &= \hat{\alpha}_1 \hat{x}_t(p) + \dots + \hat{\alpha}_p \hat{x}_t(1)\end{aligned}\quad (19)$$

Conforme com Ehlers (2009), seja um processo $\{\epsilon_t\}$ discreto puramente aleatório com média zero e variância σ_ϵ^2 . Um processo $\{X_t\}$ é chamado de processo de médias móveis de ordem q , ou MA(q), se

$$X_t = \epsilon_t + \hat{\beta}_1 \epsilon_{t-1} + \hat{\beta}_2 \epsilon_{t-2} + \dots + \hat{\beta}_q \epsilon_{t-q} \quad (20)$$

Para se ajustar um modelo de média móvel de ordem q , ou MA(q), considerando o modelo acima e uma série observada x_1, \dots, x_n o procedimento iterativo consiste basicamente em fixar os valores de $\mu, \beta_1, \dots, \beta_q$ e calcular os resíduos

$$\epsilon_t = X_t - \mu - \hat{\beta}_1 \epsilon_{t-1} - \hat{\beta}_2 \epsilon_{t-2} - \dots - \hat{\beta}_q \epsilon_{t-q} \quad (21)$$

sequencialmente com $t = 1, \dots, n$ admitindo um ajuste ótimo do modelo, então $\epsilon_0 = \epsilon_{-1} = \dots = \epsilon_{-q+1} = 0$ e substituindo $\epsilon_{t-1}, \dots, \epsilon_{t-q}$ pelos resíduos calculados. Logo

$$\begin{aligned}\epsilon_1 &= x_1 - \mu \\ \epsilon_2 &= x_2 - \mu - \hat{\beta}_1 \epsilon_1 = x_2 - \mu - \hat{\beta}_1 x_1 + \hat{\beta}_1 \mu \\ \epsilon_3 &= x_3 - \mu - \hat{\beta}_1 \epsilon_2 - \hat{\beta}_2 \epsilon_1 \\ &\dots\end{aligned}$$

Com estes resíduos, pode ser calculado a soma de quadrados residual

$$S(\mu, \beta) = \sum_{t=1}^n e_t^2 \quad (22)$$

Repetindo este procedimento para $\mu, \beta_1, \dots, \beta_q$ variando em uma grade de pontos, pode ser escolhido os valores que minimizam a soma de quadrados. Este procedimento requer o uso de algoritmos eficientes de otimização numérica e não pode ser garantido a sua convergência para um mínimo global. Como ϵ_t tem distribuição normal, Box & Jenkins (1970) descreveram regiões de confiança para os parâmetros do modelo. Neste caso, se $\epsilon_t \sim N(0, \sigma_\epsilon^2)$ a função de verossimilhança será

$$\begin{aligned}L(\mu, \beta, \sigma_\epsilon^2) &= \prod_{t=1}^n (2\pi\sigma_\epsilon^2)^{-1/2} \exp\left\{-\frac{1}{2\sigma_\epsilon^2} e_t^2\right\} \\ &\propto (\sigma_\epsilon^2)^{-n/2} \exp\left\{-\frac{1}{2\sigma_\epsilon^2} \sum_{t=1}^n e_t^2\right\}\end{aligned}\quad (24)$$

e os valores de e_t podem ser calculados como anteriormente. Logo $L(\mu, \beta, \sigma_\epsilon^2)$ é uma função não linear dos parâmetros. Com disso, a equação de previsão do modelo de médias móveis MA(q) será

$$\hat{x}_t(1) = \hat{\beta}_1 \epsilon_t + \dots + \hat{\beta}_q \epsilon_{t-q+1}$$

$$\begin{aligned}
\hat{x}_t(2) &= \hat{\beta}_2 \epsilon_t + \cdots + \hat{\beta}_q \epsilon_{t-q+2} \\
&\quad \dots \\
\hat{x}_t(q) &= \hat{\beta}_q \epsilon_t \\
\hat{x}_t(q+j) &= 0, \quad j = 1, 2, \dots
\end{aligned} \tag{25}$$

ou seja,

$$\hat{x}_t(k) = \begin{cases} \sum_{i=k}^q \hat{\beta}_i \epsilon_{t+k-i}, & k = 1, \dots, q \\ 0, & k > q \end{cases} \tag{26}$$

Combinando-se os modelo AR e MA, segundo Ehlers (2009), pode ser obtido uma representação adequada com menor número de parâmetros. Processos autoregressivos médias móveis (ARMA) formam uma classe de modelos parcimoniosos para descrever dados de séries temporais. O modelo ARMA(p, q) é dado como

$$X_t = \alpha_1 X_{t-1} + \cdots + \alpha_p X_{t-p} + \epsilon_t + \beta_1 \epsilon_{t-1} + \cdots + \beta_q \epsilon_{t-q} \tag{27}$$

Ricardo S. Ehlers (2009) diz que um modelo ARMA no qual X_t é substituído pela sua d -ésima diferença $\nabla^d X_t$ é capaz de descrever alguns tipos de séries não estacionárias. Denotando a série diferenciada como

$$Z_t = \nabla^d X_t = (1 - B)^d X_t \tag{28}$$

onde B é o operador de translação para o passado e definido por

$$BZ_t = Z_{t-1}, \quad B^m Z_t = Z_{t-m}; \tag{29}$$

e o operador diferença será

$$\Delta = 1 - B; \tag{30}$$

onde o operador soma denotado por S é

$$SZ_t = \sum_{j=0}^{\infty} Z_{t-j} = Z_t + Z_{t-1} + \cdots = (1 + B + B^2 + \cdots)Z_t, \tag{30}$$

ou seja,

$$S = \Delta^{-1}. \tag{31}$$

O processo autoregressivo integrado com médias móveis e denotado como ARIMA(p, d, q) é dado por

$$Z_t = \alpha_1 Z_{t-1} + \cdots + \alpha_p Z_{t-p} + \epsilon_t + \beta_1 \epsilon_{t-1} + \cdots + \beta_q \epsilon_{t-q} \tag{32}$$

ou, equivalente

$$\phi(B)(1 - B)^d X_t = \theta(B)\epsilon_t. \tag{33}$$

A partir desta equação, pode-se notar que o modelo X_t é claramente não estacionário já que o polinômio autoregressivo $\phi(B)(1 - B)^d$ tem exatamente d raízes sobre o círculo unitário, ou d raízes unitárias. Um processo que se torna estacionário após d diferenças é dito ser estacionário homogêneo, ou integrado de ordem $d, I(d)$.

Ehlers (2009) diz que o modelo SARIMA(p, d, q) \times (P, D, Q)_s multiplicativo se aplica à maioria das séries sazonais reais, ou seja, realizações de processos que apresentam correlação serial “dentro” e “entre” períodos sazonais. O modelo é dado por

$$\phi(B)\Phi(B^S)Z_t = \theta(B)\Theta(B^S)\epsilon_t \quad (34)$$

onde

$$\phi(B) = (1 - \alpha_1 B^1 - \dots - \alpha_p B^p) \quad (35)$$

$$\Phi(B^S) = (1 - \Phi_S B^S - \dots - \Phi_P B^{Ps}) \quad (36)$$

$$Z_t = \nabla^d \nabla_s^D X_t \quad (37)$$

$$\theta(B) = (1 - \beta_1 B^1 - \dots - \beta_q B^q) \quad (38)$$

$$\Theta(B^S) = (1 - \theta_1 B^S - \dots - \theta_Q B^{Qs}). \quad (39)$$

Ao ajustar um modelo sazonal aos dados, após identificar os valores de d e D que tornam a série estacionária, deve-se identificar os valores de p, P, q e Q com base nas funções de autocorrelação e autocorrelação parcial da série diferenciada. Os valores P e Q são especificados a partir de $r_k, k = s, 2s, \dots$

O alisamento exponencial (média ponderada que dá pesos maiores às observações mais recentes) de Holt-Winters, de acordo com Morettin & Toloí (2006), é usado quando se pretende fazer previsões para séries com sazonalidade. Um modelo será ajustado levando em consideração os parâmetros de suavização e os coeficientes provenientes de cada previsão. Trata-se de um algoritmo para ser usado com séries com efeito sazonal. Suponha que as observações mensais sejam T_t, L_t e I_t a tendência, o nível e o índice sazonal no tempo t . Conforme Ricardo S. Ehlers (2009), T_t é o aumento ou redução esperada pelo tempo de cada observação (diário, semanal, mensal, trimestral, etc.) no nível atual da série. Admitindo que no tempo t os termos $(L_1, T_1, I_1), \dots, (L_{t-1}, T_{t-1}, I_{t-1})$ sejam conhecidos. Então, após observar x_t os termos L_t, T_t e I_t são atualizados via alisamento exponencial. Para a variação sazonal aditiva as equações de atualização para o nível e o índice sazonal são

$$L_t = \alpha(x_t - I_{t-12}) + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (40)$$

$$T_t = \gamma(L_t - L_{t-1}) + (1 - \gamma)T_{t-1} \quad (41)$$

$$I_t = \delta(x_t - L_t) + (1 - \delta)I_{t-12} \quad (42)$$

e as previsões k períodos à frente serão

$$\hat{x}_t(k) = L_t + kT_t + I_{t-12+k}, k = 1, 2, \dots \quad (43)$$

Tem-se aqui os parâmetros de alisamento α, γ e δ para cada componente da série, que em geral são escolhidos no intervalo $(0,1)$ e podem ser estimados minimizando-se a soma de quadrados dos erros de previsão. Os valores próximo aos extremos variam pouco nesta região devido à

soma de quadrados. Além disso, estes parâmetros não dependem da escala das observações, mas sim das propriedades temporais do nível, tendência e sazonalidade da série.

2.4 IDENTIFICAÇÃO DO MELHOR MODELO

Ricardo S. Ehlers (2009) afirma que uma importante ferramenta para se identificar as propriedades de uma série temporal consiste de uma série de quantidades, chamadas de *coeficientes de autocorrelação amostral*. A idéia é parecida à correlação usual.

O critério de informação de Akaike (AIC) é utilizado para definição do melhor modelo. Segundo Ricardo Ehlers (2009), a definição do critério é

$$AIC = -2l + 2m \quad (44)$$

com $l = \log(L_k)$ e L_k dado pela máxima verossimilhança, e m é o número de parâmetros. Para dados normalmente distribuídos e usando-se estimativas de máxima verossimilhança para os parâmetros, pode-se mostrar que

$$AIC = n \log(\widehat{\sigma_\epsilon^2}) + 2m \quad (45)$$

onde $\widehat{\sigma_\epsilon^2} = \left(\frac{1}{n}\right) \sum \widehat{\sigma_t^2}$. Vale ressaltar que esta medida não tem significado quando olhada individualmente (considerando apenas um modelo). Portanto, o critério de informação de Akaike (AIC) pode assumir qualquer valor, inclusive valor negativo, já que ele depende da forma da função de verossimilhança. Para se comparar o AIC, é necessário que os modelos ajustados sejam feitos no mesmo período amostral. Quanto menor for o valor de AIC, melhor será o modelo ajustado.

2.5 ANÁLISE DE RESÍDUOS

Para verificar se os resíduos são independentes e identicamente distribuídos (i.i.d.), ou seja, se o resíduo é um ruído branco, o teste de Box-Pierce (PRIESTLEY, 1989) é indicado, o qual é baseado nas k primeiras autocorrelações \widehat{r}_k dos resíduos. O teste verifica as hipóteses H_0 = os resíduos são i.i.d., contra H_1 = os resíduos não são i.i.d. Suponha um processo ARIMA (p,d,q), se o modelo ajustado é apropriado, então a estatística do teste é

$$Q = n(n + 2) \sum_{k=1}^k \frac{\widehat{r}_k^2}{(n-k)} \quad (46)$$

com distribuição aproximadamente qui-quadrado (χ^2). A hipótese de ruído branco é aceita quando a estatística do teste for menor que o valor observado do qui-quadrado, ou seja, quando

$Q < \chi^2$ com $(k - p - q)$ graus de liberdade, onde k é o número de *lags*, p é a ordem da parte auto-regressiva e q é a ordem da parte de médias móveis.

3 RESULTADOS

Na Figura 3, são apresentados os gráficos da série histórica do preço da arroba do boi gordo no mercado futuro da BM&F, sendo que na Figura 3a é apresentado o valor médio trimestral (em reais). É possível notar, visualmente, a presença da componente de tendência e também a componente de sazonalidade na série. Na Figura 3b e 3c, o gráfico de autocorrelação e autocorrelação parcial também foram inspecionados e pôde-se notar que o gráfico fac não decai rapidamente para zero, enquanto que o gráfico de facp possui um pico no lag 1 decaindo após isso, o que pode ser um indício de um modelo com parâmetro AR(1), com tendência e sazonalidade.

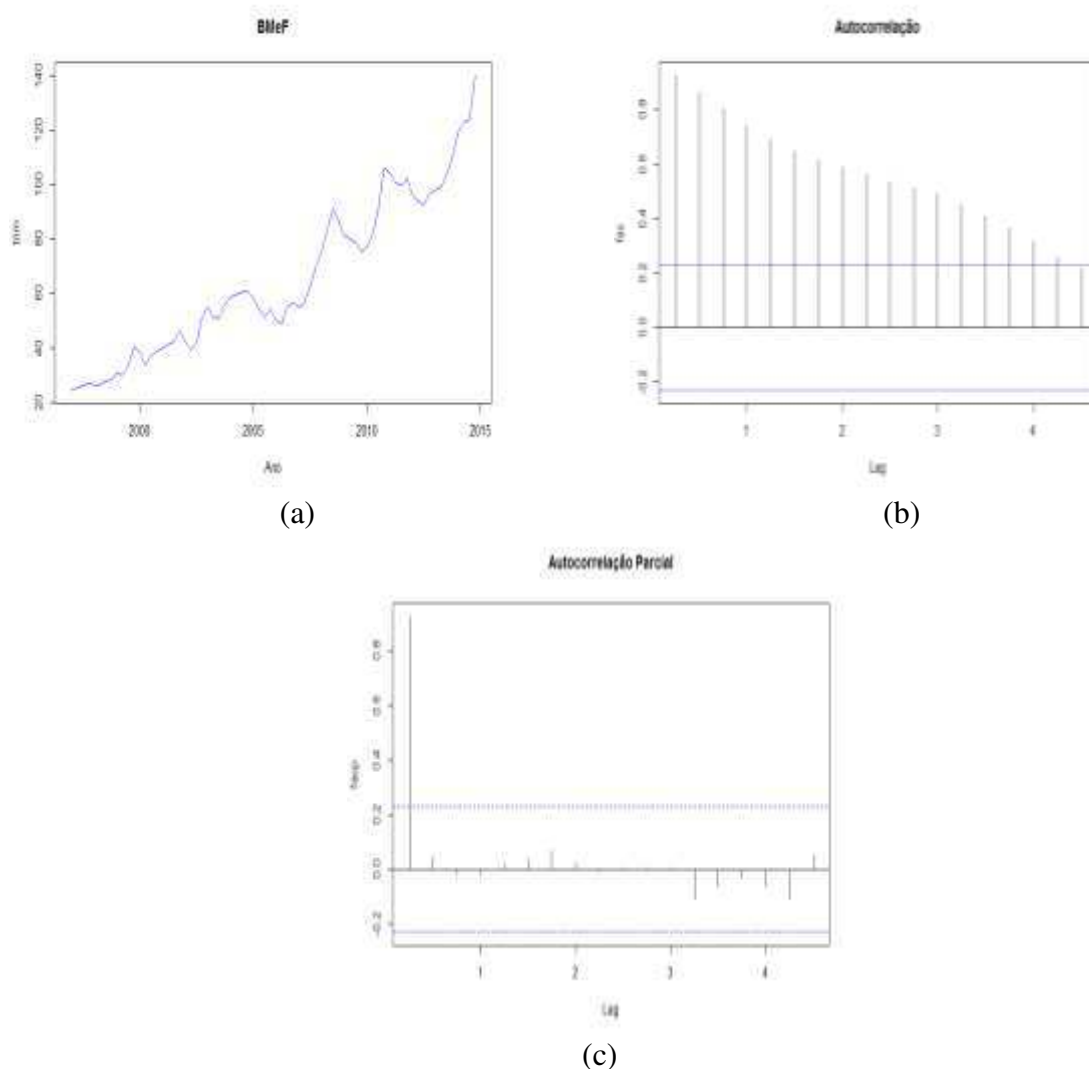


Figura 3. Representação gráfica da série original (a), gráfico de autocorrelação (b) e gráfico de autocorrelação parcial (c) da série histórica do preço da arroba do boi gordo no mercado futuro da BM&F.

Para testar a tendência na série original, o teste de sinal de Cox-Stuart foi realizado com $\alpha = 5\%$ e mostrou um $p - valor < 0,05$, portanto pode-se afirmar que existe tendência na série original. Para eliminação da componente de tendência, foi feita a primeira diferença da série. Já na primeira diferenciação da série, eliminou-se a tendência, conforme Figura 4a. Como o gráfico fac e fap (representados nas Figuras 4b e 4c) decaem rapidamente, há indícios de que a série tenha tendência. O teste de Cox-Stuart foi refeito para a série diferenciada e mostrou um $p - valor > 0,05$, confirmando assim a eliminação da tendência na série.

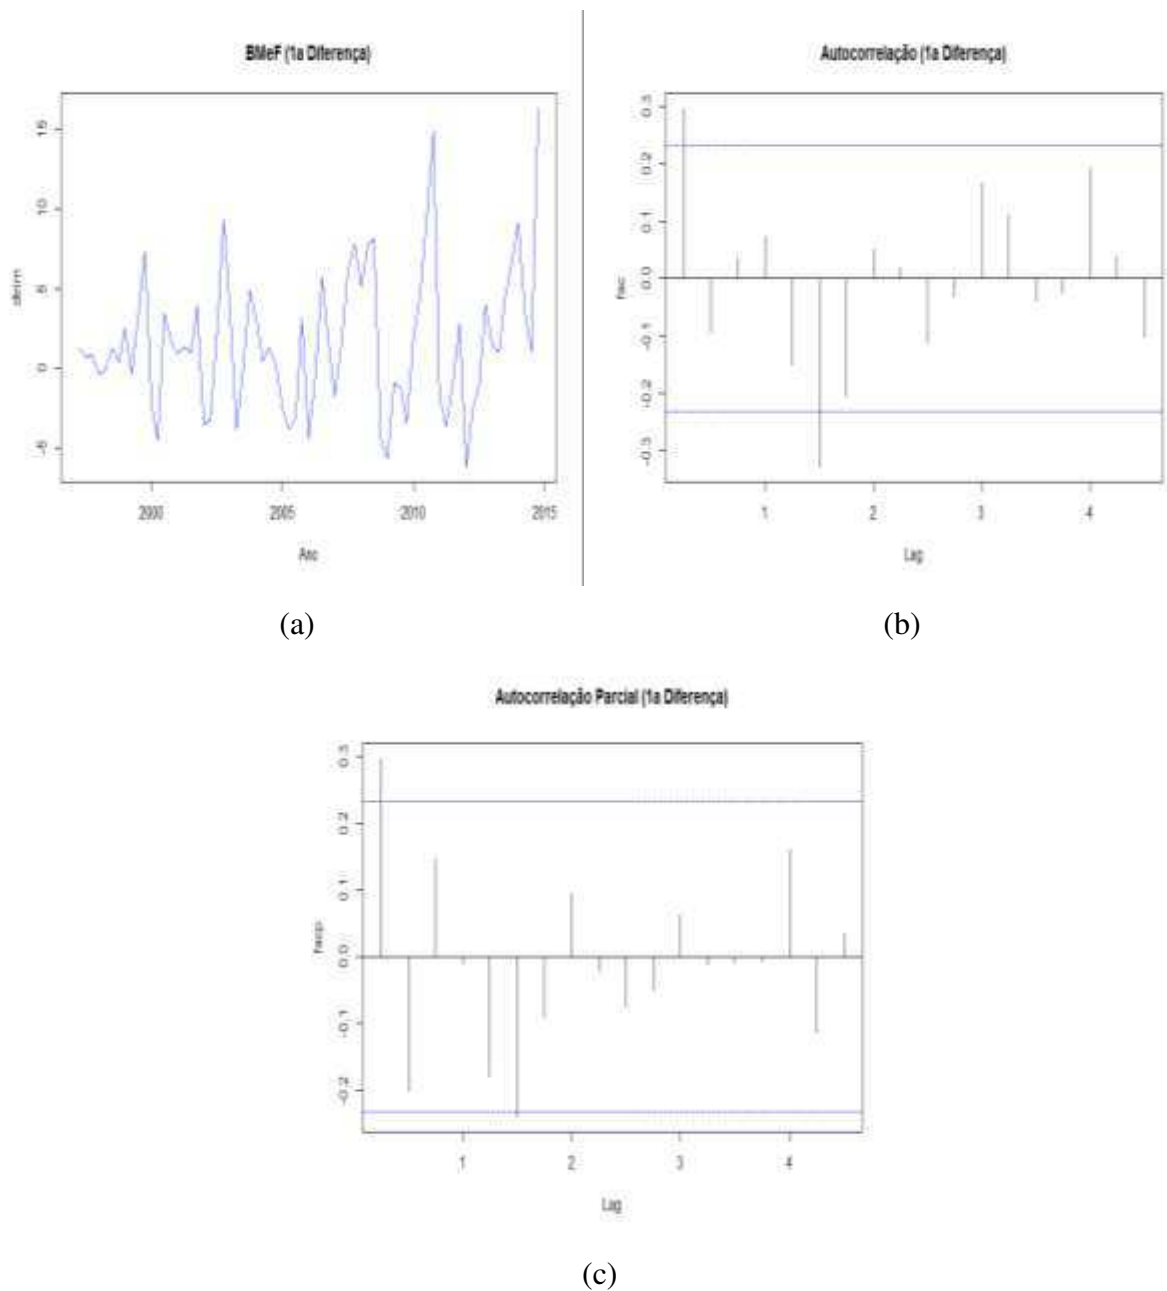


Figura 4. Representação gráfica da série diferenciada (a), gráfico de autocorrelação da série diferenciada (b) e gráfico de autocorrelação parcial da série diferenciada (c) da série histórica do preço da arroba do boi gordo no mercado futuro da BM&F.

A análise espectral do periodograma foi feita para identificar o tamanho do período cíclico da série. Através do periodograma, identificado na Figura 3, é possível verificar que o maior pico ocorre na posição 18. Para saber qual é o período cíclico da série, deve-se observar qual o valor terá a posição 18 na divisão entre $1/frequência$. Este valor observado foi de 1,00, ou seja, a componente cíclica é de 1 ciclo completo da frequência da série. Como a frequência da série é de 4 (trimestres), então a sazonalidade também possui 4 trimestres.




Figura 5. Representação gráfica do periodograma da série histórica do preço da arroba do boi gordo no mercado futuro da BM&F.

Com a série estacionária, iniciou-se o processo de identificação dos melhores modelos. Como o gráfico de autocorrelação e autocorrelação parcial mostraram os lags 1 e 6 (conforme Figura 4b e 4c) significativos e sabendo que o $pacp$ (autocorrelação parcial) indica a ordem da parte auto-regressiva e a pac (autocorrelação) a ordem da parte de médias móveis, pôde-se assim obter os primeiros passos para identificação do modelo SARIMA. Os melhores modelos foram $SARIMA(0,1,1) \times (0,1,1)$ e $SARIMA(1,1,0) \times (0,1,1)$. Além dos modelos de Box e Jenkins (SARIMA), outra técnica foi utilizada, o alisamento exponencial de Holt-Winters (AEHW).

Na Tabela 1 é mostrado os modelos ajustados, as estimativas dos parâmetros, o erro padrão e o p -valor para cada parâmetro, identificando assim se estes são, de fato, significativos. É possível notar através da Tabela 1 que todos os parâmetros são significativos para os modelos.

Tabela 1. Estimativa dos modelos SARIMA(0, 1, 1) × (0, 1, 1), SARIMA(1, 1, 0) × (0, 1, 1) e AEHW para a série histórica do preço do boi gordo no mercado futuro da BM&F.

Modelo	Parâmetro	Estimativa	Erro Padrão	<i>p</i> – valor
SARIMA (0, 1, 1) × (0, 1, 1)	θ_1	0,5250	0,1225	0,0001
	Θ_1	-0,9622	0,3348	0,0076
SARIMA (1, 1, 0) × (0, 1, 1)	ϕ_1	0,4052	0,1217	0,0021
	Θ_1	-1,0000	0,2105	0,0000
AEHW	α	1,0000	-	-
	β	0,0440	-	-

O teste de Box-Pierce foi usado para identificar se os modelos SARIMA possuem ruído branco. Analisando a Tabela 2, pode-se observar os modelos SARIMA ajustados, o grau de liberdade, a estatística do teste e *p* – valor que, se for maior que 0,05, com nível de significância $\alpha = 5\%$, pode-se admitir que os modelos possuem ruído branco.

Tabela 2. Teste de Box-Pierce para os modelos SARIMA ajustados para a série histórica do preço do boi gordo no mercado futuro da BM&F.

Modelo	Grau de Liberdade	Estatística do Teste	P-Valor
SARIMA (0, 1, 1) × (0, 1, 1)	16	6,4309	0,9827
SARIMA (1, 1, 0) × (0, 1, 1)	16	8,1485	0,9443

A seguir, são apresentadas na Tabela 3 as previsões do preço médio trimestral para o preço do boi gordo no mercado futuro da BM&F no período do primeiro trimestre de 2014 ao quarto trimestre de 2014 juntamente com seus respectivos erros, considerando os modelos SARIMA(0,1,1) × (0,1,1), SARIMA(1,1,0) × (0,1,1) e AEHW, na Tabela 3. Avaliando de modo geral, os valores previstos não aumentaram conforme os valores reais, ou seja, os modelos ajustados tendem a subestimar a série. Entretanto, estes modelos foram os melhores encontrados pelas técnicas citadas.

Tabela 3. Valores do preço médio observado para o ano de 2014, previsto e o erro de previsão para a série histórica do preço do boi gordo no mercado futuro da BM&F, considerando os modelos SARIMA(0, 1, 1) × (0, 1, 1), SARIMA(1, 1, 0) × (0, 1, 1) e AEHW.

Modelo	Trimestre	Valor Real	Valor Previsto	Erro Previsão
SARIMA (0, 1, 1) × (0, 1, 1)	1° Trimestre	119,2533	110,5967	8,6566
	2° Trimestre	122,6733	110,2340	12,4393
	3° Trimestre	123,7200	112,6373	11,0827
	4° Trimestre	140,0667	116,2477	23,8190
SARIMA (1, 1, 0) × (0, 1, 1)	1° Trimestre	119,2533	110,7662	8,4871
	2° Trimestre	122,6733	110,9200	11,7533
	3° Trimestre	123,7200	113,5402	10,1798
	4° Trimestre	140,0667	117,2522	22,8145
AEHW	1° Trimestre	119,2533	111,2967	7,9566
	2° Trimestre	122,6733	112,4833	10,1900
	3° Trimestre	123,7200	113,6700	10,0500
	4° Trimestre	140,0667	114,8567	25,2100

Para identificar o melhor modelo ajustado, foi calculado o AIC, EQMP e MAPE de cada modelo, dispostos na Tabela 4. O modelo com menor AIC, EQMP e MAPE foi o SARIMA(0,1,1) × (0,1,1), desta forma, este foi o modelo escolhido para representar a série histórica do preço do boi gordo no mercado futuro da BM&F.

Tabela 4. Estimativas dos critérios de AIC, EQMP e MAPE dos modelos ajustados para a série histórica do preço do boi gordo no mercado futuro da BM&F.

Modelo	AIC	EQMP	MAPE
SARIMA (0, 1, 1) × (0, 1, 1)	385,77	13,6492	4,1946%
SARIMA (1, 1, 0) × (0, 1, 1)	388,36	13,7836	4,3881%
AEHW	-	20,2697	5,2459%

Na Tabela 5 é apresentado os resultados do teste de Shapiro-Wilk para normalidade dos resíduos dos modelos ajustados. Todos os modelos de obtiveram p – valores maiores que 0,05

com nível de significância $\alpha > 5\%$ e, com isso, pode-se concluir que não há indícios para se rejeitar a hipótese nula do teste, ou seja, os resíduos dos modelos ajustados seguem distribuição normal.

Tabela 5. Estudo de normalidade dos resíduos via teste Shapiro-Wilk para os modelos ajustados SARIMA(0, 1, 1) \times (0, 1, 1) e SARIMA(1, 1, 0) \times (0, 1, 1) para a série histórica do preço do boi gordo no mercado futuro da BM&F

Modelo	W	<i>p</i> – valor
SARIMA (0, 1, 1) \times (0, 1, 1)	0,9714	0,1050
SARIMA (1, 1, 0) \times (0, 1, 1)	0,9779	0,2447

Com os modelos já ajustados, é possível fazer as previsões para os próximos anos da série histórica do preço do boi gordo no mercado futuro da BM&F. Estas previsões, juntamente com seus intervalos de confiança, são mostradas na Figura 6. Observe que, quanto maior for o período de previsão, maior será o intervalo de confiança e o erro encontrado na previsão. Portanto, as previsões aqui feitas foram de apenas dois anos, sendo estes 2015 e 2016.

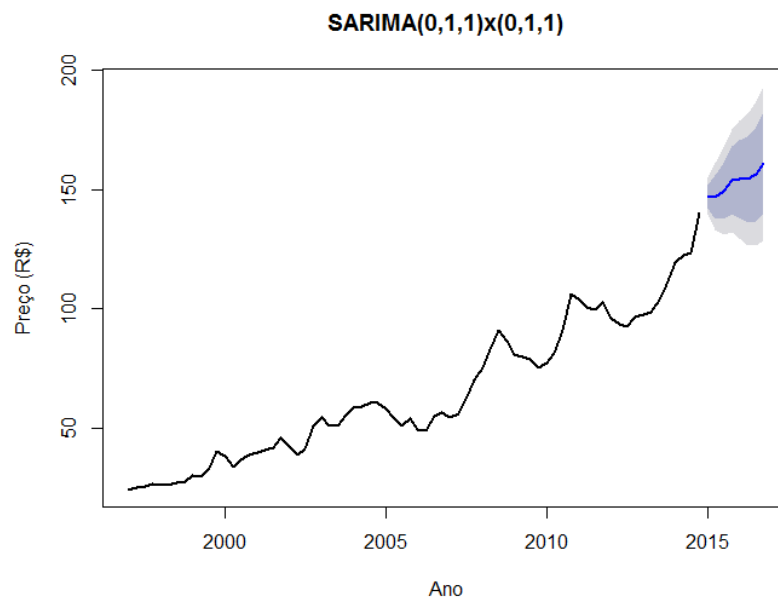


Figura 6. Representação gráfica da previsão da série pelo modelo SARIMA(0,1,1) \times (0,1,1) da série histórica do preço da arroba do boi gordo no mercado futuro da BM&F.

Na Tabela 6 são apresentados os valores preditos e o intervalo de confiança (com 80% e 95% de confiança) para as previsões dos anos de 2015 e 2016. Note que o intervalo de confiança aumenta de acordo com o tempo previsto. Este é um problema difícil de se contornar, visto que diversos componentes podem influenciar a série ao longo do tempo.

Tabela 6. Previsões para os anos de 2015 e 2016 com seus limites inferiores (LI) e limites superiores (LS) para 80% e 95% de confiança, da série histórica do preço da arroba do boi gordo no mercado futuro da BM&F.

Ano	Trimestre	Previsão	LI 80%	LS 80%	LI 95%	LS 95%
2015	1	147,0141	142,0401	151,9881	139,4070	154,6211
	2	146,9206	137,8570	155,9842	133,0590	160,7822
	3	149,2632	137,4497	161,0766	131,1961	167,3303
	4	153,7167	139,6822	167,7511	132,2528	175,1805
2016	1	154,1687	138,0705	170,2669	129,5486	178,7887
	2	154,0752	136,0851	172,0653	126,5617	181,5887
	3	156,4178	136,7166	176,1189	126,2874	186,5481
	4	160,8713	139,5962	182,1463	128,3339	193,4086

A partir da Tabela 1 é possível determinar o modelo ajustado das previsões para a série histórica do preço da arroba do boi gordo no mercado futuro da BM&F. O modelo estimado (SARIMA(0,1,1) × (0,1,1)) é dado por

$$Z_t = \frac{(1 - \theta_1 B^1)(1 - \theta_1 B^{12})}{(1 - B)(1 - B^{12})} \epsilon_t$$

onde, ao substituir os valores encontrados dos coeficientes será

$$Z_t = \frac{(1 - 0.5250B^1)(1 - (-0,9622)B^{12})}{(1 - B)(1 - B^{12})} \epsilon_t$$

4 CONCLUSÃO

Pelo modelo ajustado foi possível fazer previsões para a série histórica do boi gordo no mercado futuro da BM&F. Logo no primeiro trimestre de 2015, o valor previsto foi de R\$147,014, o que representa um aumento de 4,96% em relação ao último valor observado no preço da série. Já no próximo trimestre de 2015, o valor foi R\$146,921, diminuindo em 0,06% do último valor previsto. No último trimestre de 2015 houve um aumento de 9,74% em relação ao último valor real (que é o último trimestre de 2014), que foi R\$153,717. Considerando os intervalos de confiança, é possível que empresas e governos se adiantem e se adaptem para retirarem o melhor dos valores previstos. Portanto, fica claro a eficácia do uso de séries temporais em séries econômicas.

REFERÊNCIAS

- BM&FBOVESPA, A Nova Bolsa. **Metodologia do indicador de preços do boi gordo ESALQ/BM&FBOVESPA**. Indicadores Agropecuários. Metodologias. Boi gordo. 1 de agosto de 2011. Disponível em: <http://www.bmf.com.br/bmfbovespa/pages/contratos1/Agropecuarios/pdf/Metodologia-Boi-BM&FBOVESPA-01-08-2011.pdf>. Acesso em: 13 setembro de 2015.
- BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. **Time Series Analysis: forecasting and control**. 3 ed. New Jersey: Prentice Hall, 1994. 598 p.
- CONTINI, E.; GASQUES, J. G.; LEONARDI, R. B. A. de; BASTOS, E. T. Evolução e tendências do agronegócio. **Revista de Política Agrícola**, n.1, p.5-28, jan. 2006.
- EHLERS, Ricardo Sandes. **Análise de séries temporais**. Apostila.pdf. Material didático e instrucional. 2003.
- FRANCO, Glaura C. **Minicurso de séries temporais**. In: XII ENCONTRO MINEIRO DE ESTATÍSTICA E III SEMANA DA ESTATÍSTICA. Uberlândia. 5 de setembro de 2013. 156 p.
- LIMA, A. I.; SOUZA, A. L.; FARIA, J. A.; RODRIGUES, L.; ANDRADE, J. C. **Modelos de alisamento exponencial de Holt-Winters e modelo Sarima para previsão de séries temporais: uma análise do índice carbono eficiente (ICO2) da BM&BOVESPA**. In: CONGRESSO NACIONAL DE EXCELÊNCIA EM GESTÃO, 10., Rio de Janeiro, 2014. **Anais...** T14 0298, 2014.
- MORETTIN, P. A.; TOLOI, C. **Análise de séries temporais**. Blucher, 2006.
- OLIVEIRA NETO, Odilon José de. **Análise das operações de hedge do boi gordo no mercado futuro da BM&F para o estado de Goiás**. 2008. 80 f. Dissertação (Mestrado em Agronegócio) – Curso de Pós-graduação em Agronegócios, Universidade Federal de Goiás, Goiânia, 2008.
- PFAFF, Bernhard. **Analysis of integrated and cointegrated time series**. In: THE 1ST INTERNATIONAL R/RMETRICS USER AND DEVELOPER WORKSHOP. 8-12 July 2007, Meielisalp, Switzerland. 2007.
- PRIESTLEY, M. B. **Spectral analysis and time series**. 6 ed. New York: Academic Press, 1989.

- R DEVELOPMENT CORE TEAM (2015). **R: A language and environment for statistical computing**. R Foundation for Statistical Computing, Vienna, Austria. Disponível em: <http://www.R-project.org/>. Acesso em: 01 nov. 2015.
- SEIBEL, Felipe. **O novo salto do agronegócio**. Exame. Disponível em: <<http://exame.abril.com.br/revista-exame/edicoes/895/noticias/o-novo-salto-do-agronegocio-m0131023>>. Acesso em: 27 out.2015.
- SHUMWAY, Robert H.; STOFFER, David S. Time series analysis and its applications with R examples. EZ - 3. ed. 2003. 209 p.
- SHUMWAY, Robert H.; STOFFER, David S. Time series analysis and its applications with R examples. 3. ed. 2011. 573 p.
- TERM, Michaelmas. **Time series analysis**. University of Oxford. Department of Statistics, section 3, Oxford, 2010.
- TSAY, Ruey S. **Multivariate time series analysis with R and financial applications**. ISBN: 978-1-118-61790-8. Chicago. 2013. 520 p.
- USDA. **Foreign Agricultural Service (FAS)**. Disponível em <<http://apps.fas.usda.gov/psdonline/psdQuery.aspx>>. Acesso em 20 out. 2015.
- ŽITKOVIC, Gordan. **Introduction to stochastic processes**. December 24, 2010. 106 p. Lecture notes.

APÊNDICE

Os códigos em R utilizados para encontrar os modelos e testá-los são apresentados aqui. Os pacotes utilizados são apresentados ao início do código.

```
# Ativando o módulo de séries temporais
library(tseries)
require(TSA)
require(nortest)
require(forecast)
require(graphics)
require(car)
library(nlme)
require(randtests) # Teste de Cox-Stuart
library(FinTS)
library(lmtest)
# Leitura dos dados
trim <- read.table('trim.txt',header=T)
attach(trim)
trim <- ts(trim,start=c(1997),frequency=4)
trim
plot(trim)
ts.plot(trim, col='blue', main='BMeF', xlab='Ano')
acf(trim, lag.max=NULL, main="Autocorrelação",ylab="fac")
pacf(trim, lag.max=NULL, main="Autocorrelação Parcial",ylab="facp")
cox.stuart.test(trim) #serie com tendencia
#diferenciação pra tirar tendencia
dtrim <- diff(trim)
ts.plot(dtrim, col='blue', main='BMeF (1a Diferença)', xlab='Ano')
acf(dtrim, lag.max=NULL, main="Autocorrelação (1a Diferença)",ylab="fac")
pacf(dtrim, lag.max=NULL, main="Autocorrelação Parcial (1a Diferença)",ylab="facp")
cox.stuart.test(dtrim)
# Espectograma de BMEF
specp<-periodogram(dtrim,plot=TRUE,ylab="Periodograma", xlab="Frequência")$spec
specp # usar esse gráfico
```

```

max(specp) #posição 18 em 1/freq = 12, logo podemos dizer que tem sazonalidade 4 trimestres
window(spec.pgram(dtrim,main="",xlab="Frequência", ylab="Espectro"))#maior spectro
fazer 1/freq saber qts periodos de tempo para o ciclo completo
freq<-spec.pgram(dtrim)$freq
spec<-spec.pgram(dtrim)$spec
1/freq #
plot(specp)
# modelos
m0101 <- Arima(dtrim,order=c(0,0,1), seasonal=list(order=c(0,1,1)))
m1001 <- Arima(dtrim,order=c(1,0,0), seasonal=list(order=c(0,1,1)))
m0101 ##### USAR ESTE MODELO
shapiro.test(m0101$residuals)
teste <- (0.5250)/0.1225
dt(teste, length(dtrim))
teste <- (-0.9622)/0.3348
dt(teste, length(dtrim))
m1001 ##### USAR ESTE MODELO
shapiro.test(m1001$residuals)
teste <- (0.4052)/0.1217
dt(teste, length(dtrim))
teste <- (-1)/0.2105
dt(teste, length(dtrim))
##### AES - HoltWinters Simples - séries com tendencia e sazonalidade
par(mfrow=c(1,1))
AEHW = HoltWinters(trim,alpha=NULL,beta=NULL,gamma=FALSE,
seasonal=c("additive"))
AEHW
plot(AEHW,lwd=2,col="black",xlab="Ano")
AEHW$SSE
summary(AEHW)
#fazendo previsão nos dados originais
prevAEHW=forecast(AEHW, h=4)
plot(prevAEHW)
prevAEHW

```

```

prevAEHW$fitted
eAEHW<-prevAEHW$residuals
plot(prevAEHW, lwd=2, col="black", main="ARIMA(2,1,1)", xlab="Ano", ylab="Preço")
# testar pressuposições dos modelos escolhidos para comparar - m0101
plot(m0101$residuals,main="sARIMA(0,1,1)X(0,1,1)",xlab="Tempo", ylab="Resíduo")
abline(h=0)
hist(m0101$residuals,main="sARIMA(0,1,1)X(0,1,1)",xlab="Resíduo", ylab="Frequência")
shapiro.test(m0101$residuals)
qqnorm(m0101$residuals)
qqline(m0101$residuals)
acf(m0101$residuals, lag.max = NULL,main="sARIMA(0,1,1)X(0,1,1)",ylab="fac do
Resíduo")
pacf(m0101$residuals, lag.max = NULL,main="sARIMA(0,1,1)X(0,1,1)",ylab="facp do
Resíduo")
Box.test(m0101$residuals, lag=18,type=c("Box-Pierce"),fitdf = 2) #fitdf é qt de ordem p e q
nesse caso 0+1+0+1
# testar pressuposições dos modelos escolhidos para comparar - m0101
plot(m1001$residuals,main="sARIMA(1,1,0)X(0,1,1)",xlab="Tempo", ylab="Resíduo")
abline(h=0)
hist(m1001$residuals,main="sARIMA(1,1,0)X(0,1,1)",xlab="Resíduo", ylab="Frequência")
shapiro.test(m1001$residuals)
qqnorm(m1001$residuals)
qqline(m1001$residuals)
acf(m1001$residuals, lag.max = NULL,main="sARIMA(1,1,0)X(0,1,1)",ylab="fac do
Resíduo")
pacf(m1001$residuals, lag.max = NULL,main="sARIMA(1,1,0)X(0,1,1)",ylab="facp do
Resíduo")
Box.test(m1001$residuals, lag=18,type=c("Box-Pierce"),fitdf = 2) #fitdf é qt de ordem p e q
nesse caso 1+0+0+1
#fazendo previsão nos dados originais
fit0101=Arima(trim, order=c(0,1,1), seasonal=list(order=c(0,1,1)))
fit0101
prevfit0101<-forecast(fit0101, h=8)
prevfit0101

```

```

prevfit0101$fitted
efit0101<-prevfit0101$residuals
plot(prevfit0101, lwd=2, col="black", main="SARIMA(0,1,1)x(0,1,1)", xlab="Ano",
ylab="Preço")
fit1001=Arima(trim, order=c(1,1,0), seasonal=list(order=c(0,1,1)))
fit1001
prevfit1001<-forecast(fit1001, h=8)
prevfit1001
prevfit1001$fitted
efit1001<-prevfit1001$residuals
plot(prevfit1001, lwd=2, col="black", main="SARIMA(1,1,0)X(0,1,1)", xlab="Ano",
ylab="Preço")
prevAEHW=forecast(AEHW, h=8)
plot(prevAEHW)
prevAEHW
prevAEHW$fitted
eAEHW<-prevAEHW$residuals
plot(prevAEHW, lwd=2, col="black", main="Alisamento Exponencial de Holt-Winters",
xlab="Ano", ylab="Preço")

```

```

#avaliadores de previsão juntando com AIC que solta no modelo
EQMm0101<-(1/length(efit0101))*sum(efit0101^2)
EQMm0101
MAPEm0101<-(1/length(efit0101))*sum(abs(efit0101)/trim)
MAPEm0101
EQMm1001<-(1/length(efit1001))*sum(efit1001^2)
EQMm1001
MAPEm1001<-(1/length(efit1001))*sum(abs(efit1001)/trim)
MAPEm1001
EQMAEHW<-(1/length(eAEHW))*sum(eAEHW^2)
EQMAEHW

```

```
MAPEAEHW<-(1/length(eAEHW))*sum(abs(eAEHW)/trim)
MAPEAEHW
#### fazer predições - série ate 2013
# Leitura dos dados ate 2013
trima <- read.table('trima.txt',header=T)
attach(trima)
trima <- ts(trima,start=c(1997),frequency=4)
trima
predm0101=Arima(trima, order=c(0,1,1), seasonal=list(order=c(0,1,1)))
predm0101
forecast(predm0101,4)
plot(forecast(predm0101,4))
predm1001=Arima(trima, order=c(1,1,0), seasonal=list(order=c(0,1,1)))
forecast(predm1001,4)
predAEHW=HoltWinters(trima,alpha=NULL,beta=NULL,gamma=FALSE,
seasonal=c("additive"))
forecast(predAEHW,4)
```