



**UNIVERSIDADE FEDERAL DO PAMPA
CURSO DE PÓS-GRADUAÇÃO EM ENGENHARIA ECONÔMICA
ESPECIALIZAÇÃO EM ENGENHARIA ECONÔMICA**

CRISTIAN TALES FAGUNDES BANDEIRA

**PREVISÃO DE PREÇOS DOS PRINCIPAIS PRODUTOS AGROPECUÁRIOS
PRODUZIDOS NO MUNICÍPIO DE ALEGRETE – RS**

**Alegrete
2014**

CRISTIAN TALES FAGUNDES BANDEIRA

**PREVISÃO DE PREÇOS DOS PRINCIPAIS PRODUTOS AGROPECUÁRIOS
PRODUZIDOS NO MUNICÍPIO DE ALEGRETE – RS**

Trabalho apresentado ao Programa de Pós-Graduação em Engenharia Econômica, da Universidade Federal do Pampa – UNIPAMPA, como requisito parcial para obtenção do Título de Especialista em Engenharia Econômica.

Orientador: Prof. Dr. Alexandre Silva de Oliveira

Alegrete
2014

CRISTIAN TALES FAGUNDES BANDEIRA

**PREVISÃO DE PREÇOS DOS PRINCIPAIS PRODUTOS AGROPECUÁRIOS
PRODUZIDOS NO MUNICÍPIO DE ALEGRETE – RS**

Trabalho apresentado ao Programa de Pós-Graduação em Engenharia Econômica, da Universidade Federal do Pampa – UNIPAMPA, como requisito parcial para obtenção do Título de Especialista em Engenharia Econômica.

**Trabalho apresentado e aprovado em: 10 / 03 / 2014.
Banca examinadora:**

Prof. Dr. Alexandre Silva de Oliveira
Universidade Federal do Pampa - UNIPAMPA

Prof. Dr. Roberlaine Ribeiro Jorge
Universidade Federal do Pampa – UNIPAMPA

Prof. Dr. Jorge Luis Palacios Felix
Universidade Federal do Pampa - UNIPAMPA

Dedico este trabalho a pessoas que sempre me apoiaram, e dedicaram seu tempo para que me tornasse um homem de bem.

AGRADECIMENTOS

A Deus, por me conceder a oportunidade de sempre lutar por tudo em minha vida, com vontade, força e persistência mesmo quando haviam obstáculos a serem ultrapassados.

Ao Prof. Dr. Alexandre Silva de Oliveira, por mostrar esse novo universo da Engenharia Econômica.

A minha família, que sempre me apóia e comemora cada conquista, em especial a minha filha Crisléia(Nega).

A minha encantadora e amada Denise Dambros, intensa incentivadora em cada projeto.

Aos amigos que sempre estão juntos comemorando minhas vitórias.

A todas as pessoas que de uma forma ou de outra contribuíram para que este trabalho fosse concretizado. Muito Obrigado!

“O caminho dos vencedores é sempre traçado passo a passo, com muito esforço, suor e, muitas vezes, com lágrimas. Sabemos que a alegria da vitória compensa qualquer sacrifício. Somente pessoas corajosas, constantes e decididas chegam ao fim. A perseverança conquista a vitória.”

RESUMO

A agropecuária assume papel de destaque na economia mundial. Com os avanços científicos levaram o país a aumentar de forma significativa sua capacidade de produção e competitividade ao longo das últimas décadas. Este trabalho teve como objetivo realizar previsões para os próximos anos, referente ao preço dos principais produtos agropecuários produzidos no município de Alegrete/RS. Os dados-base da quantidade produzida dos principais produtos foram coletados junto a empresas do município, Cooperativa Agrícola Alegretense Ltda - CAAL- disponibilizou dados do Arroz, o Sindicato Rural de Alegrete os dados do Boi e, através do Centro de Estudos Avançados em Economia Aplicada - CEPEA-ESALQ/USP - dados da Soja, as previsões de preços, no período de janeiro de 1995 a dezembro de 2012. Para realização das previsões do preço das culturas de Arroz, Boi e Soja no município foi utilizada a Metodologia *Box & Jenkins*, com os modelos matemáticos *ARIMA* e *SARIMA*. Os resultados obtidos ficaram fora dos intervalos de confiança, concluindo que os modelos não se mostraram aplicáveis ao propósito de previsão.

Palavras – Chave: Arroz. Boi. Soja. Box & Jenkins. ARIMA, SARIMA.

ABSTRACT

Farming takes a prominent position in the world economy . With scientific advances led the country to significantly increase its production capacity and competitiveness over the past decades . This work aimed to make predictions for the coming years , concerning the price of the main agricultural products produced in the city of Alegrete / RS . The data base on the quantity produced of the main products were collected from township enterprises , Cooperativa Agrícola Ltda Alegretense - CAAL - provided data Rice , Rural Union Alegrete data Boi and through the Center for Advanced Studies in Applied Economics - CEPEA-ESALQ/USP - Soybean data , forecasts of prices , from January 1995 to December 2012 . For realization of the price of crops Rice , and Soybean Boi was used in the municipality estimates the Box -Jenkins methodology , mathematical models with ARIMA and SARIMA . The results were outside the confidence intervals , concluding that the models were not applicable to the purpose of forecasting .

Keywords: Rice. Boi. Soy. Box & Jenkins. ARIMA. SARIMA.

SUMÁRIO

1 INTRODUÇÃO.....	1
2 OBJETIVOS.....	3
3 REVISÃO BIBLIOGRÁFICA.....	4
3.1 Produtos.....	4
3.2 Séries Temporais.....	6
3.3 Modelo Box & Jenkins.....	7
3.4 Modelos Estacionários.....	8
3.5 FAC – Função de Autocorrelação.....	9
3.6 FACP – Função de Autocorrelação Parcial.....	11
3.7 Raiz Unitária.....	12
3.8 Modelo Auto Regressivo (AR).....	13
3.9 Modelos de médias móveis (MA).....	14
3.10 Modelos Auto Regressivos de Médias Móveis (ARMA).....	15
3.11 Modelos Não-Estacionários.....	16
3.12 Modelos Auto Regressivos Integrados de Médias Móveis (ARIMA).....	17
3.13 Modelos Sazonais.....	18
3.14 Outros Modelos.....	21
3.15 Etapas Metodologia Box & Jenkins.....	22
4 METODOLOGIA	25
4.1 Formas de Estruturação dos Dados.....	28
4.2 Procedimentos para Séries Arroz, Boi e Soja.....	28
4.3 Arroz.....	32
4.4 Boi.....	35
4.5 Soja.....	37
5 RESULTADOS E DISCUSSÕES.....	40
5.1 Arroz.....	40
5.2 Boi.....	47
5.3 Soja.....	53
6 CONSIDERAÇÕES FINAIS.....	60

REFERÊNCIAS	62
APÊNDICES	65

LISTA DE TABELAS

Tabela 1: Alimentos que ampliam as vendas.....	5
Tabela 2: Projeções de consumo de alimentos no Brasil de 2012/2013 a 2022/2023.	5
Tabela 3: Autocorrelação do MA.....	10
Tabela 4: Padrões de FAC e FACP.....	12
Tabela 5: Testes de Estacionariedade.....	12
Tabela 6: Modelos.....	22
Tabela 7: Modelos Apropriados.....	43
Tabela 8: Resumo - Teste de Estacionariedade.....	43
Tabela 9: Modelos Apropriados.....	49
Tabela 10: Modelos Apropriados.....	56

LISTA DE FIGURAS

Figura 1: Processo Estacionário.....	9
Figura 2.1: Correlograma para uma série com tendência.....	10
Figura 2.2: Correlograma para uma série com sazonalidade.....	11
Figura 3: Processo Não Estacionário.....	17

LISTA DE QUADROS

Quadro 1: procedimentos iniciais para utilização do Software R.....	29
Quadro 2: Leitura das informações.....	29
Quadro 2.1 : Descrição dos comandos.....	29
Quadro 3: Geração do Gráfico.....	30
Quadro 3.1: Descrição dos comandos.....	30
Quadro 4: Comandos para teste de estacionariedade.....	31
Quadro 5: Diferença de P.....	32
Quadro 6: Estimativas.....	33
Quadro 7: Resíduos.....	33
Quadro 8: Previsão.....	34
Quadro 9: Estimativas.....	35
Quadro 10: Resíduos.....	36
Quadro 11: Revisão.....	36
Quadro 12: Estimativas.....	38
Quadro 13: Resíduos.....	38
Quadro 14: Previsão.....	39
Quadro 15 – Previsão X Efetivado - Arroz.....	46
Quadro 16 – Previsão X Efetivado - Boi.....	52
Quadro 17 – Previsão X Efetivado - Soja.....	58

LISTA DE GRÁFICOS

Gráfico 1: Preços do Arroz em R\$.....	40
Gráfico 2: FAC (a) e FACP (b) da Série do Arroz.....	41
Gráfico 3: Plot de r da série P.....	42
Gráfico 4: FAC e FACP da série r.....	42
Gráfico 5: Resíduos FAC e FACP do modelo SARIMA (0,0,27).(3,0,0)8.....	44
Gráfico 6: Diagnóstico de Resíduos.....	45
Gráfico 7: Preços do Boi em R\$.....	47
Gráfico 8: FAC (a) e FAC (b) da Série do Boi.....	47
Gráfico 9: Plot de r da série P.....	48
Gráfico 10: FAC e FACP de r.....	49
Gráfico 11: Resíduos FAC e FACP do modelo ARIMA (1,2,21).....	50
Gráfico 12: Diagnóstico de Resíduos.....	51
Gráfico 13: Preços da Soja em R\$.....	53
Gráfico 14: FAC (a) e FACP (b) da série da Soja.....	54
Gráfico 15: Plot de r da Série P.....	55
Gráfico 17: Resíduos FAC e FACP do modelo ARIMA(1,0,15).....	57
Gráfico 18: Diagnóstico de Resíduos.....	58

1 INTRODUÇÃO

A diversidade, a qualidade e a quantidade do desenvolvimento agrícola Alegretense ocorrem por haver, no município, potencial agrícola devido a grande quantidade de terras agropastoris. Aliado a isso, tem-se incentivos agrícolas, boas máquinas, irrigação e combate a pragas, a fim de se obter uma boa safra. Mas, para se ter acesso a todos esses implementos, os gaúchos necessitam organizar-se e prever quais serão os seus benefícios, avaliando os lucros e prejuízos.

A análise de dados agrícolas por meio do uso de projeções é um instrumento que permite identificar possíveis trajetórias para fundamentar planejamentos estratégicos governamentais, além de estruturar visões de futuro do mercado de carnes no contexto mundial.

Dentre as ferramentas que visa auxiliar indiretamente os agricultores estão as análises estatísticas, que mostram uma síntese da realidade da cultura e apontam aspectos importantes na tomada de decisão dos produtores, das empresas e do próprio município. Tais decisões podem ser embasadas em análises descritivas e previsões futuras. Deve-se destacar que a análise descritiva gera uma síntese dos dados que se deseja analisar, enquanto que uma previsão é uma manifestação relativa a sucessos desconhecidos em um futuro determinado.

Para MORETTIN (1989), a previsão não constitui um fim em si, mas um meio de fornecer informações e subsídios para uma conseqüente tomada de decisão, visando a atingir determinados objetivos.

A realização de previsões é destaque atribuído ao modelo de *George Box* e *Gwilyn Jenkins*, devido, principalmente, a sua fundamentação teórica, sendo a princípio capaz de manipular séries temporais de qualquer natureza.

O método de *Box & Jenkins* consiste na busca de um modelo *ARIMA* – Auto Regressivos Integrados de Média Móveis, que representam o processo estocástico gerador de série temporal. Portanto, os modelos *ARIMA* são modelos matemáticos que almejam captar o comportamento da correlação seriada, ou autocorrelação entre os valores da série temporal, e, com base nesse comportamento, realizar previsões futuras sendo um dos modelos mais utilizados pois, consideram a sazonalidade estocástica dos dados.

Uma previsão a partir da série temporal procura construir um modelo matemático a partir do qual seja possível prever valores futuros da série, nesse sentido destaca-se o modelo *ARIMA*.

Dessa maneira a previsão de preços visa auxiliar o produtor local, na tomada de decisões e na criação de políticas de incentivo. Também, servir de suporte para a organização de programas públicos, ao detectar necessidades no município, os quais poderão desenvolver os incentivos necessários para sanar problemas enfrentados pelos empreendedores rurais.

Em vista disto, o presente trabalho tem por objetivo específico utilizar a metodologia *Box & Jenkins*, para realizar previsões, para os próximos anos, referente ao preço dos principais produtos agropecuários produzidos no município de Alegrete – RS, no período de Janeiro de 1995 a Dezembro de 2012, referente às lavouras temporárias (arroz e soja) e a produção bovina.

Este trabalho está organizado em três partes principais: revisão bibliográfica que aborda os conceitos básicos dos modelos *Box & Jenkins*, *softwares* utilizado para ler as séries temporais e efetuar os cálculos; apresentação dos resultados obtidos para a previsão dos valores futuros do arroz, soja e boi pelos modelos *ARIMA* e *SARIMA*; discussão dos resultados obtidos.

A revisão bibliográfica consiste em apresentar os produtos analisados e compreender estudos dos conceitos básicos de séries temporais, buscando o entendimento dos aspectos teóricos de forma simples e didática, para que esses conceitos pudessem ser aplicados no embasamento teórico da metodologia de previsão. O *Software R* e editor *R-Studio* foram objeto de estudo detalhado desse trabalho.

2 OBJETIVOS

Para cumprir os objetivos, analisou-se o poder do método de indicadores e comparou-o a alguns métodos de previsão existentes, como modelos *ARIMA* e *SARIMA* (metodologia *Box & Jenkins*). A análise detalhada dos procedimentos foi efetuada para a série temporal do arroz e boi de janeiro de 1995 a dezembro de 2012, na série da soja o período analisado foi de janeiro de 1998 a dezembro de 2012.

Objetivos específicos são: 1) Prever o comportamento dos preços do arroz no município de Alegrete/RS; 2) Prever o preço da soja no mesmo município; e 3) Prever o preço do boi vivo no mesmo município.

3 REVISÃO BIBLIOGRÁFICA

Nesse capítulo serão apresentados os principais produtos agropecuários que são fontes de estudo desse trabalho, também os conceitos básicos de séries temporais para aplicação dos métodos de previsão e metodologia *Box & Jenkins*. Além disso, é analisado o *Software R* e seu funcionamento.

3.1 Produtos

SILVEIRA, VIANA e WERNER JUNIOR (2009), relatam que a metade sul é uma região caracterizada pela agropecuária, sendo, predominante a pecuária e agricultura.

Segundo MAPA (2013), até o mês de abril/2013, as exportações do agronegócio cresceram 37,3%, resultado devido ao melhoramento das pesquisas para uma melhor produção dos produtos e também a participação do governo junto à iniciativa privada.

Os produtos que mais contribuíram para o crescimento de US\$ 3,98 bilhões foram os de origem vegetal, responsáveis por 84,2% da expansão. Entre os setores, destacaram-se em termos de contribuição para o crescimento: cereais, farinhas e preparações (alta de US\$ 4,61 bilhões); complexo soja (+US\$ 912,74 milhões); complexo sucroalcooleiro (+US\$ 694,90 milhões) e carnes (+US\$ 411,32 milhões). (MAPA, 2013).

Para MAPA (2013), o Brasil tem um crescimento da demanda por conta do aumento da renda dos brasileiros, puxando o aumento do consumo interno.

Produtos básicos como arroz e feijão, devem ter o crescimento do consumo associado ao aumento da população. Essa demanda tem crescido por volta de 1% ao ano, pouco abaixo do crescimento populacional do país. No entanto, outros com maior valor agregado serão ainda mais buscados no mercado devido ao maior poder aquisitivo dos brasileiros. (MAPA, 2013).

Na Tabela 1 estão os alimentos industrializados que ampliaram as vendas nos últimos cinco anos.

Tabela 1: Alimentos que ampliam as vendas

Alimento	Aumento
Carne de Frango	1,87% a.a.
Carne Bovina	2,77% a.a.
Leite de Vaca	2,29% a.a.
Iogurte	2,97% a.a.
Azeite	3,06% a.a.
Queijo	3,52% a.a.

Fonte: Dados coletados do MAPA (2013).

MAPA (2013) apresenta projeções de consumo de alimentos no Brasil de 2012/2013 a 2022/2013, conforme Tabela 2.

Tabela 2: Projeções de consumo de alimentos no Brasil de 2012/2013 a 2022/2023

Produto	Unidade	2012/13	2022/23	Variação (%)
Arroz	Mil t	12.142	13.217	8,86
Feijão	Mil t	3.598	3.985	10,75
Milho	Mil t	52.054	62.633	20,32
Soja Grão	Mil t	42.401	50.608	19,35
Soja Farelo	Mil t	14.325	18.345	28,06
Soja Óleo	Mil t	5.640	6.96	23,51
Carne Frango	Mil t	9.164	11.561	26,16
Carne Bovina	Mil t	7.233	10.330	42,82
Carne Suína	Mil t	2.947	3.502	18,86
Açúcar	Mil t	11.695	13.644	16,67
Café	Milhões sc	20	26	27,12
Leite	Milhões litros	35.266	42.398	20,22

Fonte: Dados coletados do MAPA (2013).

3.2 Séries Temporais

Na definição de Morettin e Toloí (1981, pg. 01) “uma série temporal é qualquer conjunto de observações ordenadas no tempo”.

Ainda segundo Morettin e Toloí (1981), há, basicamente, dois enfoques usados na análise de séries temporais, em ambos o objetivo é construir modelos para as séries com propósitos determinados, sendo:

- Modelos paramétricos (domínio do tempo). Ex.: Modelo *ARIMA*.
- Modelos não paramétricos (domínio de frequência).

Na realidade, o que chamamos de série temporal é uma parte de uma trajetória dentre muitas que poderiam ter sido observadas.

Morettin e Toloí (1981) apresentam os objetivos da análise de séries temporais:

- Investigar o mecanismo gerador da série temporal;
- Fazer previsões de valores futuros da série;
- Descrever apenas o comportamento da série;
- Procurar periodicidades relevantes nos dados.

Gujarati (2000, p. 715) esclarece, que “trabalho empírico baseado em dados de série temporal supõe que as séries temporais envolvidas sejam estacionárias”.

Também para Morettin e Toloí (1981, pg. 6) uma das suposições mais frequentes que se faz a respeito de uma série temporal é a de que ela é estacionária, ou seja, “ela se desenvolve no tempo aleatoriamente ao redor de uma média constante, refletindo alguma forma de equilíbrio estável”.

“Os modelos utilizados para descrever séries temporais são processos estocásticos, isto é, processos controlados por leis probabilísticas” (MORETTIN e TOLOI, 1981, pg. 17).

Fonseca (2003, pg. 265) apresenta uma definição para processo estocástico: “um processo estocástico é uma coleção de variáveis aleatórias, indexadas em relação ao tempo, representada por $\{X_t \mid t \in T\}$. O subconjunto T pode ser definido no conjunto de números reais (tempo contínuo) ou inteiros (tempo

discreto)”.

“De acordo com essa conceituação, qualquer série de informações definida no tempo - como [...] os preços diários de uma ação – pode ser considerada uma realização de um determinado processo estocástico” (FONSECA, 2003, pg. 265).

Gujarati (2000) salienta que o primeiro passo na análise de toda a série temporal, geralmente, se dá por uma representação gráfica dos dados. Assim, como, dados de qualquer série temporal podem ser pensados como sendo gerados por um processo estocástico ou aleatório; e um conjunto concreto de dados pode ser considerado como uma (particular) realização (amostra) do processo estocástico subjacente.

3.3 Modelo *Box & Jenkins*

Morretin & Tolo (1989), elaborou uma série temporal onde um conjunto de observações ordenadas no tempo.

Para a análise parti-se que uma série temporal é composta por elementos em diante dispostos, são eles:

- I. Tendência – verifica o sentido de deslocamento da série ao longo de determinado tempo anos;
- II. Ciclo – movimento dos dados que pode se tornar em um “sinal periódico”;
- III. Sazonalidade – representa o movimento dos dados em curtas durações, este, geralmente inferior a um ano, caso comumente utilizado em mudanças climáticas;
- IV. Ruído Aleatório – também denominado erro, que compreende a variabilidade inseparável dos dados, este não pode ser moldado.

Como uma série temporal tem os dados coletados sequencialmente ao longo do tempo, espera-se que ela apresente correlação seriada no tempo.

Os modelos de *Box & Jenkins*, genericamente conhecidos por *ARIMA*

(*Auto Regressive Integrated Moving Averages*) e na literatura em português por Auto Regressivos Integrados de Médias Móveis, são modelos matemáticos que visam captar o comportamento da correlação seriada ou autocorrelação entre os valores da série temporal, e com base nesse comportamento realizar previsões futuras. Se essa estrutura de correlação for bem modelada, fornecerá boas previsões.

Fava (2000) mencionou que os modelos *ARIMA* resultam da combinação de três componentes denominados “filtros”: O componente autoregressivo (*AR*), o filtro de integração (*I*) e o componente de médias móveis (*MA*).

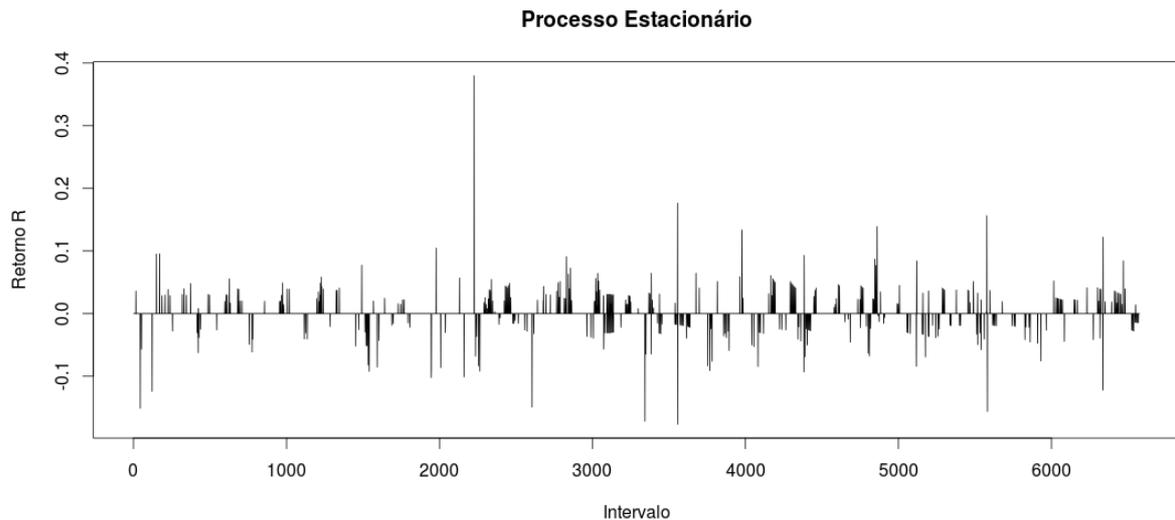
Sabendo destas particularidades podemos mediante análises mencionar que estes filtros podem modelar uma série.

3.4 Modelos Estacionários

Modelos estacionários são aqueles que assumem que o processo está em “equilíbrio”.

Gujarati (2000, pg. 719) também diz que “um processo estocástico é estacionário se sua média e variância forem constantes ao longo do tempo e o valor da covariância entre dois períodos de tempo depender apenas da distância ou defasagem entre os dois períodos, e não do período de tempo efetivo em que a covariância é calculada”. Conforme o Figura 1, pode-se notar que o gráfico se mantém em uma linha horizontal.

Figura 1: Processo Estacionário.



Fonte: Elaborado pelo autor.

Um processo é fortemente estacionário se todos os momentos conjuntos são invariantes a translações no tempo.

Para identificar se uma série é estacionária ou não, existem testes que podem ser feitos. Um teste simples de estacionariedade baseia-se na chamada função autocorrelação (*FAC*). A função de autocorrelação (*FAC*) representa uma medida de associação linear entre o processo e o seu passado, ou seja, uma medida da “memória” do processo. A função de autocorrelação parcial (*FACP*) complementa a ideia da *FAC*, sendo a correlação entre duas observações seriais y_t e y_{t-k} , eliminando-se a dependência dos termos intermediários.

3.5 *FAC* – Função de Autocorrelação

Bueno (2011), diz que a função de autocorrelação é o gráfico da autocorrelação contra a defasagem.

Em sua monografia Melo (2001), explica que a função de autocorrelação fornecem uma medida útil do grau de dependência entre os valores de uma série temporal em diferentes períodos.

Um processo *MA* de ordem q é identificado pela função de autocorrelação (BUENO, 2001, pg. 44). Melo (2001) relata que as autocorrelações medem ainda o

tamanho e a força da memória do processo. Na Tabela 3, é exposto a *FAC* para *MA(q)*.

Tabela 3: Autocorrelação do *MA*

Modelo	<i>FAC</i>
<i>MA(q)</i>	$\rho_j = \frac{\theta_j + \theta_{j+1}\theta_1 + \theta_{j+2}\theta_2 + \dots + \theta_q\theta_{q-j}}{\sum_{j=0}^q \theta_j^2}, j = 1, 2, \dots, q$ [01]

Fonte: Bueno (2011, pg. 44).

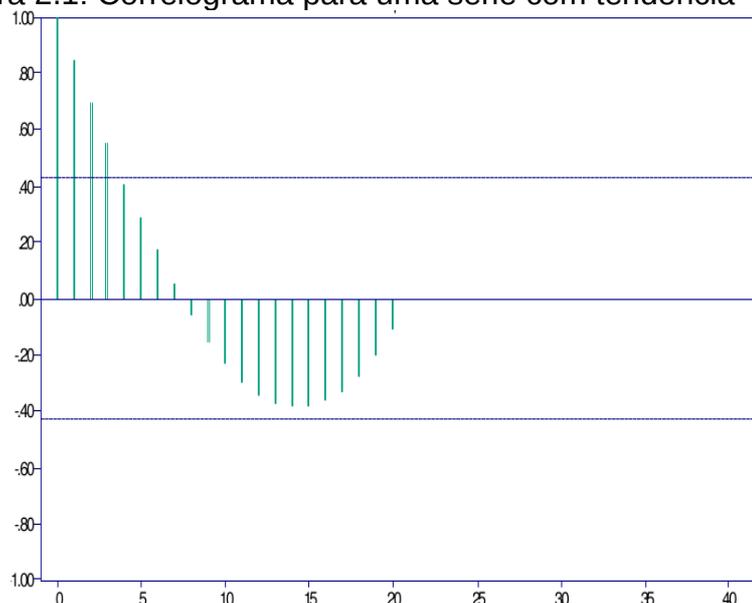
Na Tabela 3, *MA* torna-se zero a partir da defasagem *q*, onde $j > q$, não haverá erro em datas comuns.

A *FAC* gera gráfico que é chamado de correlograma. Nesse gráfico pode-se verificar as observações amostrais de modelos simulados.

Melo (2001) e Bueno (2011), relata que existe uma dificuldade para identificar padrões sobre a *FAC*, por serem dados estocásticos. Para identificação correta é necessário averiguar alguns modelos plausíveis que provejam correlogramas de formas reconhecidas (MELO, 2001, pg. 8).

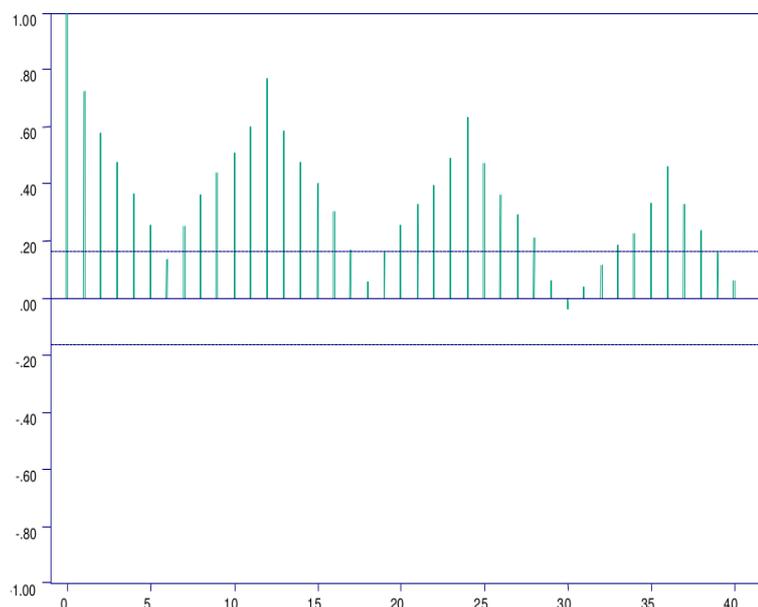
Para Melo (2001), dados que contenha tendência, *FAC* exibirá um decaimento lento na medida em que *t* aumenta, conforme mostra Figura 2.1. O mesmo autor apresenta na Figura 2.2 um gráfico com sazonalidade, apresentando um comportamento similar ao período.

Figura 2.1: Correlograma para uma série com tendência



Fonte: Melo (2001, pg. 9).

Figura 2.2: Correlograma para uma série com sazonalidade



Fonte: Melo (2001, pg. 9).

Verifica-se que, de acordo com Melo (2001), as figuras 1.1 e 1.2 representam limites significantes, aonde as autocorrelações são significamente diferente de zero. Outra definição é apresentada por Gujarati (2000), referente a unidade de medida que fica entre -1 e +1.

3.6 *FACP* – Função de Autocorrelação Parcial

A função de autocorrelação parcial (*FACP*) complementa a idéia da *FAC*, sendo a correlação entre duas observações seriais y_t e y_{t-k} , eliminando-se a dependência dos termos intermediários.

Bueno (2011) relata que é possível filtrar as correlações, mantendo-se apenas a correlação pura entre duas observações, o autor diz que a autocorrelação parcial é o gráfico φ_{jj} contra j , estimado na equação (1) onde a série original tem sua média subtraída:

$$y_t = \varphi_{j,1} y_{t-1} + \varphi_{j,2} y_{t-2} + \dots + \varphi_{j,j} y_{t-j} + e_t, j=1,2,\dots, \quad (1)$$

onde e_t , é um erro.

As escolhas dos modelos são obtidas através de análise da Tabela 4.

Tabela 4: Padrões de *FAC* e *FACP*

Tipo de modelo	Padrão típico de <i>FAC</i>	Padrão típico de <i>FACP</i>
<i>AR(p)</i>	Declina exponencialmente ou com padrão de onda senoidal amortecida, ou ambos.	Picos significativos através das defasagens p .
<i>MA(q)</i>	Picos significativos através das defasagens p .	Declina exponencialmente.
<i>ARMA(p, q)</i>	Declínio exponencial	Declínio exponencial.

Fonte: GUJARATI (2000, p. 748).

3.7 Raiz Unitária

Em nível formal, a estacionariedade pode ser checada verificando-se se a série temporal contém uma raiz unitária. Os Testes de Raiz Unitária englobam o Teste de *Dickey-Fuller (DF)*, o Teste de *Phillips-Perron (PP)* e o Teste de *Kwiatkowski-Phillips-Schmidt-Shin (KPSS)*.

Nos testes *DF* e *PP* a hipótese nula é de que a série tenha raiz unitária, não sendo estacionária. No teste *KPSS* a hipótese nula é de que não existe raiz unitária.

Tabela 5: Testes de Estacionariedade

Modelos de Testes	Resultado Esperado
<i>Dickey-Fuller</i>	< 5%
<i>Phillips-Perron</i>	< 5%
<i>KPSS</i>	> 5%

Fonte: Elaborado pelo autor.

3.8 Modelo Auto Regressivo (AR)

Em um modelo autoregressivo, a série de dados históricos Z_t é descrita por seus valores passados regredidos e pelo ruído aleatório, \sum^t .

Assim, um modelo $AR(p)$ é dado pela equação 2

$$Z_t = \theta_1 Z_{t-1} + \theta_2 Z_{t-2} + \dots + \theta_n Z_{t-n} + \varepsilon_t \quad (2)$$

em que, $Z_t = Z_t - \mu$, θ_1 parâmetro que descreve como Z_t relaciona com o valor Z_{t-i} para $i = 1, 2, 3 \dots p$.

O modelo $AR(p)$ na equação 2 é reescrito na equação 3 usando a defasagem L

$$(1 - \theta_1 L - \theta_2 L^2 - \dots - \theta_p L^p) Z_t = \varepsilon_t \quad (3)$$

O modelo autoregressivo de ordem 1 ou $AR(1)$ é a versão mais simples dessa classe de modelos. Sua apresentação algébrica é dada pela equação 4 que segue:

$$Z_t = \theta_1 Z_{t-1} + \varepsilon_t \quad (4)$$

Para o modelo ser estacionário é necessário que $|\theta_1| < 1$ condição de estacionariedade e que as autocovariâncias γ_k sejam independentes.

No caso do modelo $AR(1)$, as autocovariâncias são dadas pela equação 5.

$$\gamma_k = \theta_1^k \gamma_0 \quad (5)$$

E as autocorrelações ρ_k são dadas pela equação que segue:

$$\rho_k = \frac{\gamma_k}{\gamma_0} = \theta_1^k \quad k=0,1,2,3 \dots \quad (6)$$

A função de autocorrelação decai exponencialmente quando θ_1 é positivo, quando θ_1 é negativo a função de autocorrelação também decai exponencialmente, mas apresenta alternância de sinais positivos e negativos.

3.9 Modelos de médias móveis (MA)

Em um modelo de médias móveis a série Z_t resulta da combinação dos ruídos brancos do período atual com aqueles ocorridos em períodos anteriores.

Assim, um modelo de médias móveis de ordem q ou $MA(q)$ é dado pela equação 7.

$$Z_t = \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} \quad (7)$$

em que: $Z_t = Z_t - \mu$, θ_i é o parâmetro que descreve como Z_t se relaciona com o valor ε_{t-i} para $i = 1, 2, \dots, q$.

O modelo $MA(q)$ dado pela equação 6 pode ser reescrito pela equação 8 com o operador de defasagem L .

$$(1 - \theta_1 L - \theta_2 L^2 - \dots - \theta_q L^q) \varepsilon_t = \theta(L) \varepsilon_t = Z_t \quad (8)$$

O modelo $MA(1)$ é a versão mais simples dessa classe de modelos.

Sua apresentação algébrica é dada pela equação 9.

$$Z_t = \varepsilon_t + \theta_1 \varepsilon_{t-1} \quad (9)$$

As autocorrelações ρ_k que nada mais são do que as autocovariâncias divididas pela variância, são dadas na seguinte equação 10.

$$\rho_k = \frac{\gamma_k}{\gamma_0} = \frac{-\theta_1 \sigma_\varepsilon^2}{(1-\theta_1^2) \sigma_\varepsilon^2} = \frac{-\theta_1}{(1-\theta_1^2)} \text{ comp } k=0, k>1 \quad (10)$$

A função de autocorrelação do modelo $MA(1)$ apresenta apenas a primeira autocorrelação não nula e as demais iguais a zero. A primeira autocorrelação será positiva se θ_1 for menor que zero e negativa se θ_1 for maior que zero.

Segundo Nelson (1973), uma propriedade importante da $MA(1)$, proveniente da função de autocorrelação, é que sua memória é de somente um período.

Para obter a condição de invertibilidade, ou seja, para transformar um modelo $MA(1)$ em um Modelo $AR(\infty)$ é preciso impor a restrição de que $|\theta_1| < 1$. Segundo Abraham & Ledolter (1983), para que um processo $MA(q)$ se torne inversível, é necessário que as raízes da equação $\theta(L) = 1 - \theta_1 L - \theta_2 L^2 - \dots - \theta_q L^q = 0$ sejam maiores que um.

3.10 Modelos Auto Regressivos de Médias Móveis (ARMA)

Em alguns casos, pode ser necessário utilizar um grande número de parâmetros em modelos puramente AR ou puramente MA . Nesses casos, é vantajoso misturar os componentes de um modelo AR como os componentes de um modelo MA , gerando, assim, um modelo $ARMA$. O modelo $ARMA(p,q)$ exigirá um número menor de termos e pode ser expresso conforme a equação 11.

$$Z_t = \phi_1 Z_{t-1} + \dots + \phi_p Z_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} \quad (11)$$

O modelo *ARMA* mais simples é o *ARMA(1,1)* dado pela equação 12 que segue.

$$Z_t = \vartheta_1 Z_{t-1} + \varepsilon_t - \theta_1 \varepsilon_{t-1} \quad (12)$$

A função de autocorrelação do modelo *ARMA(1,1)* é dada pela equação 13.

$$\rho_k = \frac{(1 - \vartheta_1 \theta_1)(\vartheta_1 - \theta_1)}{(1 - \theta_1^2 + 2\vartheta_1 \theta_1)} \rho_k = \vartheta_1 \rho_{k-1} \text{ para } k > 1 \quad (13)$$

A função de autocorrelação do modelo *ARMA(p,q)* apresenta características da função *MA(q)* para as defasagens $k < q$ pelo fato de a “memória” do componente de médias móveis durar apenas *q* períodos. Para defasagens maiores que $k > 1$ as características são iguais às de um modelo *AR(p)*.

3.11 Modelos Não-Estacionários

Quando uma série temporal apresenta média e variância dependentes do tempo, é porque ela não é estacionária.

Referente a não estacionariedade de uma série:

a) possuímos inclinação nos dados e eles não permanecem ao redor de uma linha horizontal ao longo do tempo;

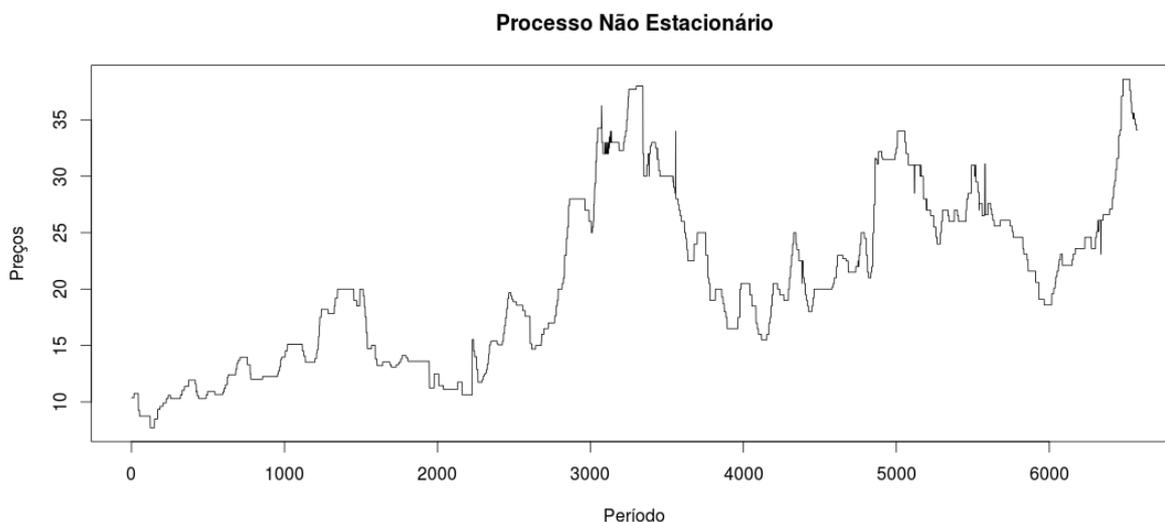
b) pode-se ter também a variação dos dados não permanecem essencialmente constantes sobre o tempo, assim, as flutuações aumentam ou diminuem com o passar do tempo, indicando que a variância está se alterando.

As referências de não estacionariedade mencionadas em (a) e (b) podem ser vistas no Figura 3.

Para detectar a não-estacionariedade de uma série, o comportamento

temporal pode ser analisado graficamente, buscando padrões (a) e (b) ou, então, aplicando os testes estatísticos de raiz unitária.

Figura 3: Processo Não Estacionário.



Fonte: Elaborado pelo autor.

Segundo Pindyck e Rubinfeld (2004) e Fava (2000), séries não estacionárias podem ser transformadas em séries estacionárias quando suas observações são diferenciadas uma ou mais vezes.

3.12 Modelos Auto Regressivos Integrados de Médias Móveis (ARIMA)

Os procedimentos de análise estatística de séries temporais supõe que estas sejam estacionárias, será necessário transformá-las caso ainda não sejam.

Segundo Morretin & Tolo (1989), a transformação mais comum consiste em tomar diferenças sucessivas da série original até obter uma série estacionária.

A primeira diferença de Z_t é definida na equação 14.

$$\Delta Z_t = Z_t - Z_{t-1} \quad (14)$$

Outra equação é a seguinte 15:

$$D^2Z_t = D[DZ_t] = D[Z_t - Z_{t-1}] = Z_t - 2Z_{t-1} - Z_{t-2} \quad (15)$$

Segundo os autores citados no artigo, será suficiente tomar uma ou duas diferenças para que a série se torne estacionária. O número d de diferenças necessárias para tornar a série estacionária é denominado ordem de integração.

A inclusão do termo de ordem de integração permite que sejam utilizados os modelos $ARIMA(p,d,q)$ dados pela equação 16.

$$w_t = \phi_1 w_{t-1} + \dots + \phi_p w_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} \quad (16)$$

Onde: $w_t = \Delta^d Z_t$

O modelo $ARIMA(p,d,q)$ dado pela equação 15 pode ser reescrito, como em 16, utilizando o operador de defasagem L $(1 - \phi_1 L - \dots - \phi_p L^p) w_t = (1 - \theta_1 L - \theta_q L^q) \varepsilon_t$.

Com: $w_t = (1-L)^d Z_t$

$$\phi(L)(1-L)^d Z_t = \theta(L) \varepsilon_t \quad (17)$$

3.13 Modelos Sazonais

Sazonalidade, definida como a propriedade de determinadas séries de apresentar certos comportamentos cíclicos ou periódicos (CAMPOS, 2009, p.31).

Como muitas séries temporais econômicas apresentam componentes sazonais em sua evolução, como é o caso das séries de preços de alguns produtos agropecuários, torna-se necessário incorporar a componente sazonal na estimativa $ARIMA$.

Os modelos $ARIMA$ exploram a autocorrelação entre os valores da série em instantes sucessivos, mas quando os dados são observados em períodos inferiores a um ano, a série também pode apresentar autocorrelação para uma estação de sazonalidade ^s.

Um dos modelos mais utilizados que consideram a sazonalidade de uma

determinada série temporal, e o chamado modelo *ARIMA* sazonal, ou *SARIMA* (Morettin & Tolo (2006)).

O *ARIMA* sazonal também é chamado de modelo de *Box & Jenkins*. Este modelo assume em conta um possível componente sazonal que pode ser aleatório, também. O período sazonal é assumido a ser conhecido, por exemplo, anual, trimestral, semanal, etc. Vai ser referido como s .

A forma como a série temporal é gerada é tomada por ruído branco, criando um Modelo *ARIMA* sazonal que explicaria a relação entre anos (se a sazonalidade é anual) e, em seguida, a criação de um modelo *ARIMA* para o que acontece dentro de cada ano.

Como definem MORAES, SALES e COSTA (2011, p. 02), para uma série, que receba a influência de fatores sazonais, tem-se a importância da correlação entre os instantes de tempo distantes entre si por s ou múltiplos de s , aonde s representa o período sazonal.

Os modelos *SARIMA* contêm uma parte não sazonal, com parâmetros (p,d,q) , e uma sazonal, com parâmetros $(P,D,Q)_s$. MARCHEZAN (2010, p. 51), apresenta o modelo mais geral dado pelas equações 18, 19 e 20.

$$(1 - \theta_1 L - \dots - \theta_p L^p) (1 - \Phi_1 L^s - \dots - \Phi_P L^{Ps}) \quad (18)$$

$$(1-L)^d (1-L^s)^D Z_t = (1 - \theta_1 L - \dots - \theta_q L^q) \quad (19)$$

$$(1 - \Theta_1 L^s - \dots - \Theta_Q L^{Qs}) \varepsilon_t \quad (20)$$

- | | |
|--|---|
| $(1 - \theta_1 L - \dots - \theta_p L^p)$ | é a parte autoregressiva não sazonal de ordem p |
| $(1 - \Phi_1 L^s - \dots - \Phi_P L^{Ps})$ | é a parte autoregressiva sazonal de ordem P e estação sazonal s |
| $(1-L)^d$ | parte de integração não-sazonal de ordem d |
| $(1-L^s)^D$ | parte de integração sazonal de ordem D e estação sazonal s |
| $(1 - \theta_1 L - \dots - \theta_q L^q)$ | é a parte não sazonal de média móvel de ordem q |
| $(1 - \Theta_1 L^s - \dots - \Theta_Q L^{Qs})$ | é a parte sazonal de médias móveis de ordem Q e estação sazonal s |

Outra definição de modelo é apresentada por SAK e HÖRMANN (2012), para os processos sazonais *ARIMA* (*SARIMA*), com período s , um *AR* polinômio sazonal $\Phi(B^s)$ de ordem p , uma sazonal *MA* polinomial $\Theta(B^s)$ de ordem q e o operador de diferença sazonal de ordem d são necessários.

$$\nabla_s^d X_t = (1 - B^s)^d X_t \quad (21)$$

O *SARIMA* $(p,d,q)(\tilde{p},\tilde{d},\tilde{q})_s$, em seguida, é definido pela equação:

$$\Phi(B^s)\varphi(B)\nabla_s^d\nabla_s^{\tilde{d}}X_t = \Theta(B^s)\theta(B)\varepsilon_t + \mu \quad (22)$$

Convém notar que, conforme salienta CAMPOS (2009, pg. 32), os coeficientes do modelo sazonal podem ser tratados de forma aditiva ou multiplicativa. Dado o exemplo, um modelo aditivo, *ARIMA* $((1,4),0,1)$, é definida pela equação:

$$(1 - a_1 L - a_4 L^4)y_t = (1 + b_1 L)\varepsilon_t \quad (23)$$

O já citado autor exemplifica o modelo multiplicativo, na forma *SARIMA* $(1,0,1) \times (1,0,0)$, definida pela equação:

$$(1 - a_1 L)(1 - a_4 L^4)y_t = (1 + b_1 L)\varepsilon_t \quad (24)$$

Não há uma forma de tratamento preferida e a checagem e diagnóstico do modelo estimado é a melhor maneira de se obter o modelo mais apropriado. Caso o modelo apresente uma raiz unitária sazonal, é necessária uma diferenciação sazonal, que, no caso de dados mensais terá a forma $(1 - L^{12}) = \Delta_{12}$.

O modelo multiplicativo é identificado como *SARIMA* $(p,d,q) \times (P,D,Q)_s$ em que:

- d = número de diferenças não sazonais;

- p e q = coeficientes não sazonais *ARMA*;
- P = número de coeficientes auto-regressivos multiplicativos;
- Q = número de coeficientes média móvel multiplicativos;
- D = número de diferenças sazonais;
- s = período do padrão sazonal.

3.14 Outros Modelos

Além dos modelos apresentados, existem outros, GUJARATI (2000, pg. 752) relata a importância de estimar tais modelos, tendo certeza de que as equações no sistema serão identificadas, sendo que algumas variáveis predeterminadas estejam presentes somente em algumas equações.

No modelo *VAR* (Tabela 6, equação 25) criado por SIMS (1980), ALEXANDER (2005, p. 370) identifica o modelo genérico (*VAR*) que estende o modelo *AR* para uma série de tempo multivariada. Ainda no que se refere, BUENO (2011, pg. 195), “[...] os modelos econômicos em geral são expressos por meio de diversas variáveis..”, visto que os modelos univariados é limitado para expressar os modelos econômicos.

Convém notar que, conforme salienta BUENO (2011 pg. 273), em relação ao modelo *ARCH* e *GARCH*:

A razão principal do surgimento desses modelos é que, antes disso, os modelos econométricos de séries de tempo, fossem os financeiros ou os macroeconômicos, enfatizavam apenas o primeiro momento condicional. As dependências temporais de ordem superior eram perturbações aleatórias, consideradas em seus momentos incondicionais. Essas dependências expressam a existência de aglomerações na série e a alternância de períodos de baixa volatilidade com períodos de alta volatilidade. (BUENO 2011 pg. 273),

ENGLE (1982) sugeriu um modelo alternativo para previsões, denominado *Autoregressive Conditional Heteroskedasticity (ARCH)* (Tabela 6, equação 26), visto que o modelo *ARIMA*, apresenta restrições em manter a variância do erro constante ao longo do tempo.

BUENO (2011, pg. 276), justifica que é necessário muitos parâmetros

para o modelo *ARCH*, BOLLERSLEV (1986) sugeriu um modelo geral e parcimonioso denominado *Generalized Autoregressive Conditional Heteroskedasticity (GARCH)* (Tabela 6, equação 27), dado o grande número de defasagens, q .

O mercado financeiro apresenta volatilidade no que diz a respeito as quedas dos preços, inversamente no período de alta dos preços. Tal fato denominado “efeito alavancagem” (SILVA; SAFADI; CASTRO JÚNIOR, 2005). Para os modelos anteriores supõem que os impactos dos choques aleatórios são simétricos, a evidência empírica contradiz essa idéia (BUENO, 2011, p.279). ZAKOIAN (1994) desenvolveu um modelo conhecido como *Threshold Autoregressive Conditional Heteroskedasticity (TARCH)* (Tabela 6, equação 28) capaz de capturar esses efeitos assimétricos na série.

Na Tabela 6 estão os modelos, identificando o ano, autor e sua equação.

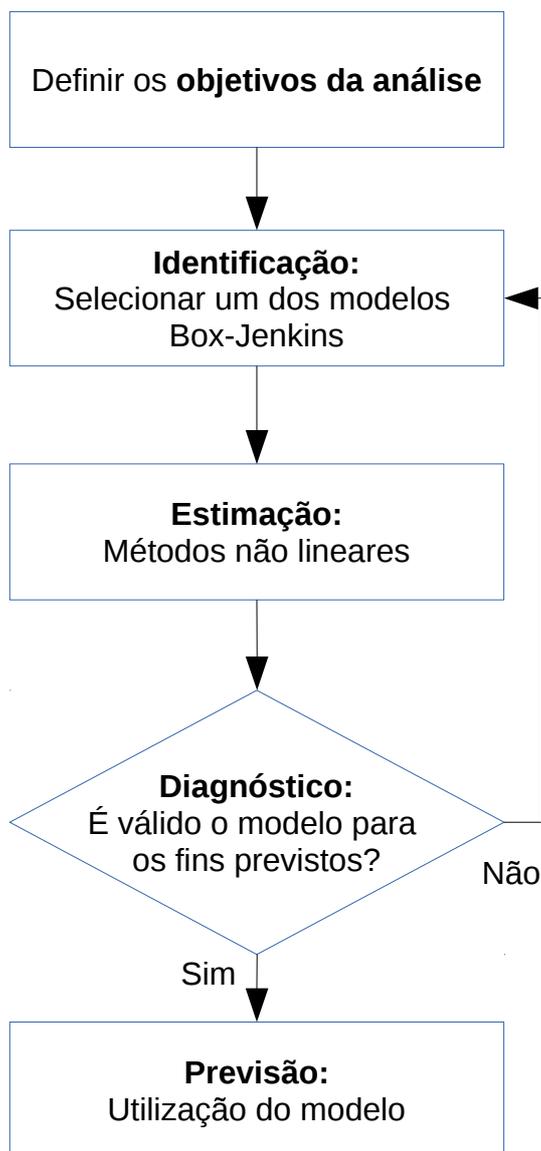
Tabela 6: Modelos

Ano	Autor	Modelo	Equação
1980	SIMS, Christopher A.	VAR	$VA_t = \alpha + \sum_{j=1}^4 \beta_j VA_{t-j} + \sum_{j=1}^4 \gamma_j LT_{t-j} + u_{1t} \quad (25)$
1982	ENGLE, R. F.	ARCH	$\sigma_t^2 = \Phi + \sum_{i=1;q} \omega_i u_{t-i}^2 \quad (26)$
1986	BOLLERSLEV, T.	GARCH	$\sigma_t^2 = \Phi + \sum_{i=1;q} \omega_i u_{t-i}^2 + \sum_{j=1;p} \phi_j \sigma_{t-i}^2 \quad (27)$
1994	ZAKOIAN, J. M.	TARCH	$\sigma_t^2 = \Phi + \omega u_{t-1}^2 + \phi \sigma_{t-1}^2 + \gamma d_{t-1} u_{t-1}^2 \quad (28)$

Fonte: Elaborado pelo autor.

3.15 Etapas Metodologia *Box & Jenkins*

Segundo Morretin & Tolo (1989), a construção dos modelos *Box & Jenkins* é baseada em um ciclo iterativo, no qual a escolha do modelo é feita com base nos próprios dados. No Diagrama 1 é descrito o fluxo da Metodologia *Box & Jenkins*.

Diagrama 1: Etapas da Metodologia *Box & Jenkins*

Fonte: Elaborado pelo autor.

Segundo Gujarati (2000), são quatro as etapas para construção do modelo:

a) **Identificação**: consiste em descobrir qual dentre as várias versões dos modelos de *Box & Jenkins* com valores apropriados de p , d , e q , sejam eles sazonais ou não, descreve o comportamento da série. A identificação do modelo a ser estimado ocorre pelo comportamento das funções de autocorrelações (*FAC*) e das funções de autocorrelações parciais (*FACP*).

b) **Estimação**: consiste em estimar os parâmetros p e q do componente autoregressivo, e os parâmetros do componente de médias móveis.

c) **Checagem de diagnóstico:** consiste em avaliar se o modelo estimado é adequado para descrever o comportamento dos dados.

d) **Previsão:** consiste em efetivar a previsão, isto é, realiza previsão da série temporal, busca-se encontrar boas previsões de valores futuros.

Um procedimento muito utilizado é identificar não só um único modelo, mas alguns modelos que serão então estimados e verificados. Quando se obtém um modelo satisfatório, passa-se para a última etapa da metodologia de *Box & Jenkins*, que constitui o objetivo principal da metodologia: realizar previsões. O detalhamento dessas etapas se dará com a aplicação no estudo de caso.

4 METODOLOGIA

Neste capítulo será apresentado a coleta dos dados, tratamento, identificação de série estacionária ou não e, forma de estruturação dos dados.

Para a elaboração do presente trabalho, a metodologia adotada foi um estudo de caso, definido como “[...] estudos dos eventos em seu contexto de vida real” (YIN, 2009, pg. 110).

O estudo de caso apresentado pode ser classificado como avaliativo, tendo em vista que “os estudos de casos avaliativos envolvem descrição e explicação (...) proporcionando informações para produzir julgamentos” (GIL, 2009, pg. 50).

Nesta pesquisa foram analisadas 2(duas) culturas pertencentes a lavoura temporárias, arroz e soja, e a produção bovina no período de 1995 a 2012. Esses dados foram coletados no Centro de Estudos Avançados em Economia Aplicada (CEPEA-ESALQ/USP), e junto a órgãos locais, como o Sindicato dos Produtores Rurais e Cooperativa Agrícola Alegretense Ltda. (CAAL). Inicialmente, realizada uma análise descritiva dos dados coletados, utilizando-se os preços de cotações diárias de Janeiro de 1995 a Dezembro de 2012. A análise do comportamento dos preços e dos valores previstos são determinados por meio da Metodologia *Box & Jenkins*.

A previsão é uma das principais razões da popularidade desta metodologia e, em muitos casos, as previsões, principalmente de curto prazo, são melhores que as obtidas com base nos modelos econométricos tradicionais. Esta metodologia é composta pelo Modelos *ARIMA*, que são modelos estatísticos lineares para análise de Séries Temporais. Esses modelos são mais sofisticados por usarem a correlação entre as observações. No modelo *ARIMA*, a Série Temporal é gerada por um processo estocástico, cuja natureza pode ser representada através de um modelo. Segundo MORETTIN & TOLOI (2004), SOUZA & CAMARGO (1996), BARROS (2006), uma Série Temporal, também pode ser definida por uma Série Histórica, que é uma sequência de dados obtidos em intervalos regulares de tempo, durante um período específico, e que apresentam uma dependência seriada.

A notação utilizada para representar uma Série Temporal Z , no momento t será Z_t , em que $t=1,2,K, n$ indica o tamanho da Série. A notação utilizada para

designar o modelo *ARIMA*, é *ARIMA*(p, d, q), em p é o número de termos autoregressivos; d , o número de diferenciações para que a série se torne estacionária e q , o número de termos de média móvel. Os termos p, d e q são todos inteiros maiores ou iguais a 0 (zero). São casos particulares: o modelo *ARMA*(p, d), o modelo autoregressivo *AR*(p) e o modelo de média móvel *MA*(q), sendo os três modelos utilizados para Séries Temporais estacionárias ($d=0$).

Nos Modelos estacionários interpretam a Série Temporal como uma realização de um vetor aleatório do tamanho das Séries disponíveis, seguindo princípio da parcimônia e da construção de modelos, através de um ciclo iterativo.

Os modelos estacionários são:

Modelos autoregressivos de ordem p - *AR*(p): corresponde à defasagem da série Z_t , denotado por *AR*(p), em que p indica a ordem do modelo, isto é, o número de defasagem. A notação é (29):

$$Z_t = \varphi_1 Z_{t-1} + \varphi_2 Z_{t-2} + \dots + \varphi_p Z_{t-p} + a_t \quad (29)$$

A identificação do modelo adequado começa pelos valores dos parâmetros, ou seja, o modelo será considerado estacionário se $|\varphi| < 1$, satisfaz a condição da estacionariedade. A condição de estacionariedade do *AR*(p) estabelece que todas as raízes da equação devem cair fora do círculo unitário.

Modelo de médias móveis de ordem q - *MA*(q): é a combinação do ruído branco a_t , do período atual com os ocorridos anteriormente. A notação do modelo é *MA*(q), na qual q indica a ordem do modelo. A notação (30):

$$Z_t = \mu + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (30)$$

Dessa forma, identificado a condição de estacionariedade, o processo apresenta ordem finita, portanto, será sempre estacionário. Quanto à condição de invertibilidade, é imposta a restrição de que o parâmetro em módulo é menor que um, ou seja, $|\theta| < 1$.

Modelo autoregressivo de médias móveis - *ARMA*(p, q): Esse modelo é a

união dos modelos vistos anteriormente, os autoregressivos e o de médias móveis. Ele é utilizado em Séries encontradas na prática, para as quais não se deseja número muito grande de parâmetros. A notação do modelo $ARMA(p, q)$ é (31):

$$Z_t = \phi_1 Z_{t-1} + \dots + \phi_p Z_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (31)$$

Percebe-se que as condições de estacionariedade de um processo $ARMA(p, q)$ são as mesmas que as de um processo $AR(p)$, e as condições de invertibilidade são as mesmas que as de um processo $MA(q)$.

Já nos Modelos Não-Estacionários, as séries não-estacionárias são aquelas que não se desenvolvem ao longo do tempo ao redor de uma média constante. Mas, essas séries podem se tornar estacionárias, ao recorrer-se ao processo de diferenciação.

Modelo autoregressivo integrado de médias móveis - $ARIMA(p, d, q)$: Os modelo estacionários e os não-estacionários diferenciam-se pelo número de diferença necessária para a estacionarização de uma série, representada pela letra d . A estratégia utilizada para a construção de modelos, pela metodologia *Box & Jenkins*, é baseada no ciclo iterativo.

O Ciclo iterativo é composto pela identificação do modelo, estimação e diagnóstico. Na identificação do modelo analisa-se a estacionariedade da série através da média e variância, em seguida analisa-se as componentes tendência, sazonalidade e ciclo chegando a análise de dados através da função de autocorrelação e função de autocorrelação parcial. Na estimação analisa-se a significância dos parâmetros estimados sejam eles modelos estacionários e não-estacionários.

Após as etapas de identificação e estimação, chega-se a adequação do modelo, através de critérios de seleção do modelo adequado podendo-se realizar as previsões. Caso o modelo se apresentar inadequado retornar a etapa da estimação de novos parâmetros.

4.1 Formas de Estruturação dos Dados

Para elaboração do referido trabalho é utilizado o *Software R* para realizar o tratamento dos dados. “Trata-se um software estatístico (*R PROJECT*, 2010), livre, que é muito utilizado pelas universidades e tem crescente aceitação entre as empresas” (MORAES, SALES, COSTA, 2011). Salienta-se que os dados deverão ser salvos no formato “txt”, para que o programa possa lê-los.

Melo (2001) salienta duas qualidades do *Software R*: 1) ser um programa gratuito e livre distribuição; 2) permitir a criação de novas funções e a possibilidade de modificação das funções internas.

Para PETERNELLI e MELLO (2007), o *Software R*: é uma linguagem orientada a objetos criada em 1996, os autores também relatam que o R é um sistema integrado, permitindo a manipulação de dados, cálculos e geração de gráficos.

Através do acesso a www.r-project.org é possível baixar o software com versões atualizadas para plataformas *windows*, *linux* ou *macintosh*.

Outro software utilizado nesse trabalho é *R-Studio*, utilizado como editor de comandos. Esse editor possui uma interação direta com o *Software R*, possibilitando que a pessoa que for trabalhar possa executar os comandos e gerar os gráficos direto no editor. Pode ser baixado através do site www.rstudio.com, também para plataformas *windows*, *linux* ou *macintosh*.

4.2 Procedimentos para Séries Arroz, Boi e Soja

Procedimentos comuns para as séries de Arroz, Boi e Soja. Assim, foram executados os procedimentos descritos no Quadro 1.

Quadro 1: procedimentos iniciais para utilização do *Software R*.

Coleta dos dados	Cooperativa Agrícola Alegretense Ltda. Sindicato Rural de Alegrete. CEPEA – ESALQ/USP
Organização dos dados	Conversão dos dados para txt Gravar as referidas séries para: 1) Cotação_Arroz.csv; 2) Cotação_Boi.csv; 3) Cotação_Soja.csv.
Interpretação do arquivo	Utilizar a coluna COTACAO para identificar o preço da cotação.
Instalação e configuração do <i>Software R</i>	Instalar o <i>Software R</i> Instalar o <i>R-Studio</i>
Inserção dos dados no R	Abrir o <i>R-Studio</i> e seguir com os comandos necessários

Fonte: Elaborado pelo autor.

A obtenção das informações dar-se-á pelo comando de leitura do *Software R* para cada arquivo corresponde à série, e atribuição de COTACAO para variável P, conforme o Quadro 2.

Quadro 2: Leitura das informações

```
#Dados
setwd("/home/cristian/Documentos/Cristian/UNIPAMPA/Projeto/")
Dados<-read.table("Cotação_XXXX.csv", sep="|", dec=",", h=T)
attach(Dados)

# Defining variables
P<-as.numeric(COTACAO)
```

Fonte: Elaborado pelo autor.

No Quadro 2.1, temos a descrição dos referidos comandos apresentados no Quadro 2.

Quadro 2.1 : Descrição dos comandos

Comando	Descrição
<i>setwd</i>	É usado para posicionar no diretório de trabalho
<i>read.table</i>	Lê um arquivo no formato de Tabela e cria um <i>data frame</i> dele, com casos correspondentes para linhas e variável para campos no arquivo. Nesse comando é informado o arquivo correspondente a série que se deseja analisar.
<i>attach</i>	O banco de dados é anexado ao caminho de pesquisa <i>R</i> . Isso significa que o banco de dados é procurado por <i>R</i> ao avaliar uma variável, por isso os objetos no banco de dados pode ser acessado por simplesmente dar seus nomes.
<i>as.numeric</i>	Cria ou coage objetos do tipo "numérico".

Fonte: Elaborado pelo autor.

Para identificar os modelos apropriados, inicialmente deve ser analisado o gráfico de tempo da série em estudo. A análise desse gráfico pode indicar a presença de tendência ou alteração na variância, o que revelaria se a série é ou não estacionária. No Quadro 3 é apresentado o comando para plotar o gráfico dos preços da referida série.

Quadro 3: Geração do Gráfico

```
# Descriptive statistics and plotting the data
par(mfrow=c(2,1))
plot( P,                                #plota x, y
      type="l",                          #tipo linha
      main="Gráfico de Preços\nSoja",    #título
      xlab="Período",                   #nomeia o eixo x
      ylab="Preços")                   #nomeia o eixo y
```

Fonte: Elaborado pelo autor.

No Quadro 3.1, temos a descrição dos referidos comandos apresentados no Quadro 3.

Quadro 3.1: Descrição dos comandos

Comando	Descrição
<i>par</i>	Esse comando pode ser usado para definir ou consulta parâmetros gráficas.
<i>plot</i>	Função genérico para plotagem de objetos <i>R</i> , nesse caso faz o objeto é o preço definido para variável <i>P</i>

Fonte: Elaborado pelo autor.

Em outro aspecto importante a ser salientado por ALEXANDRE (2005), é o teste de Raiz Unitária para detectar estacionariedade, é conhecido como teste de *Dickey-Fuller (DF)*, *Phillips-Perron (PP)* e também *Kwiatkowski-Phillips-Schmidt-Shin (KPSS)*, esse teste são obtidos com os comandos no Quadro 4.

Quadro 4: Comandos para teste de estacionariedade.

```
# Unit root test for variable
adf.test(P)
    Augmented Dickey-Fuller Test
PP.test(P)
    Phillips-Perron Unit Root Test
KPSS.test(P)
    KPSS Test for Level Stationarity

# ACF and PACF
acf(P, main="Função de Auto Correlação", xlab="(a) Defasagem", ylab="ACF
da amostra")
pacf(P, main="Função de Auto Correlação Parcial", xlab="(b) Defasagem",
ylab="PACF da amostra")
```

Fonte: Elaborado pelo autor.

Abaixo resultado da raiz unitária esperado de estacionariedade da série P :

a) *Dickey-Fuller Test*: apresentado pelo comando “*adf.test(P)*”, apresentando o teste de raiz unitária para que $H_0=1$ seja rejeitado, resultado no *p-value* deve ser menor ou igual a 1%;

b) *Phillips-Perron Unit Root Test*: apresentado pelo comando “*PP.test(P)*”, resultado no seu *p-value* deve ser menor ou igual a 1%;

c) *KPSS Test for Level Stationarity*: apresentado pelo comando “*KPSS.test(P)*”, resultado no seu *p-value* deve ser superior a 10%;

Além dos testes de raiz unitária, deve-se analisar o gráfico de correlograma apresentado pela *FAC* e *FACP*, para verificar a estacionariedade, comandos apresentados no Quadro 4 – ACF e PACF.

Após verificar os testes de raiz unitária, *FAC* e *FACP* e a série não esteja estacionária, deverá ser realizado as diferenças em relação a série original P . A primeira diferença de P , que é representada pelo Retorno (r), utilizando-se a função autocorrelação (*FAC*) e a função autocorrelação parcial (*FACP*). Dando seguimento as análises deverá ser utilizado os Teste da Raiz Unitária de *Dickey-Fuller*, *Phillips-Perron* e, também, o teste *KPSS*, utilizando-se os comandos apresentados no Quadro 5.

Quadro 5: Diferença de P.

```
# 1ª Diferença de P
r<-diff(log(P))
plot( r, type="l",main="Primeira Diferença", xlab="Intervalo",
ylab="Retorno R")
# Dickey-Fuller Test for variable
aDF.test(r)
PP.test(r)
KPSS.test(r)
# ACF and PACF
acf(r, main="Função de \nAuto Correlação", xlab="Defasagem", ylab="ACF de
R")
pacf(r, main="Função de \nAuto Correlação Parcial", xlab="Defasagem",
ylab="PACF de R")
```

Fonte: Elaborado pelo autor.

Constatada que a série analisada ainda não apresenta estacionariedade, deverá proceder com a diferença, agora sendo pelo próprio Retorno, neste caso a variável “r”.

4.3 Arroz

Na série de arroz, foram coletados as informações sobre os preços do arroz em casca no período de janeiro de 1995 a dezembro de 2012 totalizando 6575 registros. Essas informações foram obtidas através da Cooperativa Agrícola Alegretense Ltda. – CAAL. Nessas informações continham a data e o preço do arroz para cada padrão específico do arroz, foi escolhido o padrão 58x10 - rendimento de 58% de grãos inteiros e 10% de grãos quebrados (renda de 68%), para produção de arroz branco Tipo 1, seguindo a classificação da Portaria 269/88 do Ministério da Agricultura (CEPEA-ESALQ/USP), por possuir preços desde o início do período estipulado pela pesquisa. Teve-se que fazer um tratamento nas informações replicando o valor anterior nos casos onde tinha-se uma quebra na data, visto que é necessário para a metodologia *Box & Jenkins*, ter uma sequência para uma melhor análise.

A sequência do tratamento das informações deu-se através do Quadro 2, aonde é realizada a leitura dos dados, identificando o arquivo “Cotação_Arroz.csv”.

Após o tratamento, é verificada se a série é estacionária ou não, isso

ocorre no Quadro 4, identificando pela função de autocorrelação (*FAC*) e função de autocorrelação parcial (*FACP*).

No Quadro 5, é realizada a diferenciação, quantas forem necessárias até estacionar a série, e logo após também é verificado novamente a estacionariedade pela *FAC* e *FACP*.

As escolhas dos modelos são obtidas através de análise da Tabela 4, analisando os gráficos da *FAC* e *FACP*.

Ao aplicar a metodologia de séries temporais desenvolvida por *Box & Jenkins* (1976), tornou-se possível a escolha do seguinte modelos para *SARIMA*: *SARIMA(1,0,0).(3,0,0)*₇, *SARIMA(0,0,26).(3,0,0)*₈ e *SARIMA(0,0,27).(3,0,0)*₈.

No Quadro 6, é apresentado os comandos no *R*, para checagem das estimativas.

Quadro 6: Estimativas

```
# SARIMA(1,0,0).(3,0,0)7 -> AIC = -39147.04
SARIMA_100_300<-ARIMA( r, order=c(1,0,0), seasonal = list( order = c(3, 0,
0), period = 7))
SARIMA_100_300
# SARIMA(0,0,26).(3,0,0)8 -> AIC = -39178.1
SARIMA_0026_300<-ARIMA( r, order=c(0, 0, 26), seasonal = list( order = c(3,
0, 0), period = 8))
SARIMA_0026_300
# SARIMA(0,0,27).(3,0,0)8 -> AIC = -39183.57
SARIMA_0027_300<-ARIMA( r, order=c(0, 0, 27), seasonal = list( order = c(3,
0, 0), period = 8))
SARIMA_0027_300
```

Fonte: Elaborado pelo autor.

No Quadro 7 estão os comandos para: 1) cálculo do resíduo; 2) teste da raiz unitária; 3) gráfico para diagnóstico.

Quadro 7: Resíduos

```

#Residuals
res_SARIMA_0027_300<-residuals( SARIMA_100_300 )
acf( SARIMA_0027_300$residuals, main="ACF Resíduos SARIMA(0,0,27)(3,0,0)8",
xlab="Defasagem")
pacf( SARIMA_0027_300$residuals, main="PACF Resíduos SARIMA(0,0,27)
(3,0,0)8", xlab="Defasagem")
# Dickey-Fuller Test for variable
adf.test( res_SARIMA_0027_300 )
pp.test( res_SARIMA_0027_300 )
kpss.test( res_SARIMA_0027_300 )
#Gera os gráficos para diagnóstico
tsdiag( SARIMA_0027_300 )

```

Fonte: Elaborado pelo autor.

Após a identificação do modelo adequado, é necessário realizar o cálculo da previsão dos preços, preços com limite inferior e superior. Esses comandos estão no Quadro 8.

Quadro 8: Previsão

```

#Calcula a previsão com base na equação do Modelo
Previsao<-predict( SARIMA_0027_300, n.ahead=4 ) #, se.fit=T)
Previsao
#Calcula limite inferior de previs?o com 95% de confiança
LInfPrev<-Previsao$pred-1.96*Previsao$se
LInfPrev
#Calcula limiete superior de previs?o com 95% de confiança
LSuPPrev<-Previsao$pred+1.96*Previsao$se
LSuPPrev
#Preço
Preco<-exp( Previsao$pred[1] ) + P[6575]
Preco
#Preço Inferior
LInfPrev<-exp( LInfPrev[1] ) + P[6575]
LInfPrev
#Preço Superior
LSuPPrev<-exp( LSuPPrev[1] ) + P[6575]
LSuPPrev5

```

Fonte: Elaborado pelo autor.

O termo $n.ahead=4$, mostra quatro passos a frente e lembrando que SARIMA_0027_300 é o modelo SARIMA(0,0,27).(3,0,0)₈.

4.4 Boi

Para série do Boi, as informações foram coletadas através do site do Sindicato Rural de Alegrete – www.conexaorural.com.br. O período de janeiro de 1995 a dezembro de 2012 totalizando 6575 registros, as informações continham a data e o preço por quilo vivo do boi. Também, deu-se o tratamento das informações, por apresentar intervalos entre as datas.

A sequência do tratamento das informações deu-se através do Quadro 2, aonde é realizada a leitura dos dados, identificando o arquivo “Cotação_Boi.csv”.

Após o tratamento, é verificada se a série é estacionária ou não, isso ocorre no Quadro 4, identificando pela função de autocorrelação (*FAC*) e função de autocorrelação parcial (*FACP*).

No Quadro 5, é realizada a diferenciação, quantas forem necessárias até estacionar a série, e logo após também é verificado novamente a estacionariedade pela *FAC* e *FACP*.

As escolhas dos modelos são obtidas através de análise da Tabela 4, analisando os gráficos da *FAC* e *FACP*.

Ao aplicar a metodologia de séries temporais desenvolvida por *Box & Jenkins* (1976), tornou-se possível a escolha do seguinte modelos para *ARIMA*: *ARIMA*(1,2,21) e *ARIMA*(1,1,27).

No Quadro 9, é apresentado os comandos no R, para checagem estimativas.

Quadro 9: Estimativas

```
# ARIMA(1,2,21) -> AIC = -40621.26
ARIMA_1221<-ARIMA( r2, order=c(1,2,21))
ARIMA_1221
# ARIMA(1,1,27) -> AIC = -44620.63
ARIMA_1127<-ARIMA( r2, order=c(1,1,27))
ARIMA_1127
```

Fonte: Elaborado pelo autor.

No Quadro 10 estão os comandos para: 1) cálculo do resíduo; 2) teste da raiz unitária; 3) gráfico para diagnóstico.

Quadro 10: Resíduos

```
#Residuals
res_ARIMA_1127<-residuals( ARIMA_1127 )
acf( ARIMA_1127$residuals, main="ACF Resíduos SARIMA(1,1,27)",
xlab="Defasagem")
pacf( ARIMA_1127$residuals, main="PACF Resíduos SARIMA(1,1,27)",
xlab="Defasagem")
# Dickey-Fuller Test for variable
aDF.test( res_ARIMA_1127 )
PP.test( res_ARIMA_1127 )
KPSS.test( res_ARIMA_1127 )
#Gera os gráficos para diagnóstico
tsdiag( ARIMA_1127 )
```

Fonte: Elaborado pelo autor.

Após a identificação do modelo adequado, é necessário realizar o cálculo da previsão dos preços, preços com limite inferior e superior. Esses comandos estão no Quadro 11.

Quadro 11: Revisão

```
#Calcula a previsão com base na equação do Modelo
Previsao<-predict( ARIMA_1221, n.ahead=10 ) #, se.fit=T)
Previsao
#Calcula limite inferior de previs?o com 95% de confiança
LInfPrev<-Previsao$pred-1.96*Previsao$se
LInfPrev
#Calcula limiete superior de previs?o com 95% de confiança
LSuPPrev<-Previsao$pred+1.96*Previsao$se
LSuPPrev
#Preço
Preco<-exp( Previsao$pred[1] ) + P[6575]
Preco
#Preço Inferior
LInfPrev<-exp( LInfPrev[1] ) + P[6575]
LInfPrev
#Preço Superior
LSuPPrev<-exp( LSuPPrev[1] ) + P[6575]
LSuPPrev5
```

Fonte: Elaborado pelo autor.

4.5 Soja

Ao procurar informações sobre o preço do soja junto a CAAL e outras

unidades que armazenam os grãos na cidade, não foi possível obter um histórico de preços. A obtenção das informações deu-se através da CEPEA-ESALQ/USP, aonde foram fornecido os preços históricos da cidade de Passo Fundo/RS. Da mesma forma que as séries anteriores, teve-se o trabalho de tratar os dados pela quebra na data, o período da série inicia em janeiro de 1998 a dezembro de 2012, totalizando 5479 registros.

A sequência do tratamento das informações deu-se através do Quadro 2, aonde é realizada a leitura dos dados, identificando o arquivo “Cotação_Soja.csv”.

Após o tratamento, é verificada se a série é estacionária ou não, isso ocorre no Quadro 4, identificando pela função de autocorrelação (*FAC*) e função de autocorrelação parcial (*FACP*).

No Quadro 5, é realizada a diferenciação, quantas forem necessárias até estacionar a série, e logo após também é verificado novamente a estacionariedade pela *FAC* e *FACP*.

As escolhas dos modelos são obtidas através de análise da Tabela 4, analisando os gráficos da *FAC* e *FACP*.

As escolhas dos modelos são obtidas através de análise da Tabela 4, analisando os gráficos da *FAC* e *FAP*.

Ao aplicar a metodologia de séries temporais desenvolvida por *Box & Jenkins* (1976), tornou-se possível a escolha do seguinte modelos para *ARIMA* e *SARIMA*: *ARIMA*(0,0,3); *ARIMA*(1,0,15); *ARIMA*(1,0,24); *ARIMA*(3,1,3); *SARIMA*(0,0,3). (0,0,1)₉ e *SARIMA*(3,1,3)(0,0,1)₉.

No Quadro 12, é apresentado os comandos no R, para checagem das estimativas.

Quadro 12: Estimativas

```
# ARIMA(0,0,3) -> AIC = -35411.54
ARIMA_003<-ARIMA( r, order=c(0,0,3))
ARIMA_003
#ARIMA(1,0,15) -> AIC = -35415.65
ARIMA_1015<-ARIMA( r, order=c(1,0,15))
ARIMA_1015
#ARIMA(1,0,24) -> AIC = -35406.72
ARIMA_1024<-ARIMA( r, order=c(1,0,24))
ARIMA_1024
#ARIMA(3,1,3) -> AIC = -35323.31
ARIMA_313<-ARIMA( r2, order=c(3,1,3))
ARIMA_313
# SARIMA(0,0,3).(0,0,1)9 -> AIC = -35414.53
SARIMA_003_001<-ARIMA( r, order=c(0,0,3), seasonal = list( order = c(0, 0,
1), period = 9))
SARIMA_003_001
#SARIMA(3,1,3)(0,0,1)9 -> AIC = -35352.69
SARIMA_313001<-ARIMA( r2, order=c(3,1,3), seasonal = list( order = c(0, 0,
1), period = 9))
SARIMA_313001
```

Fonte: Elaborado pelo autor.

Assim se deve identificar o modelo adequado para modelar a série de comportamento temporal presente nos dados coletados que mais se ajusta. BUENO (2011) relata o uso do critério de informação verificado pelo *Akaike Information Criterion(AIC)*, e deverá apresentar *FAC* e *FACP* dos resíduos dentro do nível de confiança de estacionariedade.

No Quadro 13 estão os comandos para: 1) cálculo do resíduo; 2) teste da raiz unitária; 3) gráfico para diagnóstico.

Quadro 13: Resíduos

```
#Residuals
res_ARIMA_1024<-residuals( ARIMA_1024 )
acf( ARIMA_1024$residuals, main="ACF Resíduos ARIMA(1,0,24)",
xlab="Defasagem")
pacf( ARIMA_1024$residuals, main="PACF Resíduos ARIMA(1,0,24)",
xlab="Defasagem")
# Dickey-Fuller Test for variable
aDF.test( res_ARIMA_1024 )
PP.test( res_ARIMA_1024 )
KPSS.test( res_ARIMA_1024 )
```

Fonte: Elaborado pelo autor.

Após a identificação do modelo adequado, é necessário realizar o cálculo da previsão dos preços, preços com limite inferior e superior. Esses comandos estão

no Quadro 14.

Quadro 14: Previsão.

```
#Calcula a previsão com base na equação do Modelo
Previsao<-predict( Modelo, n.ahead=10 ) #, se.fit=T)
Previsao
#Calcula limite inferior de previs?o com 95% de confiança
LInfPrev<-Previsao$pred-1.96*Previsao$se
LInfPrev
#Calcula limiete superior de previs?o com 95% de confiança
LSuPPrev<-Previsao$pred+1.96*Previsao$se
LSuPPrev
#Preço
Preco<-exp( Previsao$pred[1] ) + P[6575]
Preco
#Preço Inferior
LInfPrev<-exp( LInfPrev[1] ) + P[6575]
LInfPrev
#Preço Superior
LSuPPrev<-exp( LSuPPrev[1] ) + P[6575]
LSuPPrev5
```

Fonte: Elaborado pelo autor.

5 RESULTADOS E DISCUSSÕES

Neste capítulo é feita a análise dos dados das séries do Arroz, Boi e Soja, utilizando as técnicas apresentadas no capítulo 3.

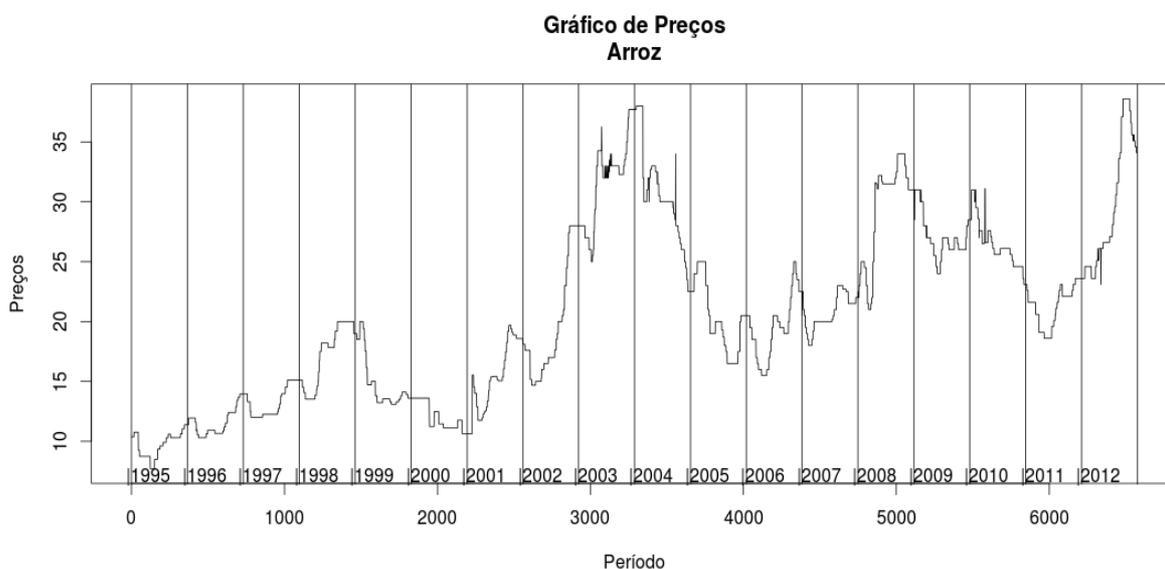
Serão apresentadas as análises das séries Arroz, Boi e Soja. Também será feita a análise da variação absoluta da taxa (série original diferenciada) para retirar a tendência da série e verificar o comportamento dos modelos.

A seguir são apresentadas as três séries que serão analisadas. A série do arroz, boi e soja e, também a série que corresponde a identificação das mesmas.

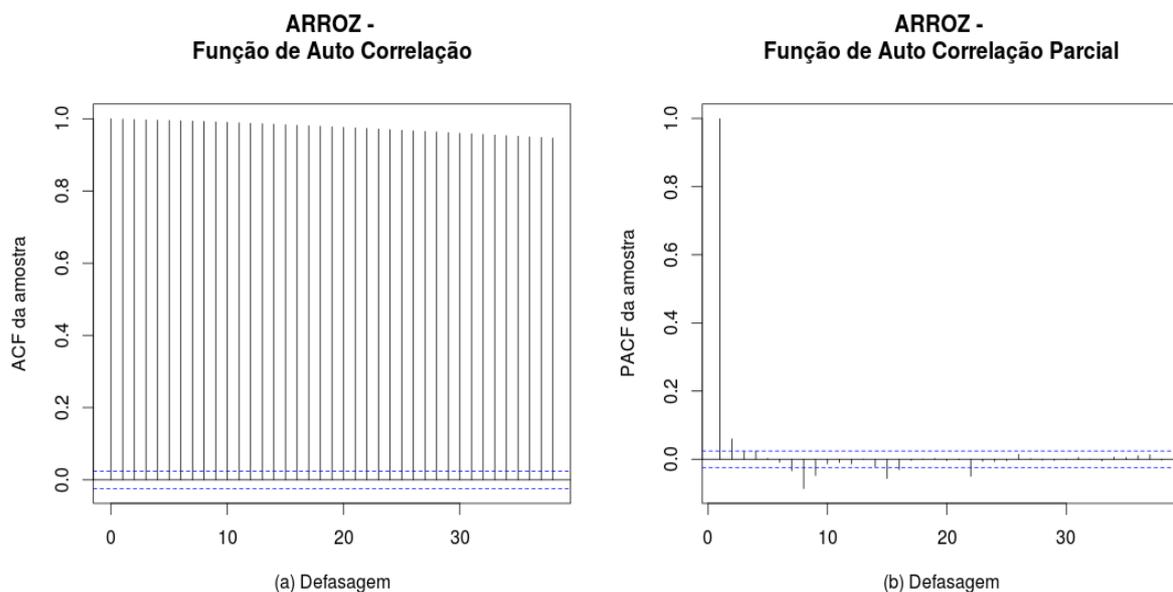
5.1 Arroz

Pode-se notar que no Gráfico 1 não apresenta uma série estacionária. Além da visualização, outros comandos do *R* podem auxiliar na tomada de decisões referente à estacionariedade. A segunda fase da metodologia *Box & Jenkins* é a identificação, que será realizada pela função de autocorrelação (*FAC*) calcula (e por parcelas padrão) estima da autocovariância ou função de autocorrelação parcial (*FACP*), apresentadas para cada série no Gráfico 2.

Gráfico 1: Preços do Arroz em R\$



Fonte: Elaborado pelo autor com uso do *Software R*.

Gráfico 2: *FAC* (a) e *FACP* (b) da Série do Arroz

Fonte: Elaborado pelo autor com uso do *Software R*.

Após a leitura das informações conforme o Quadro 2 e os testes da raiz unitária conforme o Quadro 4, segue abaixo resultado dos testes de estacionariedade da série *P*:

a) *Dickey-Fuller Test*: apresentado pelo comando "*adf.test(P)*", apresentando o teste de raiz unitária para que $H_0=1$ seja rejeitado, resultou no seu *p-value* em 50,07%;

b) *Phillips-Perron Unit Root Test*: apresentado pelo comando "*PP.test(P)*", resultou no seu *p-value* em 71,44%;

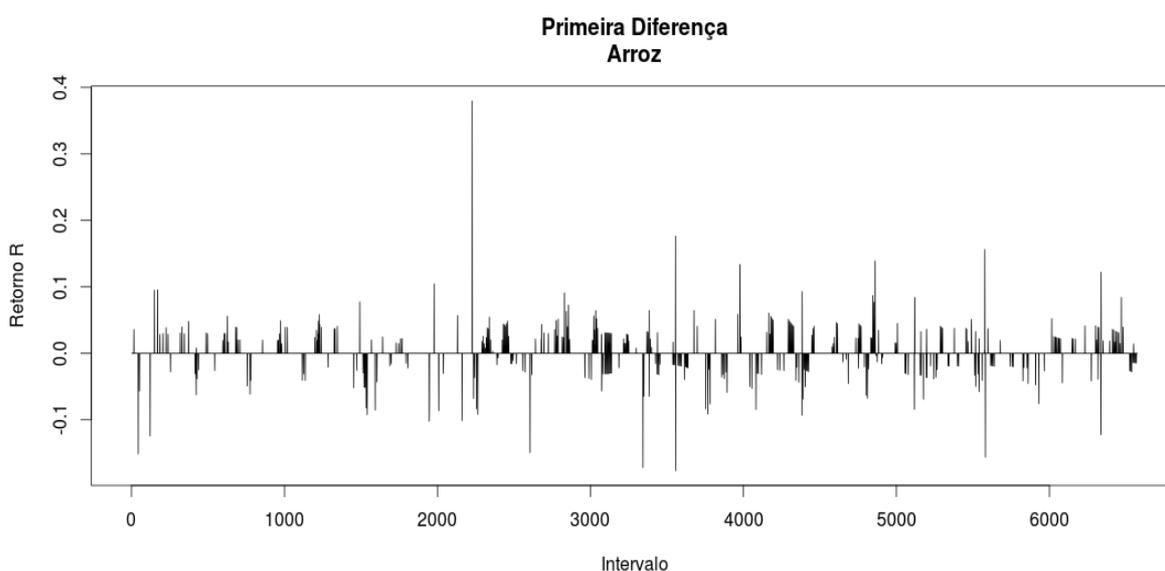
c) *KPSS Test for Level Stationarity*: resultou no seu *p-value* em 1%.

Pelo que foi exposto na função *FAC* no Gráfico 4(a), verifica-se que no correlograma não foi possível estacionar a amostra da série principal do Arroz - *P*. A função (*FACP*) é a função utilizada para as autocorrelações parciais, nota-se que no Gráfico 4(b) possui picos na 1ª, 2ª, 8ª, 14ª e 21ª defasagem, não se encontra no nível de confiança de estacionariedade de 95%(noventa e cinco por cento). Em geral, para um dado grau de confiança, quanto mais longo for o tempo de espera, maior será o intervalo de previsão. Este fato é sensível, uma vez que a incerteza associada à previsão para um instante distante é maior que a da previsão para o

instante seguinte

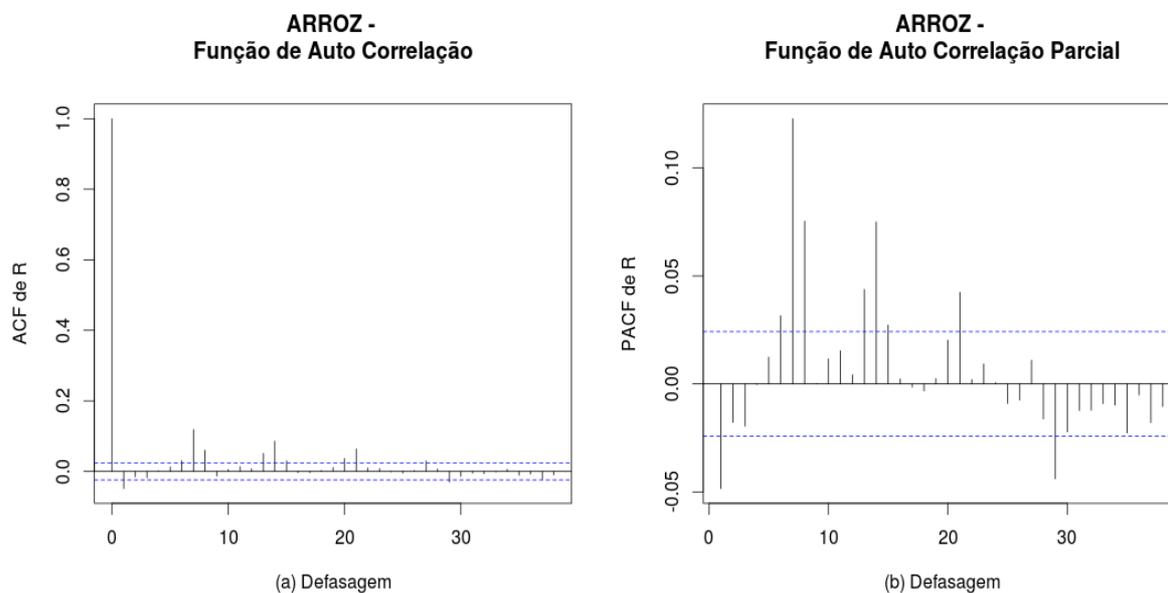
Na sequência temos o gráfico (*plot*) da série r que é a primeira diferença da série do Arroz (P) apresentado no Gráfico 3, apresentando os dados da amostra já estacionária da série. A função autocorrelação (*FAC*) e a função autocorrelação parcial (*FACP*) são apresentadas no Gráfico 4.

Gráfico 3: *Plot* de r da série P .



Fonte: Elaborado pelo autor com uso do *Software R*.

Gráfico 4: *FAC* e *FACP* da série r .



Fonte: Elaborado pelo autor com uso do *Software R*.

Foram realizados os Testes da Raiz Unitária na série r que é resultado da primeira diferença da série P : 1) *Dickey-Fuller*, que apresentou o resultado 1%; 2) *Phillips-Perron* cujo resultado apresentado foi 1%; 3) *KPSS* que trouxe como resultado 10%. Confirmando que a série Retorno (r) do arroz é estacionária.

Ao analisar o Gráfico 4(a) em relação ao *FAC*, nota-se alguns picos na 7^a, 14^a, 21^a, 26^a e 27^a defasagem e decrescendo exponencialmente com intervalo de sete e oito períodos, já em relação ao *FACP*, nota-se picos na 7^a, 14^a e 21^a defasagem, levando-nos a selecionar alguns modelos apropriados para teste conforme a Tabela 7.

Para facilitar a visualização dos resultados obtidos através das funções de autocorrelação e autocorrelação parcial, bem como dos testes de raiz unitária executados, foi elaborado a Tabela 8, que apresenta um resumo dos testes de estacionariedade.

Tabela 7: Modelos Apropriados

Modelo	AIC	ADF	PP	KPSS	Estacionário
<i>SARIMA (1,0,0).(3,0,0)₇</i>	-39147.04	1%	1%	10%	SIM
<i>SARIMA (0,0,26).(3,0,0)₈</i>	-39178.10	1%	1%	10%	SIM
<i>SARIMA(0,0,27).(3,0,0)₈</i>	-39183.57	1%	1%	10%	SIM

Fonte: Informações obtidas através do *Software R*.

Tabela 8: Resumo - Teste de Estacionariedade

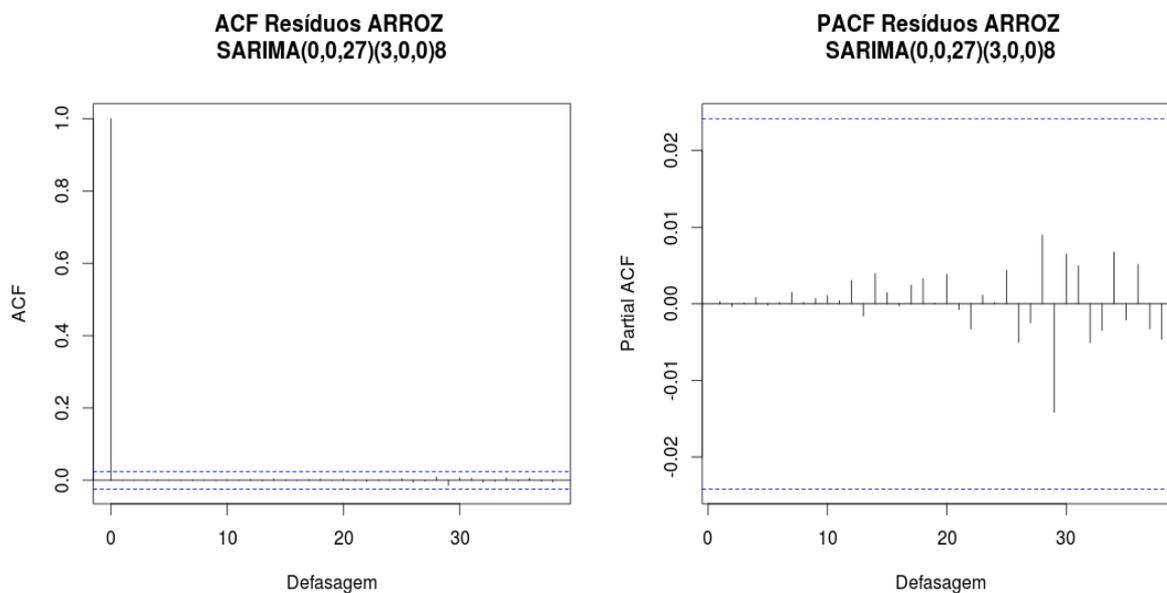
Série	FAC	FACP	ADF	PP	KPSS
<i>P</i>	Não	Não	19,95%	66,40%	1%
<i>r</i>	Não	Não	1%	1%	10%

Fonte: Elaborado pelo autor.

Assim o modelo identificado para modelar a série de comportamento temporal presente nos dados coletados que mais se ajusta, verificado pelo Critério de Informação de *Akaike (AIC)*, dentre os testados e considerando a série estacionária por apresentar o maior *AIC*, o modelo escolhido foi o *SARIMA(0,0,27).(3,0,0)₈*, por apresentar maior *AIC*.

O próximo passo é realizar a checagem dos resíduos do modelo escolhido, sendo apresentado no Gráfico 5.

Gráfico 5: Resíduos *FAC* e *FACP* do modelo $SARIMA(0,0,27).(3,0,0)_8$

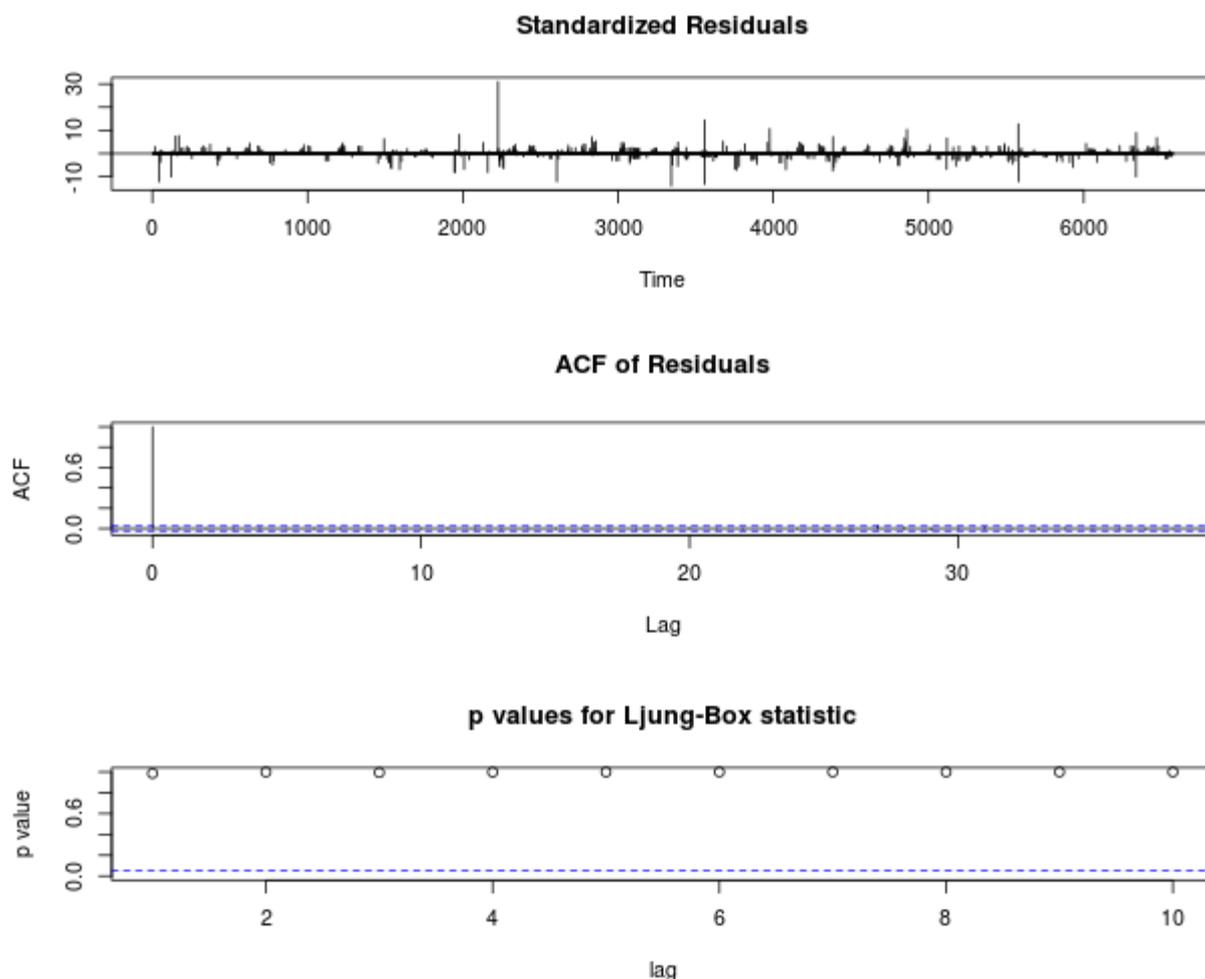


Fonte: Elaborado pelo autor com uso do *Software R*.

Pode-se notar que o Gráfico 5, encontra-se no nível de confiança de estacionariedade.

Em seguida deve ser verificado o diagnóstico dos resíduos, apresentado no Gráfico 6.

Gráfico 6: Diagnóstico de Resíduos



Fonte: Elaborado pelo autor com uso do *Software R*.

Com o comando *tsdiag* (Quadro 7) é possível analisar os gráficos dos resíduos. O modelo deve apresentar os resíduos estacionários, com média zero e variância constante, o que foi observado no Gráfico 8.

Dando sequência à metodologia *Box & Jenkins*, o último passo é realizar a previsão. Com base nas informações obtidas no Quadro 8, foram realizadas as previsões para as ocorrências número 6576, sendo feito, também um comparativo entre estas e os valores efetivados, conforme apresentado no Quadro 15.

Quadro 15 – Previsão X Efetivado - Arroz

Ocorrência	Valor previsto P (R\$)	Limite inferior P (R\$)	Limite superior P (R\$)	Valor efetivado P (R\$)
6576	35.09883	35.07518	35.12306	34,10
6577	35.09828	35.07458	35.12256	33,88
6578	35.09918	35.07545	35.12349	34,10
6579	35.09955	35.07581	35.12387	33,39
6580	35.09948	35.07574	35.12380	33,10

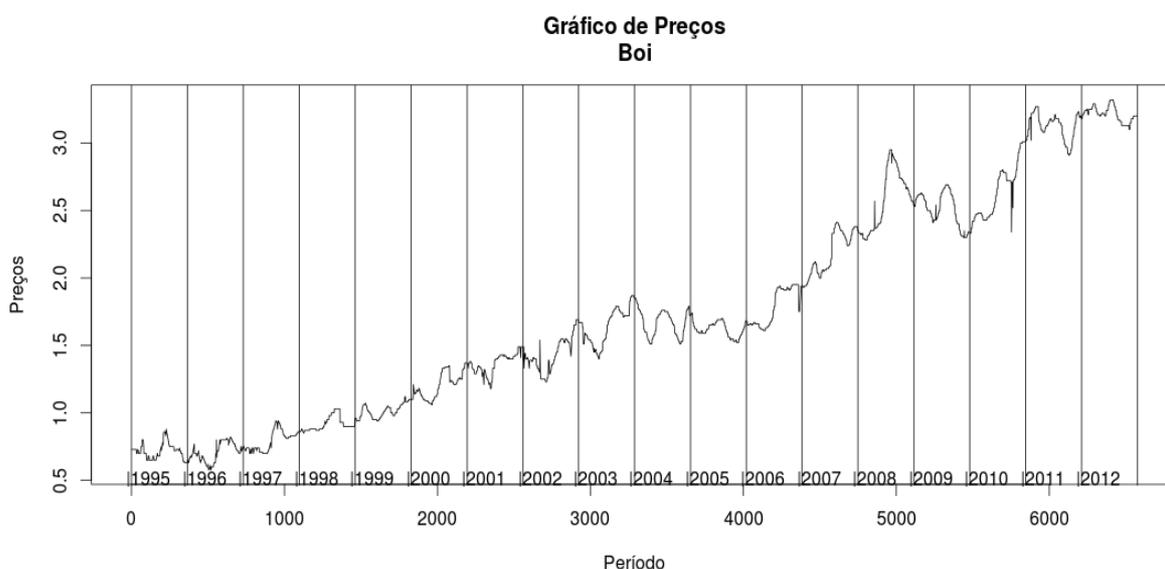
Fonte: Elaborado pelo autor.

Comparando-se as previsões com o efetivado, conforme o Quadro 15, observa-se que, o valor previsto ficaram acima do valor efetivado. Para as ocorrências 6576 a 6580 a confiabilidade aplicada foi de 95% (noventa e cinco por cento).

5.2 Boi

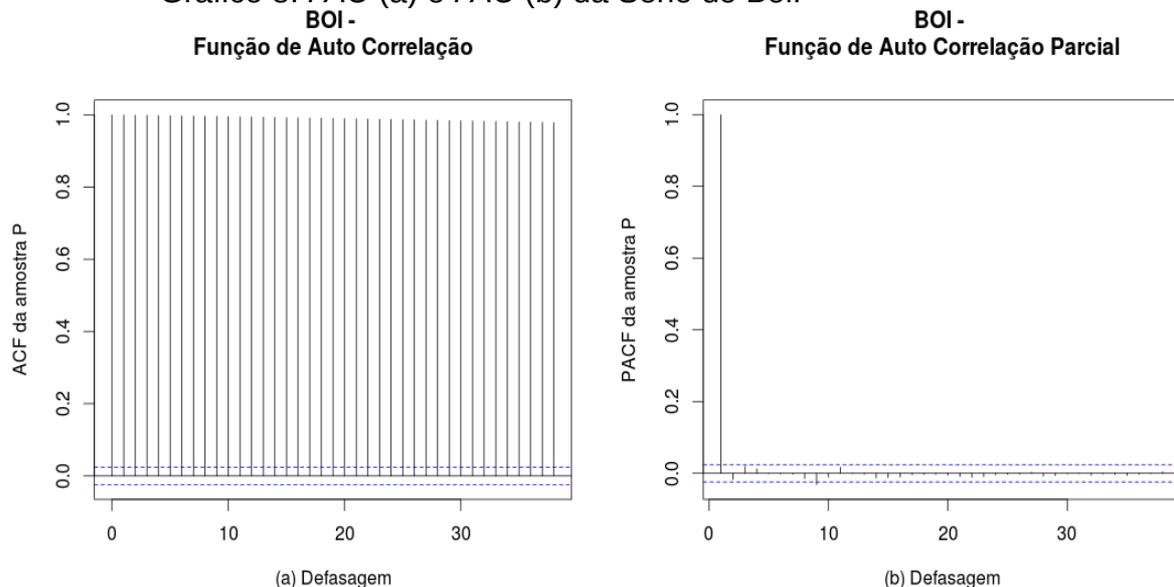
No Gráfico 7, pode-se constatar que a série do Boi não é estacionária. Para confirmação da não estacionariedade, é observada no Gráfico 9, que será realizada pela função de autocorrelação (*FAC*) e pela função de autocorrelação parcial (*FACP*), através da variável *P*, que receberá o valor da cotação da série apresentado no Gráfico 8.

Gráfico 7: Preços do Boi em R\$



Fonte: Elaborado pelo autor com uso do *Software R*.

Gráfico 8: *FAC* (a) e *FACP* (b) da Série do Boi.



Fonte: Elaborado pelo autor com uso do *Software R*.

Após a leitura das informações conforme o Quadro 2 e os testes da raiz unitária conforme o Quadro 4, segue abaixo resultado dos testes de estacionariedade da série P :

a) *Dickey-Fuller Test*: apresentado pelo comando “*adf.test(P)*”, apresentando o teste de raiz unitária para que $H_0=1$ seja rejeitado, resultou no seu *p-value* em 28,44%;

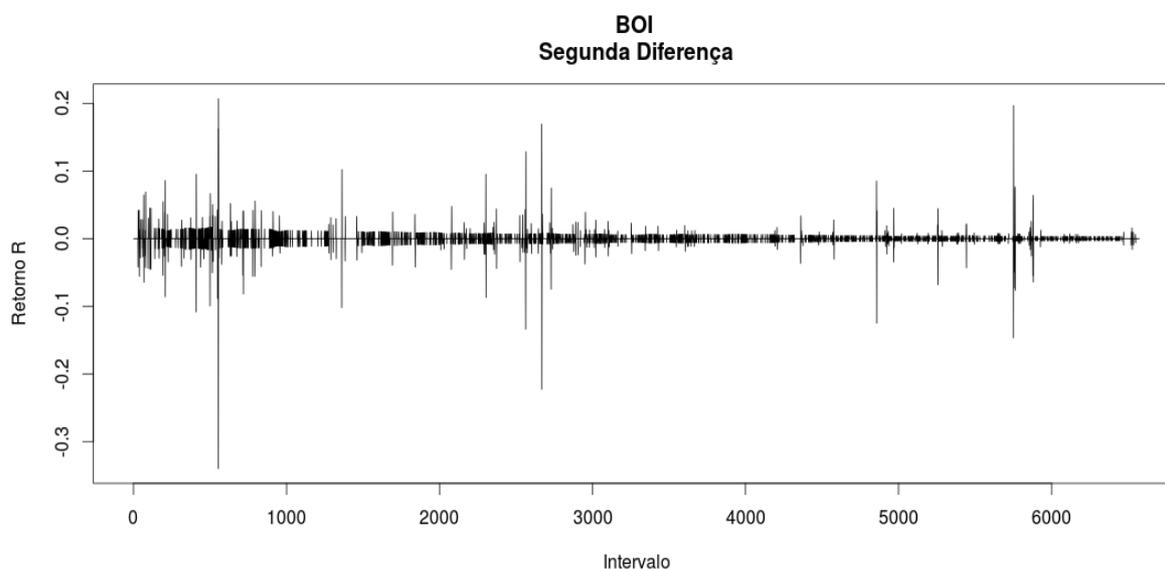
b) *Phillips-Perron Unit Root Test*: apresentado pelo comando “*PP.test(P)*”, resultou no seu *p-value* em 28,49%;

c) *KPSS Test for Level Stationarity*: resultou no seu *p-value* em 1%.

Observa-se que no Gráfico 8(a) - *FAC*, um caimento levemente exponencial não estando no nível de confiança de estacionariedade de 95%(noventa e cinco por cento), já o Gráfico 8(b), possui um pico na 9ª defasagem, podendo confirmar a não estacionariedade da série, devendo ser realizada a diferenciação da variável P .

Na sequência temos o gráfico (*plot*) da série r que é a primeira diferença da série do Boi (P) apresentado no Gráfico 9, apresentando os dados da amostra já estacionária da série. A função autocorrelação (*FAC*) e a função autocorrelação parcial (*FACP*) são apresentadas no Gráfico 6.

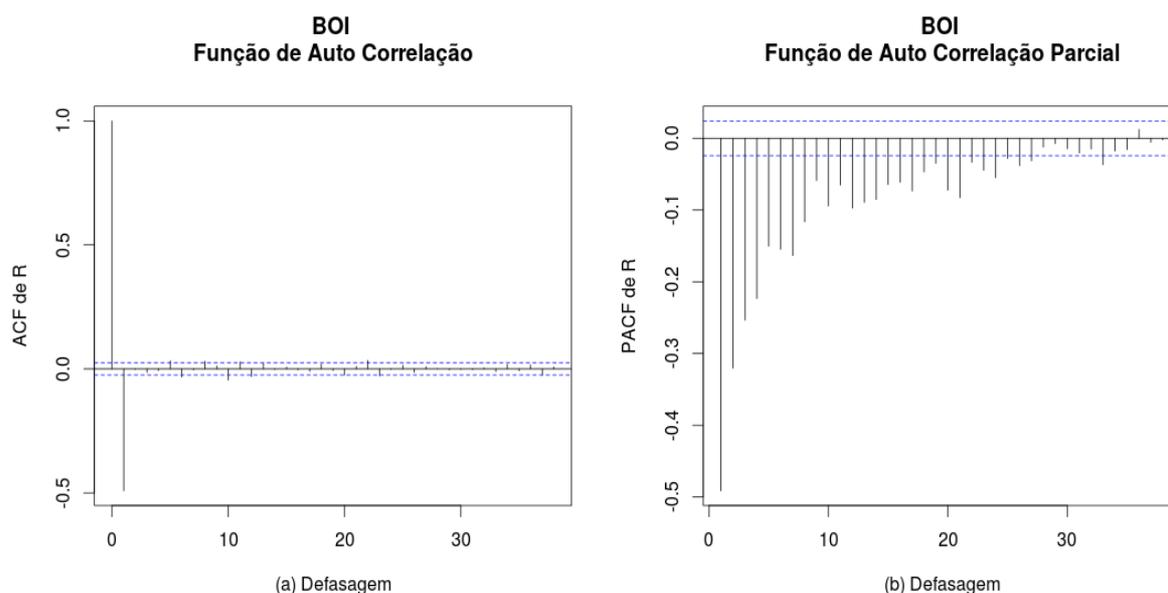
Gráfico 9: *Plot* de r da série P .



Fonte: Elaborado pelo autor com uso do *Software R*.

Para confirmar a estacionariedade, é analisado o Gráfico 10, através da *FAC* e *FACP* da variável *r*, também de ser verificado o teste de Raiz Unitária.

Gráfico 10: *FAC* e *FACP* de *r*



Fonte: Elaborado pelo autor com uso do *Software R*.

Foram realizados os Testes da Raiz Unitária na série *r* que é resultado da primeira diferença da série *P*: 1) *Dickey-Fuller*, que apresentou o resultado 1%; 2) *Phillips-Perron* cujo resultado apresentado foi 1%; 3) *KPSS* que trouxe como resultado 10%. Confirmando que a série Retorno (*r*) do boi é estacionária.

Ao analisar o Gráfico 10(a) em relação a *FAC*, pode-se notar que existe um pico na 1ª defasagem, já em relação a *FACP* apresentado no Gráfico 10(b), observa-se decaimento exponencialmente entrado no nível de confiança na 27ª defasagem, levando-nos a selecionar alguns modelos apropriados para teste conforme a Tabela 9.

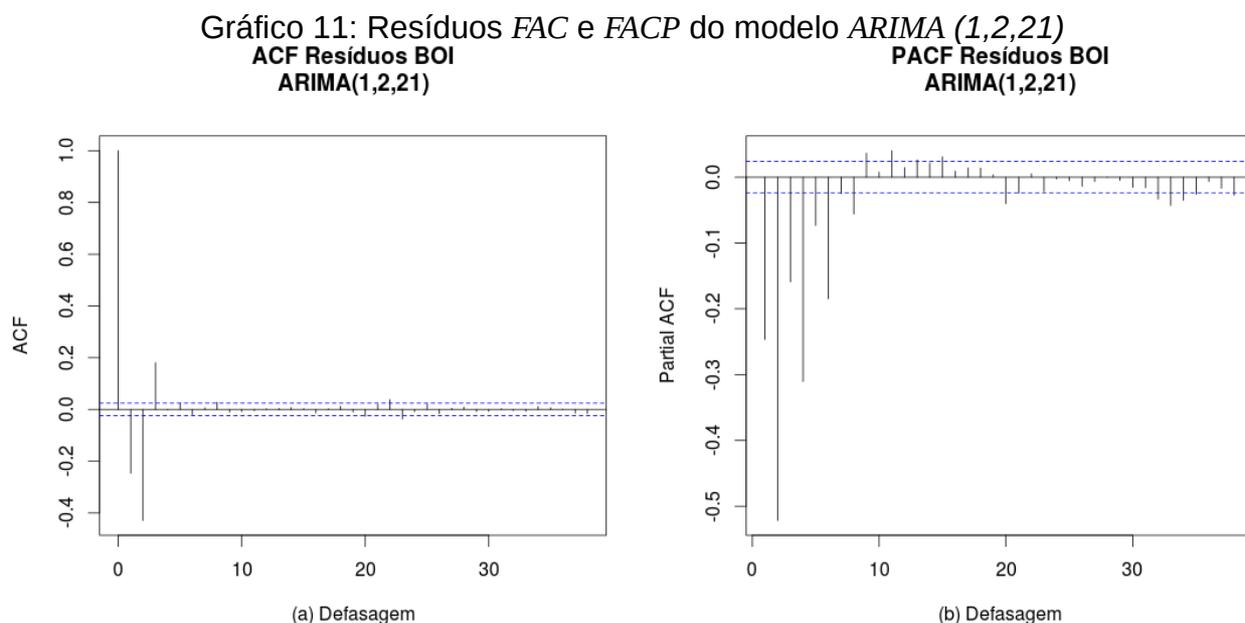
Tabela 9: Modelos Apropriados

Modelo	AIC	ADF	PP	KPSS	Estacionário
ARIMA (1,2,21)	-40621.26	1%	1%	10%	SIM
ARIMA (1,1,27)	-44620.63	1%	1%	10%	SIM

Fonte: Informações obtidas através do *Software R*.

Assim o modelo identificado para modelar a série de comportamento temporal presente nos dados coletados que mais se ajusta, verificado pelo Critério de Informação de *Akaike* (*AIC*), dentre os testados e considerando a série estacionária, o modelo escolhido foi o *ARIMA* (1,2,21), por apresentar maior *AIC*.

O próximo passo é realizar a checagem dos resíduos do modelo escolhido, sendo apresentado no Gráfico 11.

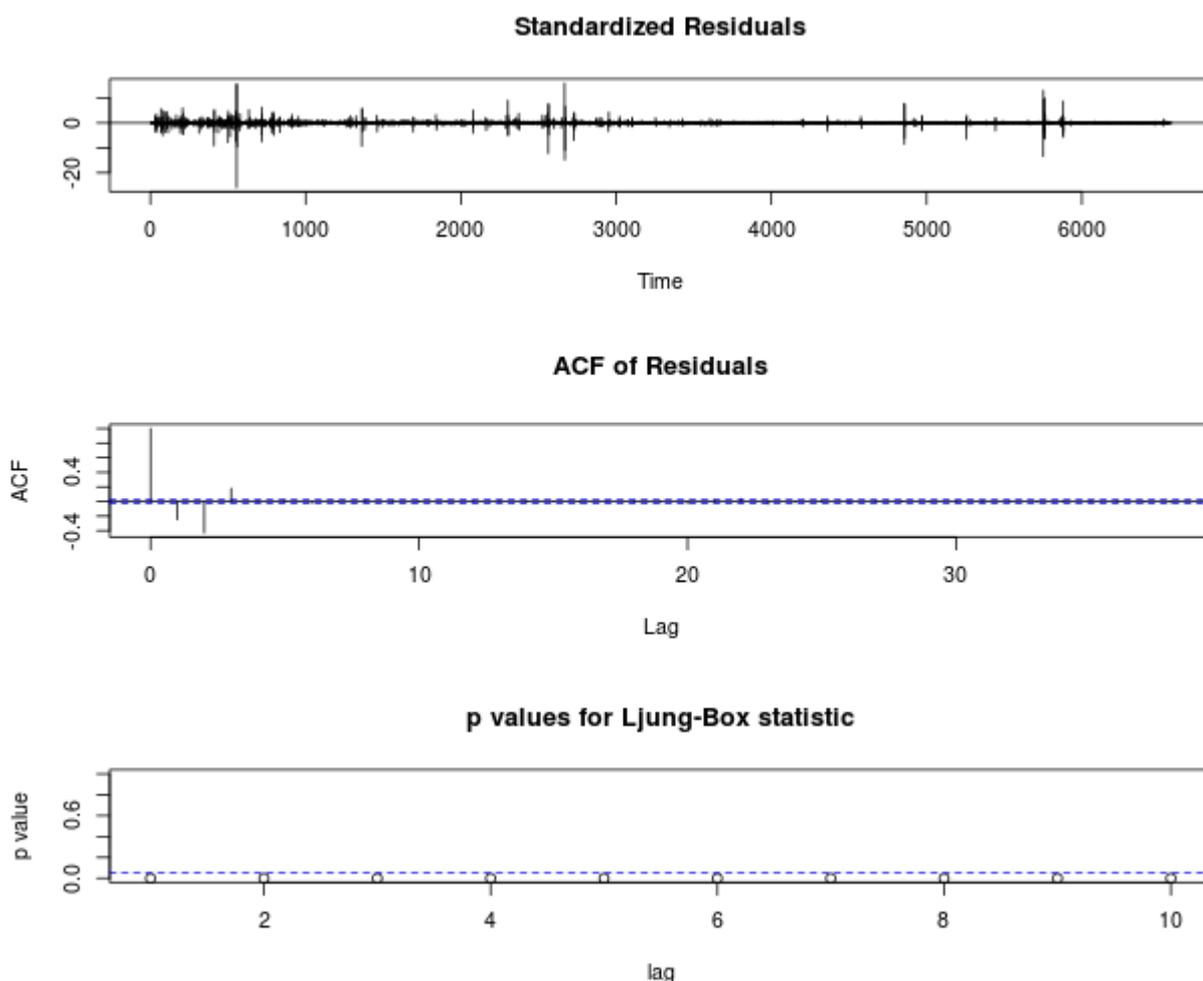


Fonte: Elaborado pelo autor com uso do *Software R*.

Ao verificar o Gráfico 11(a) corresponde a (*FAC*) e o Gráfico 11(b) que corresponde (*FACP*), observa-se picos fora dos limites de confiança. Neste caso é validado o Teste da Raiz Unitária dos resíduos com os seguintes resultados: 1) *Dickey-Fuller* - apresentou o resultado 1%; 2) *Phillips-Perron* - resultado apresentado foi 1%; 3) *KPSS* - trouxe como resultado 10%. Confirmando que a série esta estacionada.

Em seguida deve ser verificado o diagnóstico dos resíduos, apresentado no Gráfico 12.

Gráfico 12: Diagnóstico de Resíduos



Fonte: Elaborado pelo autor com uso do *Software R*.

Com o comando *tsdiag* (Quadro 7) é possível analisar os gráficos dos resíduos. O modelo deve apresentar os resíduos estacionários, com média zero e variância constante, o que foi observado no Gráfico 12.

Dando sequencia à metodologia *Box & Jenkins*, o último passo é realizar a previsão. Com base nas informações obtidas no Quadro 8, foram realizadas as previsões para as ocorrências número 6576, sendo feito, também um comparativo entre estas e os valores efetivados, conforme apresentado no Quadro 16.

Quadro 16 – Previsão X Efetivado - Boi

Ocorrência	Valor previsto P (R\$)	Limite inferior P (R\$)	Limite superior P (R\$)	Valor efetivado P (R\$)
6576	4.199988	4.178765	4.22167	3,20
6577	4.199983	4.177357	4.223132	3,20
6578	4.199994	4.176219	4.224348	3,20
6579	4.199955	4.174873	4.225682	3,20
6580	4.199961	4.174761	4.225811	3,20

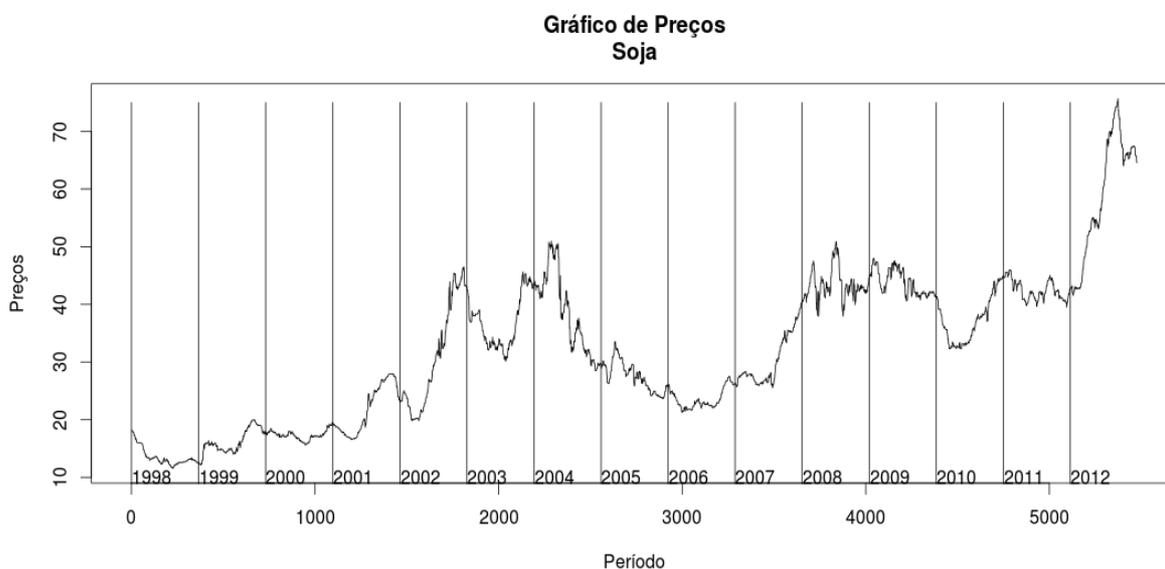
Fonte: Elaborado pelo autor

Comparando-se as previsões com o efetivado, conforme o Quadro 16, observa-se que, o valor previsto para as ocorrências 6576 a 6580 ficou R\$ 1,00 (um real) acima do valor efetivado. Para as ocorrências a confiabilidade aplicada foi de 95% (noventa e cinco por cento).

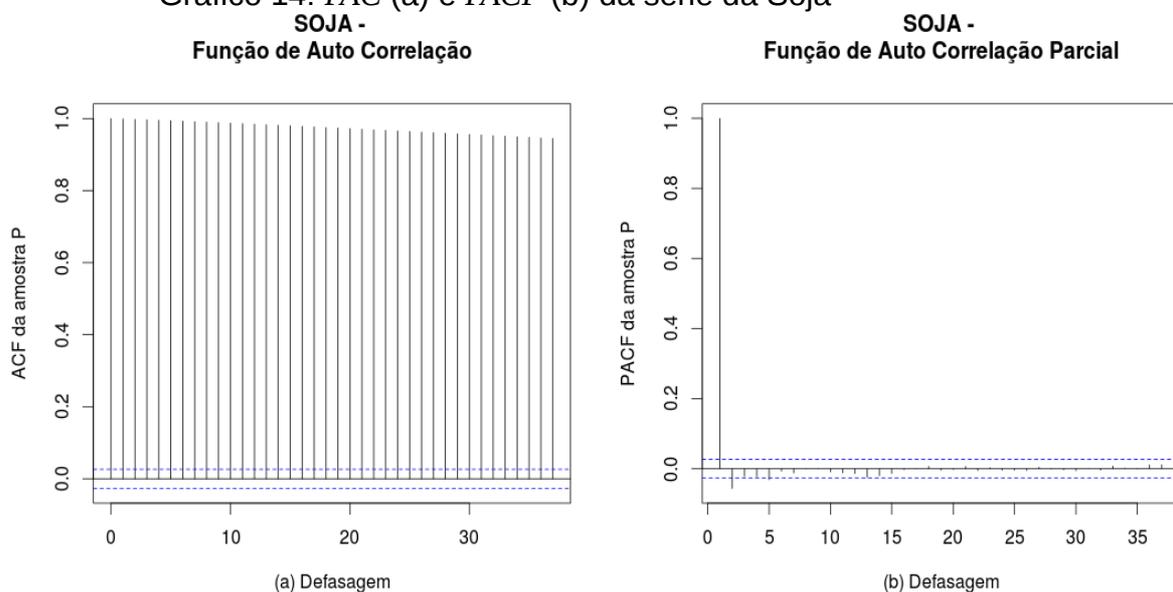
5.3 Soja

Ao analisar o Gráfico 13, o mesmo não apresenta uma série estacionária. Além da visualização, outros comandos do *R* podem auxiliar na tomada de decisões referente à estacionariedade. A segunda fase da metodologia *Box & Jenkins* é a identificação, que será realizada pela função de autocorrelação (*FAC*) calcula (e por parcelas padrão) estima da autocovariância ou função de autocorrelação parcial (*FACP*), apresentadas para cada série. Apresentada no Gráfico 14.

Gráfico 13: Preços da Soja em R\$



Fonte: Elaborado pelo autor com uso do *Software R*.

Gráfico 14: *FAC* (a) e *FACP* (b) da série da Soja

Fonte: Elaborado pelo autor com uso do *Software R*.

Após a leitura das informações conforme o Quadro 2 e os testes da raiz unitária conforme o Quadro 4, segue abaixo resultado dos testes de estacionariedade da série *P*:

a) *Dickey-Fuller Test*: apresentado pelo comando "*adf.test(P)*", apresentando o teste de raiz unitária para que $H_0=1$ seja rejeitado, resultou no seu *p-value* em 50,07%;

b) *Phillips-Perron Unit Root Test*: apresentado pelo comando "*PP.test(P)*", resultou no seu *p-value* em 71,44%;

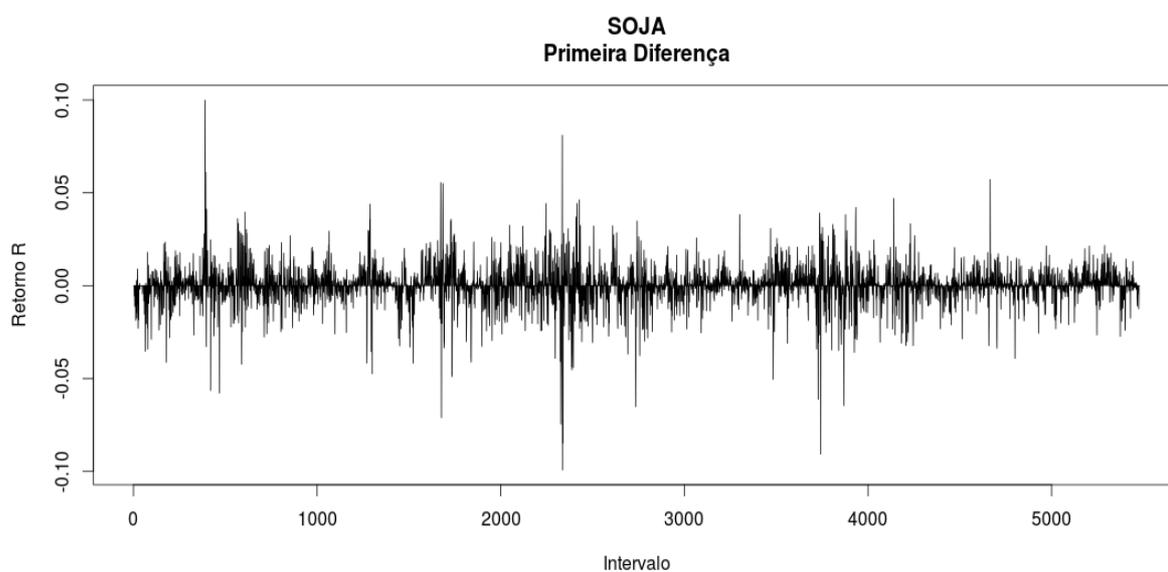
c) *KPSS Test for Level Stationarity*: resultou no seu *p-value* em 1%.

Observa-se que no Gráfico 14(a) - *FAC*, um caimento levemente exponencial não estando no nível de confiança de estacionariedade de 95%(noventa e cinco por cento), já o Gráfico 14(b), possui um pico na 1ª defasagem, podendo confirmar a não estacionariedade da série, devendo ser realizada a diferenciação da variável *P*.

Na sequência temos o gráfico (*plot*) da série *r* que é a primeira diferença

da série do Soja (P) apresentado no Gráfico 15, apresentando os dados da amostra já estacionária da série. A função autocorrelação (FAC) e a função autocorrelação parcial ($FACP$) são apresentadas no Gráfico 15.

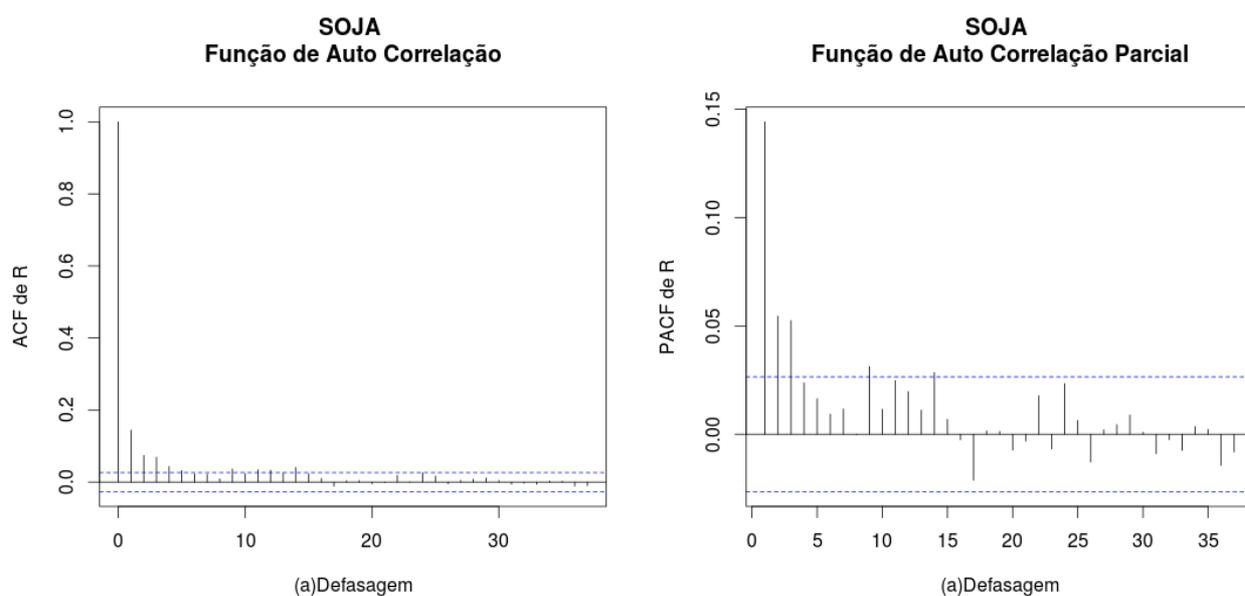
Gráfico 15: *Plot* de r da Série P .



Fonte: Elaborado pelo autor com uso do *Software R*.

Para confirmar a estacionariedade, é analisado o Gráfico 16, através da FAC e $FACP$ da variável r , também é verificado o teste de Raiz Unitária.

Gráfico 16: FAC e $FACP$ de r



Fonte: Elaborado pelo autor com uso do *Software R*.

Foram realizados os Testes da Raiz Unitária na série r que é resultado da

primeira diferença da série P : 1) *Dickey-Fuller*, que apresentou o resultado 1%; 2) *Phillips-Perron* cujo resultado apresentado foi 1%; 3) *KPSS* que trouxe como resultado 10%. Confirmando que a série Retorno (r) do boi é estacionária.

Ao analisar o Gráfico 16(a) em relação a *FAC*, pode-se notar que existe picos na 1ª a 3ª defasagem, já em relação a *FACP* apresentado no Gráfico 16(b), observa-se decaimento exponencialmente entrando no nível de confiança na 9ª defasagem, levando-nos a selecionar alguns modelos apropriados para teste conforme a Tabela 10.

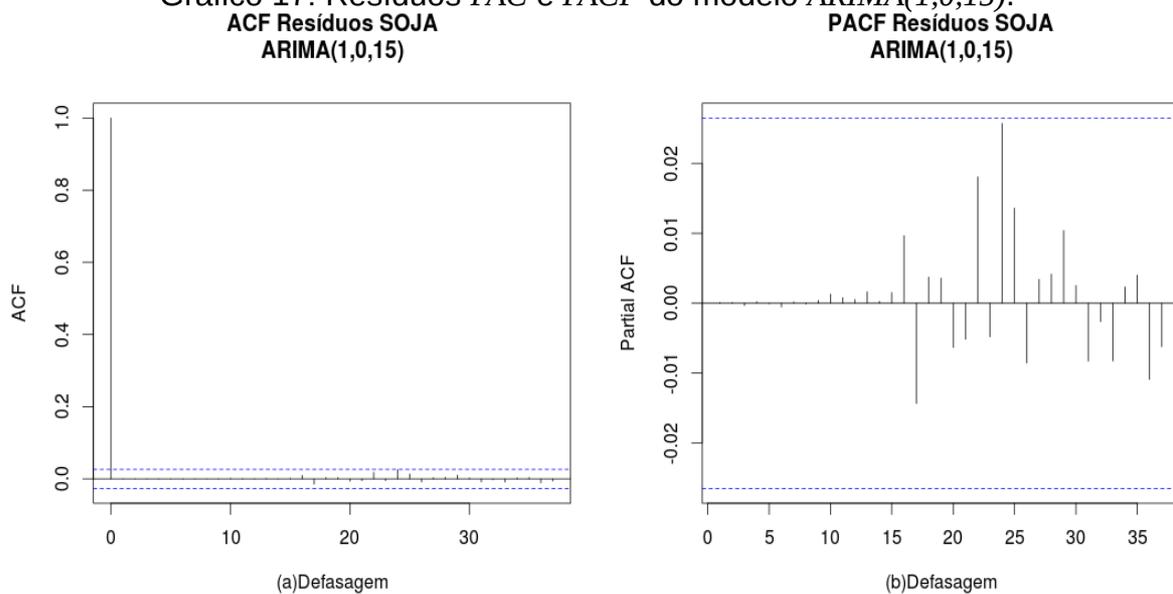
Tabela 10: Modelos Apropriados

Modelo	AIC	ADF	PP	KPSS	Estacionário
<i>ARIMA (0,0,3)</i>	-35411.54	1%	1%	10%	SIM
<i>ARIMA (1,0,15)</i>	-35415.65	1%	1%	10%	SIM
<i>ARIMA (1,0,24)</i>	-35406.72	1%	1%	10%	SIM
<i>ARIMA (3,1,3)</i>	-35323.31	1%	1%	10%	SIM
<i>SARIMA (0,0,3).(0,0,1)₉</i>	-35414.53	1%	1%	10%	SIM
<i>SARIMA (3,1,3)(0,0,1)₉</i>	-35352.69	1%	1%	10%	SIM

Fonte: Informações obtidas através do *Software R*.

Assim o modelo identificado para modelar a série de comportamento temporal presente nos dados coletados que mais se ajusta, verificado pelo Critério de Informação de *Akaike (AIC)*, dentre os testados e considerando a série estacionária, o modelo escolhido foi o *ARIMA (1,0,15)*, por apresentar um maior *AIC*.

O próximo passo é realizar a checagem dos resíduos do modelo escolhido, sendo apresentado no Gráfico 17.

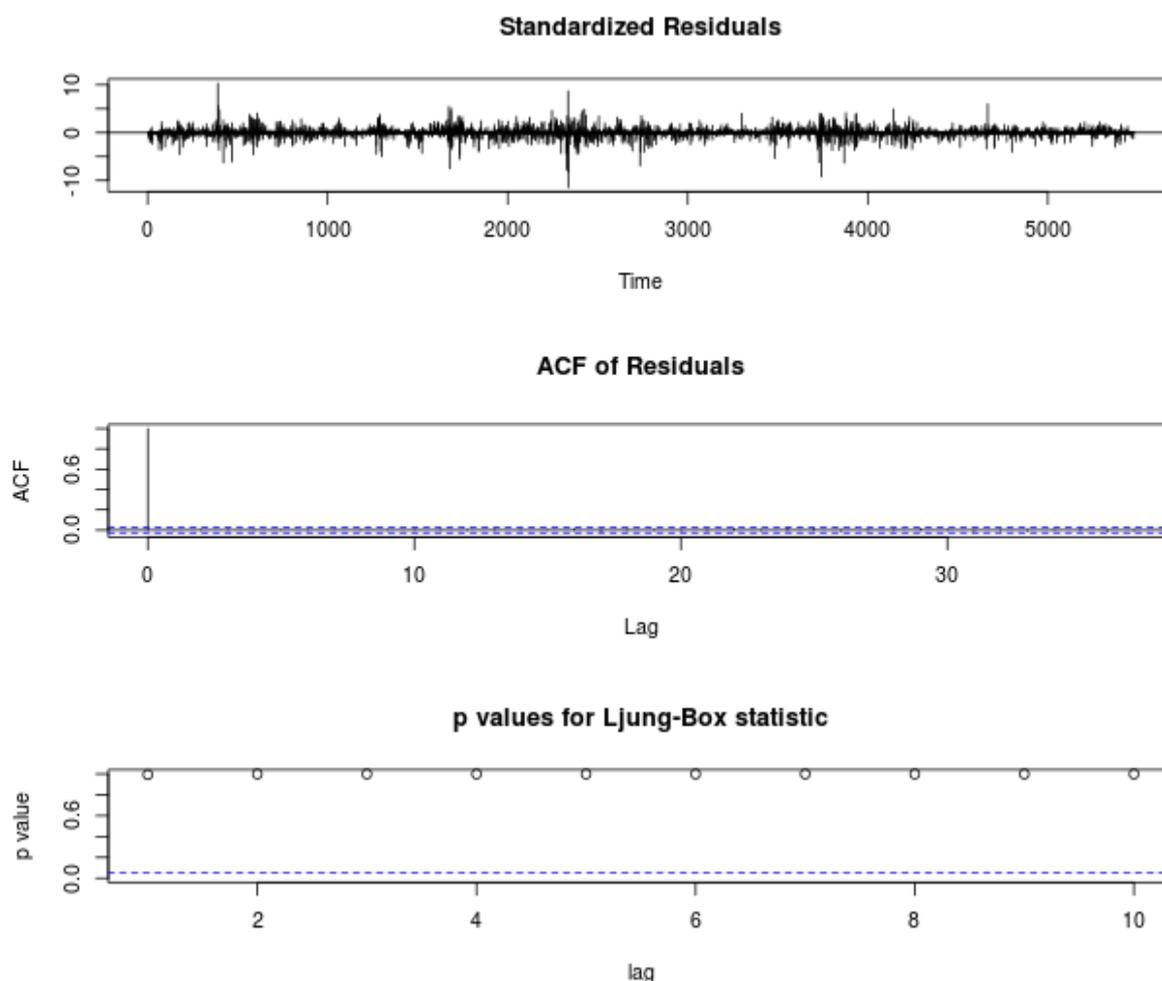
Gráfico 17: Resíduos *FAC* e *FACP* do modelo *ARIMA(1,0,15)*.

Fonte: Elaborado pelo autor com uso do *Software R*.

Pode-se notar que o Gráfico 17(a) e 17(b), encontram-se no nível de confiança de estacionariedade.

Em seguida deve ser verificado o diagnóstico dos resíduos, apresentado no Gráfico 18.

Gráfico 18: Diagnóstico de Resíduos



Fonte: Elaborado pelo autor com uso do *Software R*.

Com o comando *tsdiag*(Quadro 7) é possível analisar os gráficos dos resíduos. O modelo deve apresentar os resíduos estacionários, com média zero e variância constante, o que foi observado no Gráfico 17.

Dando sequência à metodologia *Box & Jenkins*, o último passo é realizar a previsão. Com base nas informações obtidas no Quadro 8, foram realizadas as previsões para as ocorrências número 5480, sendo feito, também um comparativo entre estas e os valores efetivados, conforme apresentado no Quadro 17.

Quadro 17 – Previsão X Efetivado - Soja

Ocorrência	Valor previsto P (R\$)	Limite inferior P (R\$)	Limite superior P (R\$)	Valor efetivado P (R\$)
5480	65.61956	65.60109	65.63838	64,25

5481	65.61953	65.60091	65.63851	63,50
5482	65.61965	65.60099	65.63866	62,50
5483	65.61979	65.60110	65.63884	61,50
5484	65.62025	65.60154	65.63932	60,50

Fonte: Elaborado pelo autor.

Comparando-se as previsões com o efetivado, conforme o Quadro 17, observa-se que, os valores previstos ficaram acima do valor efetivado. Para as ocorrências 5480 a 5484 a confiabilidade aplicada foi de 95% (noventa e cinco por cento).

6 CONSIDERAÇÕES FINAIS

Ao finalizar esse trabalho, pode-se dizer que a pesquisa atingiu o objetivo principal de aplicar métodos estatísticos e econométricos, na busca de previsões mais confiáveis para o preço dos principais produtos agropecuários do município de Alegrete/RS. Para que a pesquisa fosse possível, selecionaram-se três produtos principais Arroz, Boi e Soja.

O método estatístico de previsão utilizado ao longo do trabalho foi a metodologia de *Box & Jenkins*, com as modelagens *ARIMA* e *SARIMA*. Tais métodos geram previsões mais apuradas. A utilização dos dados históricos é um fato importante ao uso dessas modelagens, sua utilização depende apenas dos dados da série temporal.

Como cada produto tem suas peculiaridades, o comportamento de cada um é distinto no que se refere à tendência e a sazonalidade, exigindo um modelo diferente em sua representação.

O pesquisador pode modelar uma série que tenha comportamento temporal presente nos dados coletados e escolher o melhor modelo do ponto de vista de significância estatística entre um conjunto de possíveis modelos concorrentes. Com a aplicação da metodologia *Box & Jenkins*, apoiada em testes estatísticos para subsidiar a modelagem, foi possível definir os modelos apropriados. Através da manipulação deste ferramental estatístico, tornou-se possível a escolha ou sugestão de um modelo matemático representativo para as séries do Arroz, Boi e Soja.

Para o produto Arroz, observou-se o modelo $SARIMA(0,0,27).(3,0,0)_8$, produto Boi o modelo $ARIMA(1,2,21)$ e o produto Soja o modelo $ARIMA(1,0,15)$, identificou-se o comportamento da autocorrelação entre os valores da série temporal r , e com base nesse comportamento, foi realizada a previsão de valores.

Comparando as previsões com o efetivado, observa-se que, os modelos apresentaram diferenças, tendo em vista a oscilação dos preços efetivados no mercado por conta de fatores climáticos e/ou políticos, já que são fatores determinante no preço final de alguns produtos. Deve-se levar em conta o estudo

mais detalhado desses fatores para escolha de um modelo mais preciso na previsão de resultados.

Portanto, como uma segunda sugestão para um futuro trabalho sugere-se estudar os modelos *ARGH*, *GARCH* e *TARCH*, sendo também indicados para realização das estimações e previsões de preços, uma vez que esses modelos podem modelar variância condicional. Uma segunda sugestão é trabalhar com os dados históricos semanais ou mensais, visto que alguns dados analisados mostraram-se repetidos diariamente.

REFERÊNCIAS

- ABRAHAM, B.; LEDOLTER, J. **Statistical Methods for Forecasting**. *New York: John Wiley & Sons*, 1983.
- ALEXANDER, CAROL. **Modelo de Mercado: Um Guia para Análise de Informação Financeira**. São Paulo: Bolsa de Mercadorias & Futuros, 2005.
- BARROS, M.C.L. **Introdução às séries temporais e ao modelos ARIMA**. Cap. 5. Disponível em: <<http://www.mbarcos.com/sitebuildercontent/sitebuilderfiles/LivroProcessosCap5parte.pdf>>. Acesso em: 01/out/2013.
- BOLLERSLEV, T. **Generalized autoregressive conditional heteroskedasticity**. *Journal of Econometrics*, v. 31, p. 307-327, 1986.
- BUENO, RODRIGO DE L. DA S. **Econometria de séries temporais**. 2. ed. São Paulo: Cengage Learning, 2011.
- CAMPOS, C. V. C. **Previsão da Arrecadação de Receitas Federais: Aplicações de Modelos de Séries Temporais para o Estado de São Paulo**. 2009. 133 f. Dissertação (Mestrado) – Faculdade de Economia, Administração e Contabilidade de Ribeirão Preto, Universidade de São Paulo, 2009.
- CEPEA-ESALQ/USP. Centro de Estudos Avançados em Economia Aplicada- Escola Superior de Agricultura "Luiz de Queiroz"/Universidade de São Paulo. Disponível em: <<http://cepea.esalq.usp.br/>>. Acesso em: 01/jan/2014.
- ENGLE, R. F. **Autoregressive conditional heteroscedasticity with estimates of the variance of UK inflation**. *Econometrica*, v. 50, n. 4, p. 987-1008, 1982.
- EMATER/RS – Associação Riograndense de Empreendimentos de Assistência Técnica e Extensão Rural. Disponível em: <<http://www.emater.tche.br>>. Acesso em: 01/out/2013.
- FAVA, V. L. **Manual de Econometria**. In: VASCONCELS, M. A. S.; ALVES, D. São Paulo: Editora Atlas, 2000.
- FONSECA, Manuel Alcino R. da. **Álgebra linear aplicada a finanças, economia e econometria**. Barueri, SP: Manole, 2003.
- GIL, Antonio Carlos. **Estudo de Caso**. São Paulo: Atlas, 2009.
- GUJARATI, DAMODAR N.. **Econometria Básica**. 3ª. ed. – São Paulo: Pearson Makron Books, 2000.
- IBGE – Instituto Brasileiro de Geografia e Estatística. Disponível em: <<http://www.ibge.gov.br>>. Acesso em: 01/out/2013.

IRGA – Instituto Riograndense do Arroz. Disponível em: <<http://www.irga.rs.gov.br/inicial>>. Acesso em: 07/nov/2013.

IVZ. Inspeção Veterinária e Zootécnica de Alegrete. Alegrete, 2013.

MAPA, Ministério da Agricultura, Pecuária e Abastecimento. **Exportações do agronegócio atingem valor recorde de US\$ 99 bi.** Disponível em: <<http://www.agricultura.gov.br/comunicacao/noticias/2013/05/exportacoes-do-agronegocio-atingem-valor-recorde-de-uss-99-bi>>. Acesso em: 27/out/2013.

_____. **Crescimento da renda aumenta demanda por alimentos no Brasil.** Disponível em: <<http://www.agricultura.gov.br/comunicacao/noticias/2013/10/crescimento-da-renda-aumenta-demanda-por-alimentos-no-brasil>>. Acesso em: 27/out/2013.

MARCHEZAN, ANALICE; SOUZA, ADRIANO MENDONÇA. **Previsão do preço dos principais grãos produzidos no Rio Grande do Sul.** Cienc. Rural [online]. 2010, vol.40, n.11, PP. 2368-2374. Epub Dec 03, 2010. ISSN 0103-8478.

MELO, Bruno Stephan Veras de. **Modelo de Previsão para Arrecadação Tributária.** Brasília: ESAF, 2001 97 p. Monografia vencedora em 1º lugar no VI Prêmio Tesouro Nacional – 2001. Orçamentos e Sistemas de Informação sobre a Administração Financeira Pública, Brasília (DF).

MARQUES, PEDRO ROCHA. **Avaliação da Competitividade dos Sistemas de Produção de Bovinos de Corte da Fronteira Oeste do Rio Grande do Sul.** 2010. 101 f. Dissertação (Mestrado) – Centro De Estudos E Pesquisas Em Agronegócios - Programa De Pós-Graduação Em Agronegócios, Universidade Federal do Rio Grande do Sul, 2010.

MORAES , RAFAEL F.; SALES, PAULO R. H.; COSTA, JOSÉ F. S. **Utilização do Software Estatístico R na Previsão de Séries Temporais: Série Prêmio De Resseguro .** Rio de Janeiro, 2011, UERJ, ISSN 1413-9022 / v. 30, p. 01 - 17.

MORETTIN, Pedro Alberto. TOLOI, Clélia Maria de Castro. **Modelos para previsão de séries temporais.** Instituto de Matemática Pura e Aplicada. Rio de Janeiro, 1981.

_____. **Modelos de função de transferência.** São Paulo. ABR, 1989. V.1, 166p.

_____. **Análise de séries temporais.** São Paulo. E. Blücher, 2004. 533p.

PETERNELLI, Luiz Alexandre. MELLO, Márcio Pupin de. **Conhecendo o R: Uma Visão Estatística.** Minas Gerais: Ed. UFV, 2007.

NELSON, C. R. ***Aplied Time Series Analysis for Manageral Forecasting.*** San Francisco: Holden-Day, 1973.

SAK, HALIS; HÖRMANN, WOLFGANG. ***Simulating the Continuation of a Time Series in R.*** eprint arXiv:1212.2393, 2012.

SEPLAG. Secretaria de Planejamento, Gestão e Participação Cidadã: **ATLAS Sócio Econômico Rio Grande do Sul**. Disponível em: <<http://www1.seplag.rs.gov.br/atlas/default.asp>>. Acesso em: 07/nov/2013.

SILVA, WASHINGTON SANTOS DA; SAFADI, THELMA AND CASTRO JUNIOR, LUIZ GONZAGA DE. **Uma análise empírica da volatilidade do retorno de commodities agrícolas utilizando modelos ARCH: os casos do café e da soja**. Revista de Economia e Sociologia Rural, Rio de Janeiro, 2005, vol.43, n.1, PP. 119-134. ISSN 0103-2003.

SILVEIRA, Vicente Celestino Pires; VIANA, João Garibaldi Almeida; WERNER JUNIOR, Carlos. **Preço pago pelo consumidor de carne bovina nas diferentes regiões econômicas do Rio Grande do Sul, Brasil**. Ciência Rural [online]. 2009, vol.39, n.4, PP. 1201-1207. ISSN 0103-8478.

SOUZA, R.C.; CAMARGO, M.E. **Análise e previsão de séries temporais: os modelos ARIMA**. Ijuí, RS: Sedigraf, 1996. 242p.

ZAKOIAN, J. M. **Threshold heteroskedastic models**. *Journal of Economics Dynamics and Control*, v. 18, p. 931-944, 1994.

APÊNDICES

APÊNDICE A – *Script ComandosR_RCC_Arroz.r*

```

# Time Series ARIMA Models in R
# Copyright 2014 by Cristian Tales

# install.packages("tseries")
library(tseries)

#Dados
setwd("/home/cristian/Documentos/Cristian/UNIPAMPA/Projeto/")
Dados<-read.table("Cotação_Arroz.csv", sep="|", dec=".", h=T)
Dados
attach(Dados)

# Defining variables
P<-as.numeric(COTACAO)
P

# Descriptive statistics and plotting the data
par(mfrow=c(3,3))
plot( P,                #plota x, y
      type="l",         #tipo linha
      main="Gráfico de Preços\nArroz", #título
      xlab="Período",   #nomeia o eixo x
      ylab="Preços")   #nomeia o eixo y
segments(0,0,0,40)
text( 0+110, 7, "|1995")
segments(366,0,366,40)
text( 366+110, 7, "|1996")
segments(731,0,731,40)
text( 731+110, 7, "|1997")
segments(1097,0,1097,40)
text( 1097+110, 7, "|1998")
segments(1462,0,1462,40)
text( 1462+110, 7, "|1999")
segments(1827,0,1827,40)
text( 1827+110, 7, "|2000")
segments(2194,0,2194,40)

```

```

text( 2194+110, 7, "|2001")
segments(2558,0,2558,40)
text( 2558+110, 7, "|2002")
segments(2923,0,2923,40)
text( 2923+110, 7, "|2003")
segments(3288,0,3288,40)
text( 3288+110, 7, "|2004")
segments(3655,0,3655,40)
text( 3655+110, 7, "|2005")
segments(4019,0,4019,40)
text( 4019+110, 7, "|2006")
segments(4384,0,4384,40)
text( 4384+110, 7, "|2007")
segments(4749,0,4749,40)
text( 4749+110, 7, "|2008")
segments(5116,0,5116,40)
text( 5116+110, 7, "|2009")
segments(5480,0,5480,40)
text( 5480+110, 7, "|2010")
segments(5845,0,5845,40)
text( 5845+110, 7, "|2011")
segments(6211,0,6211,40)
text( 6211+110, 7, "|2012")
segments(6575,0,6575,40)

```

```
# Dickey-Fuller test for variable
```

```
adf.test(P)
```

```
pp.test(P)
```

```
kpss.test(P)
```

```
# ACF and PACF
```

```
acf(P, main="ARROZ - \nFunção de Auto Correlação", xlab="(a) Defasagem", ylab="ACF da amostra")
```

```
pacf(P, main="ARROZ - \nFunção de Auto Correlação Parcial", xlab="(b) Defasagem", ylab="PACF da amostra")
```

```
# 1ª Diferença de P
```

```
r<-diff(log(P))
```

```
plot( r, type="l",main="Primeira Diferença\nArroz", xlab="Intervalo", ylab="Retorno R")
```

```
# Dickey-Fuller test for variable
```

```

adf.test(r)
pp.test(r)
kpss.test(r)
# ACF and PACF
acf(r, main="ARROZ - \nFunção de Auto Correlação", xlab="(a) Defasagem", ylab="ACF de R")
pacf(r, main="ARROZ - \nFunção de Auto Correlação Parcial", xlab="(b) Defasagem", ylab="PACF de R")

# 2ª Diferença de P
r2<-diff(r)
plot(r2, type="l",main="Segunda Diferença", xlab="Intervalo", ylab="Retorno R")
# ACF and PACF
acf(r2, main="ARROZ - \nFunção de Auto Correlação", xlab="Defasagem", ylab="ACF de R")
pacf(r2, main="ARROZ - \nFunção de Auto Correlação Parcial", xlab="Defasagem", ylab="PACF de R")

par(mfrow=c(1,2))
rXd<-diff(log(P))
rm(i)
Sys.sleep(2)
for( i in 1:13 ){
  rX<-rXd
  acf(rX, main=c("ACF > ",i), xlab="Defasagem", ylab="ACF de R")
  pacf(rX, main=c("PACF > ", i), xlab="Defasagem", ylab="PACF de R")
  rXd<-diff(rX)
  Sys.sleep(1)
}

#
# SARIMA(1,0,0).(3,0,0)7 -> aic = -39147.04
#
sarima_100_300<-arima( r, order=c(1, 0, 0), seasonal = list( order = c(3, 0, 0), period = 7))
sarima_100_300
#Residuals
res_sarima_100_300<-residuals( sarima_100_300 )
acf( sarima_100_300$residuals, main="ACF Resíduos SARIMA(3,1,3)(0,0,1)9", xlab="Defasagem")
pacf( sarima_100_300$residuals, main="PACF Resíduos SARIMA(3,1,3)(0,0,1)9", xlab="Defasagem")
# Dickey-Fuller test for variable
adf.test( res_sarima_100_300 )
pp.test( res_sarima_100_300 )
kpss.test( res_sarima_100_300 )

```

```

#Gera os gráficos para diagnóstico
tsdiag( sarima_100_300 )

#
# SARIMA(0,0,26).(3,0,0)8 -> aic = -39178.1
#
sarima_0026_300<-arima( r, order=c(0, 0, 26), seasonal = list( order = c(3, 0, 0), period = 8))
sarima_0026_300
#Residuals
res_sarima_0026_300<-residuals( sarima_0026_300 )
acf( sarima_0026_300$residuals, main="ACF Resíduos ARROZ \nSARIMA(0,0,26)(3,0,0)8",
xlab="Defasagem")
pacf( sarima_0026_300$residuals, main="PACF Resíduos ARROZ \nSARIMA(0,0,26)(3,0,0)8",
xlab="Defasagem")
# Dickey-Fuller test for variable
adf.test( res_sarima_0026_300 )
pp.test( res_sarima_0026_300 )
kpss.test( res_sarima_0026_300 )
#Gera os gráficos para diagnóstico
tsdiag( sarima_0026_300 )

#
# SARIMA(0,0,27).(3,0,0)8 -> aic = -39183.57
#
sarima_0027_300<-arima( r, order=c(0, 0, 27), seasonal = list( order = c(3, 0, 0), period = 8))
sarima_0027_300
#Residuals
res_sarima_0027_300<-residuals( sarima_0027_300 )
acf( sarima_0027_300$residuals, main="ACF Resíduos ARROZ \nSARIMA(0,0,27)(3,0,0)8",
xlab="Defasagem")
pacf( sarima_0027_300$residuals, main="PACF Resíduos ARROZ \nSARIMA(0,0,27)(3,0,0)8",
xlab="Defasagem")
# Dickey-Fuller test for variable
adf.test( res_sarima_0027_300 )
pp.test( res_sarima_0027_300 )
kpss.test( res_sarima_0027_300 )
#Gera os gráficos para diagnóstico
tsdiag( sarima_0027_300 )

##
## Parte V - PREVISÃO

```

```

##
#Calcula a previsão com base na equação do Modelo
Previsao<-predict( sarima_0027_300, n.ahead=4 ) #, se.fit=T)
Previsao
#Calcula limite inferior de previs?o com 95% de confiança
LInfPrev<-Previsao$pred-1.96*Previsao$se
LInfPrev
#Calcula limiete superior de previs?o com 95% de confiança
LSupPrev<-Previsao$pred+1.96*Previsao$se
LSupPrev
#Preço
Preco6576<-exp( Previsao$pred[1] ) + P[6575]
Preco6576
#Preço Inferior
LInfPrev<-exp( LInfPrev[1] ) + P[6575]
LInfPrev
#Preço Superior
LSupPrev<-exp( LSupPrev[1] ) + P[6575]
LSupPrev

#Calculo da Previsão Preço
Preco6577<-exp( Previsao$pred[2] ) + Preco6576
Preco6577
Preco6578<-exp( Previsao$pred[3] ) + Preco6577
Preco6578
Preco6579<-exp( Previsao$pred[4] ) + Preco6578
Preco6579
Preco6580<-exp( Previsao$pred[5] ) + Preco6579
Preco6580

```

APÊNDICE B – *Script* ComandosR_RCC_Boi.r

```

# Time Series ARIMA Models in R
# Copyright 2014 by Cristian Tales

# install.packages("tseries")
library(tseries)

#Dados

```

```

setwd("/home/cristian/Documentos/Cristian/UNIPAMPA/Projeto/")
Dados<-read.table("Cotação_Boi.csv", sep="|", dec=".", h=T)
Dados
attach(Dados)

# Defining variables
P<-as.numeric(COTACAO)
P

# Descriptive statistics and plotting the data
plot( P,                #plota x, y
      type="l",         #tipo linha
      main="Gráfico de Preços\nBoi", #título
      xlab="Período",   #nomeia o eixo x
      ylab="Preços")    #nomeia o eixo y
segments(0,0,0,4)
text( 0+110, 0.5, "|1995")
segments(366,0,366,4)
text( 366+110, 0.5, "|1996")
segments(731,0,731,4)
text( 731+110, 0.5, "|1997")
segments(1097,0,1097,4)
text( 1097+110, 0.5, "|1998")
segments(1462,0,1462,4)
text( 1462+110, 0.5, "|1999")
segments(1827,0,1827,4)
text( 1827+110, 0.5, "|2000")
segments(2194,0,2194,4)
text( 2194+110, 0.5, "|2001")
segments(2558,0,2558,4)
text( 2558+110, 0.5, "|2002")
segments(2923,0,2923,4)
text( 2923+110, 0.5, "|2003")
segments(3288,0,3288,4)
text( 3288+110, 0.5, "|2004")
segments(3655,0,3655,4)
text( 3655+110, 0.5, "|2005")
segments(4019,0,4019,4)
text( 4019+110, 0.5, "|2006")
segments(4384,0,4384,4)

```

```

text( 4384+110, 0.5, "|2007")
segments(4749,0,4749,4)
text( 4749+110, 0.5, "|2008")
segments(5116,0,5116,4)
text( 5116+110, 0.5, "|2009")
segments(5480,0,5480,4)
text( 5480+110, 0.5, "|2010")
segments(5845,0,5845,4)
text( 5845+110, 0.5, "|2011")
segments(6211,0,6211,4)
text( 6211+110, 0.5, "|2012")
segments(6575,0,6575,4)

# Dickey-Fuller test for variable
adf.test(P)
pp.test(P)
kpss.test(P)

# ACF and PACF
acf(P, main="BOI - \nFunção de Auto Correlação", xlab="(a) Defasagem", ylab="ACF da amostra P")
pacf(P, main="BOI - \nFunção de Auto Correlação Parcial", xlab="(b) Defasagem", ylab="PACF da amostra P")

# 1ª Diferença de P
r<-diff(log(P))
plot( r, type="l",main="BOI \nPrimeira Diferença", xlab="Intervalo", ylab="Retorno R")
# Dickey-Fuller test for variable
adf.test(r)
pp.test(r)
kpss.test(r)
# ACF and PACF
acf(r, main="BOI \nFunção de Auto Correlação", xlab="Defasagem", ylab="ACF de R")
pacf(r, main="BOI \nFunção de Auto Correlação Parcial", xlab="Defasagem", ylab="PACF de R")

# 2ª Diferença de P
r2<-diff(r)
plot(r2, type="l",main="BOI \nSegunda Diferença", xlab="Intervalo", ylab="Retorno R")
# ACF and PACF
acf(r2, main="BOI \nFunção de Auto Correlação", xlab="(a) Defasagem", ylab="ACF de R")
pacf(r2, main="BOI \nFunção de Auto Correlação Parcial", xlab="(b) Defasagem", ylab="PACF de R")

```

```

# Dickey-Fuller test for variable
adf.test(r2)
pp.test(r2)
kpss.test(r2)

par(mfrow=c(1,2))
rXd<-diff(log(P))
rm(i)
Sys.sleep(2)
for( i in 1:13 ){
  rX<-rXd
  acf(rX, main=c("ACF > ",i), xlab="Defasagem", ylab="ACF de R")
  pacf(rX, main=c("PACF > ", i), xlab="Defasagem", ylab="PACF de R")
  rXd<-diff(rX)
  Sys.sleep(1)
}

#
# ARIMA(1,2,21) -> aic = -40621.26
#
arima_1221<-arima( r2, order=c(1,2,21))
arima_1221
#Residuals
res_arima_1221<-residuals( arima_1221 )
acf( arima_1221$residuals, main="ACF Resíduos BOI\nARIMA(1,2,21)", xlab="(a) Defasagem")
pacf( arima_1221$residuals, main="PACF Resíduos BOI\nARIMA(1,2,21)", xlab="(b) Defasagem")
# Dickey-Fuller test for variable
adf.test( res_arima_1221 )
pp.test( res_arima_1221 )
kpss.test( res_arima_1221 )
#Gera os gráficos para diagnóstico
tsdiag( arima_1221 )
#
# ARIMA(1,2,27) -> aic = -44620.63
#
arima_1127<-arima( r2, order=c(1,1,27))
arima_1127
#Residuals
res_arima_1127<-residuals( arima_1127 )

```

```

acf( arima_1127$residuals, main="ACF Resíduos SARIMA(1,1,27)", xlab="Defasagem")
pacf( arima_1127$residuals, main="PACF Resíduos SARIMA(1,1,27)", xlab="Defasagem")
# Dickey-Fuller test for variable
adf.test( res_arima_1127 )
pp.test( res_arima_1127 )
kpss.test( res_arima_1127 )
#Gera os gráficos para diagnóstico
tsdiag( arima_1127 )

##
## Parte V - PREVISÃO
##
#Calcula a previsão com base na equação do Modelo
Previsao<-predict( arima_1221, n.ahead=4 ) #, se.fit=T)
Previsao
#Calcula limite inferior de previs?o com 95% de confiança
LInfPrev<-Previsao$pred-1.96*Previsao$se
LInfPrev
#Calcula limiete superior de previs?o com 95% de confiança
LSupPrev<-Previsao$pred+1.96*Previsao$se
LSupPrev
#Preço
Preco6576<-exp( Previsao$pred[1] ) + P[6575]
Preco6576
#Preço Inferior
LInfPrev<-exp( LInfPrev[1] ) + P[6575]
LInfPrev
#Preço Superior
LSupPrev<-exp( LSupPrev[1] ) + P[6575]
LSupPrev

#Calculo da Previsão Preço
Preco6577<-exp( Previsao$pred[2] ) + Preco6576
Preco6577
Preco6578<-exp( Previsao$pred[3] ) + Preco6577
Preco6578
Preco6579<-exp( Previsao$pred[4] ) + Preco6578
Preco6579
Preco6580<-exp( Previsao$pred[5] ) + Preco6579
Preco6580

```

APÊNDICE C – Script ComandosR_RCC_Soja.r

```

# Time Series ARIMA Models in R
# Copyright 2014 by Cristian Tales

# install.packages("tseries")
library(tseries)

#Dados
setwd("/home/cristian/Documentos/Cristian/UNIPAMPA/Projeto/")
Dados<-read.table("Cotação_Soja.csv", sep="|", dec=".", h=T)
attach(Dados)

# Defining variables
P<-as.numeric(COTACAO)

# Descriptive statistics and plotting the data
par(mfrow=c(2,1))
plot( P,                #plota x, y
      type="l",         #tipo linha
      main="Gráfico de Preços\nSoja", #título
      xlab="Período",   #nomeia o eixo x
      ylab="Preços")    #nomeia o eixo y
segments(0,0,0,75)
text( 0+110, 10, "1998")
segments(366,0,366,75)
text( 366+110, 10, "1999")
segments(731,0,731,75)
text( 731+110, 10, "2000")
segments(1097,0,1097,75)
text( 1097+110, 10, "2001")
segments(1462,0,1462,75)
text( 1462+110, 10, "2002")
segments(1827,0,1827,75)
text( 1827+110, 10, "2003")
segments(2192,0,2192,75)
text( 2192+110, 10, "2004")

```

```
segments(2558,0,2558,75)
text( 2558+110, 10, "2005")
segments(2923,0,2923,75)
text( 2923+110, 10, "2006")
segments(3288,0,3288,75)
text( 3288+110, 10, "2007")
segments(3653,0,3653,75)
text( 3653+110, 10, "2008")
segments(4019,0,4019,75)
text( 4019+110, 10, "2009")
segments(4384,0,4384,75)
text( 4384+110, 10, "2010")
segments(4749,0,4749,75)
text( 4749+110, 10, "2011")
segments(5114,0,5114,75)
text( 5114+110, 10, "2012")
```

```
# Dickey-Fuller test for variable
```

```
adf.test(P)
```

```
pp.test(P)
```

```
kpss.test(P)
```

```
# ACF and PACF
```

```
acf(P, main="SOJA - \nFunção de Auto Correlação", xlab="(a) Defasagem", ylab="ACF da amostra P")
```

```
pacf(P, main="SOJA - \nFunção de Auto Correlação Parcial", xlab="(b) Defasagem", ylab="PACF da amostra P")
```

```
# 1ª Diferença de P
```

```
r<-diff(log(P))
```

```
plot( r, type="l",main="SOJA\nPrimeira Diferença", xlab="Intervalo", ylab="Retorno R")
```

```
# Dickey-Fuller test for variable
```

```
adf.test(r)
```

```
pp.test(r)
```

```
kpss.test(r)
```

```
# ACF and PACF
```

```
acf(r, main="SOJA \nFunção de Auto Correlação", xlab="(a)Defasagem", ylab="ACF de R")
```

```
pacf(r, main="SOJA \nFunção de Auto Correlação Parcial", xlab="(a)Defasagem", ylab="PACF de R")
```

```

# 2ª Diferença de P
r2<-diff(r)
plot(r2, type="l",main="Segunda Diferença", xlab="Intervalo", ylab="Retorno R")
# ACF and PACF
acf(r2, main="Função de \nAuto Correlação", xlab="Defasagem", ylab="ACF de R")
pacf(r2, main="Função de \nAuto Correlação Parcial", xlab="Defasagem", ylab="PACF de R")

par(mfrow=c(1,2))
#rX<-diff(log(P))
#rm(i)
#for( i in 1:3 ){
# acf(rX, main=c("ACF > ",i), xlab="Defasagem", ylab="ACF de R")
# pacf(rX, main=c("PACF > ", i), xlab="Defasagem", ylab="PACF de R")
# rX<-diff(rX)
#}

#
# ARIMA(0,0,3) -> aic = -35411.54
#
arima_003<-arima( r, order=c(0,0,3))
arima_003
#Residuals
res_arima_003<-residuals( arima_003 )
acf( arima_003$residuals, main="ACF Resíduos ARIMA(0,0,3)", xlab="Defasagem")
pacf( arima_003$residuals, main="PACF Resíduos ARIMA(0,0,3)", xlab="Defasagem")
# Dickey-Fuller test for variable
adf.test( res_arima_003 )
pp.test( res_arima_003 )
kpss.test( res_arima_003 )
#Gera os gráficos para diagnóstico
tsdiag( arima_003 )

#
#ARIMA(1,0,15) -> aic = -35415.65
#
arima_1015<-arima( r, order=c(1,0,15))
arima_1015
#Residuals
res_arima_1015<-residuals( arima_1015 )
acf( arima_1015$residuals, main="ACF Resíduos SOJA\nARIMA(1,0,15)", xlab="(a)Defasagem")

```

```
pacf( arima_1015$residuals, main="PACF Resíduos SOJA\nARIMA(1,0,15)", xlab="(b)Defasagem")
# Dickey-Fuller test for variable
adf.test( res_arima_1015 )
pp.test( res_arima_1015 )
kpss.test( res_arima_1015 )
#Gera os gráficos para diagnóstico
tsdiag( arima_1015 )

#
#ARIMA(1,0,24) -> aic = -35406.72
#
arima_1024<-arima( r, order=c(1,0,24))
arima_1024
#Residuals
res_arima_1024<-residuals( arima_1024 )
acf( arima_1024$residuals, main="ACF Resíduos ARIMA(1,0,24)", xlab="Defasagem")
pacf( arima_1024$residuals, main="PACF Resíduos ARIMA(1,0,24)", xlab="Defasagem")
# Dickey-Fuller test for variable
adf.test( res_arima_1024 )
pp.test( res_arima_1024 )
kpss.test( res_arima_1024 )
#Gera os gráficos para diagnóstico
tsdiag( arima_1024 )

#
#ARIMA(3,1,3) -> aic = -35323.31
#
arima_313<-arima( r2, order=c(3,1,3))
arima_313
#Residuals
res_arima_313<-residuals( arima_313 )
acf( arima_313$residuals, main="ACF Resíduos ARIMA(3,1,3)", xlab="Defasagem")
pacf( arima_313$residuals, main="PACF Resíduos ARIMA(3,1,3)", xlab="Defasagem")
# Dickey-Fuller test for variable
adf.test( res_arima_313 )
pp.test( res_arima_313 )
kpss.test( res_arima_313 )
#Gera os gráficos para diagnóstico
tsdiag( arima_313 )
```

```

#
# SARIMA(0,0,3).(0,0,1)9 -> aic = -35414.53
#
sarima_003_001<-arima( r, order=c(0,0,3), seasonal = list( order = c(0, 0, 1), period = 9))
sarima_003_001
#Residuals
res_sarima_003_001<-residuals( sarima_003_001 )
acf( sarima_003_001$residuals, main="ACF Resíduos SARIMA(0,0,3).(0,0,1)9", xlab="Defasagem")
pacf( sarima_003_001$residuals, main="PACF Resíduos SARIMA(0,0,3).(0,0,1)9",
xlab="Defasagem")
# Dickey-Fuller test for variable
adf.test( res_sarima_003_001 )
pp.test( res_sarima_003_001 )
kpss.test( res_sarima_003_001 )
#Gera os gráficos para diagnóstico
tsdiag( sarima_003_001 )

#
#SARIMA(3,1,3)(0,0,1)9 -> aic = -35352.69
#
sarima_313001<-arima( r2, order=c(3,1,3), seasonal = list( order = c(0, 0, 1), period = 9))
sarima_313001
#Residuals
res_sarima_313001<-residuals( sarima_313001 )
acf( sarima_313001$residuals, main="ACF Resíduos SARIMA(3,1,3)(0,0,1)9", xlab="Defasagem")
pacf( sarima_313001$residuals, main="PACF Resíduos SARIMA(3,1,3)(0,0,1)9", xlab="Defasagem")
# Dickey-Fuller test for variable
adf.test( res_sarima_313001 )
pp.test( res_sarima_313001 )
kpss.test( res_sarima_313001 )
#Gera os gráficos para diagnóstico
tsdiag( sarima_313001 )

##
## Parte V - PREVISÃO
##
#Calcula a previsão com base na equação do Modelo
Previsao<-predict( arima_1015, n.ahead=4 ) #, se.fit=T)
Previsao

```

```
#Calcula limite inferior de previs?o com 95% de confian?a
LInfPrev<-Previsao$pred-1.96*Previsao$se
LInfPrev
#Calcula limiete superior de previs?o com 95% de confian?a
LSupPrev<-Previsao$pred+1.96*Previsao$se
LSupPrev
#Pre?o
Preco5480<-exp( Previsao$pred[1] ) + P[5479]
Preco5480
#Pre?o Inferior
LInfPrev<-exp( LInfPrev[1] ) + P[5479]
LInfPrev
#Pre?o Superior
LSupPrev<-exp( LSupPrev[1] ) + P[5479]
LSupPrev

#Calculo da Previs?o Pre?o
Preco5481<-exp( Previsao$pred[2] ) + Preco5480
Preco5481
Preco5482<-exp( Previsao$pred[3] ) + Preco5481
Preco5482
Preco5483<-exp( Previsao$pred[4] ) + Preco5483
Preco5483
Preco5484<-exp( Previsao$pred[4] ) + Preco5483
Preco5484
```