

**UNIVERSIDADE FEDERAL DE SANTA MARIA  
CENTRO DE CIÊNCIAS NATURAIS E EXATAS  
CURSO DE ESPECIALIZAÇÃO EM ESTATÍSTICA E MODELAGEM  
QUANTITATIVA**

**OFERTA E DEMANDA DE EMPREGOS NO BRASIL  
MEDIANTE A MODELAGEM ARIMA**

**MONOGRAFIA DE ESPECIALIZAÇÃO**

**Renata Rocha de Oliveira**

**SANTA MARIA, RS, BRASIL**

**2015**

# **OFERTA E DEMANDA DE EMPREGOS NO BRASIL MEDIANTE A MODELAGEM ARIMA**

**Renata Rocha de Oliveira**

Monografia apresentada ao Curso de Especialização em Estatística e Modelagem Quantitativa, da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para a obtenção do grau de **Especialista em Estatística e Modelagem Quantitativa.**

**Orientador: Prof<sup>a</sup> Dr<sup>a</sup> Lorena Vicini**  
**Coorientador: Prof. Dr. Adriano Mendonça Souza**

**Santa Maria, RS, Brasil**

**2015**

**Universidade Federal de Santa Maria  
Centro de Ciências Naturais e Exatas  
Curso de Especialização em Estatística e Modelagem Quantitativa**

A Comissão Examinadora, abaixo assinada  
aprova a Monografia de Especialização

**OFERTA E DEMANDA DE EMPREGOS NO BRASIL MEDIANTE A  
MODELAGEM ARIMA**

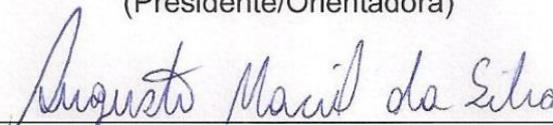
elaborada por  
**Renata Rocha de Oliveira**

Como requisito parcial para obtenção do grau de  
**Especialista em Estatística e Modelagem Quantitativa.**

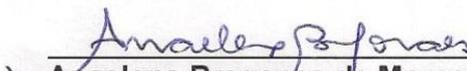
**COMISSÃO EXAMINADORA:**



**Lorena Vicini, Dr<sup>a</sup>.**  
(Presidente/Orientadora)



**Augusto Maciel da Silva, Dr. (UFSM)**



**Anaelena Bragança de Moraes, Dr<sup>a</sup>. (UFSM)**

Santa Maria, 23 de janeiro de 2015.

## **AGRADECIMENTOS**

Primeiramente a Deus, pois o que seria de mim sem fé.

A meu Pai Carlos Alberto, pelo apoio moral, financeiro e, por muitas vezes, ter mais esperança em mim do que eu mesma.

A minha Mãe Cléia, pela força, por me ensinar a perseverar e sempre ir até o fim em tudo que faço.

A minha Irmã Roberta por todas as vezes que esteve ao meu lado, incansavelmente, por me ouvir e apoiar e, muitas vezes, aconselhar.

A minha família como um todo, pela paciência e todas as mudanças que foram necessárias para que voltasse a estudar.

Ao Professor Adriano Souza, por me desafiar a ser uma profissional cada vez melhor.

A Professora Lorena, pela paciência incansável, pela dedicação em me orientar e apoio quase que incondicional para que este trabalho se realizasse.

Aos meus professores pelo incentivo e ensinamento.

Em suma, a todos que de alguma forma contribuíram para realização deste trabalho.

Jamais considere seus estudos uma obrigação, mas sim uma oportunidade invejável para aprender a conhecer a influência libertadora da beleza do reino do espírito, para seu próprio prazer pessoal e para proveito da comunidade à qual seu futuro trabalho pertencer.

(Albert Einstein)

## RESUMO

Monografia de Especialização  
Programa de Pós-Graduação em Estatística e Modelagem Quantitativa  
Universidade Federal de Santa Maria

### **OFERTA E DEMANDA DE EMPREGOS NO BRASIL ATRAVÉS DE MODELAGEM ARIMA**

AUTORA: RENATA ROCHA DE OLIVEIRA

ORIENTADOR: LORENA VICINI

Data e Local de Defesa: 23 de janeiro de 2015.

O desenvolvimento econômico nacional está intimamente ligado à quantidade de empregos disponíveis. Assim, para que seja possível estudar esse desenvolvimento, é necessário analisar variáveis relacionadas a ele, como dados sobre admissões e demissões. Portanto, o objetivo deste estudo é determinar modelos matemáticos que expliquem o comportamento dessas variáveis por meio de modelos de previsão lineares (ARIMA), isso foi possível com a aplicação da metodologia de Box e Jenkins. A análise refere-se à quantidade de admissões e demissões, no período de maio de 1999 até agosto de 2014. Os modelos matemáticos encontrados para a variável de admissões foi um SARIMA(2,1,0)(1,0,0)<sub>12</sub>, bem como para demissões, também um SARIMA(2,1,0)(1,0,0)<sub>12</sub>. Esses modelos são capazes prever o comportamento das séries, acompanhando a movimentação econômica do país. Dessa forma, pode-se proporcionar um estudo mais aprofundado sobre o desenvolvimento econômico, por meio dessas modelagens, visando identificar as melhores épocas do ano para a troca de emprego, quando ocorre maior quantidade de empregos livres no mercado, assim como, se utilizar desses modelos para aliar a séries de índices econômicos e embasar o comportamento dessas variações.

**Palavras-chave:** Modelagem ARIMA, Metodologia Box e Jenkins, Séries temporais, admissões, demissões.

## **ABSTRACT**

Specialization monograph  
Graduate Program in Statistics and Quantitative Modeling  
Federal University of Santa Maria

### **SUPPLY AND DEMAND JOBS IN BRAZIL THROUGH MODELING ARIMA**

**AUTHOR: RENATA ROCHA DE OLIVEIRA**

**SUPERVISOR: LORENA VICINI**

Santa Maria, 23<sup>th</sup> January, 2015.

The national economic development is closely linked to the quantity of jobs available. So, to be able to study other variables responsible for this development, it is necessary to analyze data from admissions and dismissals. Therefore, by Box and Jenkins methodology, the aim of this study is to determine mathematical models to explain the behavior of these data using linear prediction models (ARIMA). The analysis refers to the amount of admissions and dismissals, from May 1999 until August 2014. The mathematical models found for the variable admissions was a SARIMA (2,1,0)(1,0,0)<sub>12</sub> and for termination, also a SARIMA (2,1,0)(1,0,0)<sub>12</sub>. These models are able to predict the behavior of the series, following the economic activity of the country. Thus, one can provide a further study on economic development through these modeling, to identify the best times of the year for the exchange of employment where there is a greater amount of free jobs in the market and, if you use these models to combine the economic indices series and to support the behavior of these variations.

**Keyword:** ARIMA modeling, Box and Jenkins methodology, time series, admissions, dismissals.

## LISTA DE FIGURAS

Figura 1 -	Organograma adaptado da metodologia Box e Jenkins.....	20
Figura 2 -	Média, mediana e desvio padrão da série de admissões no período de 1999 a 2014.....	33
Figura 3 -	Comportamento mensal da série de admissões no período de 1999 a 2014.....	34
Figura 4 -	Valores mensais da média, mediana e desvio padrão da série de admissões no período de 1999 a 2014.....	35
Figura 5 -	Série de admissões no período de 1999 a 2014.....	36
Figura 6 -	Série original e diferenciada de admissões.....	36
Figura 7 -	FAC, FACP e estatística Ljung-Box da série de admissões.....	37
Figura 8 -	FAC, FACP dos resíduos do modelo SARIMA(2,1,0)(1,0,0) <sub>12</sub> e estatística Ljung-Box da série de admissões.....	40
Figura 9 -	FAC, FACP dos resíduos quadráticos do modelo SARIMA(2,1,0)(1,0,0) <sub>12</sub> e estatística Ljung-Box.....	40
Figura 10 -	Valores originais, valores estimados e resíduos do modelo.....	42
Figura 11 -	Previsão de admissões pelo modelo SARIMA(2,1,0)(1,0,0) <sub>12</sub> .....	42
Figura 12 -	Média, mediana e desvio padrão da série de demissões no período de 1999 a 2014.....	45
Figura 13 -	Comparação mensal da série de demissões no período de 1999 a 2014.....	46
Figura 14 -	Valores mensais da média, mediana e desvio padrão da série de demissões no período de 1999 a 2014.....	47
Figura 15 -	Série de demissões no período de 1999 a 2014.....	47
Figura 16 -	Série original e primeira diferença de demissões.....	48
Figura 17 -	FAC, FACP e estatística Ljung-Box da Série de demissões.....	49
Figura 18 -	FAC, FACP dos resíduos do modelo SARIMA(2,1,0)(1,0,0) <sub>12</sub> e estatística Ljung-Box(Q).....	51
Figura 19 -	FAC, FACP dos resíduos do modelo SARIMA(2,1,0)(1,0,0) <sub>12</sub> e estatística Ljung-Box.....	52
Figura 20 -	Valores originais, valores estimados e resíduos do modelo.....	53
Figura 21 -	Previsão pelo modelo SARIMA(2,1,0)(1,0,0) <sub>12</sub> .....	54

## LISTA DE QUADROS

Quadro 1 - Quadro de modelos concorrentes da série de admissões.....	38
Quadro 2 - Quadro de modelos concorrentes da série de demissões.....	50

## LISTA DE TABELAS

Tabela 1 -	Análise descritiva da série de admissões.....	33
Tabela 2 -	Testes de Estacionariedade ADF e KPSS da série original e primeira diferença da série de admissões.....	38
Tabela 3 -	Coeficiente do modelo SARIMA(2,1,0)(1,0,0) <sub>12</sub> da série de admissões.....	39
Tabela 4 -	Teste de heterocedasticidade condicional residual dos resíduos quadráticos para o Modelo SARIMA(2,1,0)(1,0,0) <sub>12</sub> – (ARCH) da série de admissões.....	41
Tabela 5 -	Previsão de 16 meses pelo modelo SARIMA(2,1,0)(1,0,0) <sub>12</sub> .....	43
Tabela 6 -	Análise descritiva da série de demissões.....	44
Tabela 7 -	Testes de Estacionariedade ADF e KPSS da série original e primeira diferença da série de demissões.....	49
Tabela 8 -	Coeficientes do modelo SARIMA(2,1,0)(1,0,0) <sub>12</sub> da série de demissões.....	51
Tabela 9 -	Teste de heterocedasticidade condicional residual, dos resíduos quadráticos para o modelo SARIMA(2,1,0)(1,0,0) <sub>12</sub> - (ARCH) da série de demissões.....	53
Tabela 10 -	Previsão 16 meses pelo modelo SARIMA(2,1,0)(1,0,0) <sub>12</sub> .....	55

## LISTA DE SIGLAS

AC	Autocorrelação
ACP	Autocorrelação Parcial
ADF	Dickey-Fuller Aumentado
AIC	Critério de Informação Akaike
AR	Autoregressivo
ARCH	Autoregressivo com Heterocedasticidade Condicional
ARCH-LM	Autoregressivo com Heterocedasticidade Condicional Multiplicador de Lagrange
ARFIMA	Autoregressivo Fracionário Integrado de Médias Móveis
ARIMA	Autoregressivo Integrado de Médias Móveis
ARMA	Autoregressivo de Médias Móveis
BIC	Critério de Informação Bayesiano
CNI	Confederação Nacional da Indústria
DF	Dickey-Fuller
FAC	Função de Autocorrelação
FACP	Função de Autocorrelação Parcial
IBGE	Instituto Brasileiro de Geografia e Estatística
IPEA	Instituto de Pesquisa e Economia Aplicada
JB	Jarque-Bera
KPSS	Kwiatkowski-Phillips-Schmidt-Shin
MA	Médias Móveis
MTE	Ministério do Trabalho e Emprego
OIT	Organização Internacional do Trabalho
PP	Phillips-Perron
RB	Ruído Branco
SARIMA	Autoregressivo Integrado de Médias Móveis Sazonal

# SUMÁRIO

<b>1 INTRODUÇÃO</b> .....	12
<b>1.1 Tema de pesquisa</b> .....	13
<b>1.2 Justificativa e importância do trabalho</b> .....	13
<b>1.3 Problema de pesquisa</b> .....	13
<b>1.4 Objetivos</b> .....	14
1.4.1 Objetivo geral.....	14
1.4.2 Objetivos específicos.....	14
<b>1.5 Delimitação do tema</b> .....	14
<b>1.6 Estrutura do trabalho</b> .....	15
<b>2 REFERENCIAL TEÓRICO</b> .....	16
<b>2.1 Empregos</b> .....	16
<b>2.2 Análise de Séries Temporais</b> .....	17
<b>2.3 Metodologia Box e Jenkins</b> .....	18
<b>2.4 Modelos de séries temporais</b> .....	21
2.4.1 Modelos autorregressivos AR(p) .....	21
2.4.2 Modelos de médias móveis MA(q) .....	21
2.4.3 Modelos Autorregressivos e de Médias Móveis ARMA(p,q).....	22
2.4.4 Modelos Autorregressivos Integrado e de Médias Móveis ARIMA(p,d,q).	22
2.4.5 Modelos Autorregressivos Fracionário de Médias Móveis ARFIMA(p,d,q) .....	24
<b>2.5 Pressupostos da Análise de Séries Temporais</b> .....	25
2.5.1 Normalidade.....	25
2.5.2 Autocorrelação.....	26
2.5.3 Estacionariedade (Raiz Unitária).....	26
2.5.4 Heterocedasticidade Condicional Residual.....	27
<b>2.6 Critérios de Informação</b> .....	28
2.6.1 Critério de Informação Akaike (AIC) e Critério de Informação Bayesiano (BIC) .....	28
<b>3 METODOLOGIA</b> .....	30
<b>4 APRESENTAÇÃO E ANÁLISE DE RESULTADOS</b> .....	32
<b>4.1 Análise da série de admissões</b> .....	32
4.1.1 Análises descritiva, gráfica e testes de estacionariedade.....	32
4.1.2 Análise do melhor modelo e quadro de modelos concorrentes.....	38
<b>4.2 Análise da série de demissões</b> .....	44
4.2.1 Análise descritiva, gráfica e testes de estacionariedade.....	44
4.2.2 Análise do melhor modelo e quadro dos modelos concorrentes.....	50
<b>CONSIDERAÇÕES FINAIS</b> .....	56
<b>REFERÊNCIAS</b> .....	57

# 1 INTRODUÇÃO

A palavra emprego, da língua inglesa, teve sua origem em 1400 D.C. até o início do século XVIII, a qual fazia referência a alguma tarefa ou determinada empreitada; nunca referiu-se a um papel ou a uma posição numa organização. A partir do século XIX, passou a ser entendida como o trabalho realizado nas fábricas ou nas nações em que o capitalismo estava em ascensão na fase de industrialização (WOLEK, 2008).

O termo emprego, em sua conotação moderna, reflete a relação entre o indivíduo e a organização onde uma tarefa produtiva é realizada, pela qual aquele que recebe rendimentos, e cujos bens ou serviços são passíveis de transações no mercado (SOUZA, 1986; WOLEK, 2008).

A temática do emprego é sempre muito discutida, pois este fator é uma das maiores influencias para que uma economia seja desenvolvida ou esteja em processo desenvolvimento. A quantidade de admissões traz a tona o andamento do mercado, abertura de empresas e novas oportunidades econômicas. Por outro lado as demissões traduzem estagnação no mercado financeiro e perda econômica para o país.

Para analisar o comportamento da quantidade de admissões e demissões os dados foram organizados em observações mensais, a fim de estudar e descrever seu comportamento.

Sendo assim, no presente trabalho serão analisadas por meio de séries temporais, as variáveis admissão e demissão. (aqui tinha quantidade a moça tirou, mas acho que está certo)

De acordo com a teoria de Box, Jenkins e Reinsel (1994), a análise de séries temporais tem como objetivos: analisar as séries, modelar e a realização da previsão (ta meio estranho a frase, mas como é citação). Essa metodologia permite que valores futuros de uma série sejam previstos tendo como base seus valores passados. A previsão é realizada por meio da correlação temporal entre os valores existentes na série.

## **1.1 Tema de pesquisa**

O tema desta pesquisa consiste em analisar a evolução dos empregos no Brasil, para isso utilizou-se a metodologia Box e Jenkins. Com este intuito, foram consideradas nesse estudo duas variáveis relacionadas ao emprego, número de admissões e número de demissões no período de maio de 1999 a agosto de 2014, com isso foi possível realizar uma análise comportamental e de previsão para as séries em estudo.

## **1.2 Justificativa e importância do trabalho**

O mercado de trabalho no Brasil tem apresentado, nas últimas décadas, intensa variação na taxa de participação de pessoas economicamente ativas (de 15 a 64 anos que trabalha ou procura emprego), em relação à criação de novos postos de trabalho, no perfil dos trabalhadores (em termos de sexo, idade, escolaridade e qualificação) e em diversos aspectos relacionados a qualidade dos empregos e condições de contratação (CEPAL; PNUD; OIT, 2013).

Algumas variáveis têm afetado o mercado de trabalho de forma direta tal como o desemprego que é um problema macroeconômico. Para a maioria das pessoas, a perda de um emprego significa um padrão de vida reduzido e uma angústia psicológica. Não causa surpresa o fato de que o desemprego seja um tópico frequente em debates políticos, e que frequentemente declarem que as políticas econômicas propostas por eles auxiliam na criação de novos postos de trabalho (MANKIW, 2011).

Dada à importância da quantidade de empregos disponíveis em um país, para seu desenvolvimento econômico, justifica-se analisar as variáveis relacionadas com este tema. Com base na economia brasileira e suas oscilações em relação aos postos de trabalho, analisa-se as séries de admissões e demissões, a fim de compreender o comportamento e prever essas variações ao longo do tempo e do contexto econômico, para que se necessário, sejam tomadas novas estratégias na criação de novos postos de trabalho.

### **1.3 Problema de pesquisa**

O problema de pesquisa é analisar as variáveis referentes a admissões e demissões, e prever a quantidade de empregos, no Brasil, no período de maio de 1999 até agosto de 2014, utilizando para isso a metodologia Box e Jenkins, por meio de modelos lineares. Assim, será possível determinar quais as épocas mais propícias a admissões e a demissões? Qual a tendência a oportunidades de emprego?

Logo, com a aplicação da técnica exposta acima, será viável responder a essas questões.

### **1.4 Objetivos**

#### **1.4.1 Objetivo geral**

Identificar mediante análise de séries temporais, quais são as épocas do ano mais propícias para admissões e demissões, no Brasil, por meio de modelos ARIMA. Dessa forma torna-se possível explicar e prever, quais os meses que possuem maiores ofertas de postos de trabalho, bem como os com maiores índice de desemprego no país.

#### **1.4.2 Objetivos específicos**

- Realizar uma análise descritiva das variáveis em estudo buscando identificar algumas características específicas;
- Estimar os parâmetros, utilizando a metodologia Box e Jenkins para analisar o comportamento das séries de emprego: admissões e demissões;
- Analisar e prever o comportamento das séries em estudo.

### **1.5 Delimitação do tema**

As variáveis analisadas admissão e demissão correspondem ao período de maio de 1999 a agosto de 2014, no Brasil, sendo obtidas junto ao IPEA (Instituto de Pesquisa e Economia Aplicada). Os modelos utilizados na análise são modelos

lineares da classe geral ARIMA com sazonalidade. Torna-se pertinente salientar que os modelos de previsões encontrados neste trabalho serão capazes de fornecer o comportamento dos dados mediante do modelo mais adequado encontrado em cada série de estudo.

## **1.6 Estrutura do trabalho**

Esse trabalho estrutura-se em cinco capítulos. No Capítulo 1, apresenta-se a introdução, delimitação do tema da pesquisa, justificativa e a importância do trabalho, bem como é exposto o problema em estudo. Consta também os objetivos da pesquisa, com a delimitação do tema e a estrutura do trabalho.

No capítulo 2 encontra-se a revisão bibliográfica sobre as séries relacionadas as variáveis de empregos, incluindo pontos importantes da metodologia de Box e Jenkins para o embasamento da análise de séries temporais.

No capítulo 3 é apresentada a metodologia da pesquisa, em que são expostas as etapas necessárias para modelagem das variáveis em estudo.

No capítulo 4 constam os resultados e discussões das análises feitas mediante os modelos SARIMA(2,1,0)(1,0,0)<sub>12</sub> para série de admissões e SARIMA(2,1,0)(1,0,0)<sub>12</sub> para série de demissões.

Pertencentes ao capítulo 5 constam as considerações finais e sugestões de trabalhos futuros.

## **2 REFERENCIAL TEÓRICO**

A seguir será apresentado o embasamento teórico para o desenvolvimento desta pesquisa.

### **2.1 Empregos**

O relatório da CEPAL/PNUD/OIT (2013) declarou que o mercado de trabalho no Brasil, entre o início dos anos 90 e 2006, caracterizou-se pela heterogeneidade e por um elevado déficit de trabalho condizente aos padrões considerados pela Organização Internacional do Trabalho (OIT), e tem como principais razões as altas taxas de desemprego e de informalidade, resultando em baixo grau de proteção social e inadequada inserção dos trabalhadores no mercado de trabalho.

Dessa forma, não apenas o desemprego é um grave problema no Brasil, mas também a insuficiente qualidade das ocupações. Assim, a taxa de desocupação não é capaz de indicar, isoladamente, todo o grau de precariedade da inserção dos trabalhadores no mercado (CEPAL; PNUD; OIT, 2013).

### **Admissões**

O conceito de admissões vem de um compromisso firmado por meio do contrato de trabalho, estabelecido entre empregado e empregador, no qual o colaborador compromete-se a prestar serviço não eventual para o empregador mediante recebimento de salário (VIANNA, 2014).

### **Demissões**

Demissões é um conceito que se refere à renúncia ou ao abandono de um emprego, de um cargo, de uma comissão, etc. Conforme Nascimento (2009) a demissão ocorre por meio da rescisão do contrato de trabalho, sendo esse o termo utilizado para indicar o fim da relação de emprego.

Cabe ao empregador contratar e também demitir o funcionário. A demissão não é necessariamente uma punição, nem mesmo depende da aceitação do empregado (NASCIMENTO, 2009).

## 2.2 Análise de Séries Temporais

Uma série temporal é um conjunto de observações em uma sequência de tempo se referindo a um fenômeno aleatório (BAYER, 2008), sendo elas compostas por quatro elementos: a tendência (evidencia o sentido do deslocamento da série ao longo do tempo); o ciclo (periodicidade do movimento da série ao longo dos anos); a sazonalidade (picos repetitivos em intervalos iguais de tempo dentro da série, geralmente inferior a um ano); e o erro aleatório (corresponde a variabilidade intrínseca dos dados, não podendo ser modelado). Em suma, o conceito de série temporal está relacionado a um conjunto de observações de uma determinada variável feita em períodos sucessivos de tempo ao longo de um determinado intervalo.

De acordo com Morettin e Tolo (2006), Matos (2000), os objetivos da análise de uma série temporal, observada nos instantes  $t$  de tempo, são:

- (a) Investigar o mecanismo gerador da série temporal; como por exemplo, analisar uma série de altura de ondas, surgindo o questionamento de como as ondas foram geradas;
- (b) Fazer previsões de valores futuros de uma série; estas previsões podem ser de curto prazo, como uma série de vendas, de produção de estoque, ou de longo prazo, como séries populacionais, etc.;
- (c) Descrever o comportamento da série; aqui, a construção do gráfico, a verificação da existência de tendências, ciclos ou variações sazonais, construção de histogramas e diagramas de dispersão, etc.; podem ser ferramentas úteis a serem analisadas;
- (d) Procurar periodicidades relevantes nos dados; neste caso, pode ser de grande valia o uso da análise espectral.

Existem dois principais aspectos a serem considerados no estudo de séries temporais: análise e modelagem. A primeira condição para a análise e modelagem de séries temporais é a estacionariedade.

A detecção da existência ou não de estacionariedade em uma série pode ser feita a partir da análise gráfica, em busca de padrões, ou realizando testes estatísticos de raiz unitária. Séries de tempo não estacionárias geram resultados distorcidos, mas podem ser transformadas em estacionárias através do uso de diferenças (MATOS, 2000).

Conforme Matos (2000), um processo estocástico é estacionário, quando sua média e sua variância são constantes ao longo do tempo e quando o valor da covariância entre os dois períodos de tempo depende apenas da defasagem entre eles. Assim, de acordo com as equações escritas a seguir, pode-se observar:

- (i)  $E[y_t] = [y_{t-s}] = \mu$  , com  $t \neq s$ , média constante ao longo do tempo;
- (ii)  $E[(y_t - \mu)^2] = E[(y_{t-s} - \mu)^2] = \sigma_y^2$ , variância constante;
- (iii)  $E[(y_t - \mu)(y_{t-s} - \mu)] = E[(y_{t-s} - \mu)(y_{t-j-s} - \mu)] = \gamma_s$ , covariância constante.

Dessa maneira, usam-se testes específicos para se testar a estacionariedade de uma série, tais como, Teste Dickey-Fuller (DF) (1979), Teste Dickey-Fuller Aumentado (ADF) (1984), Teste Kwiatkowski-Phillips-Schmidt-Shin (KPSS) (1992), Teste Philips-Perron (PP) (1998).

Para fins deste trabalho, será utilizado o teste ADF. E como um complemento ao teste será utilizado o teste KPSS.

### 2.3 Metodologia Box e Jenkins

Uma das técnicas quantitativas mais difundidas na década de 70 é a metodologia de Box e Jenkins, que parte da ideia de que cada valor da série (temporal) pode ser explicado por valores prévios, a partir do uso da estrutura de correlação temporal que, geralmente, há entre os valores da série (BOX; JENKINS, 1970). Estes modelos têm sido amplamente utilizados para a modelagem e previsão em aplicações médicas, ambientais, financeiras e de engenharia (WERNER; RIBEIRO, 2003; MORETTIN; TOLOI, 2006; PEREIRA; PAIS; SALES, 1986; FAVA, 2000).

A metodologia de Box e Jenkins tem sua modelagem baseada em um ciclo iterativo, em que a escolha da estrutura do modelo é a partir dos dados e considera as seguintes etapas:

- 1) Na especificação, avalia-se uma classe geral de modelos;
- 2) A fase de identificação é realizada com base na análise de autocorrelações, autocorrelações parciais e outros critérios;
- 3) Após, identificado o modelo, estima-se os parâmetros dos modelos;
- 4) E por fim, a verificação ou diagnóstico do modelo ajustado, por meio de uma análise de resíduos, para certificar-se de que o modelo é adequado para a finalidade da técnica, a previsão.

Caso o modelo não seja adequado, repete-se o ciclo, voltando para a fase inicial de identificação.

A Modelagem de Box e Jenkins é uma das técnicas mais utilizadas para a previsão comportamental de variáveis, empregando modelos univariados na econometria contemporânea. A construção de modelos de séries univariados é baseada na teoria de que existe uma grande quantidade de informação presente na série de dados, sendo esses dados capazes de fornecer estimativas sobre o comportamento futuro da variável, uma previsão. Assim, será apenas o comportamento da variável que responderá pela sua dinâmica futura. Este é conhecido, na literatura, como o modelo autorregressivo integrado e de médias móveis (ARIMA), ou definido simplesmente por modelo ARIMA (BOX; JENKINS, 1970).

A Figura 1 apresenta um organograma com todas as etapas da metodologia de Box e Jenkins.

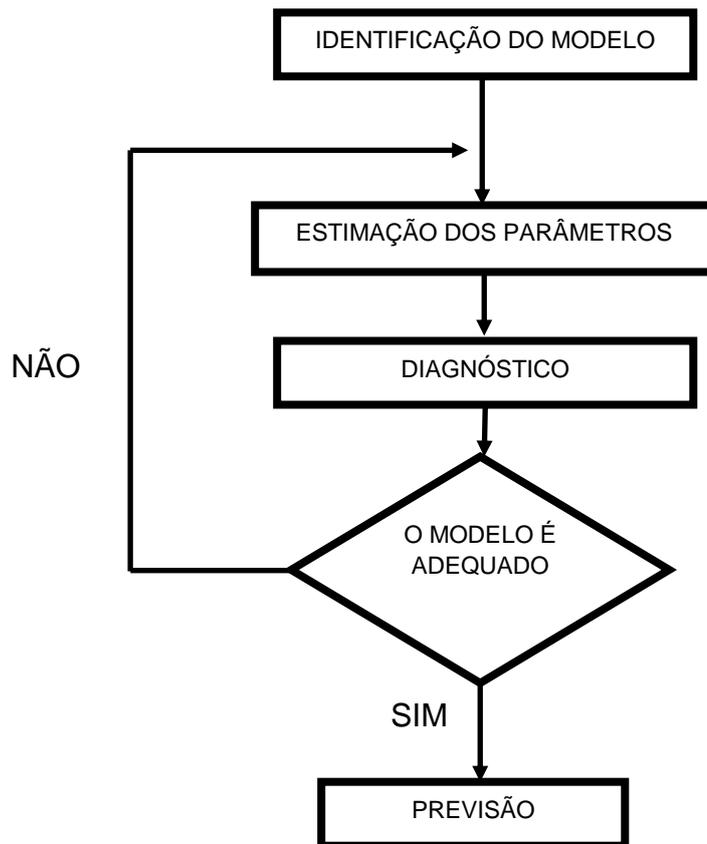


Figura 1 - Organograma adaptado da metodologia Box e Jenkins.  
Fonte: Souza (2011).

De acordo com o organograma apresentado na Figura 1, observa-se o detalhamento dos passos da metodologia Box e Jenkins. Essa metodologia só é aplicada após identificação de alguns requisitos fundamentais na série para que seja possível aplicar a modelagem. A primeira atividade a se realizar é a identificação do modelo, seguindo com a estimação dos parâmetros desse modelo. Após os parâmetros serem estimados, busca-se identificar se os resíduos do modelo possuem comportamento ruído branco (RB) para que o modelo seja adequado. Caso não seja adequado, volta-se para a etapa de estimação onde uma nova equação e novos parâmetros serão encontrados para a série. Essa sequência se repete até a obtenção de modelos que estejam dentro dos pressupostos exigidos pela metodologia, só assim, após escolher o melhor modelo, pode-se realizar a previsão.

## 2.4 Modelos de séries temporais

Os modelos de séries temporais são dados pelas especificações de processos autorregressivos (AR), processos de médias móveis (MA), processos autorregressivos e médias móveis (ARMA) ou ainda modelos com processos mistos (ARIMA) (JUNIOR et al., 2013).

### 2.4.1 Modelos autorregressivos AR(p)

O modelo AR(p), em que  $Z_t$  é descrito por seus valores passados e por seu RB  $a_t$ , sendo que  $a_t \sim RB(0, \sigma^2)$ . Em que sua versão mais simples é aquela em que  $Z_t$  depende somente de  $Z_{t-1}$  e de  $a_t$ . Assim caracteriza-se o modelo autorregressivo de ordem 1, o qual é indicado compactamente por AR(1).

Denotam-se os modelos autorregressivos de ordem  $p$ :

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + a_t, \quad (1)$$

em que  $p$  representa o número de defasagens de  $Z_t$ . Sendo que  $\phi$  é o coeficiente autorregressivo que acompanha o instante de  $Z_t$ ; e  $a_t$  é o erro aleatório do modelo. A forma mais simples de um processo autorregressivo é a que contém apenas uma defasagem, ou seja,  $p = 1$ . Uma vez especificado o número de defasagens, pode-se usar o método de estimação de mínimos quadrados para estimar os parâmetros do modelo AR (MATOS, 2000).

### 2.4.2 Modelos de médias móveis MA(q)

Conforme Matos (2000), nos modelos de médias móveis, os valores de  $Z_t$  são resultados de uma soma ponderada, semelhante a uma média, dos valores mais recentes dos erros. O modelo de médias móveis, expressa os valores correntes da série  $Z_t$  como função linear dos erros passados não correlacionados até um número limitado de defasagens. O modelo MA com  $q$  defasagens, é definido como MA(q), é escrito da seguinte forma:

$$Z_t = \theta_0 + a_t + \theta_1 a_{t-1} + \theta_2 a_{t-2} + \dots + \theta_q a_{t-q}, \quad (2)$$

em que  $a_t$  são os erros ou resíduos aleatórios não correlacionados, não observáveis, que possuem média zero e variância constante. E  $\theta$  é o coeficiente de médias móveis.

Os modelos AR e MA são fáceis de identificar, pois suas funções de autocorrelações e autocorrelações parciais apresentam características definidas como estacionariedade e invertibilidade dos modelos Morettin e Tolo (2006).

#### 2.4.3 Modelos Autorregressivos e de Médias Móveis ARMA(p,q)

Alguns tipos de séries apresentam a necessidade de utilizar uma modelagem composta, em que se utilizam os dois modelos em conjunto, o AR e o MA, pois em separado eles acabam não se tornando adequados para analisar as mesmas. Dependendo do comportamento dessas séries, os modelos compostos, podem resultar em coeficientes com valores mais baixos, tendo também uma previsão mais próxima do real. Esses modelos são denominados modelos ARMA(p,q).

Conforme Matos (2000), o modelo ARMA é tratado como uma série  $Z_t$  e considera suas duas primeiras diferenças  $Z_t = Z_t - Z_{t-1}$ ,  $p$  defasagens para essa variável e  $q$ , para os erros aleatórios, tem-se o modelo ARMA(p,q). Esse modelo pode ser escrito da seguinte forma:

$$Z_t = \phi_0 + \phi_1 Z_{t-1} + \dots + \phi_p Z_{t-p} + a_t + \theta_1 a_{t-1} + \theta_2 a_{t-2} + \dots + \theta_q a_{t-q}. \quad (3)$$

#### 2.4.4 Modelos Autorregressivos Integrado e de Médias Móveis ARIMA(p,d,q)

Os modelos autorregressivos integrados de médias móveis são modelos compostos pelos AR e MA, possuindo ainda um componente de integração I, que mostra o número de diferenças necessárias para que a série em estudo se torne estacionária.

Para Morettin e Toloí (2006), se  $W_t = \Delta^d Z_t$  ( $W_t$ ) representa a série diferenciada entre dois instantes de tempo de  $Z_t$ , caso essa série seja estacionária, pode-se representar  $W_t$  por um modelo ARMA(p,q), ou seja,

$$\phi(B)W_t = \theta(B)a_t \quad (4)$$

Se  $W_t$  for uma diferença de  $Z_t$ , então  $Z_t$  é uma integral de  $W_t$ , daí diz-se que  $Z_t$  segue um modelo autorregressivo, integrado, de médias móveis, ou modelo ARIMA,

$$\phi(B)\Delta^d Z_t = \theta(B)a_t \quad (5)$$

de ordem (p,d,q) e escreve-se ARIMA(p,d,q), sendo p e q as ordens de  $\phi(B)$  e  $\theta(B)$ ,  $d = 1$ , respectivamente (MORETTIN; TOLOI, 2006).

Na equação 7 todas as raízes de  $\phi(B)$  devem estar fora do círculo unitário, sendo esta a condição para que o modelo encontrado seja não explosivo.

$$\phi(B)Z_t = \theta(B)a_t \quad (6)$$

em que  $\phi(B)$  é um operador autorregressivo, de ordem  $p + d$ , com  $d$  raízes iguais a um (sobre o círculo unitário) e as restantes  $p$  fora do círculo unitário, ou seja,

$$\phi(B) = \phi(B)\Delta^d = \phi(B)(1 - B)^d \quad (7)$$

Desta forma, o modelo da equação 8, supõe que a d-ésima diferença da série  $Z_t$  pode ser representada por um modelo ARIMA. Em grande parte dos casos usuais,  $d = 1$  ou  $d = 2$ , que correspondem a dois casos comuns de não-estacionariedade (MORETTIN; TOLOI, 2006):

- a) Séries não-estacionárias quanto ao nível: oscilam ao redor de um nível médio durante algum tempo e depois passam para outro nível temporário. Para que se tornem estacionárias é suficiente tomar apenas uma diferença;

- b) Séries não-estacionárias quanto à inclinação: oscilam em uma direção por um tempo e depois mudam para outra direção, também temporária. Para estacionarizá-las é necessário uma segunda diferença.

#### 2.4.5 Modelos Autorregressivos Fracionário de Médias Móveis ARFIMA(p,d,q)

A partir da década de 80, Granger e Joyeux (1980) e ainda Hosking (1984) propõem uma generalização da modelagem em ARIMA, relação ao parâmetro  $d$ , podendo assumir não só valores inteiros, mas também representar diferenciações fracionárias. Modelos com esta propriedade permitem estudar séries com características de longas dependências temporais. Estes modelos intitulam-se ARFIMA ( $p,d,q$ ), onde F significa *fractional* (TREVISAN; SOUZA; SOUZA, 2000).

O modelo ARFIMA(p,d,q) - (*Auto-Regressive-Fractionally-Integrated-Moving-Average*), diferencia-se, pois sua ordem de integração  $d$  varia entre  $(-\frac{1}{2}, +\frac{1}{2})$ . Para Silva, Lopes e Rebelo (2011), esses modelos ajudam na resolução de um problema amplamente conhecido, o baixo poder dos tradicionais testes de raiz unitária.

Bayer (2008) ainda complementa que  $\{Z_t\}$  é um processo autorregressivo fracionário de médias móveis se for estacionário e satisfazer a equação:

$$\phi(B)(1 - B)^d Z_t = \theta(B)a_t, \quad (8)$$

Em que  $a_t$  é RB, com média zero e variância  $\sigma^2$ , e  $\phi(B)$  e  $\theta(B)$  são polinômios em  $B$  de graus  $p$  e  $q$ , respectivamente, de forma que  $B$  é o operador retroativo.

As condições de estacionariedade do modelo ARFIMA ( $p,d,q$ ) são  $d < 0,5$  e todas as raízes de  $\phi(B) = 0$  devem estar fora do círculo unitário. Assim como, as condições de invertibilidade do modelo, como sendo  $d > -0,5$  e todas as raízes de  $\theta(B) = 0$  também devem estar fora do círculo unitário (HOSKING, 1981).

## 2.5 Pressupostos da Análise de Séries Temporais

### 2.5.1 Normalidade

#### Teste de Normalidade Jarque-Bera

Estatística de operacionalização simples, dependendo apenas dos coeficientes de assimetria e curtose. Possui poder elevado com menor grau de erro na identificação de presença de normalidade.

Conforme Souza (2011), a estatística de Jarque-Bera é mensurada pela equação abaixo e segue uma distribuição de Qui-Quadrado ( $\chi^2$ ) com dois graus de liberdade:

$$JB = N \left[ \frac{A_3^2}{6} + \frac{(K_4-3)^2}{24} \right] \sim \chi_{2,\alpha}^2 \quad (9)$$

Em que o  $A_3$  é o coeficiente de assimetria,  $K_4$  é o coeficiente de curtose e  $N$  é o tamanho da amostra.

Hipóteses do teste são:

$H_0$ : Assimetria = Zero e Curtose = 3 (normalidade)

$H_1$ : Assimetria  $\neq$  Zero e Curtose  $\neq$  3 (não normalidade)

Regra de decisão do Teste:

p-valor  $>$   $\alpha$  - não existe evidência suficiente para rejeitar a hipótese nula de normalidade.

Este teste serve para verificar se a série segue uma distribuição normal, mensurando a diferença entre os coeficientes de assimetria e curtose da série com a distribuição normal. Quando assimetria e curtose são elevadas, a curva em forma de sino que caracteriza a distribuição normal fica muito irregular e a expressão de Jarque-Bera terá um valor maior que o nível de significância, indicando não-normalidade na distribuição dos dados.

## 2.5.2 Autocorrelação

### Teste de Ljung-Box

A estatística de Ljung-Box (1978) tem o objetivo de identificar a existência de autocorrelação entre os resíduos da série analisada. A não existência dessa

autocorrelação, mostra que os resíduos tem comportamento de RB e que possuem média zero e variância constante. Para séries temporais os resíduos devem ter comportamento de RB, do contrário, o modelo que não possuir essa característica é descartado.

Teste proposto por Ljung e Box (1978) em que sua estatística é dada pela equação:

$$Q(K) = n(n + 2) \sum_{k=1}^h \frac{\hat{r}_k^2}{(n-K)}, \quad (10)$$

em que  $\hat{r}_k^2$  significa a autocorrelação no *lag* K,  $n$  representa o número de observações e  $h$  significa o número de *lag*'s que serão testados, os quais seguem uma distribuição de Qui-Quadrado com  $p$  graus de liberdade,  $\chi_{2,p}^2$ .

As hipóteses do teste são:

$H_0$ : os resíduos são i.i.d.

$H_1$ : os resíduos não são i.i.d.

### 2.5.3 Estacionariedade (Raiz Unitária)

#### Teste Dickey-Fuller Aumentado (ADF)

Os testes de raiz unitária consistem em avaliar a presença de raízes dentro do círculo unitário.

Existe um procedimento específico para a realização desse teste em uma série  $Z_t$ , que se baseia em regredir a série  $Z_t$  contra seus valores defasados de um período  $Z_{t-1}$ . Na sequência da metodologia, testa-se a significância do parâmetro de  $Z_{t-1}$ .

Existem três tipos de relação entre  $Z_t$  e  $Z_{t-1}$ , que são:

- Equação sem intercepto e sem tendência ( $Z_t = \phi Z_{t-1} + a_t$ );
- Equação com intercepto e sem tendência ( $Z_t = \alpha + \phi Z_{t-1} + a_t$ ); e
- Equação com intercepto e com tendência ( $Z_t = \beta + \delta T + a_t$ ).

Nas quais  $a_t$  é RB, o que significa que possui média zero, variância constante e ausência de autocorrelação serial.

Considerando que  $\phi = 0$ , as equações acabam não dependendo de  $Z_{t-1}$ , tornando-as apenas dependente da tendência ( $T$ ), o que indica que  $Z_t$  segue um passeio aleatório (NOTINI, 2009).

Uma série é não estacionária se possui uma raiz unitária, ou seja, quando a hipótese de que  $\phi = 1$  for aceita. As hipóteses pertencentes ao Teste ADF são:

$H_0$ : tem raiz unitária (não é estacionária)

$H_1$ : não tem raiz unitária (é estacionária).

### **Teste KPSS**

Este teste também serve para identificar presença de estacionariedade na série, corroborando com o Teste ADF.

As hipóteses do teste KPSS são as seguintes:

$H_0$ : A série é estacionária.

$H_1$ : A série não é estacionária.

Com a aplicação de ambos os testes, KPSS e ADF, é possível uma conclusão mais precisa, uma vez que se pode distinguir entre séries com comportamento estacionário, séries com comportamento não estacionário, e séries em que os dados não são suficientemente informativos para saber sobre a estacionariedade.

### **2.5.4 Heterocedasticidade Condicional Residual**

A heterocedasticidade condicional acontece quando a variância dos resíduos, ou erros, não é constante. Para que se teste a homocedasticidade dos resíduos se fez necessária a utilização de um teste ARCH que se baseia na Estatística F.

### **Estatística F**

Conforme Morettin e Tolo (2006), o Teste F é utilizado para pequenas amostras e baseia-se na seguinte estatística:

$$F = \frac{(SQR_0 - SQR_1)/m}{SQR_1/(N - 2m - 1)} \sim F(m, N - 2m - 1) \quad (11)$$

Em que  $SQR_0 = \sum_{n=m+1}^N (r^2 - \bar{r})^2$  e  $SQR_1 = \sum_{n=m+1}^N \hat{u}_n^2$ , em que  $\bar{r}$  é a média amostral dos valores de  $r_n^2$  e  $\hat{u}_n$ , que são resíduos dos Mínimos Quadrados Ordinários (MQO) referente à regressão da equação 11. Se o valor de F for significativo, diz-se que há heterocedasticidade condicional na série.

$H_0$ : Todos os coeficientes de regressão são iguais à zero.

$H_1$ : Os coeficientes de regressão são diferentes de zero.

## 2.6 Critérios de Informação

Para Bueno (2008), o critério de informação é uma forma de encontrar o número ideal de parâmetros para um modelo e a qualidade do ajuste realizado. O critério de informação associa uma penalidade para balancear a redução de erros, devido ao aumento de regressores (parâmetros) que causam a diminuição à soma dos resíduos. Se a penalidade for menor que a redução da soma dos resíduos, o regressor deve ser adicionado ao modelo. Em caso de a penalidade ser maior que a diminuição da soma, esse regressor deve ser descartado, pois estará prejudicando o modelo (BUENO, 2008).

### 2.6.1 Critério de Informação Akaike (AIC) e Critério de Informação Bayesiano (BIC)

A estatística de *Akaike*, e a estatística de *Schwartz* ou critério bayesiano são dadas da seguinte maneira:

$$AIC(k) = n \log \sigma^2 + 2k \quad (12)$$

$$BIC(k) = n \log \sigma^2 + k \log n \quad (13)$$

Dessa forma,  $k$  corresponde ao número de parâmetros estimados, o  $n$  é o tamanho da amostra e o  $\sigma^2$  é a variância (ALMEIDA, 2010).

Na sequencia deste estudo, é apresentada a metodologia, descreve-se etapa por etapa do estudo e sua principal colaboração no trabalho.

### 3 METODOLOGIA

Neste capítulo apresenta-se a metodologia utilizada para modelar e prever as séries de admissões e demissões.

O conjunto de dados considerado neste estudo corresponde ao período de maio de 1999 a agosto de 2014, sendo que as observações que irão compor a amostra correspondem ao número total de pessoas que foram admitidas e que foram demitidas em cada um dos 182 meses de coleta, para cada série analisada. Estes dados foram obtidos a partir do site oficial do Instituto de Pesquisa Econômica Aplicada (IPEA) - [www.ipeadata.gov.br](http://www.ipeadata.gov.br).

A metodologia proposta neste trabalho foi desenvolvida nas seguintes etapas:

- a) Realizou-se uma análise descritiva dos dados, para verificar as características específicas dos mesmos. Desta forma torna-se possível verificar se no decorrer do período analisado houve alguma mudança abrupta;
- b) Após a análise descritiva, fez-se o gráfico com cada série original, de modo a verificar se as mesmas possuíam tendência, sazonalidade, ciclo e oscilações abruptas, com isso é possível verificar se as mesmas são estacionárias. Caso não sejam, aplicam-se diferenciações buscando estacionarizá-las;
- c) Em seguida gerou-se o correlograma com a FAC e FACP da série original a fim de identificar a categoria de um provável modelo e também se realizou testes de hipótese para confirmar a estacionariedade ou não-estacionariedade da série;
- d) Tendo definido o modelo a ser utilizado para modelar cada série, foram estimados seus parâmetros;
- e) Foi realizada a análise dos resíduos, para verificar se os mesmos são RB; após, também se analisou a homocedasticidade dos resíduos quadráticos. Em se tratando das séries deste estudo, não houve série com heterocedasticidade;
- f) Na sequência, verificou-se o gráfico das séries modeladas juntamente com as séries ajustadas pelo modelo escolhido, a fim de visualizar o

comportamento do mesmo. Por fim é realizada a previsão com o modelo determinado pela metodologia.

A escolha do modelo que melhor ajuste a série para a previsão, depende de uma prévia seleção de três modelos que representem essas séries. Estes modelos são denominados modelos concorrentes, e a partir dos critérios de penalização, define-se o melhor, sendo os critérios escolhidos para esse estudo, o Critério de Informação Akaike (AIC) e o Critério de Informação Bayesiano (BIC).

A partir do modelo escolhido realizaram-se as previsões. Para que fossem cumpridos todos os passos da modelagem, fez-se necessária a utilização dos softwares *Statistica 10*, *PcGive 4.0*, *Microsoft Office Excel 2010* e *EViews 8.0*.

## **4 APRESENTAÇÃO E ANÁLISE DE RESULTADOS**

Neste capítulo serão apresentados os resultados da análise do comportamento dos empregos, mais especificamente da quantidade de admissões e demissões. Por meio da modelagem ARIMA, verificou-se a necessidade de utilização de modelos lineares ou não lineares nas séries. Assim, visando observar o comportamento dessas variáveis, em escala nacional dessas séries.

### **4.1 Análise da série de admissões**

#### **4.1.1 Análises descritiva, gráfica e testes de estacionariedade**

Buscando conhecer melhor o conjunto de dados a ser analisado, foi realizada uma análise descritiva, na qual se torna possível verificar o comportamento de cada série ao longo do período. Neste trabalho, utilizam-se as medidas descritivas, tais como: média, mediana, desvio padrão e coeficiente de variação (CV).

Com o objetivo de identificar os anos em que houve maiores variações de admissões no país, na Tabela 1, apresentam-se algumas medidas descritivas, correspondentes à série de admissões.

Pela análise descritiva da Tabela 1, pode-se dizer que a média é representativa desse conjunto de dados, pois pelo coeficiente de variação no período de maio de 1999 a agosto de 2014, a variabilidade de admissões não é tão alta, ou seja, esteve abaixo de 15%. Observa-se que o valor mínimo é de 5,75 e máximo 12,85. Isso mostra que a amplitude de variabilidade no período foi de 7,1. Analisando as medidas descritivas, nesse período, também se observou um aumento da oferta média de admissões no país.

Tabela 1 - Análise descritiva da série de admissões.

Ano	Nº Meses	Média	Mediana	Mínimo	Máximo	Desvio Padrão	CV
1999	8	682.605	688.966	547.526	732.704	57.930,2	8,49
2000	12	805.678	810.073	631.029	923.681	72.460,0	8,99
2001	12	862.637	882.232	593.996	1.003.027	96.763,3	11,22
2002	12	817.698	842.330	570.959	945.874	99.734,0	12,20
2003	12	817.445	832.177	581.563	904.068	84.072,4	10,28
2004	12	941.375	972.052	725.819	1.048.597	90.039,9	9,56
2005	12	1.014.917	1.031.833	768.425	1.110.030	95.298,0	9,39
2006	12	1.069.262	1.080.069	819.288	1.165.777	87.013,3	8,14
2007	12	1.195.107	1.210.948	908.128	1.293.497	104.199,0	8,72
2008	12	1.388.278	1.442.173	887.299	1.554.571	178.366,6	12,85
2009	12	1.348.970	1.377.265	1.068.481	1.491.580	120.759,8	8,95
2010	12	1.600.404	1.621.807	1.230.563	1.820.045	156.059,8	9,75
2011	12	1.713.552	1.764.474	1.305.051	1.912.665	152.568	8,90
2012	12	1.702.670	1.736.195	1.211.216	1.881.127	169.367,2	9,95
2013	12	1.745.171	1.799.865	1.094.522	1.938.169	217.939,4	12,49
2014	8	1.797.794	1.773.023	1.639.407	1.989.181	103.416,5	5,75

Na Figura 2, apresentam-se algumas medidas descritivas anuais, no período de 1999 a 2014, sendo elas a média, a mediana e o desvio padrão.

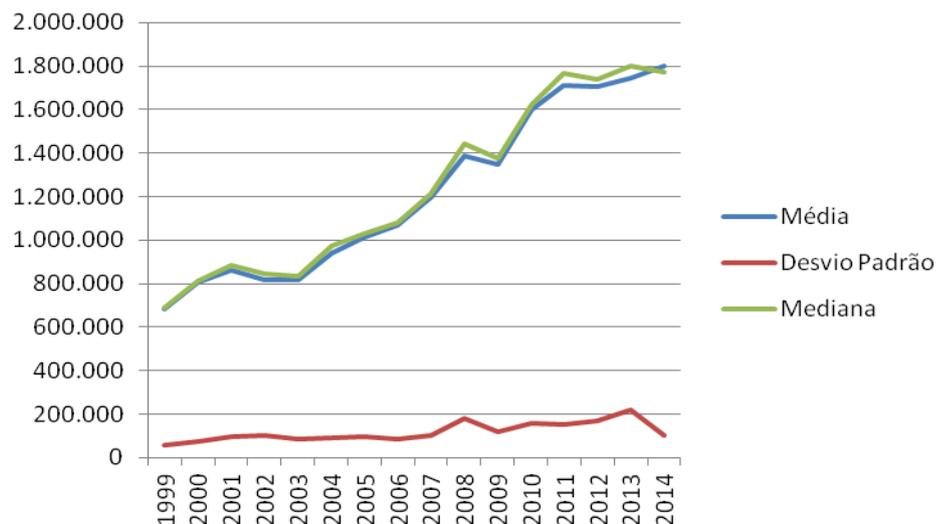


Figura 2 - Média, mediana e desvio padrão da série de admissões no período de 1999 a 2014.

É possível de observar, na Figura 2, que a média e a mediana da série de admissões possuíram um comportamento semelhante, observando-se uma pequena diferença, pela análise gráfica, no período de 2008 a 2013. Analisando também, o comportamento do desvio padrão, têm-se picos de variação nos mesmos anos que a média e a mediana.

Na Figura 3 apresenta-se o comportamento mensal da série de admissões no período de 1999 a 2014.

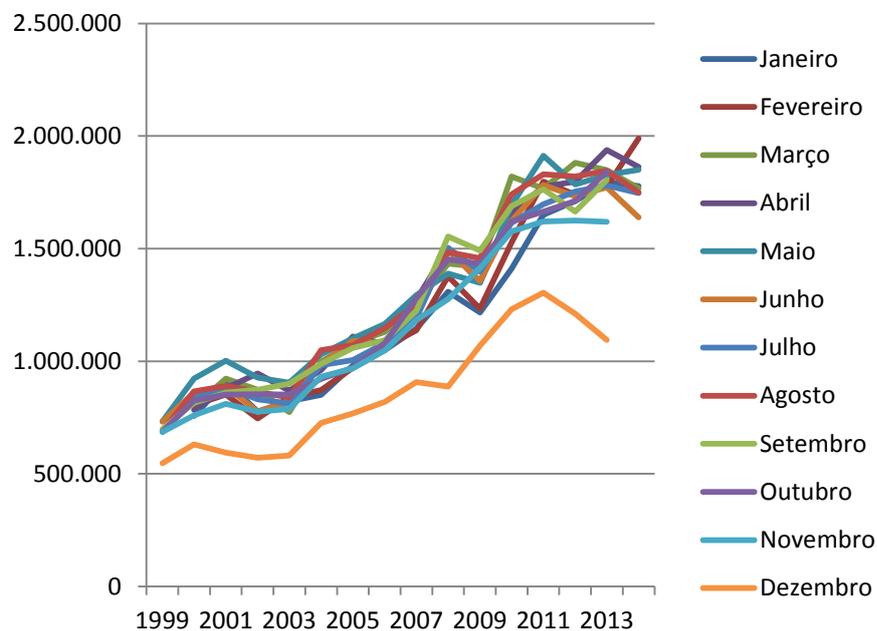


Figura 3 - Comportamento mensal da série de admissões no período de 1999 a 2014.

Pela Figura 3, verifica-se que a quantidade de admissões teve um aumento no decorrer dos anos, tendo como valor mínimo 547.526 vagas preenchidas no ano de 1999, para 1.989.181 até agosto de 2014. Também é possível observar que nos meses de dezembro teve-se uma quantidade reduzida de admissões em relação aos demais meses analisados.

Na Figura 4, apresentam-se os valores mensais da média, mediana e desvio padrão durante o período.

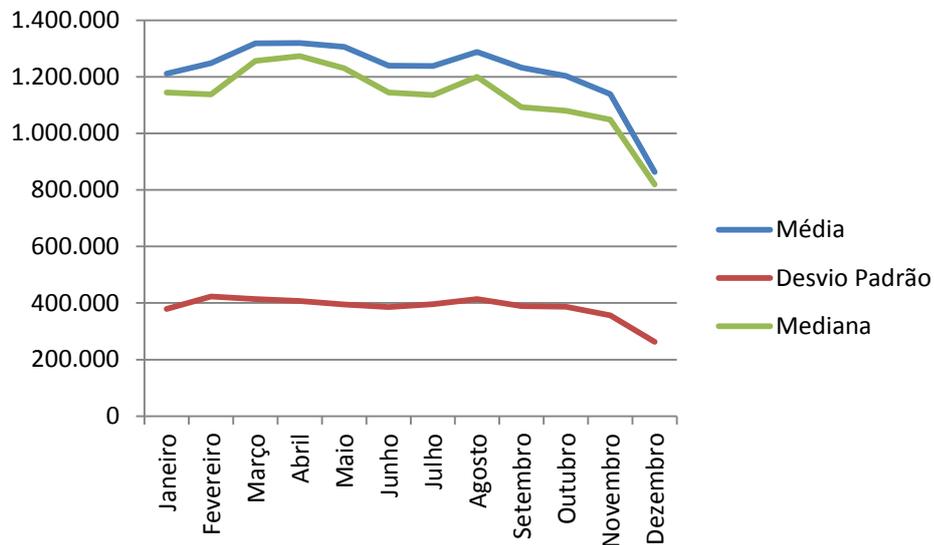


Figura 4 - Valores mensais da média, mediana e desvio padrão, da série de admissões no período de 1999 a 2014.

Na Figura 4, é possível visualizar o comportamento médio, mediano e o desvio padrão no decorrer do período. Nota-se que a quantidade média e mediana de admissões de janeiro a outubro permanece entre 1 milhão e 1,4 milhão, em que nos meses de novembro e dezembro ocorre uma queda. O mesmo acontece em relação ao desvio padrão.

Na Figura 5 apresenta-se o gráfico temporal da série de admissões. Essa Figura representa o comportamento da série original em que se verifica a não estacionariedade da série, observa-se um crescimento com picos de queda no decorrer do período.

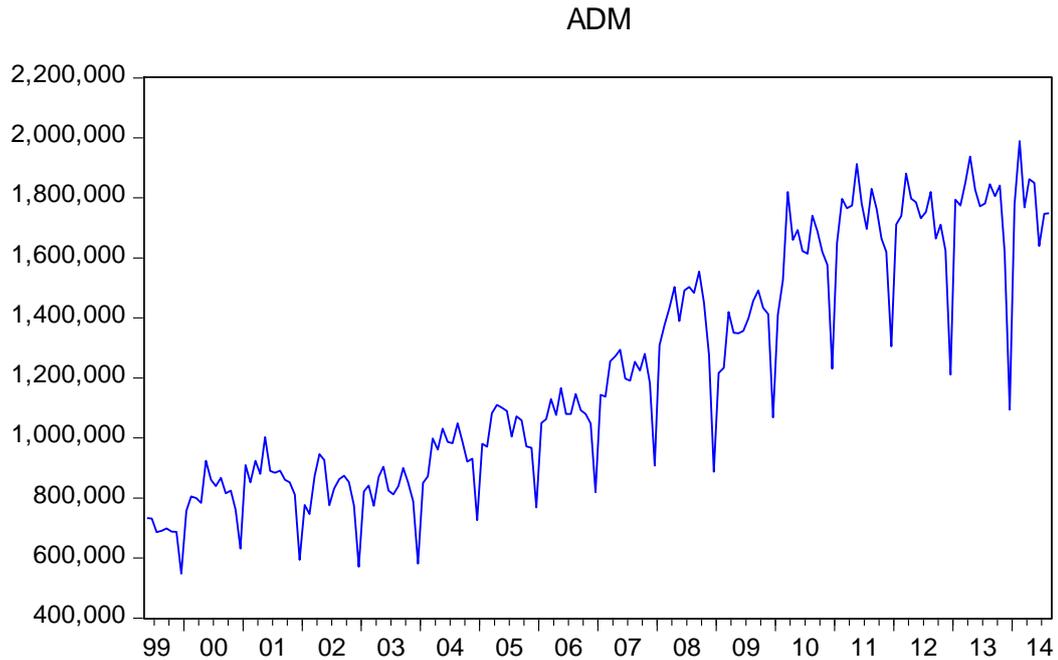


Figura 5 - Série de admissões no período de 1999 a 2014.

Na Figura 5, tem-se o comportamento da série original em que se verifica a não estacionariedade da série, observa-se um crescimento com picos de queda no decorrer do período, o que caracteriza a presença de uma possível sazonalidade.

Na Figura 6, apresenta-se a série original e a série diferenciada.

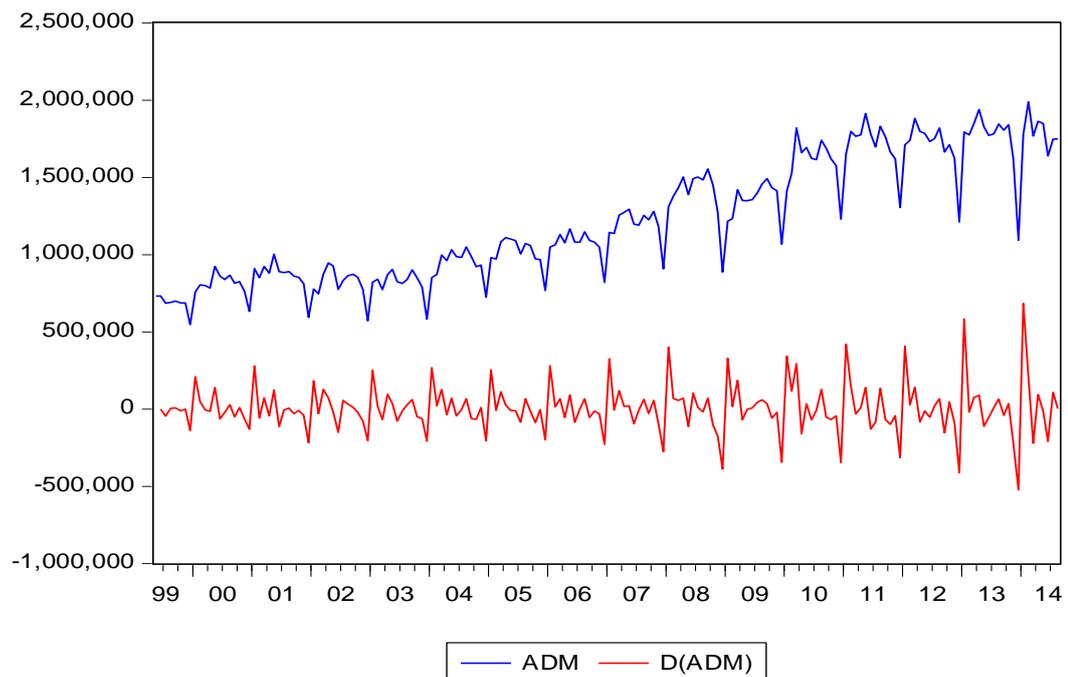


Figura 6 - Série original e diferenciada de admissões.

Na Figura 6, observa-se um comportamento estacionário na série diferenciada, sugerindo a utilização da mesma para estimar os parâmetros do modelo em estudo.

Para identificar a estacionariedade da série, também, utilizou-se as Funções de Autocorrelação (FAC) e Autocorrelação Parcial (FACP) da série de admissões, as quais são apresentadas na Figura 7, que também fornecem o possível modelo a ser estimado.

FAC	FACP	AC	ACP	Estatística Q	p-valor	
		1	0,91	0,91	155,83	0,000
		2	0,870	0,223	298,30	0,000
		3	0,842	0,131	432,23	0,000
		4	0,816	0,072	558,94	0,000
		5	0,810	0,153	684,34	0,000
		6	0,807	0,116	809,42	0,000
		7	0,777	-0,087	926,19	0,000
		8	0,753	-0,019	1036,5	0,000
		9	0,760	0,193	1149,6	0,000
		10	0,776	0,190	1268,0	0,000
		11	0,786	0,079	1390,1	0,000
		12	0,829	0,327	1526,9	0,000
		13	0,759	-0,537	1642,1	0,000
		14	0,723	-0,063	1747,3	0,000
		15	0,688	-0,220	1843,2	0,000

Figura 7 - FAC, FACP e estatística Ljung-Box da série de admissões.

Na Figura 7, observa-se que a FAC amostral apresenta um decaimento muito lento, apresentando uma longa dependência serial, o que pode ser uma indicação de um modelo fracionário. A FACP, neste caso, indica que a ordem do modelo seja AR(1), pois apenas o primeiro *lag* está fora dos limites, assim como, também identifica-se o *lag* 13 com decaimento contrário ao *lag* 1 indicando um modelo MA(1) com sazonalidade. Ainda pode-se observar que conforme o teste de Ljung-Box, seus respectivos p-valores são menores que o nível de significância de 5%, o que evidencia a presença de autocorrelação para todos os 15 *lag*'s. Pode-se considerar, dessa forma, que a série de admissões é não estacionária.

Para verificar a presença ou não de estacionariedade da série de admissões, realizam-se os seguintes testes de hipótese, ADF e KPSS na série original e primeira diferença, sendo que ambos são apresentados na Tabela 2.

Tabela 2 – Testes de Estacionariedade ADF e KPSS da série original e primeira diferença da série de admissões.

Série Admissões	ADF Estatística do Teste	p-valor ADF	Valor Crítico ADF (5%)	KPSS Estatística do Teste	Valor Crítico KPSS (5%)
Original	-0,484727	0,8900	-2,878413	1,72389	0,46300
1ª Diferença	-2,696275	0,0767		0,15486	

Analisando os resultados da Tabela 2, temos que pelo teste KPSS não se rejeita a hipótese nula de estacionariedade, na série diferenciada. Pelo teste ADF, o p-valor esteve um pouco acima de 0,05, ou seja, a série diferenciada foi considerada estacionária, pois nessa série a modelagem obteve um melhor comportamento e também considerando que ambos os testes se complementam.

#### 4.1.2 Análise do melhor modelo e quadro de modelos concorrentes

Os modelos determinados para a série foram escolhidos seguindo os preceitos obrigatórios da metodologia proposta. A seguir serão apresentados, exemplos aplicados da metodologia Box e Jenkins, e a escolha do modelo que melhor explica esse conjunto de dados.

Levando em conta a escolha de um melhor modelo para representar cada série a ser analisada, foram estimados diversos modelos concorrentes, conforme Quadro 1, e dentre esses, escolheu-se o que obteve os menores valores de AIC e BIC.

Modelo	Coefficientes	AIC	BIC
<b>SARIMA(2,1,0)(1,0,0)<sub>12</sub></b>	$\phi_1: -0,384831$ $\phi_2: -0,299625$ $\Phi: 0,951846$	<b>25,34420</b>	<b>25,39976</b>
SARIMA(1,1,1)(1,0,1) <sub>12</sub>	$\phi: 0,591082$ $\Phi: -0,188190$ $\theta: -0,889791$ $\Theta: 0,832829$	25,87117	25,94709
ARFIMA (1,d,1)	$\phi: -0,997151$ $\theta: -0,947541$ $d: 0,398086$	26,573	26,625

Quadro 1 - Quadro de modelos concorrentes da série de admissões.

O modelo que melhor ajustou a série de admissões, foi o SARIMA(2,1,0)(1,0,0)<sub>12</sub>, pois pelos critérios de informação, esse possui um menor valor do AIC.

Na Tabela 3 constam os resultados obtidos para o modelo SARIMA(2,1,0)(1,0,0)<sub>12</sub> estimado para a série de admissões.

Tabela 3 - Coeficientes do Modelo SARIMA(2,1,0)(1,0,0)<sub>12</sub> da série de admissões

Variável	Coeficiente	Desvio Padrão	Estatística t	p-valor
AR(1)	-0,384831	0,077454	-4,968508	0,0000
AR(2)	-0,299625	0,077955	-3,843583	0,0002
SAR(12)	0,951846	0,042814	22,23198	0,0000

Os resultados dispostos na Tabela 3, são referentes ao modelo SARIMA(2,1,0)(1,0,0)<sub>12</sub>, os quais apresentam compatibilidade com os pressupostos da metodologia, cujo p-valor dos coeficientes é menor que o nível de significância de 5%, observando que a soma e diferença entre coeficientes de mesmos filtros deve ser menor que 1.

Após o modelo ser estimado, é realizada a análise de resíduos, a qual deve possuir comportamento de RB, dessa forma, indicando comportamento estacionário. A Figura 8 apresenta a FAC e FACP dos resíduos, bem como a estatística de teste Ljung-Box dos resíduos e dos resíduos quadráticos.

Na Figura 8, pode-se verificar que se tem um processo estacionário, devido ao fato que a FAC e a FACP dos resíduos apresenta as autocorrelações de seus *lag's* dentro dos limites de confiabilidade, considerando um nível de significância de 5%. Para confirmar que os resíduos não são autocorrelacionados fez-se o teste Ljung-Box(Q). Conforme os p-valores, pode-se observar que seus valores foram superiores aos níveis de significância adotados, indicando assim, que não se rejeita a hipótese nula, ou seja, existe estacionariedade nos resíduos.

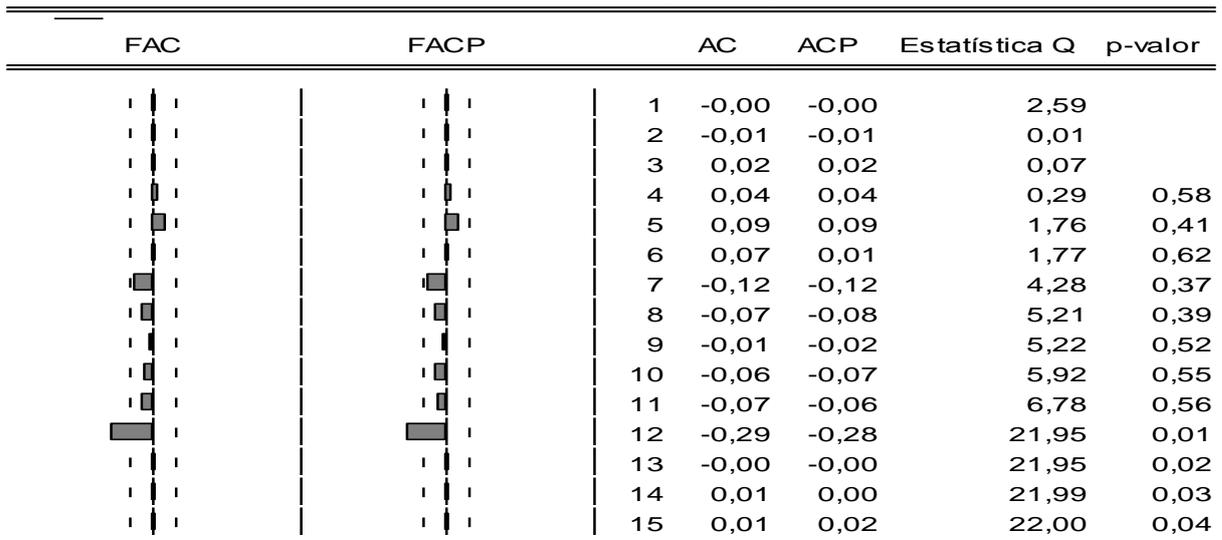


Figura 8 - FAC, FACP dos resíduos do modelo SARIMA(2,1,0)(1,0,0)<sub>12</sub> e estatística Ljung-Box da série de admissões.

Para identificar a existência de heterocedasticidade residual foi realizada a análise dos resíduos quadráticos, conforme a Figura 9.

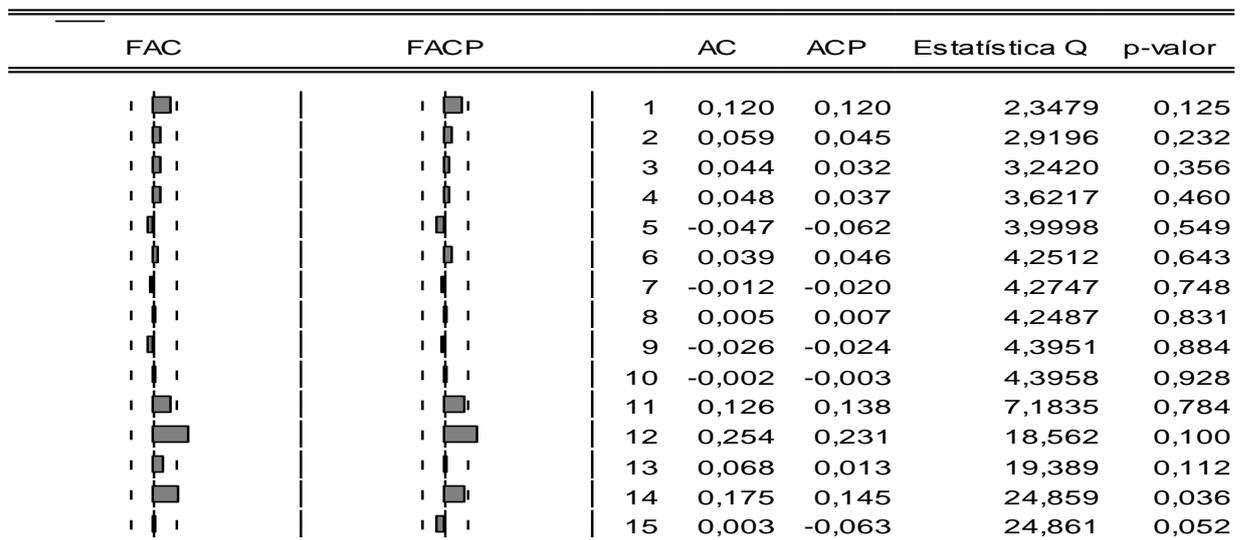


Figura 9 - FAC, FACP dos resíduos quadráticos do modelo SARIMA(2,1,0)(1,0,0)<sub>12</sub> e estatística Ljung-Box.

Na Figura 9, pode-se observar que o processo é estacionário e não autocorrelacionado, pois pela FAC e FACP observa-se que os *lag*'s apresentam as

autocorrelações dentro dos limites de confiabilidade, considerando um nível de significância de 5%. Seus p-valores confirmam este resultado, na medida em que pode-se observar que seus valores foram superiores ao nível de significância adotado, indicando assim, que não rejeita-se a hipótese nula, ou seja, não existe heterocedasticidade nos resíduos.

Para corroborar com a FAC e FACP dos resíduos quadráticos foi utilizado o teste de heterocedasticidade ARCH, com o intuito de verificar estatisticamente se o modelo conseguiu captar a presença de heterocedasticidade condicional residual.

Na Tabela 4, apresenta-se o resultado da estatística F referente ao teste de heterocedasticidade condicional residual (ARCH) dos resíduos quadráticos do modelo SARIMA(2,1,0)(1,0,0)<sub>12</sub> da série de admissões.

Tabela 4 - Teste de heterocedasticidade condicional residual dos resíduos quadráticos para o Modelo SARIMA(2,1,0)(1,0,0)<sub>12</sub> - (ARCH) da série de admissões.

Estatística F	2,470781	p-valor F(1,158)	0,118
N*R <sup>2</sup>	2,463532	p-valor Qui-Quadrado(1)	0,117

Na Tabela 4, apresenta-se o teste da estatística F, pelo p-valor, pode-se verificar que o mesmo não rejeita a hipótese nula, ou seja, indicando que não há heterocedasticidade condicional nos resíduos quadráticos deste modelo, sendo assim não será necessário utilizar outras formas de modelagem.

Na Figura 10, são apresentadas as séries: original, valores ajustados e resíduos do modelo.

Conforme a Figura 10 observa-se que se obteve um bom ajuste, pois a série de admissões diferenciada e a ajustada pelo modelo estão próximas, indicando que o modelo se adequou para ser realizada a previsão.

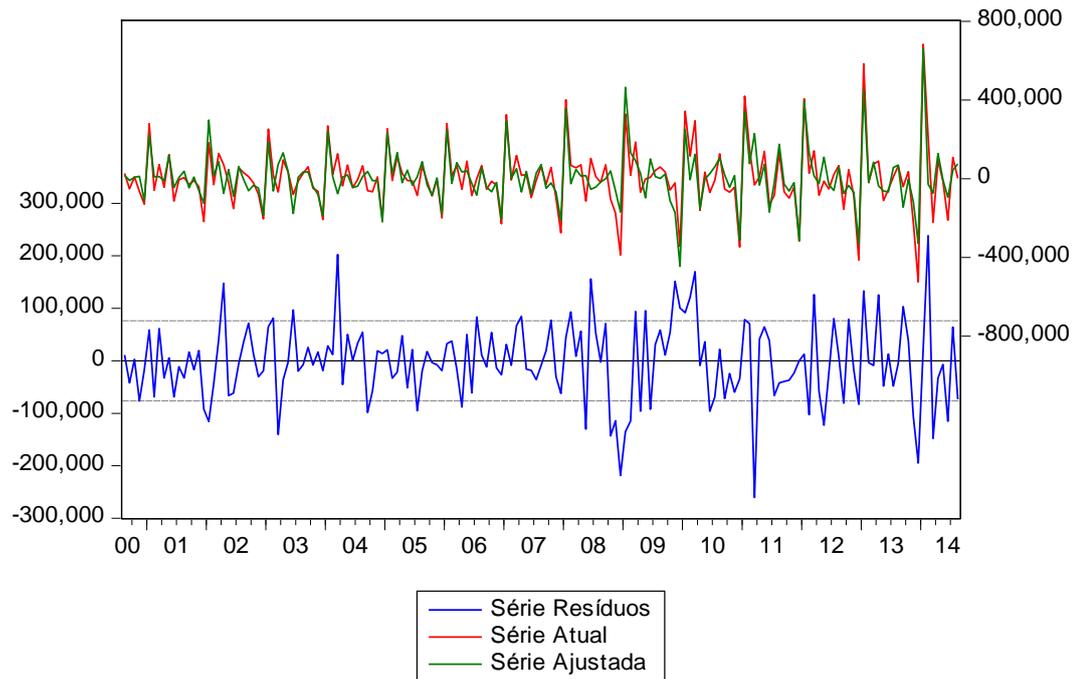


Figura 10 - Valores originais, valores estimados e resíduos do modelo.

Após o ajuste do modelo foi realizada as previsões. Na Figura 11, apresenta-se as previsões para 16 meses a frente, para a série de admissões, utilizando-se o modelo  $SARIMA(2,1,0)(1,0,0)_{12}$ .

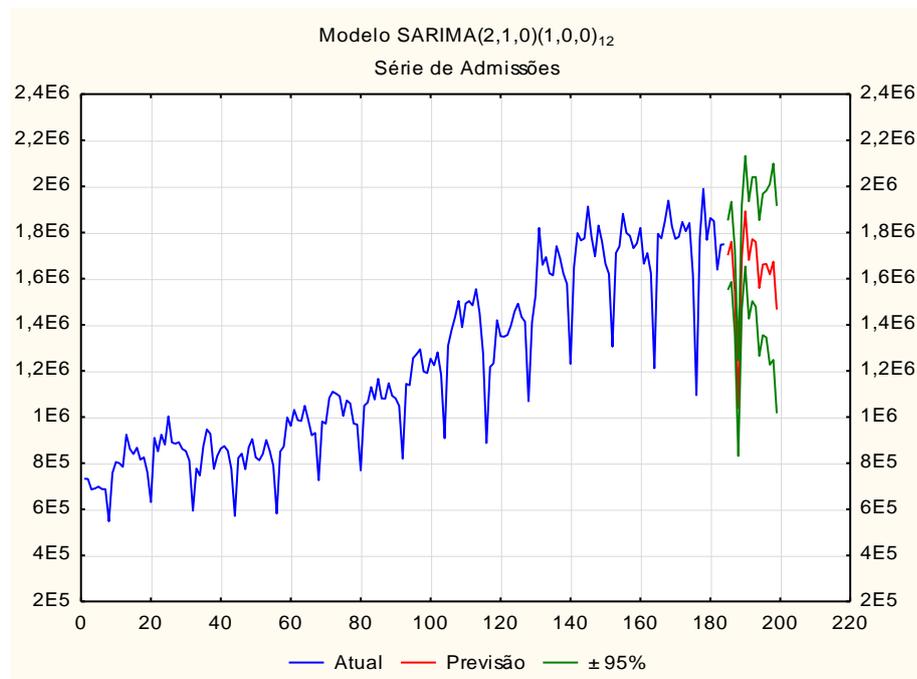


Figura 11 - Previsão do modelo  $SARIMA(2,1,0)(1,0,0)_{12}$ .

Conforme a Figura 11 pode-se verificar que os resultados da previsão encontram-se dentro dos intervalos de confiança. Observa-se também que no eixo horizontal têm-se os meses correspondentes às observações, sendo que, no mês 188 ocorreu um pico nas previsões, correspondendo este ao mês de dezembro, o que vem confirmar os resultados já obtidos na estatística descritiva, no qual este apresenta uma característica diferente dos demais meses, conforme Figura 3.

Na Tabela 5, constam os valores da previsão para 16 meses, obtidos a partir do modelo escolhido SARIMA(2,1,0)(1,0,0)<sub>12</sub>.

Tabela 5 - Previsão de 16 meses pelo modelo SARIMA(2,1,0)(1,0,0)<sub>12</sub>.

	Previsão	Limite Inferior	Limite Superior	Erro Padrão
set/14	1701598	1550859	1852337	76392,2
out/14	1759634	1585787	1933481	88102,8
nov/14	1541037	1356496	1725578	93522,3
dez/14	1038550	831205	1245895	105078,9
jan/15	1692039	1466333	1917745	114383,9
fev/15	1892191	1652660	2131723	121390,3
mar/15	1680695	1426238	1935151	128954,3
abr/15	1771155	1502383	2039928	136209,5
mai/15	1759113	1477429	2040798	142752,8
jun/15	1559285	1265049	1853521	149114,0
jul/15	1661277	1354872	1967682	155280,7
ago/15	1663285	1345297	1981273	161151,0
set/15	1618407	1227046	2009767	198334,9
out/15	1673483	1247819	2099146	215719,0
nov/15	1466041	1016711	1915370	227712,5
dez/15	989130	506981	1471279	244345,0

Conforme a Tabela 5 observa-se que a previsão possui valores oscilantes. Essas oscilações podem ocorrer pela época do ano e variações no mercado de trabalho. Sendo assim, seria interessante analisar a série em períodos específicos, nos quais essas oscilações ocorrem, pois no mês de dezembro, conforme as Figuras 3 e 11 observa-se uma característica específica, pela Tabela 5 ocorre uma diminuição na quantidade de vagas, a qual deveria ser analisada em particular.

## 4.2 Análise da série de demissões

#### 4.2.1 Análise descritiva, gráfica e testes de estacionariedade:

Com o intuito também de verificar o comportamento da série de demissões, faz-se aqui uma análise descritiva. Dessa forma, pode-se verificar se esta série possui oscilações ou se comportou de maneira estável no período de maio de 1999 até agosto de 2014. Para isso são utilizadas as medidas descritivas, como a média, mediana, desvio padrão e CV.

A Tabela 6 apresenta as medidas descritivas referentes à série de demissões.

Tabela 6 - Análise descritiva da série de demissões

Ano	Nº Meses	Média	Mediana	Mínimo	Máximo	Desvio Padrão	CV
1999	8	689.854	677.343	635.522	790.647	45.138,10	6,54
2000	12	750.878	746.424	658.984	856.818	51.065,50	6,80
2001	12	813.380	814.502	740.237	889.041	44.250,80	5,44
2002	12	754.164	770.951	642.005	820.473	56.695,50	7,52
2003	12	763.659	758.399	699.084	881.481	44.990,20	5,89
2004	12	814.435	784.292	732.972	1.077.912	94.522,50	11,61
2005	12	910.418	891.607	843.935	1.055.144	61.141,90	6,72
2006	12	966.872	956.713	846.299	1.136.781	78.996,50	8,17
2007	12	1.060.325	1.060.819	970.960	1.227.542	72.403,60	6,83
2008	12	1.267.261	1.235.734	1.166.001	1.542.245	109.844,70	8,67
2009	12	1.266.044	1.237.909	1.166.348	1.483.673	88.882,60	7,02
2010	12	1.422.325	1.424.127	1.229.043	1.638.073	103.931,60	7,31
2011	12	1.583.048	1.561.362	1.498.281	1.713.223	71.574,80	4,52
2012	12	1.630.317	1.611.316	1.514.413	1.769.381	71.363,10	4,38
2013	12	1.684.280	1.727.483	1.543.966	1.765.372	79.015,10	4,69
2014	8	1.722.002	1.741.742	1.614.044	1.790.755	59.966,80	3,48

Na Tabela 6, pode-se observar que a média também foi representativa para a série de demissões, pois todos os valores do coeficiente de variação estiveram abaixo de 15% em que, o valor mínimo do CV foi de 3,48 no ano de 2014, e seu valor máximo foi de 11,61 no ano de 2004, tendo uma amplitude de variabilidade no período de 8,13. Pelas medidas descritivas observou-se um aumento na oferta média de demissões no país nesse período, sendo que as maiores variabilidades encontradas foram nos anos de 2004 e 2008. As maiores oscilações ocorridas

nesses anos partem das dificuldades encontradas em meio às crises econômicas e demissões em massa, principalmente no ramo automobilístico (SATO, 2009).

Na Figura 12, são apresentados o comportamento da média, mediana e desvio padrão em relação aos anos pesquisados.

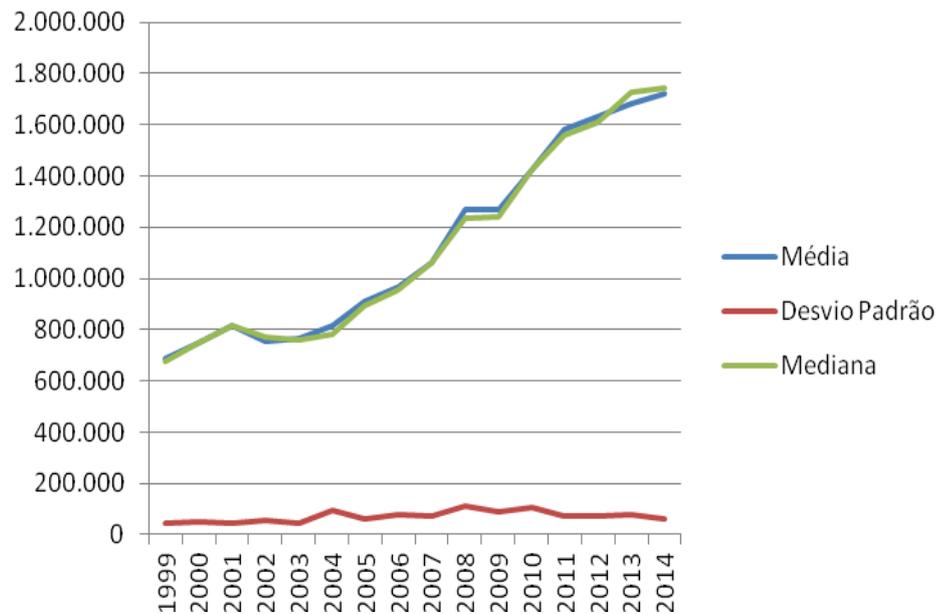


Figura 12 - Média, mediana e desvio padrão da série de demissões no período de 1999 a 2014.

Conforme a Figura 12 pode-se observar que a média e a mediana da série de demissões estiveram sobrepostas, praticamente, em todo o período, com algumas oscilações em 2004, e entre os anos de 2008 a 2009. Essas variações são o reflexo de uma economia que tem oscilado nesse período.

A seguir, na Figura 13, apresenta-se o comportamento mensal da série de demissões no período de 1999 a 2014.

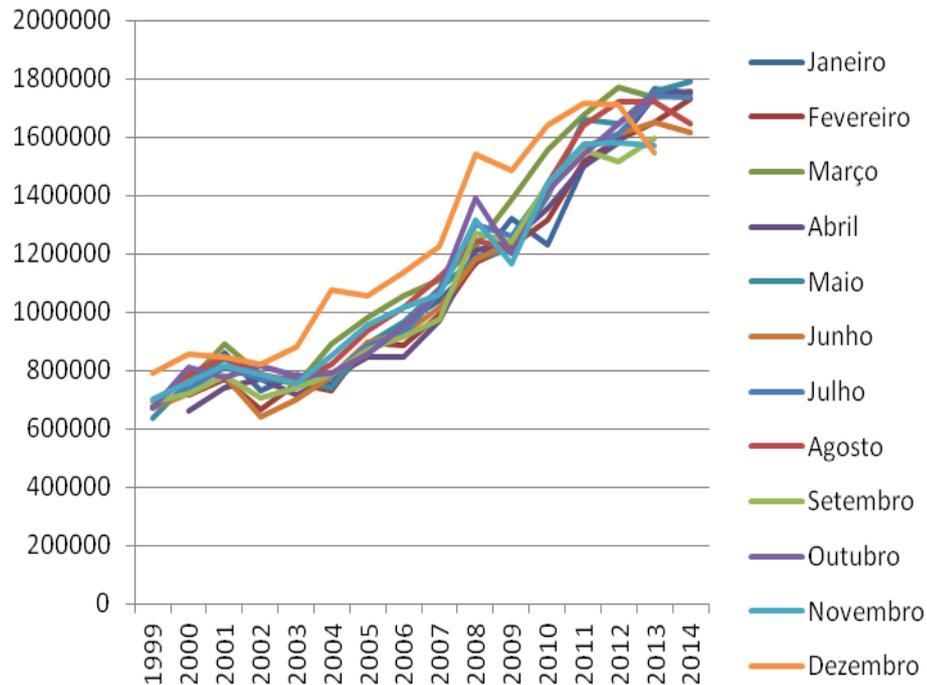


Figura 13 - Comparação mensal da série de demissões no período de 1999 a 2014.

Conforme a Figura 13 pode-se observar que a quantidade de demissões teve um aumento no decorrer do período. Pode-se também observar que os meses de dezembro tiveram um comportamento contrário em relação às Figuras 3 e 13, em que, na Figura 3, a quantidade de admissões foi reduzida. Já na Figura 13, a quantidade de demissões foi superior aos demais meses.

Na Figura 14, é possível visualizar o comportamento da média e da mediana com algumas oscilações entre os meses de janeiro e outubro, já nos meses de novembro e dezembro ocorre um crescimento na quantidade de demissões. Esse comportamento se confirma pela Figura 4, em que a quantidade de admissões possui um decréscimo.

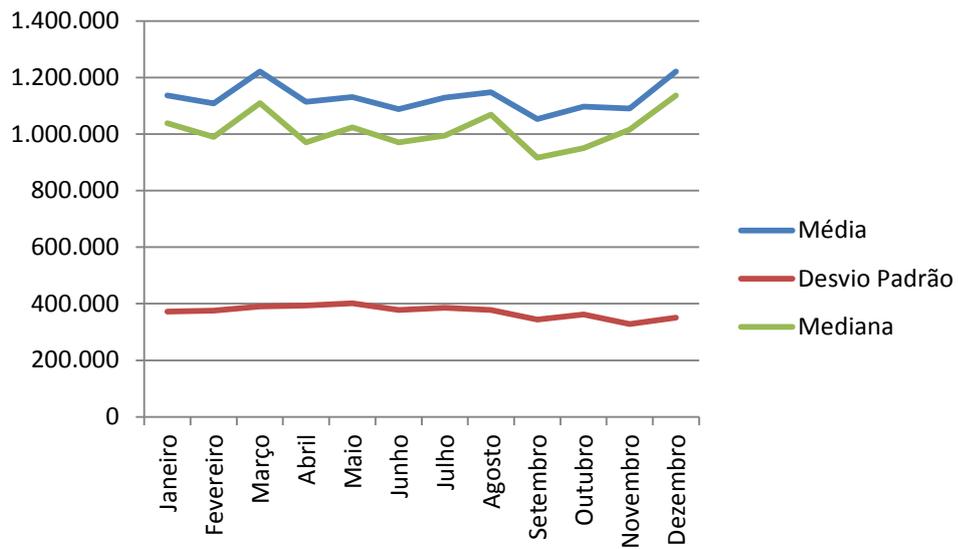


Figura 14 - Valores mensais da média, mediana e desvio padrão da série de demissões no período de 1999 a 2014.

A Figura 15 apresenta-se a série de demissões.

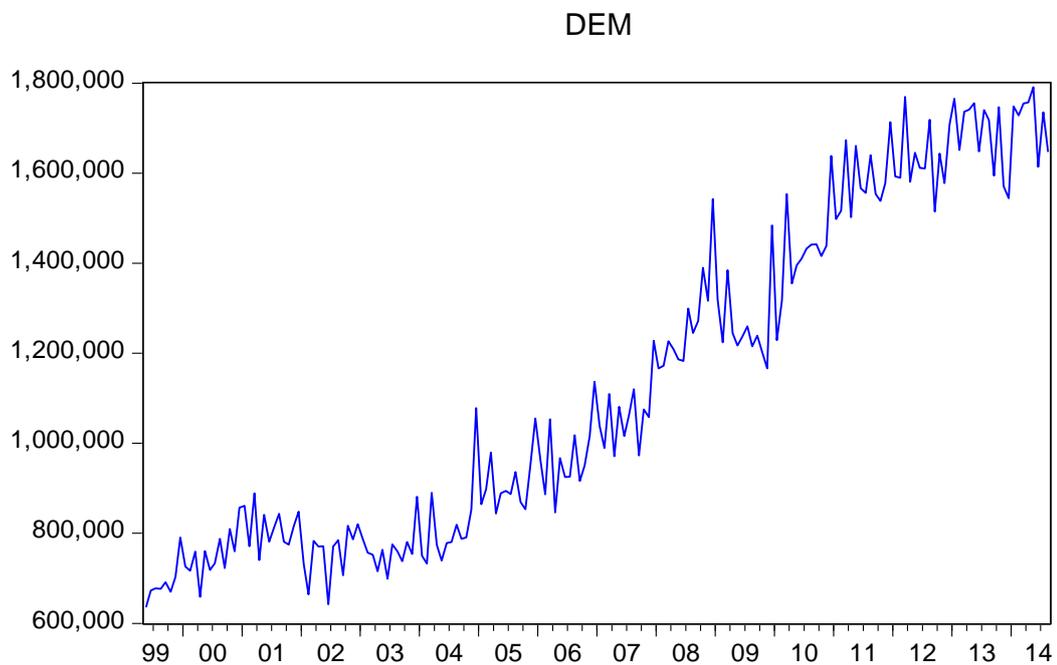


Figura 15 - Série de demissões no período de 1999 a 2014.

Na Figura 15 tem-se o gráfico da série original de demissões o qual não indica estacionariedade e apresenta um comportamento crescente no período.

Conforme Mueller (2013), em 2004, houve demissões em massa nas indústrias de diversos setores no país, tais como automobilística, moveleira, etc. No ano de 2008, assim como nas admissões, as demissões aconteceram, grande parte, devido à crise internacional. Já em 2012, contava-se que o país não seria mais afetado pela crise, mas essa variabilidade ocorreu pela estagnação da economia brasileira, vinda do ano de 2011, e um fraco crescimento econômico no ano que se seguia.

Na Figura 16 apresenta-se a série original e a série diferenciada de demissões.

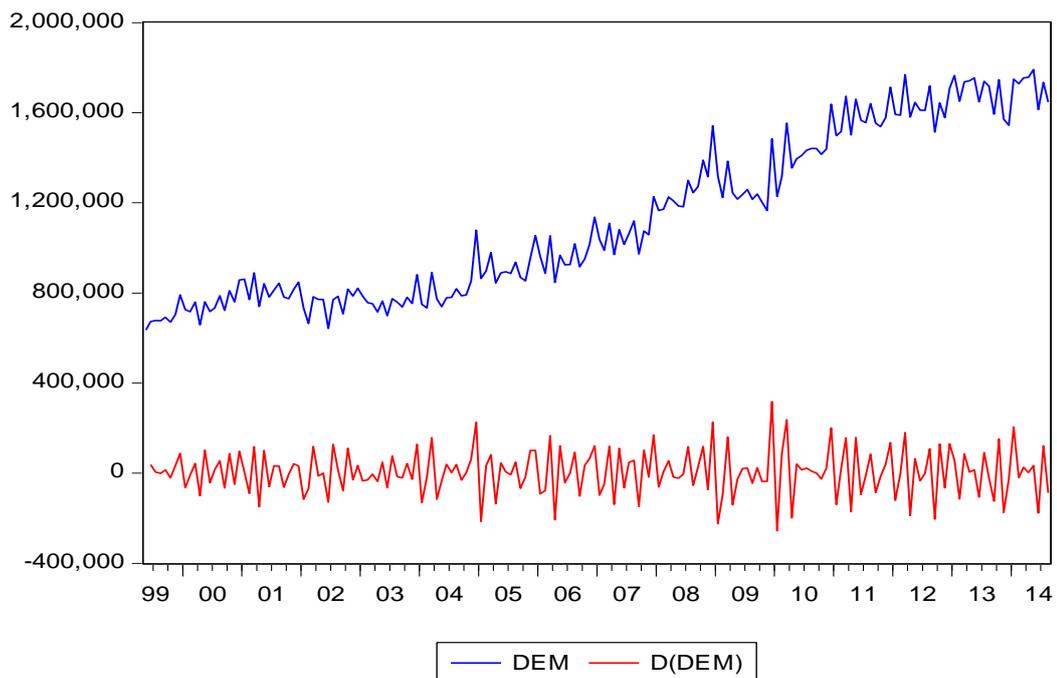


Figura 16 - Série original e primeira diferença de demissões.

Pela Figura 16, observa-se a série diferenciada, na qual se verifica um comportamento de estacionariedade. Sendo assim, a mesma será utilizada para estimar os parâmetros do modelo em estudo.

Na Figura 17, são apresentadas a FAC e FACP da série original de demissões.

FAC	FACP	AC	ACP	Estatística Q	p-valor	
		1	0,953	0,953	169,71	0,000
		2	0,944	0,396	337,33	0,000
		3	0,940	0,255	504,54	0,000
		4	0,912	-0,165	662,81	0,000
		5	0,905	0,039	819,26	0,000
		6	0,880	-0,160	968,10	0,000
		7	0,872	0,153	1115,1	0,000
		8	0,856	-0,046	1257,6	0,000
		9	0,853	0,267	1400,0	0,000
		10	0,834	-0,222	1537,0	0,000
		11	0,819	0,037	1669,6	0,000
		12	0,829	0,139	1806,2	0,000
		13	0,790	-0,290	1931,1	0,000
		14	0,782	0,012	2054,3	0,000
		15	0,770	-0,043	2174,3	0,000

Figura 17 - FAC, FACP e estatística Ljung-Box da Série de demissões.

Conforme Figura 17, observa-se que a FAC amostral apresenta decaimento lento com longa dependência serial. A FACP indica que a ordem do modelo seja um AR(2), pois possui dois *lag's* fora dos limites de confiabilidade. Mas, no período de doze meses, é possível visualizar que há uma incidência de um filtro MA no mês de janeiro. Essa variação indica a necessidade de um estudo de possível sazonalidade na série.

Assim como na série de admissões, a série de demissões apresentou decaimento lento, o que poderia indicar um modelo fracionário, mas não foi encontrado nenhum modelo que se comporte melhor com fracionariedade.

Na Tabela 7, constam os valores dos testes de estacionariedade ADF e KPSS, juntamente com o p-valor respectivo.

Tabela 7 - Testes de Estacionariedade ADF e KPSS da série original e primeira diferença da série de demissões.

Série Demissões	ADF Estatística do Teste	p-valor ADF	Valor Crítico ADF (5%)	KPSS Estatística do Teste	Valor Crítico KPSS (5%)
Original	0,198722	0,9718	-2,878311	1,70432	0,46300
1ª Diferença	-4,660903	0,0002		0,11542	

Os testes da Tabela 7 apresentaram resultados de estacionariedade para a série de demissões em primeira diferença, Série essa que será realizada a modelagem.

Na Tabela 7, observa-se que pelo teste KPSS não se rejeita a hipótese nula de estacionariedade, na série diferenciada de demissões. Assim como, pelo teste ADF, em que o p-valor foi significativo ao nível de 5%, ou seja, a série diferenciada foi considerada estacionária.

#### 4.2.2 Análise do melhor modelo e quadro dos modelos concorrentes

Considerando-se o melhor modelo selecionado para representar a série de demissões, foram estimados vários modelos concorrentes, dentre os quais os que tiveram melhor resultado estão dispostos no Quadro 2, que segue.

Modelo	Coefficientes	AIC	BIC
ARIMA(1,1,1)	$\phi: 0,652133$ $\theta: -0,548834$	24,93477	24,97273
<b>SARIMA(2,1,0)(1,0,0)<sub>12</sub></b>	$\phi_1: -0,665672$ $\phi_2: -0,418701$ $\Phi: 0,641094$	<b>24,82244</b>	<b>24,90986</b>
SARIMA(1,1,3)(1,0,0) <sub>12</sub>	$\phi: -0,757162$ $\Phi: 0,607039$ $\theta_1: 0,177830$ $\theta_2: -0,429983$ $\theta_3: -0,364784$	24,83222	24,92752

Quadro 2 - Quadro de modelos concorrentes da série de demissões.

O modelo que melhor ajustou a série de demissões foi um SARIMA(2,1,0)(1,0,0)<sub>12</sub>, pois apresentou melhor modelagem na série de demissões e menores valores dos Critérios de Informação Akaike e Bayesiano.

A Tabela 8 apresenta os resultados obtidos do modelo escolhido da série de demissões.

Tabela 8 - Coeficientes do modelo SARIMA(2,1,0)(1,0,0)<sub>12</sub> da série de demissões.

Variáveis	Coeficientes	Desvio Padrão	Estatit. t	p-valor
AR(1)	-0,665672	0,074542	-8,930132	0,0000
AR(2)	-0,418701	0,075295	-5,560779	0,0000
SAR(12)	0,641094	0,063798	10,04875	0,0000

O modelo apresentado na Tabela 8, foi selecionado a partir dos menores valores dos critérios de informação AIC e BIC, como já visto no Quadro 2 de modelos concorrentes. Pelo p-valor, pode-se verificar que todos os seus valores foram significativos ao nível de 5%.

Após a escolha do modelo, é estudado se os resíduos desse modelo tem comportamento de RB, em que se busca validar o modelo escolhido mediante a estatística de Ljung-Box dos resíduos e dos resíduos quadráticos.

Na Figura 18, constam a FAC e FACP da série dos resíduos do modelo SARIMA(2,1,0)(1,0,0)<sub>12</sub>.

FAC	FACP	AC	ACP	Estatística Q	p-valor	
		1	0,057	0,057	0,5393	
		2	0,056	0,053	1,0580	
		3	0,090	0,085	2,4151	
		4	-0,024	-0,037	2,5130	0,113
		5	0,042	0,036	2,8042	0,246
		6	-0,015	-0,024	2,8525	0,417
		7	-0,096	-0,094	4,4141	0,353
		8	-0,031	-0,028	4,5804	0,469
		9	0,111	0,133	6,7195	0,348
		10	-0,149	-0,151	10,559	0,159
		11	-0,185	-0,192	16,576	0,123
		12	-0,171	-0,163	21,756	0,157
		13	-0,219	-0,173	30,224	0,234
		14	0,023	0,053	30,318	0,324
		15	0,028	0,086	30,457	0,235

Figura 18 - FAC, FACP dos resíduos do modelo SARIMA(2,1,0)(1,0,0)<sub>12</sub> e estatística Ljung-Box(Q).

Conforme a Figura 18, o comportamento dos resíduos é estacionário, ou seja, RB, pois todos os valores constam dentro dos limites de confiabilidade. De acordo

com o resultado da estatística Ljung-Box, os p-valores foram superiores ao nível de significância adotado, indicando a não autocorrelação dos resíduos.

Assim, segue-se com a análise dos resíduos quadráticos a fim de identificar a existência de heterocedasticidade condicional residual, observa-se a FAC e FACP dos resíduos quadráticos, conforme Figura 19.

FAC	FACP	AC	ACP	Estatística Q	p-valor	
		1	0,109	0,109	1,9569	0,162
		2	0,093	0,082	3,4037	0,182
		3	0,136	0,121	6,5347	0,088
		4	0,045	0,014	6,8839	0,142
		5	0,078	0,054	7,9265	0,160
		6	-0,070	-0,106	8,7675	0,187
		7	-0,055	-0,059	9,2931	0,232
		8	0,012	0,018	9,3175	0,316
		9	0,043	0,071	9,6449	0,380
		10	0,072	0,081	10,563	0,393
		11	0,052	0,046	11,035	0,440
		12	0,045	0,012	11,399	0,495
		13	0,100	0,054	13,206	0,432
		14	0,134	0,095	16,446	0,287
		15	0,085	0,050	17,772	0,275

Figura 19 - FAC, FACP dos resíduos do modelo SARIMA(2,1,0)(1,0,0)<sub>12</sub> e estatística Ljung-Box.

Com base na Figura 19, o comportamento é estacionário, isso pode ser verificado pela FAC e FACP, em que seus *lag's* estão dentro dos limites de confiabilidade e os p-valores foram superiores aos níveis de significância adotados, isso indica que não existe heterocedasticidade nos resíduos quadráticos.

Para confirmar este resultado também se fez o teste de heterocedasticidade ARCH e com o intuito de testar estatisticamente se o modelo conseguiu captar a presença de heterocedasticidade condicional.

Na Tabela 9, é apresentado o resultado do teste de heterocedasticidade condicional residual (ARCH) dos resíduos quadráticos para o modelo SARIMA(2,1,0)(1,0,0)<sub>12</sub> da série de demissões, com base na estatística F.

Tabela 9 - Teste de heterocedasticidade condicional residual, dos resíduos quadráticos para o Modelo SARIMA(2,1,0)(1,0,0)<sub>12</sub> – (ARCH) da série de demissões.

Estadística F	3.922040	p-valor F(1,158)	0.0494
N*R <sup>2</sup>	3.875485	p-valor Chi-Square(1)	0.0490

O teste ARCH, da Tabela 9, apresenta o resultado que indica a ausência de heterocedasticidade condicional residual, isso pode ser verificado pelo p-valor, o qual não rejeita a hipótese nula, corroborando com a FAC e FACP, da Figura 19.

Na Figura 20, apresenta-se a série original, valores estimados e resíduos do modelo.

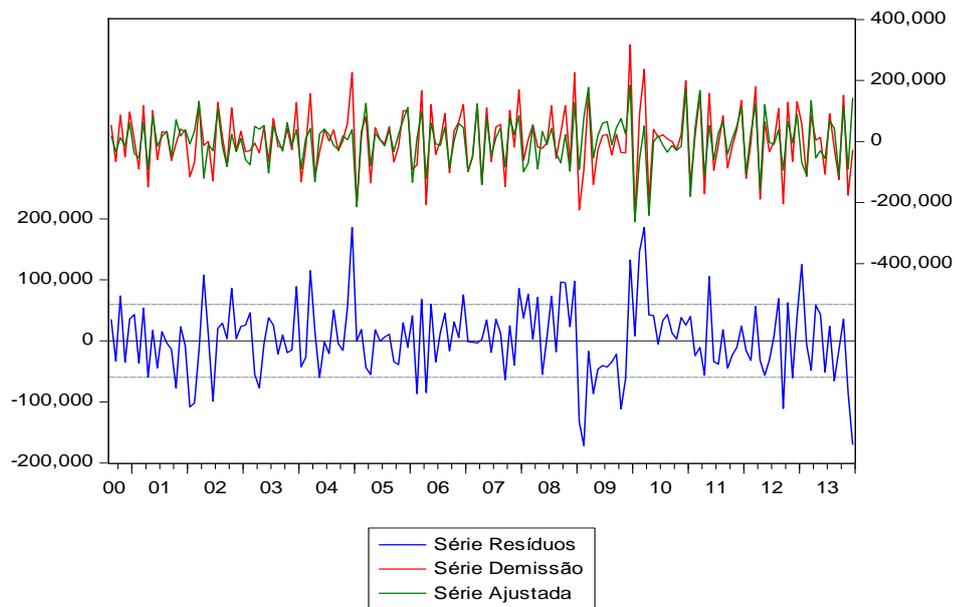


Figura 20 - Valores originais, valores estimados e resíduos do modelo.

Conforme a Figura 20 verifica-se um bom ajuste do modelo estimado, pois a série ajustada e a série diferenciada de demissões estão próximas, sendo assim, o modelo é adequado para realizar previsões.

Na Figura 21, apresenta-se as previsões para 16 meses a frente para a série de demissões, utilizando-se o modelo SARIMA(2,1,0)(1,0,0)<sub>12</sub>.

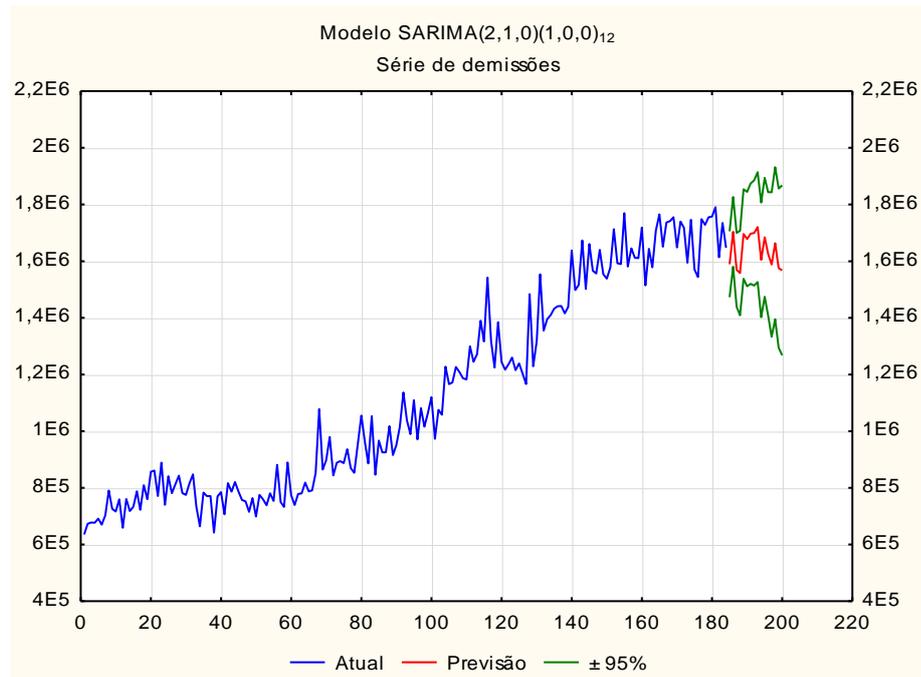


Figura 21 - Previsão do modelo SARIMA(2,1,0)(1,0,0)<sub>12</sub>.

Na Figura 21 pode-se verificar que os resultados da previsão para a série de demissões encontram-se dentro dos limites de confiança. Verifica-se também, que a série de demissões prevista apresenta certa estabilidade com alguns picos.

Na Tabela 10, constam os valores da previsão para a variável de demissões para 16 meses, obtidos a partir do modelo SARIMA(2,1,0)(1,0,0)<sub>12</sub>. Apresentada na referida Tabela, a previsão dos meses de 2014 e 2015 para a série de demissões em primeira diferença. Observa-se que as diferenças entre os valores da série e os previstos possuem algumas oscilações.

Tabela 10 - Previsão 16 meses pelo modelo SARIMA(2,1,0)(1,0,0)<sub>12</sub>

	Previsão	Limite Inferior	Limite Superior	Erro Padrão
set/14	1589145	1472919	1705370	58901,2
out/14	1703521	1580408	1826635	62391,7
nov/14	1569404	1439028	1699780	66072,3
dez/14	1558050	1409151	1706949	75459,4
jan/15	1696024	1538269	1853779	79947,6
fev/15	1677973	1511459	1844487	84386,5
mar/15	1697148	1519977	1874319	89787,2
abr/15	1699453	1513840	1885066	94065,6
mai/15	1720343	1526526	1914161	98223,6
jun/15	1604569	1402376	1806761	102467,8
jul/15	1684327	1474459	1894196	106357,7
ago/15	1626381	1409068	1843694	110130,6
set/15	1588191	1333254	1843128	129197,9
out/15	1663477	1395308	1931646	135903,5
nov/15	1575168	1293922	1856414	142530,7
dez/15	1567733	1267888	1867578	151956,4

Assim, depois de testadas todas as séries, modeladas com base na metodologia objeto deste estudo, e analisadas em conjunto com o andamento econômico dos últimos 15 anos, serão descritas algumas conclusões, como segue no próximo ponto deste trabalho.

## 5 CONSIDERAÇÕES FINAIS

Com o modelo proposto foi possível analisar e prever o comportamento de cada série, no período de maio de 1999 a agosto de 2014, sendo que a série de admissões apresentou algumas tendências, sugerindo assim a utilização de um modelo fracionário devido seu caimento lento na FAC da série original. Pela análise também foi possível identificar, na série de demissões, que a mesma também apresentou um comportamento sazonal, a qual teve um decaimento lento com longa dependência serial.

A utilização dos modelos propostos  $SARIMA(2,1,0)(1,0,0)_{12}$  e  $SARIMA(2,1,0)(1,0,0)_{12}$ , é justificada pelo fato de que as séries em estudo apresentaram efeito sazonal que se repete de doze em doze meses, com longa dependência serial, com isso tornou-se necessário a aplicação de modelos que levem em consideração esta característica, captando assim o verdadeiro processo gerador da série.

A série de admissões teve como melhor modelo um  $SARIMA(2,1,0)(1,0,0)_{12}$ , o que significa que admissões possuem sazonalidade intensa no mês de dezembro, propiciada pela época de Natal e virada de ano. De acordo com uma análise específica da série de demissões, escolheu-se o melhor modelo um  $SARIMA(2,1,0)(1,0,0)_{12}$ , com sazonalidade pois em todos os dezembros existem picos, levantando a hipótese de pessoas trocarem de empregos por possuírem melhores propostas nessas mesmas épocas ou pelos empregos temporários que surgem neste período, esse resultado pode ser visto também nas análises descritivas de cada série.

Em relação aos modelos ARFIMA, a série não se apresentou como sendo de memória longa, apenas a série de admissões apresentou esta característica, mas os modelos SARIMA apresentaram melhores estatísticas de ajustes AIC e BIC.

Quando observado se a série possuía volatilidade, os resíduos não apresentaram esta característica, portanto não há flutuação muito grande em termos de variabilidade de um período para outro. O que ocorre é um incremento de valor que a sazonalidade consegue explicar. Há de se observar que os modelos SARIMA

refletem o comportamento do nível da série e os modelos de volatilidade o comportamento de variabilidade.

Sugere-se como estudo futuro, um período maior de análise e testar outras variáveis bem como outros modelos.

## REFERÊNCIAS

ALMEIDA, A. F. M. **Análise comparativa da aplicação de modelos para imputação do volume médio diário de Séries Históricas de volume de tráfego**. 2010. 100f. Dissertação (Mestrado em Engenharia de Transportes) – Universidade Federal do Ceará, Fortaleza, 2010.

BAYER, F. M. **Previsão do Preço e da Volatilidade de Commodities Agrícolas, por meio de Modelos Arfima-Garch**. 2008. 83f. Dissertação (Mestrado em Engenharia de Produção) – Universidade Federal de Santa Maria, Santa Maria, 2008.

BOX, G.; JENKINS, G. M.; REINSEL, G. **Time series analysis: Forecasting and control**. 3.ed. New York. Prentice Hall, 1994.

BOX, G.; JENKINS, G. M.; **Time series analysis: Forecasting and control**. San Francisco: Holden-Day, 1970.

BUENO, R. L. S. **Econometria de séries temporais**. FGV – Fundação Getúlio Vargas. São Paulo: Cengage Learning, 2008.

CEPAL/PNUD/OIT. Emprego, desenvolvimento humano e trabalho decente: a experiência brasileira recente. **Projeto CEPAL/PNUD/OIT**. Brasília: CEPAL/PNUD/OIT, 2013.

FAVA, V. L. **Manual de econometria**. São Paulo: Atlas, 2000.

GRANGER, C.; JOYEUX, R. An introduction to long memory time series and fractional differencing. **Journal of Time Series Analysis**, v.1, p.15-29, 1980.

HOSKING, J. Fractional differencing. **Biometrika**, n.68, 1981.

HOSKING, J. Modeling persistence in hydrological time series using fractional differencing. **Water Resources Research**, v.20, p.1898-1908, 1984.

IPEA - INSTITUTO DE PESQUISA E ECONOMIA APLICADA. Disponível em: <http://www.ipeadata.gov.br/>. Acesso em: nov., 2014.

LJUNG, G. M., BOX, G. E. P. **On a measure of lack of fit in time series models**. **Biometrika**, v.65, 1978.

MANKIW, N. G., **Macroeconomia**. Tradução e revisão técnica Teresa Cristina Padilha de Souza. Rio de Janeiro: LTC, 2011.

MATOS, O. C. **Econometria Básica: Teoria e Aplicações**. 3.ed. São Paulo: Atlas, 2000.

MORETTIN, P. A.; TOLOI, C. M. C. **Análise de séries temporais**. Edgard Blucher, Associação Brasileira de Estatística ABE – Projeto Fisher, 2006.

MORETTIN, P. A.; TOLOI, C. M. C. Econometria Financeira: Um curso em séries temporais financeiras. SIMPÓSIO NACIONAL DE PROBABILIDADE ESTATÍSTICA, 17, **Anais**. ABE, Caxambu, 2006.

MUELLER, A. **Por que o Brasil não cresce mais?** IMB – Instituto Ludwig von Mises Brasil. maio, 2013. Disponível em: <http://www.mises.org.br/Article.aspx?id=1557>.

NASCIMENTO, A. M. **Curso de Direito do Trabalho**. 24.ed. São Paulo: Saraiva, 2009.

NOTINI, H. H. **Ensaio sobre ciclos de negócios**. Tese (Doutorado em Economia) - Escola de Pós-Graduação em Economia da Fundação Getúlio Vargas – FGV. Rio de Janeiro, 2009.

PEREIRA, B. B.; PAIS, M. B. Z.; SALES, P. R. H. **Análise Espectral de séries temporais**: Uma introdução para Engenharia, Economia e Estatística. Rio de Janeiro: Arte Final Leasing Editorial; Eletrobrás S. A., 1986.

OIT - ORGANIZAÇÃO INTERNACIONAL DO TRABALHO. **Crise Financeira Mundial** – Impactos Sociais e no Mercado de Trabalho. ANFIP - Associação Nacional dos Auditores Fiscais da Receita Federal do Brasil. Brasília, 2009.

OIT - ORGANIZAÇÃO INTERNACIONAL DO TRABALHO. **Crise Financeira Mundial** – Impactos Sociais e no Mercado de Trabalho. ANFIP - Associação Nacional dos Auditores Fiscais da Receita Federal do Brasil. Brasília: 2014.

PADILHA JUNIOR, J. B. et al. Modelagem Box-Jenkins (Arima) para gestão de risco de preço na Pecuária de Corte do Estado do Paraná. CONVIBRA ADMINISTRAÇÃO – CONGRESSO VIRTUAL BRASILEIRO DE ADMINISTRAÇÃO, 10, **Anais eletrônicos**. 2013. Disponível em: [www.adm.convibra.com.br](http://www.adm.convibra.com.br).

SATO, P. O que causou a crise econômica mundial entre 2008 e 2009? **Revista Nova Escola**. maio, 2009. Disponível em: <http://revistaescola.abril.com.br/geografia/fundamentos/causou-crieseconomica-mundial-470382.shtml>.

SILVA, C. G.; LOPES, D. T.; REBELO, A. M. Persistência inflacionária: comparações entre três economias emergentes. **Revista de Economia e Administração**, v.10, n.1, p.152-167, jan./mar., 2011.

SOUZA, F. M. **Estudo do consumo e do número de consumidores de energia elétrica do RS por meio de componentes principais e modelagem ARIMA**. 2011. 107f. Dissertação (Mestrado em Engenharia de Produção) – Universidade Federal de Santa Maria, Santa Maria, 2011.

SOUZA, P. R. **O que são empregos e salários**. Coleção primeiros passos; Nova Cultura. São Paulo: Brasiliense, 1986.

TREVISAN, E. S.; SOUZA, R. C.; SOUZA, L. R. Estimação de Parâmetros “d” em Modelos ARFIMA. **Sociedade Brasileira de Pesquisa Operacional**. V.20, n.1, 2000.

VIANNA, Cláudia Salles Vilela. **Manual Prático das Relações Trabalhistas**. 12.ed. São Paulo: LTr, 2014.

WERNER, L., RIBEIRO, J. L. D. Previsão de demanda: uma aplicação dos Modelos Box-Jenkins na área de assistência técnica de computadores pessoais. **Revista Gestão e Produção**. v.10, n.1, p.47-67, abril/2003.

WOLEK, A. **O trabalho, a ocupação e o emprego**: uma perspectiva histórica. Instituto Catarinense de Pós-Graduação. 23 out., 2008. Disponível em: <http://www.posuniasselvi.com.br/artigos/rev01-05.pADF>.