



Instituto de
MATEMÁTICA
E ESTATÍSTICA

UFRGS



UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
INSTITUTO DE MATEMÁTICA E ESTATÍSTICA

DEPARTAMENTO DE ESTATÍSTICA

**PREVISÃO DE DESEMPREGO EM REGIÕES
METROPOLITANAS DO BRASIL: UM EXECÍCIO
EMPÍRICO USANDO MODELOS SARIMA, VAR E VEC**

CAMILA THAÍS WEBER

Porto Alegre
2016

INSTITUTO DE MATEMÁTICA E ESTATÍSTICA
DEPARTAMENTO DE ESTATÍSTICA

**PREVISÃO DE DESEMPREGO EM REGIÕES
METROPOLITANAS DO BRASIL: UM EXERCÍCIO
EMPÍRICO USANDO MODELOS SARIMA, VAR E VEC**

Autor: Camila Thaís Weber

Trabalho de Conclusão de Curso
apresentado para obtenção
do grau de Bacharel em Estatística.

Banca Examinadora:
Professor Dr. Flávio Augusto Ziegelmann
Professor Dr. Hudson da Silva Torrent

Porto Alegre, 08 de dezembro de 2016.

AGRADECIMENTOS

Gostaria de deixar registrado meu agradecimento a todos que me apoiaram ao longo deste curso de estatística, desde quando decidi me mudar até o final da graduação. Inicialmente, um agradecimento especial aos meus amados pais, Ana Rosa e Luiz Carlos, que sempre me apoiaram e me deram suporte em todas minhas escolhas. Agradeço aos meus amigos e irmãos pelo apoio e paciência por compreender que muitas vezes foi necessário ficar ausente para me dedicar aos estudos. Agradeço também aos meus colegas de faculdade, pelas horas de estudos juntos, pelo apoio nos momentos difíceis e as horas de *happy hour* para descontrair. Em especial para aquelas que são além de colegas da faculdade, que estiveram do início ao fim desta trajetória, Angélica Segala, Raiane Padilha e Natalia Vais, não há palavras para expressar todo o carinho que tenho por vocês. Agradeço também aos meus colegas de trabalho, por acrescentar conhecimentos extras na minha vida acadêmica e profissional.

Em especial, agradeço aos meus amigos que contribuíram de alguma forma durante esta etapa da minha vida. Agradeço a Karen Espinosa por ter tido a coragem de revisar o trabalho, apesar do medo dos números. Agradeço a Tanise Dias Freitas, pela ajuda em várias formulações de ideias e motivação para escrever este trabalho. E agradeço ao Bruno Klahr pelo apoio incondicional durante todo o curso. Agradeço aos meus amigos que mesmo distante sempre pude contar Walleff Silva, Estênio Santos, Maylon Leoncio, Pedro Ricardo Alves, Thaís Pinto e Bruna Nadielle.

Ao meu professor e orientador Flávio por todo aprendizado durante o curso e por ter aceitado como orientador nesta etapa final da graduação. E ao Hudson Torrent por ter aceitado fazer parte da banca examinadora. Obrigada também aos demais professores do Departamento de Estatística que foram essenciais na minha formação, obrigada a todo carinho, dedicação, disponibilidade e aprendizado repassado ao longo destes anos.

RESUMO

O presente trabalho propõe o encontro de um modelo econométrico dentro das classes SARIMA, VAR e VEC para prever o desemprego em algumas regiões metropolitanas do Brasil no período de 2014 a 2016. Os comportamentos da série de desemprego, assim como de outras séries de variáveis econômicas são de extrema importância nas decisões de políticas públicas. Neste trabalho utilizamos séries da taxa de desemprego da Pesquisa de Emprego e Desemprego (PED) do Departamento Intersindical de Estatística e Estudos Socioeconômicos (DIEESE) de três regiões metropolitanas: Porto Alegre (RS), São Paulo (SP) e Salvador (BA). Propomos o uso de modelos sazonal autorregressivo integrado médias móveis (SARIMA), com ou sem variáveis exógenas (representadas por variáveis macroeconômicas), e modelos vetorial autorregressivo (VAR) e vetorial de correção de erros (VEC) para previsão de desemprego. Escolhemos três indicadores macroeconômicos para incorporar a análise: o Índice de Atividade Econômica do Banco Central, a Taxa de Juros e a Produção Industrial Mensal. Comparamos as previsões dos modelos candidatos através do teste de *Diebold-Mariano*. Com base no teste e na análise gráfica dos resultados deste estudo, concluímos que, de maneira geral, o modelo VEC produz uma previsão superior, principalmente quando ocorre uma crise econômica no país a partir de 2015.

Palavras Chaves: Previsão, Desemprego, SARIMA, VAR, VEC

ABSTRACT

The present work proposes looking for an econometric model (within the SARIMA, VAR and VEC classes) to predict unemployment in some metropolitan areas of Brazil from 2014 to 2016. The behaviour of the unemployment series, as well as other series of economic variables, is of extreme importance in public policy decisions. This paper uses unemployment time series from the “*Pesquisa de Emprego e Desemprego*” (PED) of the “*Departamento Intersindical de Estatística e Estudos Socioeconômicos*” (DIEESE) of three metropolitan regions: Porto Alegre (RS), São Paulo (SP) and Salvador (BA). We use seasonal autoregressive integrated moving average (SARIMA), with or without exogenous variables (represented by macroeconomic variables), vector autoregressive (VAR) and vector error correction (VEC) models for unemployment prediction. We choose three macroeconomic indicators to incorporate into our analysis: the Central Bank's Economic Activity Index, the Monthly Interest Rate and the Monthly Industrial Production. We compare the predictions of the models using Diebold-Mariano test. Based on the test and graphical analyses of the results of this study, we conclude that, in general, the VEC model produces better forecasts, especially when an economic crisis takes place in the country in the beginning of 2015.

Key Words: Forecasting, Unemployment, SARIMA, VAR, VEC

SUMÁRIO

1. INTRODUÇÃO	8
2. DESEMPREGO NO BRASIL	10
2.1. INTRODUÇÃO E HISTÓRICO RECENTE.....	10
2.2. PESQUISA DE EMPREGO E DESEMPREGO.....	11
2.3. VARIÁVEIS MACROECONÔMICAS	14
3. METODOLOGIA ESTATÍSTICA	16
3.1. DENIÇÕES BÁSICAS EM SÉRIES TEMPORAIS.....	16
3.2. MODELO SAZONAL AUTORREGRESSIVO INTEGRADO DE MÉDIAS MÓVEIS (SARIMA)	18
3.3. MODELO VETORIAL AUTORREGRESSIVO (VAR)	18
3.4. MODELO VETORIAL DE CORREÇÃO DE ERROS (VEC)	19
3.5. EQUAÇÕES DE PREVISÃO E COMPARAÇÃO DE MODELOS	20
4. ANÁLISE EMPÍRICA	21
4.1. DESCRIÇÃO DA MODELAGEM	21
4.1.1. SARIMA	21
4.1.2. VAR e VEC	23
4.1.3. Teste Diebold Mariano	27
4.2. RESULTADOS	28
4.2.1. Análise inicial das séries da taxa de desemprego	28
4.2.2. Previsão da taxa de desemprego Região Metropolitana de Porto Alegre	31
4.2.3. Previsão da taxa de desemprego Região Metropolitana de São Paulo	36
4.2.4. Previsão da taxa de desemprego Região Metropolitana de Salvador.....	41
4.2.5. Comparação das previsões dos modelos econométricos.....	46
5. CONCLUSÃO	50
REFERÊNCIAS BIBLIOGRÁFICAS	51
APÊNDICE A	53
APÊNDICE B	56
APÊNDICE C	61
APÊNDICE D	65

1. INTRODUÇÃO

A taxa de desemprego é a porcentagem da força de trabalho que não está empregada (FROYEN, 2002). Para ser considerada desempregada uma pessoa deve atender a duas condições: deve estar sem emprego e deve estar procurando algum trabalho. Aquelas que não têm um trabalho e não procuram uma vaga são contabilizadas como fora da força de trabalho. A maioria dos países classifica uma pessoa como desempregada “se ela não tiver trabalho e estiver procurando uma vaga nas últimas quatro semanas” (BLANCHARD, 2011).

No Brasil temos a Pesquisa de Emprego e Desemprego (PED) do Departamento Intersindical de Estatística e Estudos Socioeconômicos (DIEESE), a qual apresenta dados e informações referentes à taxa de desemprego em diferentes regiões metropolitanas do país. Neste trabalho, foi utilizado dados referentes ao período entre 2004 a 2016, obtidos através do site do DIEESE (2016). Assim, o objetivo deste trabalho é encontrar um modelo econométrico adequado para previsão de desemprego nas regiões metropolitanas de Porto Alegre, São Paulo e Salvador. Inclusive, será testado se covariáveis macroeconômicas contribuem para a obtenção de uma melhor previsão da taxa de desemprego.

Para este trabalho foi escolhido o teste de Diebold-Mariano (Diebold, 1995) para se comparar as previsões das taxas de desemprego obtidas através dos vários modelos econométricos ajustados às séries temporais. O teste de Diebold-Mariano indicou que para a região metropolitana de Porto Alegre a previsão da taxa de desemprego com o modelo vetor de correção de erros (VEC) é superior em horizontes inferiores a seis meses, enquanto a previsão com o modelo sazonal autorregressivo de médias móveis (SARIMA) é mais precisa para horizontes a partir de seis meses. Para as regiões metropolitanas de São Paulo e de Salvador o modelo VEC produziu previsões superiores da taxa de desemprego para o período previsto de 2014 a 2016.

Cabe ressaltar que o acompanhamento da taxa de desemprego é muito importante para tomada de decisões nas políticas públicas, principalmente quando vivenciamos momentos de crise e recessão econômica. A oportunidade de melhorar os indicadores de emprego realizando a previsão da taxa de desemprego foi a principal motivação para este estudo. Como no país não há nenhum órgão que

efetue mensalmente previsão de desemprego das regiões metropolitanas, este trabalho pode contribuir para implementar este tipo de previsão nos órgãos que efetuam pesquisas de desemprego ou até mesmo para observar outros indicadores macroeconômicos.

Este trabalho está estruturado em 5 capítulos além desta introdução. No Capítulo 2, conduzimos uma revisão bibliográfica focada em aspectos econômicos, discutindo superficialmente sobre o desemprego, o mercado de trabalho e a crise econômica atual. Também no Capítulo 2 descrevemos a PED e as covariáveis macroeconômicas utilizadas no trabalho. No Capítulo 3 definimos resumidamente os modelos estatísticos/econométricos: modelo sazonal autorregressivo de médias móveis (SARIMA), modelo vetorial autorregressivo (VAR) e modelo vetor de correção de erros (VEC). No Capítulo 4 exploramos a análise empírica, discutindo os resultados. Finalmente, no capítulo 5 trazemos as considerações finais.

2. DESEMPREGO NO BRASIL

Neste capítulo fazemos uma discussão sobre o desemprego no país, histórico recente, Pesquisa de Emprego e Desemprego (PED) e as variáveis econômicas relevantes.

2.1. INTRODUÇÃO E HISTÓRICO RECENTE

Para discutirmos sobre o desemprego e o mercado de trabalho, é importante ter claro suas definições. Segundo Blanchard (2011), as pessoas que estão inseridas no mercado de trabalho e/ou que estão procurando emprego, fazem parte da população economicamente ativa (PEA), ou força de trabalho. As pessoas que não estão inseridas no mercado de trabalho e não estão procurando trabalho fazem parte da população inativa, ou da também chamada população não economicamente ativa. A população em idade ativa (PIA) é a soma da PEA e da população inativa, no Brasil, são contabilizados indivíduos com 10 anos ou mais para a PIA. A taxa de participação é a razão entre a PEA e PIA, ou seja, é a proporção de ocupados no mercado de trabalho. A razão entre o número de desempregados e a PEA, é chamada de taxa de desemprego, ou também taxa de desocupação, ou seja, é a proporção de desempregados no mercado de trabalho.

Bastos (2016) afirma que que, na conjuntura de grande contração da atividade econômica de 2015, o mercado de trabalho da Região Metropolitana de Porto Alegre (RMPA), por exemplo, evidenciou sinais claros de deterioração. O nível de ocupação total retraiu, a taxa de desemprego total teve o maior aumento de toda a série histórica da Pesquisa de Emprego e Desemprego (PED), e os rendimentos do trabalho tiveram queda de grande magnitude. Esse processo interrompeu o ciclo de melhora que o mercado de trabalho da região experimentou de 2004 a 2010 e que continuava avançando, ainda que de forma mais modesta, de 2011 a 2014. Três dos principais setores de atividade econômica tiveram grande retração do nível ocupacional em 2015: indústria de transformação, construção e comércio, reparação de veículos automotores e motocicletas.

A ocupação total só não teve maior descenso pelo fato de que houve recuperação parcial de seu nível nos serviços. De acordo com a inserção na

estrutura ocupacional, houve forte queda da ocupação nos segmentos de assalariados sem carteira assinada e de autônomos e recuperação parcial da ocupação nos segmentos assalariados com carteira assinada e de trabalhadores domésticos. O desemprego na RMPA elevou-se muito em 2015 devido à sobreposição de dois movimentos: a retração do nível de ocupação e o ingresso de pessoas na força de trabalho — neste último caso, nos seis primeiros meses do ano. Por fim, o contexto de retração da atividade econômica e de aumento da inflação teve consequências negativas sobre os rendimentos do trabalho. Tanto o rendimento médio real, quanto a massa de rendimentos reais dos ocupados, tiveram quedas substanciais em 2015, o que representou um retrocesso em relação aos avanços que haviam sido obtidos de 2005 a 2013.

2.2. PESQUISA DE EMPREGO E DESEMPREGO

A Pesquisa de Emprego e Desemprego (PED) iniciou em 1984 através do Departamento Intersindical de Estatística e Estudos Socioeconômicos (DIEESE) e da Fundação de Sistema Estadual de Análise de Dados (SEADE). Atualmente a PED é realizada no Distrito Federal (DF) e nas Regiões Metropolitanas de São Paulo (SP), Porto Alegre (RS), Belo Horizonte (MG), Salvador (BA) e Fortaleza (CE).

Os dados da PED são obtidos por meio de entrevistas em unidades domiciliares, selecionadas a partir de uma amostra probabilística em dois estágios: no primeiro, sorteiam-se os setores censitários e, em seguida, procede-se ao arrolamento de todos os seus domicílios e à seleção das unidades domiciliares para pesquisa. Para ter a precisão desejada dos indicadores, é necessário um tamanho mínimo de amostra, que é levantado a cada em 3 meses, por razões de custos. O número total de setores censitários sorteados foi dividido em três painéis diferentes, A, B e C, que podem ser analisados através da Fig. 2.1.




Figura 2.1 – Gráfico dos painéis da amostragem da PED

Fonte: DIEESE

Para os meses 1, 4, 7 e 10 são utilizados setores censitários do painel A, mas com sorteio de novas unidades domiciliares. As unidades domiciliares dos meses 2, 5, 8 e 11 são obtidas pelo painel B e dos meses 3, 6, 9 e 12 no painel C. Assim, a cada mês são levantadas amostras independentes ao mesmo tempo em que se aproveitam melhor os custos despendidos no processo de listagem dos setores censitários.

Apesar da periodicidade mensal dos levantamentos, o cálculo dos indicadores é realizado com os dados acumulados no trimestre, para garantir a precisão desejada. Ou seja, os indicadores são obtidos através de médias móveis, que incluem sempre os três painéis. A Tabela 2.1 apresenta um resumo das informações sobre os tamanhos amostrais regionais.

Tabela 2.1 – Tamanho amostral por Região Metropolitana.

Regiões	Número esperado de domicílios por trimestre	Número esperado de domicílios por mês	Número de conglomerados pesquisados por trimestre	Número de conglomerados pesquisados por mês	Número médio de domicílios pesquisados por conglomerado, por mês
Porto Alegre	8.100	2.700	501	167	16,2
Salvador	7.500	2.500	381	127	19,1
São Paulo	10.380	3.460	655	218	15,9

Fonte: DIEESE, 2009.

No planejamento da amostra, quando a pesquisa foi iniciada, foi estabelecida a precisão desejada para alguns indicadores, como a taxa de desemprego total,

para garantir a confiabilidade dos resultados. Para o levantamento de informações, foi realizada uma sequência de ações (DIEESE, 2009):

- Realização da entrevista – um pesquisador de campo treinado com a metodologia da PED realiza as entrevistas nas casas sorteadas e apresenta o questionário, que é aplicado para todos os moradores dos domicílios. Para aqueles com 10 anos ou mais, são realizadas entrevistas pessoais. Em casos extremos é realizada entrevista indireta, através de outro morador da residência. O trabalho do pesquisador é orientado e controlado por um supervisor de campo.
- Supervisão da coleta de dados – tem como finalidade assegurar a qualidade da produção de dados no momento da coleta, com o acompanhamento direto de sua execução e solução de problemas detectados nas visitas ao domicílio.
- Crítica de questionários – realizada por uma equipe interna que examina cada um dos questionários, verificando: se a aplicação das questões seguiu aos comandos previstos; se as alternativas de resposta foram corretamente codificadas; e se as observações descritas estão coerentes com a alternativa de resposta assinalada. Quando necessário, ocorre retorno do pesquisador de campo ao domicílio para solução de problemas detectados.
- Checagem de questionários – cerca de 30% do material criticado e aprovado é selecionado para checagem. A equipe de checagem verifica diretamente no campo a qualidade dos trabalhos realizados pelos pesquisadores, desde a correta localização do domicílio entrevistado, a forma de apresentação da pesquisa para os entrevistados até a aplicação do questionário. O material revisado é enviado para digitação e posterior consistência eletrônica dos dados.
- Consistência eletrônica dos dados – tem como objetivo detectar e corrigir erros ou possíveis incoerências na aplicação do questionário, não identificadas nos procedimentos anteriores. Para tanto, foram desenvolvidos diversos softwares para auxiliar na verificação.
- Banco de dados e indicadores – as respostas do questionário são codificadas numericamente, permitindo que as informações coletadas

sejam digitadas eletronicamente, gerando um arquivo com estrutura fixa que pode ser acessado pelos principais softwares de dados.

2.3. VARIÁVEIS MACROECONÔMICAS

A escolha das covariáveis utilizadas como possíveis indicadores da variação da taxa de desemprego advém da literatura existente e do que é possível extrair da mesma. É necessária a adaptação de algumas séries já utilizadas como indicadores de desemprego em outros países para aquelas que são encontradas no Brasil. Nesse sentido, o trabalho de Keilis Borok *et al.* (2005) propõe seis covariáveis, dentre as quais duas são utilizadas neste estudo: o índice de produção industrial e a taxa básica de juros. No estudo de Simionescu (2012) são realizadas previsões usando as taxas de juros, inflação e desemprego para a República Tcheca.

Para o presente estudo foi selecionado o índice de produção industrial da Pesquisa Industrial Mensal Produção Física (PIM-PF) regional do IBGE (IBGE, 2016), a série temporal inicia em 2003 e é utilizada neste estudo a partir deste ano. E também foi selecionada para o presente estudo a taxa básica de juros utilizando a corresponde Selic mensal conseguida junto ao Banco Central do Brasil (BCB, 2016).

Outra variável que pode apresentar alguma relação relevante com a taxa de desemprego é o Produto Interno Bruto (PIB), como descrito em diversos artigos e discussões de órgãos do país (LAVINAS, 2000). A variável PIB também se encontra em inúmeras publicações internacionais para auxiliar na previsão de desemprego. No estudo de Bialowolski *et al.* (2011) foram utilizados o PIB, taxa de inflação e taxa de desemprego para realizar as previsões. Martinsen *et al.* (2014) também trabalhou com o PIB, taxa de inflação e taxa de desemprego.

Com base nestes estudos, o presente trabalho utilizou PIB como Índice Atividade Econômica do Banco Central Regional (IBC-BCB, 2016), uma vez que o PIB não é gerado mensalmente. Logo, foram utilizados os dados a partir de 2003 para trabalhar com os modelos econométricos. Foi usado a série da taxa de desemprego iniciando em 2004 para trabalhar com a defasagem de cada variável macroeconômica. O indicador IBC é comparável com o PIB, como é possível ver na Fig. (2.2).

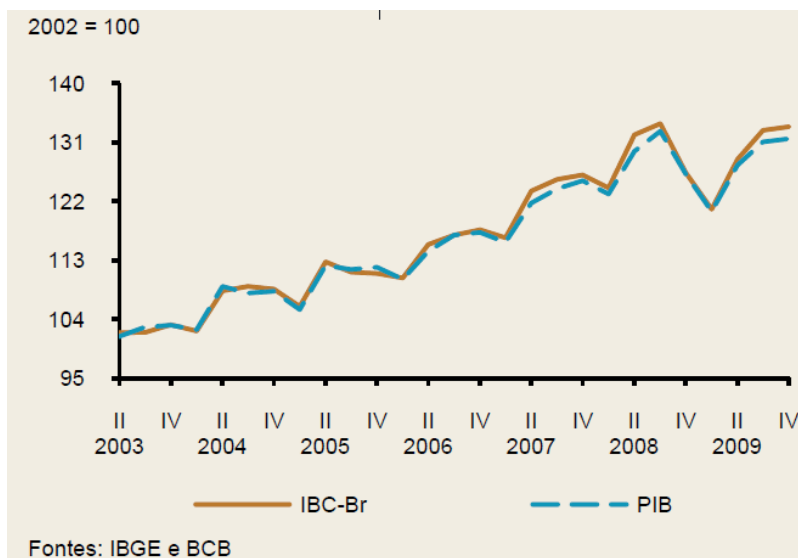


Figura 2.2 – Índice de atividade do Banco Central e PIB (BCB, 2010).

3. METODOLOGIA ESTATÍSTICA

A econometria é formada por um conjunto de modelos e métodos estatísticos empregados para descrever, analisar e prever fenômenos econômicos. A modelagem econométrica apoia-se fortemente em modelos de regressão, séries temporais, processos estocásticos, dentre outros.

Neste trabalho usaremos métodos de séries temporais para prever a taxa de desemprego. Segundo Wei (2006) uma série temporal é uma sequência de observações ao longo do tempo, onde a série tem por finalidade modelar relações entre variáveis, onde o futuro é influenciado pelo passado. Morettin (2006) afirma que os modelos utilizados para descrever séries temporais são processos estocásticos, isto é, processos controlados por leis probabilísticas. A construção dos modelos depende de vários fatores, tais como o comportamento de fenômeno ou o conhecimento *a priori* que temos de sua natureza e do objetivo da análise.

Diversos órgãos nacionais e estaduais, como o Instituto Brasileiro de Geografia e Estatística (IBGE), o Instituto de Pesquisa Econômica Aplicada (IPEA), a Fundação de Economia e Estatística (FEE), e a Fundação João Pinheiro (FJP), utilizam séries temporais para realizar diversas pesquisas e análises.

A seguir, são apresentados os modelos de séries temporais utilizados na análise deste estudo: modelo sazonal autorregressivo de médias móveis (SARIMA), modelo vetorial autorregressivo (VAR) e modelo vetor de correção de erros (VEC).

3.1. DENIÇÕES BÁSICAS EM SÉRIES TEMPORAIS

Para explorarmos as propriedades dos modelos SARIMA, VAR e VEC, é importante definirmos os conceitos básicos. Usaremos y_t no instante t como notação de série temporal neste trabalho. Assim, apresentaremos as seguintes definições, segundo Wei (2006):

Definição 3.1. O processo y_t será fracamente estacionário se:

- i) $\mu_t = E[y_t], \text{ para } \forall t$
- ii) $E[y_t^2] = c < \infty, \text{ para } \forall t$

$$\text{iii) } Cov(y_t, y_{t+k}) = Cov(y_t - y_{t+k}) = \gamma(t, t - k) = c(k) \forall t$$

Definição 3.2. O processo y_t será fortemente estacionário se:

$$F(y_{t+h}, y_{t+h+1}, \dots, y_{t+h+p}) = F(y_t, y_{t+1}, \dots, y_{t+p}) \text{ para } \forall h \text{ e } \forall p$$

Definição 3.3. O processo y_t será um ruído branco (ε_t) se satisfizer as seguintes condições:

- i) $E[y_t] = \mu, \text{ para } \forall t$
- ii) $Var[y_t] = \sigma^2, \text{ para } \forall t$
- iii) $Cov(y_t, y_{t+k}) = 0, \text{ para } \forall t \text{ e } \forall k \neq 0$

Definição 3.4. y_t será um processo de Autorregressivo de ordem p , AR(p), quando satisfizer a relação:

$$\phi(B)(y_t - \mu) = \varepsilon_t,$$

onde ε_t é ruído branco com $Var[\varepsilon_t] = \sigma^2, E[y_t] = \mu$ e $\mu = \frac{c}{\phi(B)}$, sendo

$$\phi_p(B) = (1 - \phi_1 B - \dots - \phi_p B^p) \text{ e } B\varepsilon_t = \varepsilon_{t-1}$$

A função de autocorrelação do AR(1) é dada por:

$$\rho_k = \phi_1 \rho_{k-1} = \phi_1^k, \quad k \geq 1$$

Definição 3.5. y_t será um processo de Médias Móveis de ordem q , MA(q), quando satisfizer a relação:

$$\theta_q(B)\varepsilon_t = y_t - \mu,$$

onde ε_t é ruído branco com $Var[\varepsilon_t] = \sigma^2, E[y_t] = \mu$,

$$\theta_q(B) = (1 - \theta_1 B - \dots - \theta_q B^q)$$

A função de autocorrelação do MA(1) é dada por:

$$\rho_k = \begin{cases} \frac{-\theta_1}{1 + \theta_1^2}, & k = 1, \\ 0, & k > 1. \end{cases}$$

Observação: Se a série temporal tiver pelo menos uma raiz unitária (ou tendência estocástica), denotando-a por $I(k), k \geq 1$, tomaremos k diferenças de ordem 1 obtendo uma nova série temporal $I(0)$.

3.2. MODELO SAZONAL AUTORREGRESSIVO INTEGRADO DE MÉDIAS MÓVEIS (SARIMA)

O modelo autorregressivo integrado de médias móveis (ARIMA) foi popularizado por Box e Jenkins (1970) e tornou-se um “*benchmark*”¹ na área de séries temporais. Sua fundação básica é descrever o valor presente de uma série temporal como uma função de seus valores passados. Muitas séries econômicas contêm o fenômeno sazonal, ou seja, possuem um padrão de comportamento que tende a se repetir após um determinado período de tempo é chamado de período sazonal (Wei, 2006). O modelo sazonal autorregressivo integrado de médias móveis (SARIMA) $(p,d,q) \times (P,D,Q)_t$ é determinado pela Eq. 3.1.

$$\Phi_P(B^S) \phi_p(B)(1 - B)^d (1 - B^S)^D \Delta y_t = \theta_q(B) \Theta_Q(B^S) \varepsilon_t \quad (3.1)$$

onde:

$$\Delta y_t = \begin{cases} \Delta y_t - \mu, & \text{se } d = D = 0; \\ \Delta y_t, & \text{caso contrário;} \end{cases}$$

$\phi_p(B)$ e $\theta_q(B)$ = autorregressivo e médias moveis;

$\Phi_P(B^S)$ e $\Theta_Q(B^S)$ = sazonal autorregressivo e médias móveis;

s = referência do período sazonal.

A estimação é feita por máxima verossimilhança.

3.3. MODELO VETORIAL AUTORREGRESSIVO (VAR)

O modelo de vetorial autorregressivo (VAR) surgiu na década de 80 como resposta às críticas quanto ao grande número de restrições impostas às estimações pelos modelos estruturais. A ideia era desenvolver modelos dinâmicos com o mínimo de restrições, nos quais todas as variáveis econômicas fossem tratadas

¹ Benchmark - Consiste no processo de busca das melhores práticas e conduzem ao desempenho superior.

como endógenas². Sendo assim, o modelo VAR examina relações lineares entre cada variável e os valores defasados dela própria e de todas as demais variáveis, impondo como restrições à estrutura da economia somente a escolha do conjunto relevante de variáveis e do número máximo de defasagens envolvidas nas relações entre elas. O processo VAR (p) é definido pela Eq. 3.2 (Pfaff, 2008).

$$y_t = A_0 + A_1 y_{t-1} + A_2 y_{t-2} + \dots + A_p y_{t-p} + \varepsilon_t \quad (3.2)$$

onde

y_t = um vetor (nx1) que contém cada uma das n covariáveis incluídas no VAR;

A_0 = um vetor (nx1) de interceptos;

A_i = uma matriz (nxn) de coeficientes;

ε_t = um vetor (nx1) dos erros;

Para selecionar o melhor modelo VAR, usa-se o critério de informação de Akaike (AIC), o qual é importante para determinar o número de defasagens a serem incluídas no modelo. A estimação do modelo VAR é feita por Mínimos Quadrados Ordinários. Depois de estimado, podemos trabalhar com a equação de previsão.

3.4. MODELO VETORIAL DE CORREÇÃO DE ERROS (VEC)

Assim como no modelo VAR, o modelo vetorial de correção de erros (VEC) examina relações lineares entre cada variável e os valores defasados dela própria e de todas as demais variáveis. Porém, quando as séries não são I(0) e são cointegradas, o modelo adequado é o modelo VEC, onde o mesmo é definido pela Eq. 3.3 (Pfaff, 2008).

$$\Delta y_t = \pi_0 + \pi y_{t-1} + \pi_1 \Delta y_{t-1} + \pi_2 \Delta y_{t-2} + \dots + \pi_p \Delta y_{t-p} + \varepsilon_t \quad (3.3)$$

onde:

π_0 = um vetor (nx1) de termos de intercepção dos elementos π_{i0} ;

π_1 = uma matriz (nxn) de coeficientes com elementos $\pi_{jk}(i)$;

π = uma matriz com elementos π_{jk} tal que um ou mais dos $\pi_{jk} \neq 0$;

ε_t = um vetor (nx1) com elementos ε_{it} ;

² Variáveis endógenas – são as variáveis explicadas e determinadas pelas equações do modelo. O oposto seriam as variáveis exógenas que são explicadas e determinadas fora do modelo, introduzindo informações externas necessárias ao modelo.

O modelo VEC é estimado por Máxima Verossimilhança Concentrada, seguindo o procedimento de Johansen (1995). Depois de estimado o modelo VEC, podemos trabalhar com a equação de previsão.

3.5. EQUAÇÕES DE PREVISÃO E COMPARAÇÃO DE MODELOS

A equação de previsão escolhida é aquela que minimiza o erro quadrático médio de previsão. Pode-se mostrar que a mesma é obtida pela esperança de y_t dado o conjunto de informações até o instante $t-1$, I_{t-1} . Para a escolha do modelo adequado é importante realizar uma comparação de modelos. Neste trabalho foi utilizado o teste de Diebold-Marino (Diebold, 1995), onde a hipótese nula do teste bicaudal é que dois modelos possuem a mesma capacidade de previsão. Para mensurar o poder de previsão, comparou-se o erro quadrático médio da previsão dos modelos.

O teste de Diebold-Mariano foi aplicado em outros trabalhos para comparar previsões, como é possível ver, entre vários exemplos, nos estudos dos autores Zuanazzi e Ziegelmann (2014) utilizando o modelo MIDAS para realizar previsão do Produto Interno Bruto (PIB). E no estudo de Duarte (2014) com modelos ARIMA, GARCH e RNA para prever a vazão em redes.

4. ANÁLISE EMPÍRICA

Neste trabalho utilizamos os dados da taxa de desemprego de três grandes regiões metropolitanas do país, Porto Alegre, São Paulo e Salvador. A escolha destas regiões ocorreu em função de sua localização em diferentes regiões do Brasil (sul, sudeste e nordeste). As séries temporais são mensais e cada série tem 152 observações. Os dados utilizados foram extraídos da Pesquisa de Emprego e Desemprego (PED), que é realizada por órgãos ligados aos governos estaduais e municipais de cada região de estudo.

A PED ainda realiza a pesquisa em outras regiões como o Distrito Federal e as regiões metropolitanas de Fortaleza e Belo Horizonte. Mas estas séries não podem ser trabalhadas com estes modelos por diferentes questões. Para o Distrito Federal e a região metropolitana de Belo Horizonte houve quebra de série, e na região metropolitana de Fortaleza, há poucas observações. No site do DIEESE estão disponíveis as séries da taxa de desemprego (DIEESE, 2016).

4.1. DESCRIÇÃO DA MODELAGEM

Utilizamos três classes de modelos de séries temporais para realizar a modelagem e previsão, SARIMA, VAR e VEC para as três regiões metropolitanas, Porto Alegre, São Paulo e Salvador. A PED ainda realiza a pesquisa em outras regiões como o Distrito Federal e as regiões metropolitanas de Fortaleza e Belo Horizonte. Mas estas séries não podem ser trabalhadas com estes modelos por diferentes questões, para o Distrito Federal e a região metropolitana de Belo Horizonte por ter quebra de série, e na região metropolitana de Fortaleza por não ter observações suficientes para ser aplicado os modelos econométricos. A seguir apresentamos a metodologia aplicada em cada classe de modelos.

4.1.1. SARIMA

Para trabalhar com o modelo SARIMA utilizamos o programa de análise estatística R versão 3.3.0. O código da análise é encontrado no apêndice D. Antes de iniciar a modelagem dos dados, foram testadas as suposições do modelo. Para a estacionariedade realizamos o teste da raiz unitária de Dickey-Fuller (ver mais

detalhes em Enders, 2015 página 195). Para a hipótese nula de independência realizamos o teste de Ljung-Box. A normalidade dos resíduos avaliamos graficamente. A suposição de estacionariedade foi rejeitada, portanto foi realizada a primeira diferença como sugerido na literatura (por exemplo, Enders, 2015).

Após a primeira diferença, é verificado através do teste da raiz unitária de Dickey – Fuller que a série se torna estacionária, $I(0)$. Na modelagem trabalhamos usando a primeira diferença na parte não sazonal e nenhuma diferença na parte sazonal já que a série sazonal é $I(0)$, como vimos através do teste da raiz unitária sazonal baseado em Hylleberg *et al* (1990). Após as suposições atendidas, as séries da taxa de desemprego foram trabalhadas com e sem as covariáveis macroeconômicas. Para determinarmos a defasagem de série das covariáveis, analisamos a correlação das séries em cada mês em relação a taxa de desemprego de cada região metropolitana. Então, o mês com maior R^2 foi selecionado. Para analisar a taxa de juros (Selic) utilizamos com 9 meses de defasagem, ou seja, iniciando em abril de 2003. Para avaliar Índice de Atividade Econômica do Banco do Brasil (IBC) de cada região metropolitana, e a Produção Industrial Mensal (PIM) de cada região metropolitana, utilizamos a série com 3 meses de defasagem, ou seja, iniciando em outubro de 2003. Os coeficientes estimados pelo modelo SARIMA não foram significativos para as covariáveis macroeconômicas, portanto, para trabalhar com este modelo utilizamos somente as taxas de desemprego.

Para realizarmos as previsões dos valores futuros das taxas de desemprego selecionamos os modelos que apresentaram os menores valores de Akaike (AIC) com 12 passos à frente. Trabalhamos com três diferentes períodos de tempo em cada uma das regiões metropolitanas, de 2004 a 2013, de 2004 a 2014 e de 2004 a 2015, para prever os anos de 2014, 2015 e o primeiro semestre de 2016, respectivamente.

Entre os modelos SARIMA testados neste trabalho, o que melhor se ajustou pelo critério de informação de AIC para a Região Metropolitana de Porto Alegre (RMPA) foi o modelo SARIMA $(4,1,4) \times (1,0,0)_{12}$. Ou seja, na parte não sazonal com 4 termos autorregressivos e 4 termos médias móveis, e na sazonal, um termo autorregressivo. O período da sazonalidade é 12, ou seja, temos um ciclo de comportamento que se repete de 12 em 12 meses. O modelo que melhor se ajustou pelo critério de informação de Akaike para a Região Metropolitana de São Paulo (RMSP) foi o modelo SARIMA $(9,1,9) \times (0,0,1)_{12}$, ou seja, na parte não sazonal com

9 termos autorregressivos e 9 termos médias móveis e, na sazonal, um termo autorregressivo. O período da sazonalidade é 12. O modelo que melhor se ajustou pelo critério de informação de Akaike para a Região Metropolitana de Salvador (RMS) foi o mesmo que o modelo SARIMA da RMSP.

4.1.2. VAR e VEC

Os modelos VAR e VEC foram trabalhados utilizando dois programas estatísticos, o programa R versão 3.3.0 e o programa EViews versão 9.5 versão estudante. Modelamos três diferentes períodos de tempo em cada uma das regiões metropolitanas, de 2004 a 2013, de 2004 a 2014 e de 2004 a 2015, para prever os anos de 2014, 2015 e o primeiro semestre de 2016, respectivamente.

Foram modelados quatro modelos VEC onde: no modelo 1 utilizamos a taxa de desemprego de Porto Alegre, SELIC, IBC-RS e PIM-RS, no modelo 2 utilizamos a taxa de desemprego de São Paulo, SELIC, IBC-SP e PIM-SP. No modelo 3 utilizamos a taxa de desemprego de Salvador, SELIC, IBC-BA e PIM-BA e o modelo 4 utilizamos as taxas de desemprego da RMPA, RMSP, RMS, a taxa SELIC, os indicadores IBC das três regiões metropolitanas. O modelo VAR foi um modelo contendo as três taxas de desemprego, RMPA, RMSP e RMS.

Testamos as suposições do modelo, para a estacionariedade realizamos o teste da raiz unitária de Dickey-Fuller. Para a hipótese nula de independência realizamos o teste de Ljung-Box. Realizamos o teste de Johansen (Johansen, 1995) para investigar a cointegração. Para a homocedasticidade da série realizamos o teste de heterocedasticidade de Harvey e a normalidade dos resíduos avaliamos graficamente. Realizamos os testes descritos acima em todas as dez séries temporais trabalhadas neste estudo. A suposição de que a série possui raiz unitária não foi rejeitada em todas das séries. Realizamos a primeira diferença como sugere a literatura (Enders, 2015) em cada uma das séries, após a primeira diferença as séries se tornam $I(0)$, como é possível verificar através do teste da raiz unitária de Dickey – Fuller.

Como visto no capítulo 3, se existir cointegração, devemos usar o modelo VEC ao invés do VAR. Todos os grupos obtiveram cointegração exceto pelo último grupo, onde temos somente as taxas de desemprego das três regiões metropolitanas, aplicamos o modelo VAR neste último grupo e nos demais grupos o modelo VEC. Para verificarmos as suposições dos modelos, utilizamos o

programa R, já para estimar com as séries utilizamos o programa EViews. No entanto todos os resultados gráficos apresentados neste trabalho foram gerados no programa R para uniformização dos gráficos.

Para a escolha da ordem tanto do VAR como do VEC foram testadas diversas defasagens e selecionado o modelo que obteve menor valor do AIC como é possível ver nas tabelas 4.1 até 4.6 para cada grupo de variáveis. A ordem VAR (7) foi escolhida para a RMPA nos três anos, já que todas têm o menor valor de AIC com 0,366, 0,414 e 0,499, Tabela 4.1.

A ordem VAR (12) foi escolhida para a RMSP nos anos de 2014 e 2015, pois tem os menores valores de AIC, 0,563 e 0,547 e a ordem VAR (13) para 2016, com o valor de AIC de 0,589, Tabela 4.2. A ordem VAR (13) foi escolhida para a RMS nos três anos, já que todas têm o menor valor de AIC com 1,366, 1,406 e 1,32, Tabela 4.3.

Na tabela 4.1 são apresentados os valores de AIC obtidos pelas estimativas do modelo VAR para os anos de 2014, 2015 e 2016 para a região metropolitana de Porto Alegre.

Tabela 4.1 – Valores AIC do modelo VAR da RMPA.

Ordem	2014	2015	2016
VAR (1)	1.120947	1.064551	1.082115
VAR (2)	0.778985	0.745331	0.743201
VAR (3)	0.676819	0.654139	0.666904
VAR (4)	0.544875	0.52641	0.567341
VAR (5)	0.489981	0.500301	0.524372
VAR (6)	0.420226	0.475533	0.521351
VAR (7)	0.366046	0.413678	0.498635
VAR (8)	0.426632	0.465368	0.533429
VAR (9)	0.481817	0.50642	0.576882
VAR (10)	0.412014	0.446764	0.53674
VAR (11)	0.407361	0.434367	0.530717
VAR (12)	0.469616	0.460528	0.520395

Na tabela 4.2 são apresentados os valores de AIC obtidos pelas estimativas do VAR para os anos de 2014, 2015 e 2016 para a região metropolitana de São Paulo.

Tabela 4.2 – Valores AIC do modelo VAR da RMSP.

Ordem	2014	2015	2016
VAR (1)	1.385965	1.37811	-
VAR (2)	1.118193	1.058785	1.065843
VAR (3)	1.109204	1.047284	1.065587
VAR (4)	0.958294	0.931428	0.977414
VAR (5)	0.924067	0.917584	0.952664
VAR (6)	0.874472	0.871323	0.941273
VAR (7)	0.760867	0.76411	0.850056
VAR (8)	0.751742	0.764968	0.872277
VAR (9)	0.728794	0.716108	0.852406
VAR (10)	0.584811	0.554311	0.684284
VAR (11)	0.585928	0.570007	0.663676
VAR (12)	0.562714	0.54664	0.601636
VAR (13)	0.593177	0.569667	0.589597
VAR (14)	0.615278	0.579804	0.601528
VAR (15)	0.619165	0.585533	0.591993

Na tabela 4.3 são apresentados os valores de AIC obtidos pelas estimativas do VAR para os anos de 2014, 2015 e 2016 para a região metropolitana de Salvador.

Tabela 4.3 – Valores AIC do modelo VAR da RMS.

Ordem	2014	2015	2016
VAR (1)	1.876507	1.823476	1.778328
VAR (2)	1.752262	1.705143	1.670675
VAR (3)	1.802966	1.752503	1.716252
VAR (4)	1.612057	1.576012	1.536159
VAR (5)	1.604996	1.589576	1.541556
VAR (6)	1.599224	1.587105	1.553119
VAR (7)	1.603674	1.58847	1.542886
VAR (8)	1.643861	1.619269	1.583732
VAR (9)	1.582469	1.603603	1.5818
VAR (10)	1.504969	1.544949	1.534074
VAR (11)	1.414827	1.470636	1.465333
VAR (12)	1.42614	1.464167	1.430014
VAR (13)	1.366213	1.405964	1.32042
VAR (14)	1.370985	1.425331	1.333542
VAR (15)	1.43867	1.48748	1.385689

A ordem VEC (9) foi escolhida para a RMPA no ano de 2014, pois tem o menor valor de AIC de 0,351, e a ordem VEC (7) para os anos de 2015 e 2016 já que têm

os menores valores de AIC com 0,358 e 0,447, Tabela 4.4. A ordem VEC (9) foi escolhida para a RMSP nos anos de 2014 e 2016, pois tem os menores valores de AIC, 0,264 e 0,387.

E a ordem VAR (8) para 2015 com o valor de AIC de 0,218, Tabela 4.5. A ordem VAR (14) foi escolhida para a RMS nos anos de 2014 e 2015 já que têm os menores valores de AIC com 1,07 e 1,103 e a ordem VEC (12) no ano de 2016 com o menor de valor de AIC de 1,309, Tabela 4.6.

Na tabela 4.4 são apresentados os valores de AIC obtidos pelas estimativas do VEC para os anos de 2014, 2015 e 2016 para a região metropolitana de Porto Alegre.

Tabela 4.4 – Valores AIC do modelo VEC da RMPA.

Ordem	2014	2015	2016
VAR (1)	0.861159	0.81145	0.862119
VAR (2)	0.843567	0.802441	0.842809
VAR (3)	0.626586	0.477834	0.549199
VAR (4)	0.392088	0.405651	0.532722
VAR (5)	0.429556	0.476822	0.489325
VAR (6)	0.4648	0.500393	0.484112
VAR (7)	0.419667	0.357618	0.447121
VAR (8)	0.45048	0.4353	0.467012
VAR (9)	0.350665	0.38824	0.447527
VAR (10)	0.416194	0.427929	0.50178
VAR (11)	0.431076	0.402078	0.511046
VAR (12)	0.497183	0.450907	0.585997

Na tabela 4.5 são apresentados os valores de AIC obtidos pelas estimativas do VEC para os anos de 2014, 2015 e 2016 para a região metropolitana de São Paulo.

Tabela 4.5 – Valores AIC do modelo VEC da RMSP.

Ordem	2014	2015	2016
-------	------	------	------

VAR (1)	0.532931	0.472519	0.522141
VAR (2)	0.520274	0.463884	0.533262
VAR (3)	0.429365	0.351238	0.459078
VAR (4)	0.367322	0.287972	0.42075
VAR (5)	0.448511	0.385157	0.483085
VAR (6)	0.481861	0.407968	0.509413
VAR (7)	0.308899	0.263984	0.418428
VAR (8)	0.292435	0.217988	0.395979
VAR (9)	0.263704	0.237535	0.387015
VAR (10)	0.344769	0.277574	0.403434
VAR (11)	0.30794	0.269574	0.452462
VAR (12)	0.340736	0.289282	0.432985

Na tabela 4.6 são apresentados os valores de AIC obtidos pelas estimativas do VEC para os anos de 2014, 2015 e 2016 para a região metropolitana de Salvador.

Tabela 4.6 – Valores AIC do modelo VEC da RMS.

Ordem	2014	2015	2016
VAR (1)	1.754795	1.727601	1.691764
VAR (2)	1.761269	1.730695	1.72942
VAR (3)	1.550851	1.535991	1.573348
VAR (4)	1.576276	1.554671	1.582544
VAR (5)	1.567001	1.519993	1.512602
VAR (6)	1.49288	1.434161	1.412959
VAR (7)	1.520006	1.448644	1.414829
VAR (8)	1.489683	1.407521	1.391944
VAR (9)	1.478177	1.400827	1.414601
VAR (10)	1.340479	1.304638	1.415071
VAR (11)	1.347511	1.296783	1.417242
VAR (12)	1.280634	1.246502	1.309311
VAR (13)	1.294112	1.227538	1.367475
VAR (14)	1.070032	1.103005	1.310656
VAR (15)	1.128987	1.178796	1.352681

4.1.3. Teste Diebold Mariano

Para a comparação de modelos pelo teste de Diebold-Mariano, foram realizadas previsões um passo à frente por 36 meses, ou seja, modelado de 2004 a 2011, para prever 2012, 2013, 2014 e assim respectivamente até 2004 a 2013, para prever do primeiro semestre de 2014, o ano de 2015 até o primeiro semestre de 2016.


O teste realizado tem a modificação proposta por Harvey, Leybourne e Newbold em 1997 (Hydman, 2016). A hipótese nula do teste é que os dois modelos possuem a mesma capacidade de previsão, ou seja, quando rejeita a hipótese nula um modelo deve ser mais preciso. Quando o teste rejeita a hipótese nula olhamos para a soma dos erros quadrados de previsão para identificar o melhor modelo.

4.2. RESULTADOS

Neste tópico apresentaremos os resultados obtidos dos modelos SARIMA, VAR e VEC das três regiões metropolitanas, e apresentaremos a discussão. No entanto, antes de iniciarmos a apresentação dos resultados dos modelos, iremos apresentar uma análise inicial das séries temporais que trabalhamos neste estudo.

4.2.1. Análise inicial das séries da taxa de desemprego

Primeiramente realizamos uma avaliação inicial das séries da taxa de desemprego. Na Fig. 4.1, são mostradas as séries das taxas de desemprego das três regiões metropolitanas: Porto Alegre, São Paulo e Salvador, no período de 2004 a 2016.






Figura 4.1 - Séries temporais da taxa de desemprego das Regiões Metropolitanas entre 2004 e 2016.

(a) Porto Alegre. (b) São Paulo. (c) Salvador.

As séries temporais apresentadas na Fig. 4.1 são mensais e possuem 152 observações no período dos 12 anos. Ao analisarmos visualmente, podemos perceber que existem tendências e sazonalidades nas séries, portanto, é possível que as séries temporais sejam não estacionárias. Calculamos as funções de autocorrelação e as funções de autocorrelação parcial das séries das taxas de desemprego, onde as mesmas podem ser observadas no apêndice A. Como as funções tem decaimento lento, é provável que as séries possuam tendência. Além do teste visual através do gráfico da função de autocorrelação, também realizamos o teste da raiz unitária de Dickey-Fuller. Neste teste, a hipótese nula é que tenhamos pelo menos uma raiz unitária. Como o p-valor resultou em maior que 0.05, não é rejeitada a hipótese. Logo as séries das taxas de desemprego podem não ser estacionárias. Como é necessário que as séries sejam estacionárias para utilizamos os modelos SARIMA, VAR ou VEC, tomamos as diferenças das séries.

No apêndice A, as Fig. A.1, Fig. A.2 e Fig. A.3 mostram a primeira diferença das séries, suas respectivas funções de autocorrelação e funções de autocorrelação parcial. Neste momento, visualmente, a séries de taxa de desemprego parecem ser estacionárias. Novamente realizamos o teste da raiz unitária de Dickey-Fuller. O p-valor resultou em menor que 0.05, ou seja, é rejeitada a hipótese nula. Assim, podemos concluir que a primeira diferença das séries da taxa de desemprego são estacionárias, $I(0)$, ao nível de significância de 5%.

No apêndice B, as Fig. B.1, Fig. B.2 e Fig. B.3, mostram as séries e as funções de autocorrelação das covariáveis macroeconômicas. As séries das covariáveis macroeconômicas apresentam tendência e aparentemente possuem sazonalidade,

e com a análise visual poderíamos assumir que as séries macroeconômicas possuam raízes unitárias. No entanto, visualmente através da função de autocorrelação não temos como concluir que as séries das covariáveis realmente sejam não estacionárias, pois apresentam um decaimento não tão lento como nas séries de desemprego analisadas anteriormente.

Pelo teste da raiz unitária de Dickey-Fuller o p-valor foi maior que 0,05, logo não é rejeitada a hipótese nula de presença de raiz unitária. Tomamos a primeira diferença das séries e a função de autocorrelação das mesmas, como é possível ver no apêndice B, nas Fig. B.4, Fig. B.5 e Fig. B.6. Para a primeira diferença, as séries aparentam ser estacionárias a partir de uma análise visual. Novamente realizado o teste da raiz unitária de Dickey-Fuller, onde rejeitamos a hipótese nula.

4.2.2. Previsão da taxa de desemprego Região Metropolitana de Porto Alegre

Iniciaremos apresentando as previsões de taxa de desemprego para a região metropolitana de Porto Alegre (RMPA) dos modelos SARIMA, VAR e VEC, respectivamente. O comportamento da série ao longo dos dez anos tem tendência negativa, com leve aumento no primeiro semestre de cada ano e decaimento no segundo semestre. No segundo semestre de 2014 ocorreu um pequeno aumento da taxa de desemprego. Na Fig. 4.2a a previsão do desemprego pelo modelo SARIMA com 12 passos à frente ficou razoável, já que os primeiros meses ficaram bem previstos e ao longo das 12 previsões os dados reais permaneceram dentro dos intervalos de confiança. A previsão na Fig. 4.2b do modelo VAR (7) com as demais séries da taxa de desemprego mostram que só é eficiente nos primeiros meses do ano de 2014, após, a tendência das previsões não se mostra a mesma dos dados reais, porém as observações ainda se encontram dentro do intervalo de confiança. A previsão do modelo VEC (9) na Fig. 4.2c mostra que a inclusão de covariáveis macroeconômicas melhorou a previsão.

O ano de 2015 têm grande aumento no primeiro semestre, e no segundo semestre não decai, como visto nos anos anteriores. Ao observarmos a Fig. 4.3a, parece que a previsão com o modelo SARIMA não é boa, e logo nos primeiros meses os dados reais já estão fora do intervalo de confiança. A previsão da Fig. 4.3b pelo modelo VAR (7) com as demais séries da taxa de desemprego mostram não serem boas com o impacto grande do aumento da taxa de desemprego. O comportamento é muito semelhante ao do modelo SARIMA, onde já nos primeiros meses os dados reais saem do intervalo de confiança. A previsão do modelo VAR (7) indica que irá diminuir a taxa de desemprego no segundo semestre, quando na realidade ocorre um aumento elevado da taxa. A previsão da Fig. 4.3c pelo modelo VEC (9) mostra que com as covariáveis macroeconômicas a previsão melhora consideravelmente, pois consegue prever que a taxa de desemprego da RMPA aumenta neste período. Apesar que em dois pontos os dados reais saírem do intervalo de confiança podemos dizer que é um bom modelo para o caso de 2015, onde temos uma mudança significativa na tendência da série.

Na Fig. 4.4a temos a previsão do primeiro semestre de 2016 com o modelo SARIMA, a previsão segue o padrão de aumento no primeiro semestre do ano, mas

subestima as observações. Nos primeiros meses os dados reais estão no limite superior do intervalo de confiança. Podemos dizer que é um modelo razoável para o primeiro semestre de 2016. Na Fig. 4.4b temos a previsão do primeiro semestre de 2016 do modelo VAR (7) com as demais séries da taxa de desemprego, a previsão segue semelhante com a previsão do modelo SARIMA, os primeiros meses estão no limite superior do intervalo de confiança. Os dados previstos estão subestimados nos primeiros meses, e os últimos ficam mais próximos dos dados reais. Podemos dizer que este modelo ficou razoável para este caso de 2016. A previsão do primeiro semestre de 2016 com o modelo VEC (7), Fig. 4.4c, mostra que com as covariáveis macroeconômicas a previsão segue semelhante com os demais modelos. E a previsão subestima mais os dados reais da taxa de desemprego nos primeiros meses saindo do limite superior do intervalo de confiança. Nos meses seguintes a previsão fica mais próxima dos dados reais. Podemos assumir que o modelo VEC (7) não é o mais adequado para estimar o caso de 2016.

A Fig. 4.2a apresenta a previsão da taxa de desemprego para os 12 meses do ano de 2014 com o modelo SARIMA para a RMPA. A Fig. 4.2b apresenta a previsão da taxa de desemprego para os 12 meses do ano de 2014 para a RMPA com o modelo VAR (7) utilizando como covariáveis as taxas de desemprego das RMs de Porto Alegre, São Paulo e Salvador. A Fig. 4.2c apresenta a previsão da taxa de desemprego para os 12 meses do ano de 2014 para a RMPA com o modelo VEC (9) utilizando a série da taxa de desemprego da RMPA, e as covariáveis SELIC, IBC-RS e PIM-RS.

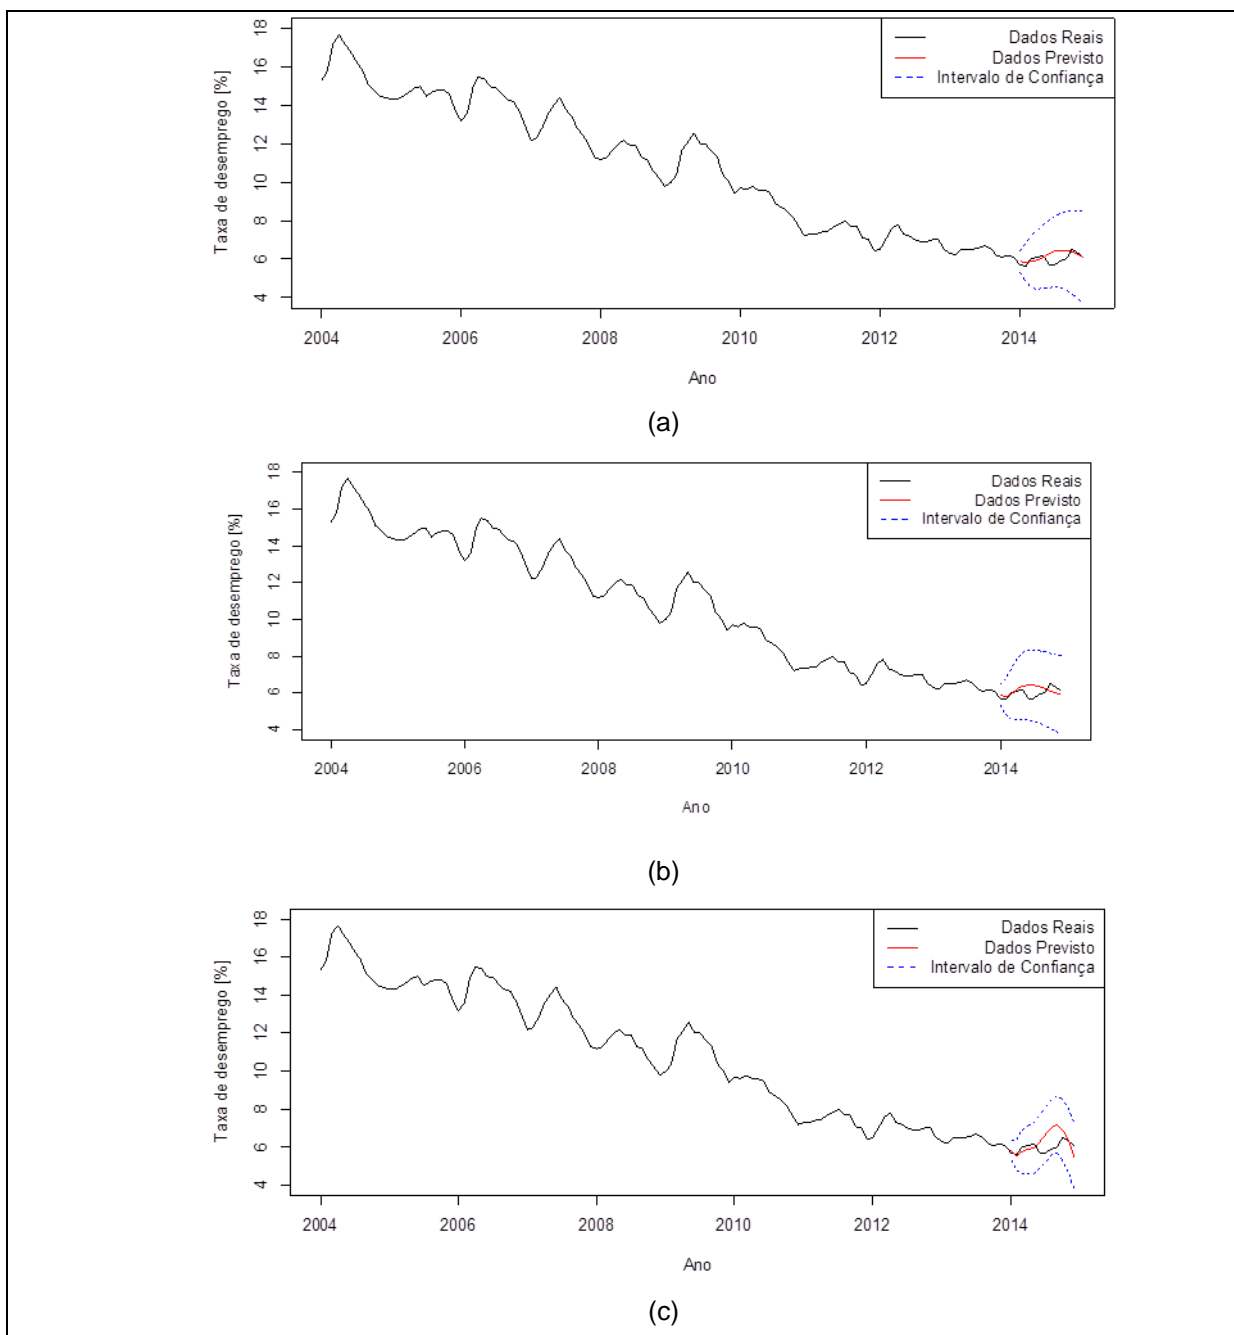


Figura 4.2 – Prevendo o ano de 2014 para Região Metropolitana de Porto Alegre. (a) Taxa de desemprego modelo SARIMA $(4,1,4) \times (1,0,0)$. (b) Taxa de desemprego modelo VAR (7) com taxas de desemprego das RMs de POA, SP e SAL. (c) Taxa de desemprego modelo VEC (9) com covariáveis SELIC, IBC-RS e PIM-RS.

A Fig. 4.3a mostra a previsão da taxa de desemprego para os 12 meses do ano de 2015 com o modelo SARIMA para a RMPA. A Fig. 4.3b mostra a previsão da taxa de desemprego para os 12 meses do ano de 2015 para a RMPA com o modelo VAR (7) utilizando como covariáveis as taxas de desemprego das RMs de POA, SP e SAL. A Fig. 4.3c mostra a previsão da taxa de desemprego para os 12

meses do ano de 2015 para a RMPA com o modelo VEC (7) utilizando a série da taxa de desemprego da RMPA, e as covariáveis SELIC, IBC-RS e PIM-RS.

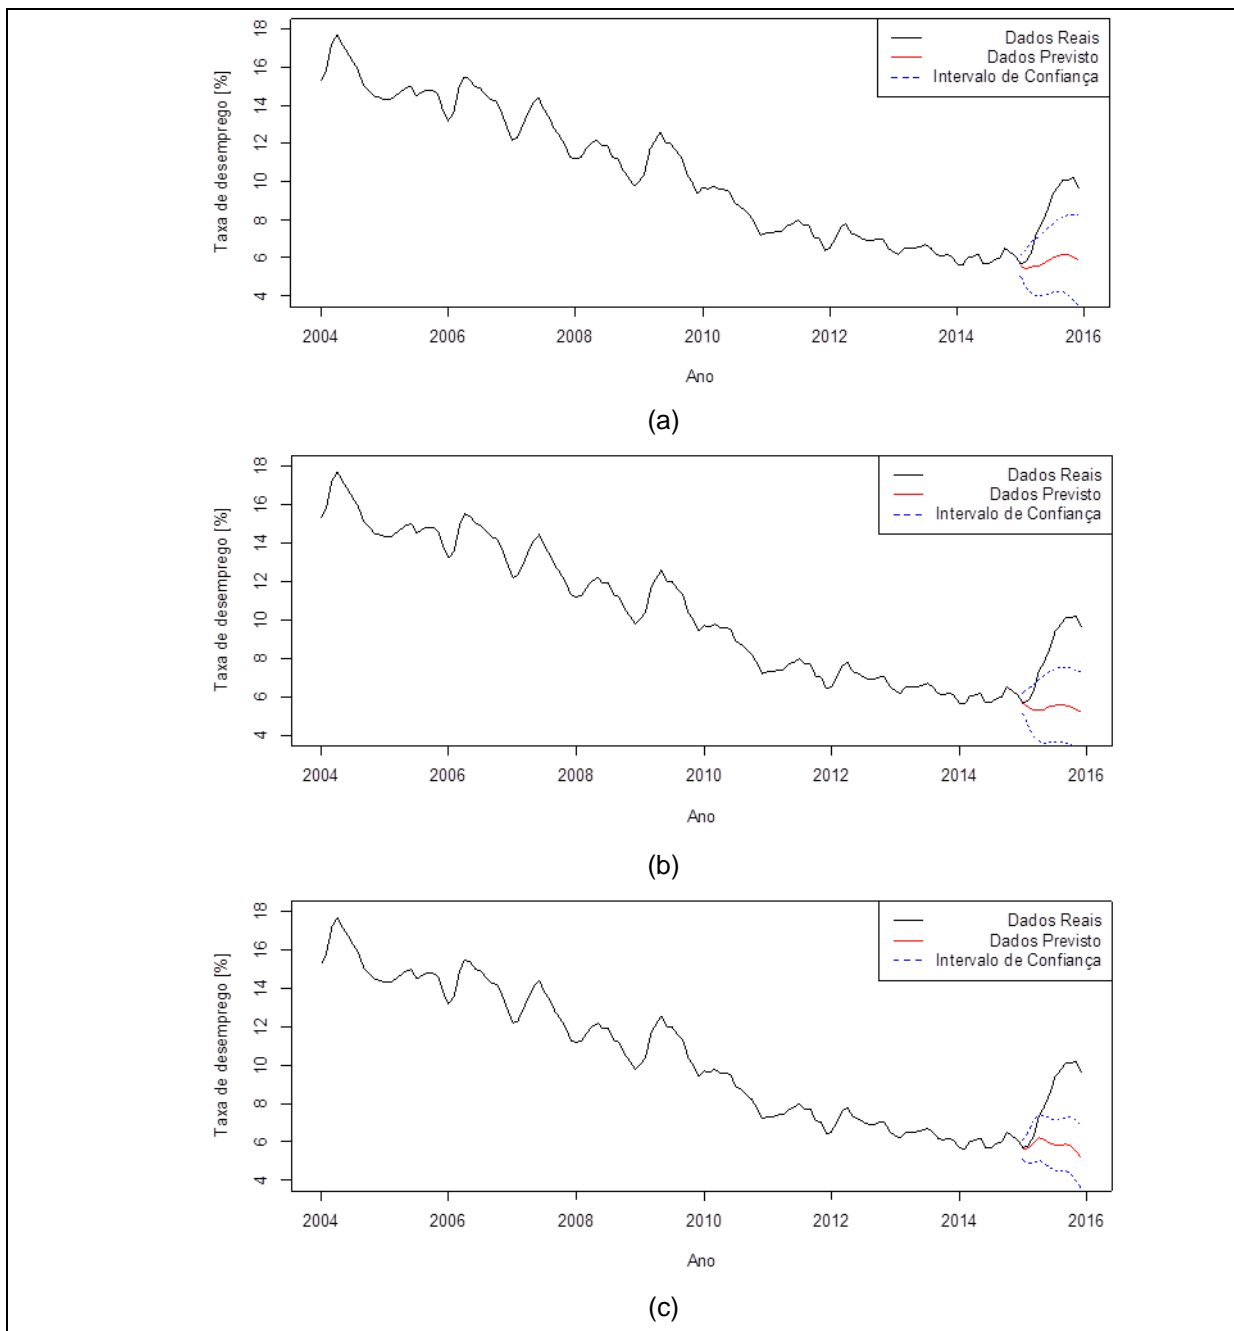


Figura 4.3 – Prevendo o ano de 2015 para Região Metropolitana de Porto Alegre. (a) Taxa de desemprego modelo SARIMA $(4,1,4) \times (1,0,0)$. (b) Taxa de desemprego modelo VAR (7) com taxas de desemprego das RMs de POA, SP e SAL. (c) Taxa de desemprego modelo VEC (7) com covariáveis SELIC, IBC-RS e PIM-RS.

A Fig. 4.4a apresenta a previsão da taxa de desemprego para os 6 meses do primeiro semestre de 2016 com o modelo SARIMA para a RMPA. A Fig. 4.4b apresenta a previsão da taxa de desemprego para os 6 meses do primeiro semestre

de 2016 para a RMPA com o modelo VAR (7) utilizando como covariáveis as taxas de desemprego das RMs de POA, SP e SAL. A Fig. 4.4c apresenta a previsão da taxa de desemprego para os 6 meses do primeiro semestre de 2016 para a RMPA com o modelo VEC (7) utilizando a série da taxa de desemprego da RMPA, e as covariáveis SELIC, IBC-RS e PIM-RS.




Figura 4.4 – Prevendo o primeiro semestre de 2016 para Região Metropolitana de Porto Alegre. (a) Taxa de desemprego modelo SARIMA (4,1,4)x(1,0,0). (b) Taxa de desemprego modelo VAR (7) com taxas de desemprego das RMs de POA, SP e SAL. (c) Taxa de desemprego modelo VEC (7) com covariáveis SELIC, IBC-RS e PIM-RS.

4.2.3. Previsão da taxa de desemprego Região Metropolitana de São Paulo

A próxima região a ser discutida é a Região Metropolitana de São Paulo (RMSP). É possível observar na Fig. 4.5a que o comportamento da série ao longo dos dez anos tem tendência negativa, com leve aumento no primeiro semestre de cada ano e decaimento no segundo semestre, assim como na RMPA. Pela previsão do modelo SARIMA observamos que no primeiro trimestre de 2014, há um aumento dos dados observados saindo do limite superior do intervalo de confiança. Podemos dizer que a previsão pelo modelo SARIMA ficou satisfatória para o ano de 2014 da RMSP.

Na Fig. 4.5b, a previsão do modelo VAR (12) com as taxas de desemprego para o ano de 2014, mostra que segue a tendência dos dados observados, exceto para um valor do segundo semestre, que sai do intervalo de confiança no limite superior. Podemos dizer que usando VAR (12) a previsão ficou satisfatória para o ano de 2014 da RMSP.

Na Fig. 4.5c a previsão do modelo VEC (9) mostra que com as covariáveis macroeconômicas a previsão da taxa de desemprego para o ano de 2014 ficou com a mesma tendência e precisa. Porém nos últimos meses a previsão está subestimada e os dados reais ficam no limite superior do intervalo de confiança. Podemos dizer que para o ano de 2014 o modelo VEC (9) ficou satisfatória.

Assim como na RMPA, no ano de 2015 ocorre um aumento brusco da taxa de desemprego, não decaindo no segundo semestre como nos anos anteriores. Pela Fig. 4.6a é possível analisar que o comportamento da previsão da RMSP pelo modelo SARIMA, não consegue prever um aumento tão elevado na taxa de desemprego. Durante o primeiro semestre de 2015 os dados reais estão dentro do intervalo de confiança, já o segundo semestre a previsão não consegue estimar o aumento. A previsão do ano de 2015, Fig. 4.6b, do modelo VAR (12) com as demais taxas de desemprego, também não consegue ser eficiente quando temos um aumento da taxa de desemprego. Os dados reais ficam dentro do intervalo de confiança somente nos primeiros meses, a previsão não está precisa. Este comportamento com o modelo VAR (12) pode se dar devido as séries de desemprego não ter grande aumento da taxa de desemprego antes de 2015.

A previsão do ano de 2015, Fig. 4.6c, com o modelo VEC (8) mostra que com a inclusão de covariáveis macroeconômicas a previsão melhora em relação aos

demais modelos, pois consegue prever que a taxa de desemprego da RMSP aumenta bastante neste período. Apesar dos dados reais estar subestimados saindo do limite inferior do limite de confiança no primeiro semestre, no segundo semestre o modelo VEC (8) consegue uma precisão melhor do que os demais modelos. Podemos dizer que para o ano de 2015 o modelo VEC (8) é o mais adequado. O comportamento do modelo pode se dar devido as covariáveis macroeconômicas apresentar mudança de comportamento, ajustando assim, para uma previsão adequada.

O comportamento da taxa de desemprego da RMSP segue o padrão de aumento no primeiro semestre do ano, assim como na RMPA. A taxa de desemprego continuou a subir, indicando que a crise econômica continuava no primeiro semestre de 2016. A previsão do primeiro semestre de 2016 do modelo SARIMA, Fig. 4.7a, subestimou os valores reais, nos últimos meses do primeiro semestre os dados reais saíram do limite superior do intervalo de confiança. A previsão do primeiro semestre de 2016, Fig. 4.7b, do modelo VAR (13) com as demais taxas de desemprego não foi precisa, todos os dados reais saíram do intervalo de confiança no limite superior. Podemos concluir que o modelo VAR (13) para o primeiro semestre de 2016 não é adequado. Com o modelo VEC (9) a previsão do primeiro semestre de 2016, Fig. 4.7c, nos primeiros 3 meses de 2016 é bastante precisa. Contudo os últimos meses os dados reais saem do limite superior do intervalo de confiança. Podemos concluir que para o primeiro semestre de 2016 o modelo VEC (9) é o mais adequado.

A Fig. 4.5a apresenta a previsão da taxa de desemprego para os 12 meses do ano de 2014 com o modelo SARIMA para a RMSP. A Fig. 4.5b apresenta a previsão da taxa de desemprego para os 12 meses do ano de 2014 para a RMSP com o modelo VAR (12) utilizando como covariáveis as taxas de desemprego das RMs de POA, SP e SAL. A Fig. 4.5c apresenta a previsão da taxa de desemprego para os 12 meses do ano de 2014 para a RMSP com o modelo VEC (9) utilizando a série da taxa de desemprego da RMSP, e as covariáveis SELIC, IBC-SP e PIM-SP.

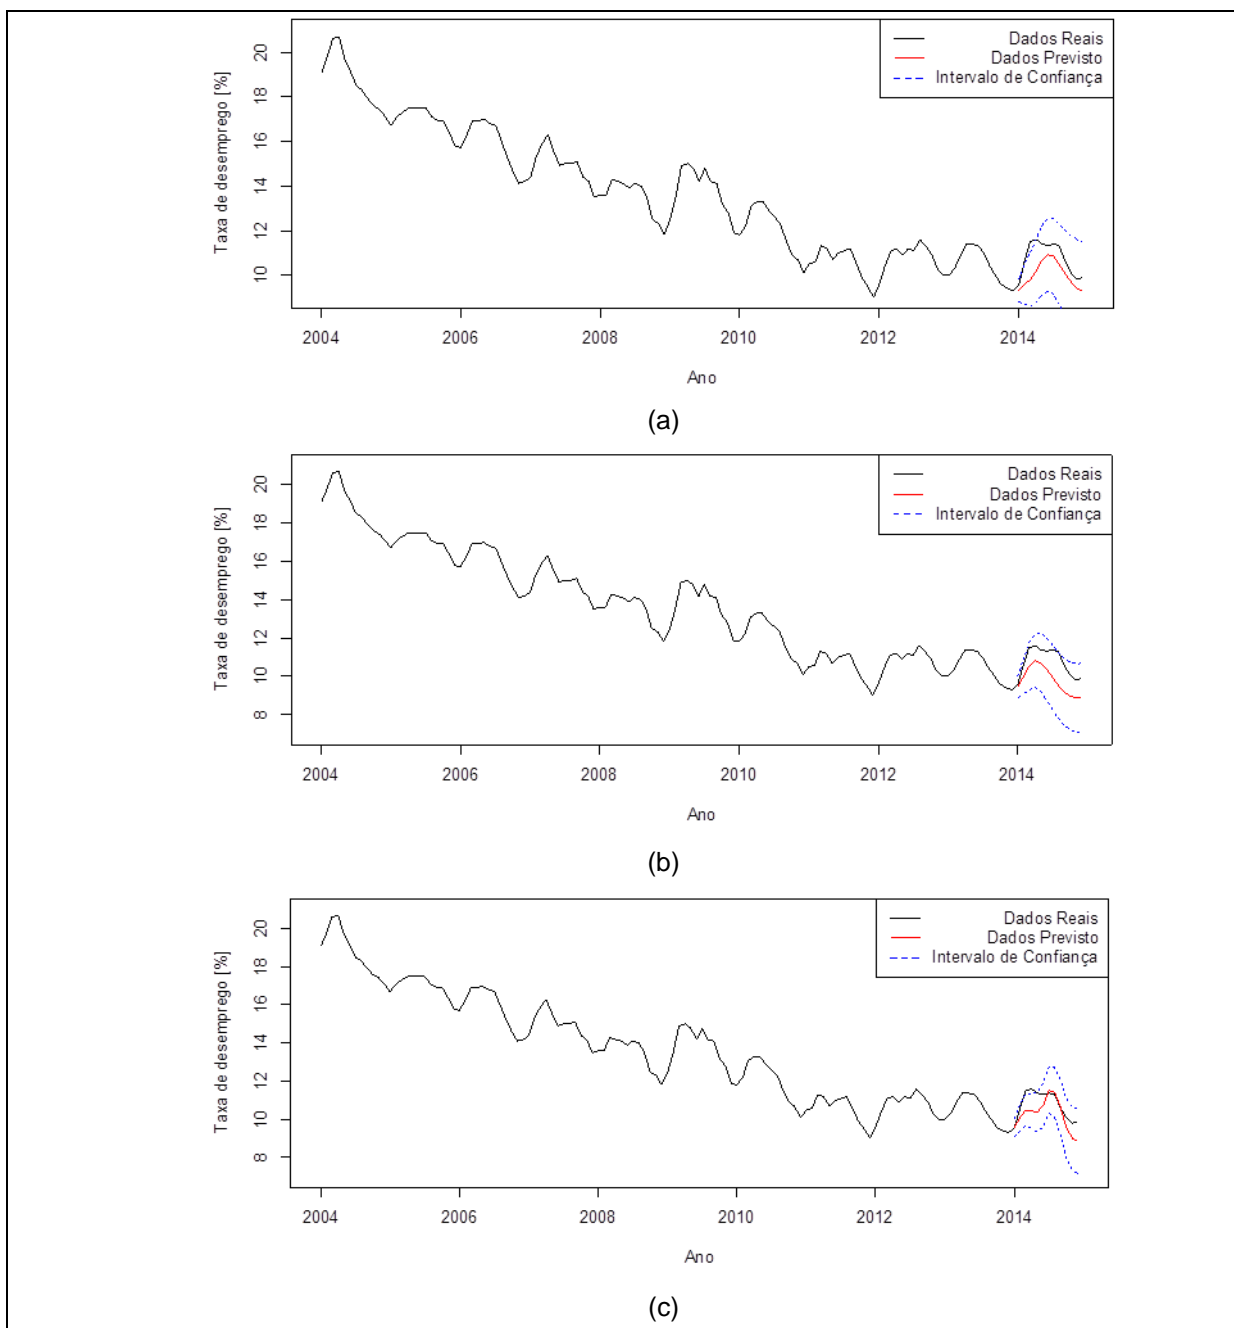


Figura 4.5 – Prevendo o ano de 2014 para Região Metropolitana de São Paulo. (a) Taxa de desemprego modelo SARIMA $(9,1,9) \times (0,0,1)$. (b) Taxa de desemprego modelo VAR (12) com taxas de desemprego das Regiões Metropolitanas de São Paulo, Porto Alegre e Salvador. (c) Taxa de desemprego modelo VEC (9) com covariáveis SELIC, IBC-SP e PIM-SP.

A Fig. 4.6a apresenta a previsão da taxa de desemprego para os 12 meses do ano de 2015 com o modelo SARIMA para a RMSP. A Fig. 4.6b apresenta a previsão da taxa de desemprego para os 12 meses do ano de 2015 para a RMSP com o modelo VAR (12) utilizando como covariáveis as taxas de desemprego das RMs de POA, SP e SAL. A Fig. 4.6c apresenta a previsão da taxa de desemprego para os 12 meses do ano de 2015 para a RMSP com o modelo VEC (8) utilizando

a série da taxa de desemprego da RMSP, e as covariáveis SELIC, IBC-SP e PIM-SP.




Figura 4.6 – Prevendo o ano de 2015 para Região Metropolitana de São Paulo. (a) Taxa de desemprego modelo SARIMA $(9,1,9) \times (0,0,1)$. (b) Taxa de desemprego modelo VAR (12) com taxas de desemprego das Regiões Metropolitanas de São Paulo, Porto Alegre e Salvador. (c) Taxa de desemprego modelo VEC (8) com covariáveis SELIC, IBC-SP e PIM-SP.

A Fig. 4.7a mostra a previsão da taxa de desemprego para os 6 meses do ano de 2016 com o modelo SARIMA para a RMSP. A Fig. 4.7b apresenta a previsão da taxa de desemprego para os 6 meses do ano de 2016 para a RMSP com o modelo

VAR (13) utilizando como covariáveis as taxas de desemprego das RMs de POA, SP e SAL. A Fig. 4.7c apresenta a previsão da taxa de desemprego para os 6 meses do ano de 2016 para a RMSP com o modelo VEC (9) utilizando a série da taxa de desemprego da RMSP, e as covariáveis SELIC, IBC-SP e PIM-SP.




Figura 4.7 – Prevendo o ano de 2016 para Região Metropolitana de São Paulo. (a) Taxa de desemprego modelo SARIMA $(9,1,9) \times (0,0,1)$. (b) Taxa de desemprego modelo VAR (13) com taxas de desemprego das Regiões Metropolitanas de São Paulo, Porto Alegre e Salvador. (c) Taxa de desemprego modelo VEC (9) com covariáveis SELIC, IBC-SP e PIM-SP.

4.2.4. Previsão da taxa de desemprego Região Metropolitana de Salvador

Neste tópico realizamos a análise para a Região Metropolitana de Salvador (RMS). É possível observar na Fig. 4.8a que o comportamento ao longo dos sete anos da série tem tendência negativa, com leve aumento no primeiro semestre de cada ano e decaimento no segundo semestre até o ano de 2011. No ano de 2012 até metade de 2013 a série começa a ter tendência positiva, ou seja, a RMS, tem um aumento da taxa de desemprego neste período. Após a metade de 2013 a série tem decaimento novamente, ou seja, houve novamente queda da taxa de desemprego.

Na RMS a taxa de desemprego é mais alta do que nas regiões metropolitanas, e também tem maior variabilidade entre os anos quando comparada com as demais regiões metropolitanas analisadas neste trabalho. A previsão do ano de 2014, Fig. 4.8a, do modelo SARIMA segue a tendência e fica próximo os dados reais. A taxa de desemprego da RMS para o ano de 2014 está dentro do intervalo de confiança para o modelo. O modelo VAR (13) com as demais taxas de desemprego, Fig. 4.8b, mostra que a previsão de 2014 segue a tendência dos dados reais, no entanto a partir do segundo semestre subestima os dados reais. A taxa de desemprego da RMS para o ano de 2014 está dentro do intervalo de confiança para o modelo VAR (13). O modelo VEC (14) mostra que com a inclusão de covariáveis macroeconômicas, Fig. 4.8c, a previsão do ano de 2014 é eficiente, pois segue a mesma tendência e são bastante precisos aos reais dados. A taxa de desemprego da RMS para o ano de 2014 está dentro do intervalo de confiança do modelo VEC (14).

Pela Fig. 4.9a, é possível observar que o comportamento da taxa de desemprego é semelhante com as demais séries no ano de 2015, devido ao aumento no primeiro semestre de 2015, e pelo segundo semestre não ter decaimento, como visto nos anos anteriores. A previsão do modelo SARIMA para 2015 mostra ser eficiente no primeiro semestre, todavia no último mês o dado real sai do limite superior do intervalo de confiança. A previsão do ano de 2015, Fig. 4.9b, do modelo VAR (13) com as demais taxas de desemprego mostra que é eficiente nos primeiros meses do ano de 2015 e no segundo semestre a previsão subestima os dados reais, mas os dados permanecem dentro do intervalo de confiança. A previsão do ano de 2015, Fig. 4.9c, do modelo VEC (14) mostra que

com as covariáveis macroeconômicas o primeiro semestre está superestimando os dados reais. Nos primeiros meses do ano de 2015 os dados reais saem do limite inferior do intervalo de confiança e no segundo semestre os reais dados permanecem dentro do intervalo de confiança e a previsão com o modelo VEC (14) é precisa.

A previsão da taxa de desemprego do primeiro semestre de 2016, Fig. 4.10a, do modelo SARIMA subestima os dados reais nos últimos meses do primeiro semestre de 2016, saindo do limite superior. A previsão do primeiro semestre de 2016, Fig. 4.10b, do modelo VAR (13) com as demais taxas de desemprego mostra que os primeiros meses a previsão segue os dados reais e nos últimos meses a previsão não fica tão precisa, e somente o último dado previsto sai do intervalo de confiança. A previsão do primeiro semestre de 2016, Fig. 4.10c do modelo VEC (12) mostra que com a inclusão de covariáveis macroeconômicas, melhora em relação aos demais modelos para 2016, com a mesma tendência dos reais dados e precisos. Nos dois últimos meses a previsão não é tão exata, mas os dados reais permanecem dentro do intervalo de confiança.

A Fig. 4.8a apresenta a previsão da taxa de desemprego para os 12 meses do ano de 2014 com o modelo SARIMA para a RMS. A Fig. 4.8b apresenta a previsão da taxa de desemprego para os 12 meses do ano de 2014 para a RMS com o modelo VAR (13) utilizando como covariáveis as taxas de desemprego das RMs de POA, SP e SAL. A Fig. 4.8c apresenta a previsão da taxa de desemprego para os 12 meses do ano de 2014 para a RMS com o modelo VEC (14) utilizando a série da taxa de desemprego da RMS, e as covariáveis SELIC, IBC-BA e PIM-BA.




Figura 4.8 – Prevendo o ano de 2014 para Região Metropolitana de Salvador. (a) Taxa de desemprego modelo SARIMA $(9,1,9) \times (0,0,1)$. (b) Taxa de desemprego modelo VAR (13) com taxas de desemprego das Regiões Metropolitanas de Salvador, Porto Alegre e São Paulo. (c) Taxa de desemprego modelo VEC (14) com covariáveis SELIC, IBC-BA e PIM-BA.

A Fig. 4.9a mostra a previsão da taxa de desemprego para os 12 meses do ano de 2015 com o modelo SARIMA para a RMS. A Fig. 4.9b mostra a previsão da taxa de desemprego para os 12 meses do ano de 2015 para a RMS com o modelo VAR (13) utilizando como covariáveis as taxas de desemprego das RMs de POA, SP e SAL. A Fig. 4.9c mostra a previsão da taxa de desemprego para os 12 meses

do ano de 2015 para a RMS com o modelo VEC (14) utilizando a série da taxa de desemprego da RMS, e as covariáveis SELIC, IBC-BA e PIM-BA.

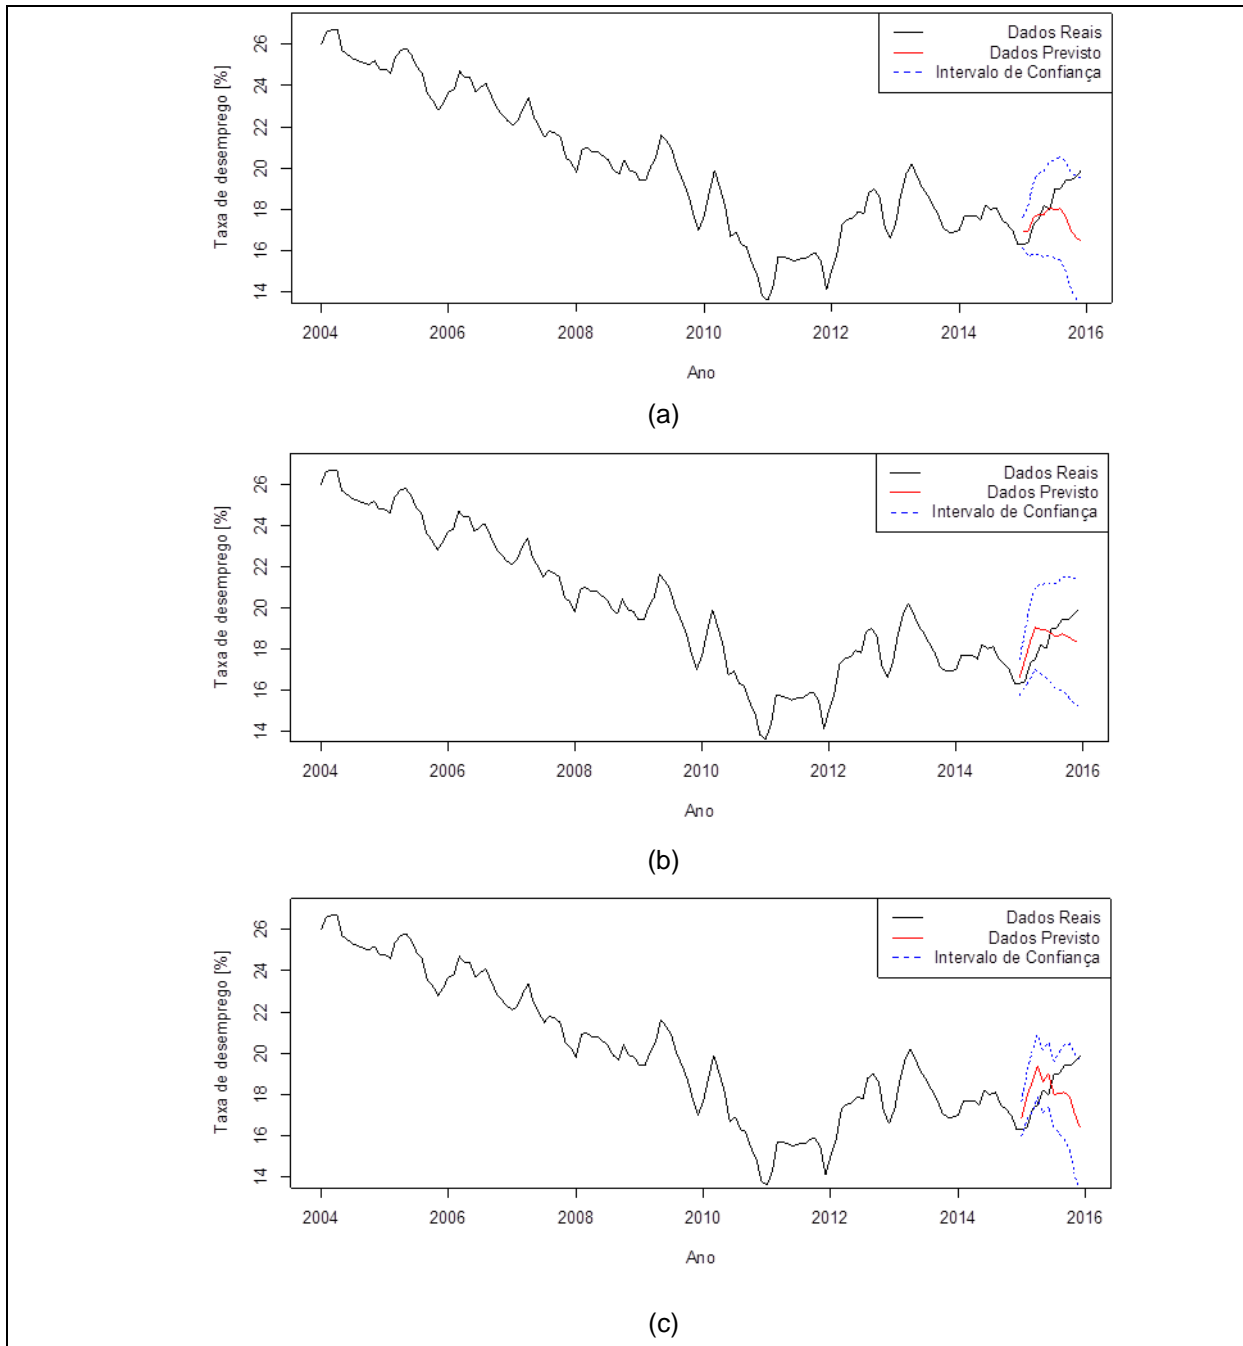


Figura 4.9 – Prevendo o ano de 2015 para Região Metropolitana de Salvador. (a) Taxa de desemprego modelo SARIMA $(9,1,9) \times (0,0,1)$. (b) Taxa de desemprego modelo VAR (13) com taxas de desemprego das Regiões Metropolitanas de Salvador, Porto Alegre e São Paulo. (c) Taxa de desemprego modelo VEC (14) com covariáveis SELIC, IBC-BA e PIM-BA.

A Fig. 4.10a apresenta a previsão da taxa de desemprego para os 6 meses do ano de 2016 com o modelo SARIMA para a RMS. A Fig. 4.10b apresenta a previsão da taxa de desemprego para os 6 meses do ano de 2016 para a RMS com

o modelo VAR (13) utilizando como covariáveis as taxas de desemprego das RMS de POA, SP e SAL. A Fig. 4.10c apresenta a previsão da taxa de desemprego para os 6 meses do ano de 2016 para a RMS com o modelo VEC (12) utilizando a série da taxa de desemprego da RMS, e as covariáveis SELIC, IBC-BA e PIM-BA.




Figura 4.10 – Prevendo o ano de 2016 para Região Metropolitana de Salvador. (a) Taxa de desemprego modelo SARIMA (9,1,9)x(0,0,1). (b) Taxa de desemprego modelo VAR (13) com taxas de desemprego das RMS de SAL, POA e SP. (c) Taxa de desemprego modelo VEC (12) com covariáveis SELIC, IBC-BA e PIM-BA.

Como mencionado no tópico da análise empírica, foi realizado o modelo 4 do VEC com as séries temporais (SELIC, IBC-RS, IBC-SP, IBC-BA e taxas de desemprego das regiões metropolitanas). No entanto, não são mostrados os resultados, pois não foram satisfatórios, o que podemos concluir é que a variável macroeconômica de cada região não influencia positivamente a previsão de desemprego de demais regiões metropolitanas quando modeladas conjuntamente, mas quando modelada separadamente são eficientes para a previsão.

Quando analisamos visualmente os gráficos de previsão de desemprego, concluímos que o modelo VEC é mais preciso que os demais modelos quando se tem aumento da taxa de desemprego. Através das covariáveis macroeconômicas regionais de cada região, o modelo consegue se adequar a realidade, prevendo assim o aumento em todas as três regiões metropolitanas analisadas neste estudo.

4.2.5. Comparação das previsões dos modelos econométricos

Para a comparação das previsões dos modelos econométricos foi realizado o teste de Diebold-Mariano, conforme mencionado no tópico 4.1.3 foram feitas 36 predições um passo à frente para aplicação do teste. Os erros de predição da região metropolitana de Porto Alegre são encontrados no apêndice C tabela C.1. A hipótese nula do teste é que as duas estimativas possuem a mesma capacidade de previsão. Quando o teste rejeita a hipótese nula um dos modelos deve ter melhor capacidade de previsão que o outro. Nas tabelas 4.7, 4.9 e 4.11 são apresentados os p-valores obtidos pelo teste de Diebold-Mariano e nas tabelas 4.8, 4.10 e 4.12 são expostas as somas dos quadrados dos erros de previsão.

Na região metropolitana de Porto Alegre, na comparação do VEC x SARIMA em todos os anos o teste rejeitou a hipótese nula (p -valor=0,00), Tabela 4.7, ou seja, rejeita que os modelos têm a mesma capacidade de previsão. O modelo mais preciso no ano de 2014 deve ser o modelo VEC, pois tem a menor soma dos erros quadrados, 2,58, como visto na Tabela 4.8, e para os anos de 2015 e de 2016 o modelo SARIMA que deve ser mais preciso, pelas somas dos erros quadrados de 2,377 e 2,459.

Quando comparamos VEC x VAR o teste rejeitou a hipótese nula (p -valor=0,00) para os anos de 2014 e 2016 e (p -valor=0,01) para 2016, Tabela 4.7, ou seja, rejeita que os modelos têm a mesma capacidade de previsão. O modelo com maior precisão no ano de 2014 deve ser o modelo VEC, pois tem a menor

soma dos erros quadrados, 2,58, Tabela 4.8, e para os anos de 2015 e de 2016 o modelo SARIMA que deve ser mais preciso, pelas somas dos erros quadrados de 2,377 e 2,459.

A comparação do VAR x SARIMA em todos os anos o teste rejeitou a hipótese nula ($p\text{-valor}=0,00$), Tabela 4.7, ou seja, rejeita que os modelos têm a mesma capacidade de previsão. O modelo com maior precisão em 2014 deve ser o modelo VEC, pois tem a menor soma dos erros quadrados, 2,58, Tabela 4.8, e para os anos de 2015 e de 2016 o modelo SARIMA que deve ser mais preciso, pelas somas dos erros quadrados de 2,377 e 2,459.

Na tabela 4.7 são apresentados os p-valores obtidos pelo teste de Diebold-Mariano para comparação dos modelos VEC-SARIMA, VEC-VAR e VAR-SARIMA para os anos de 2014, 2015 e 2016 baseados em 36 valores preditos para a região metropolitana de Porto Alegre.

Tabela 4.7 – P-valor do teste de Diebold-Mariano para a RMPA.

VEC – SARIMA			VEC – VAR			VAR – SARIMA		
2014	2015	2016	2014	2015	2016	2014	2015	2016
0.00	0.00	0.00	0.00	0.00	0.01	0.00	0.00	0.00

Na tabela 4.8 são apresentadas as somas dos erros quadrados dos modelos SARIMA, VAR e VEC para os anos de 2014, 2015 e 2016 baseados em 36 valores preditos para a região metropolitana de Porto Alegre.

Tabela 4.8 – Soma dos erros quadrados da RMPA.

2014			2015			2016		
SARIMA	VAR	VEC	SARIMA	VAR	VEC	SARIMA	VAR	VEC
2.862	2.668	2.580	2.377	2.700	2.532	2.459	2.875	2.816

Na região metropolitana de São Paulo a comparação do VEC x SARIMA em todos os anos o teste rejeitou a hipótese nula ($p\text{-valor}=0,00$), Tabela 4.9, ou seja, rejeita que os modelos têm a mesma capacidade de previsão. O modelo mais preciso deve ser o modelo VEC em todos os anos, pois tem a menor soma dos erros quadrados, 2,144, 2,223 e 2,439, Tabela 4.10.

Quando comparamos VEC x VAR o teste rejeitou a hipótese nula ($p\text{-valor}=0,00$) para todos os anos, Tabela 4.9, ou seja, rejeita que os modelos têm a

mesma capacidade de previsão. O modelo mais preciso deve ser o modelo VEC em todos os anos, pois tem a menor soma dos erros quadrados, 2,144, 2,223 e 2,439, Tabela 4.10.

A comparação do VAR x SARIMA o teste rejeitou a hipótese nula (p-valor=0,00) para o ano de 2016, Tabela 4.9, ou seja, rejeita que os modelos têm a mesma capacidade de previsão e, portanto, o modelo mais preciso no ano de 2014 deve ser o modelo VEC, pois tem a menor soma dos erros quadrados, 2,439, Tabela 4.10. O teste não rejeitou a hipótese nula (p-valor=0,725) para o ano de 2014 e (p-valor=0,302) para o ano de 2015, Tabela 4.9. Ou seja, não rejeita que os modelos têm a mesma capacidade de previsão, logo o modelo 1 (VAR) é mais preciso que o modelo 2 (SARIMA).

Na tabela 4.9 são apresentados os p-valores obtidos pelo teste de Diebold-Mariano para comparação dos modelos VEC-SARIMA, VEC-VAR e VAR-SARIMA para os anos de 2014, 2015 e 2016 baseados em 36 valores preditos para a região metropolitana de São Paulo.

Tabela 4.9 – P-valor do teste de Diebold-Mariano para a RMSP.

VEC - SARIMA			VEC - VAR			VAR - SARIMA		
2014	2015	2016	2014	2015	2016	2014	2015	2016
0.00	0.00	0.00	0.00	0.00	0.00	0.725	0.302	0.00

A tabela 4.10 são apresentadas as somas dos erros quadrados dos modelos SARIMA, VAR e VEC para os anos de 2014, 2015 e 2016 baseados em 36 valores preditos para a região metropolitana de São Paulo.

Tabela 4.10 – Soma dos erros quadrados da RMSP.

2014			2015			2016		
SARIMA	VAR	VEC	SARIMA	VAR	VEC	SARIMA	VAR	VEC
2.828	2.837	2.144	2.907	2.942	2.223	2.954	3.043	2.439

Na região metropolitana de Salvador a comparação do VEC x SARIMA em todos os anos o teste rejeitou a hipótese nula (p-valor=0,00) para os anos de 2014 e 2016 e (p-valor=0,03) para o ano de 2015, Tabela 4.11, ou seja, rejeita que os modelos têm a mesma capacidade de previsão. O modelo mais preciso deve ser o

modelo SARIMA em todos os anos, pois tem a menor soma dos erros quadrados, 4,634, 4,497 e 2,5, Tabela 4.12.

Quando comparamos VEC x VAR o teste rejeitou a hipótese nula (p -valor=0,00) para todos os anos, Tabela 4.11, ou seja, rejeita que os modelos têm a mesma capacidade de previsão. O modelo com maior precisão deve ser o modelo SARIMA em todos os anos, pois tem a menor soma dos erros quadrados, 4,634, 4,497 e 2,5, Tabela 4.12. A comparação do VAR x SARIMA o teste rejeitou a hipótese nula (p -valor=0,00) para todos os anos, Tabela 4.11, ou seja, rejeita que os modelos têm a mesma capacidade de previsão. O modelo com maior precisão deve ser o modelo SARIMA em todos os anos, pois tem a menor soma dos erros quadrados, 4,634, 4,497 e 2,5, Tabela 4.12.

A tabela 4.11 são apresentados os p -valores obtidos pelo teste de Diebold-Mariano para comparação dos modelos VEC-SARIMA, VEC-VAR e VAR-SARIMA para os anos de 2014, 2015 e 2016 baseados em 36 valores preditos para a região metropolitana de Salvador.

Tabela 4.11 – P-valor do teste de Diebold-Mariano para a RMS.

VEC – SARIMA			VEC – VAR			VAR – SARIMA		
2014	2015	2016	2014	2015	2016	2014	2015	2016
0.00	0.03	0.00	0.00	0.00	0.00	0.00	0.00	0.00

A tabela 4.12 são apresentadas as somas dos erros quadrados dos modelos SARIMA, VAR e VEC para os anos de 2014, 2015 e 2016 baseados em 36 valores preditos para a região metropolitana de Salvador.

Tabela 4.12 – Soma dos erros quadrados da RMS.

2014			2015			2016		
SARIMA	VAR	VEC	SARIMA	VAR	VEC	SARIMA	VAR	VEC
4.634	6.948	5.259	4.497	7.093	4.671	4.500	7.081	5.844

Através das análises do teste de Diebold-Mariano é possível inferir que para a região metropolitana de Porto Alegre o modelo SARIMA é o mais adequado para os anos 2015 e 2016 e o modelo VEC é o mais adequado para o ano de 2014. Para a região metropolitana de São Paulo, o teste de Diebold-Mariano infere o modelo VEC é mais adequado para todos os anos. Para a região metropolitana de

Salvador, o teste de Diebold-Mariano infere que o modelo SARIMA é mais adequado para todos os anos.

5. CONCLUSÃO

Neste trabalho, a proposta foi encontrar um modelo econométrico adequado para previsão de desemprego para as regiões metropolitanas de Porto Alegre, São Paulo e Salvador. As classes de modelos escolhidas foram as seguintes: modelo sazonal autorregressivo e de médias móveis (SARIMA), modelo vetorial autorregressivo (VAR) e modelo de correção de erros (VEC). Devido ao comportamento da série de desemprego nos últimos anos, escolhemos analisar três períodos de tempo diferentes para observar o comportamento dos modelos: 2014, 2015 e o primeiro semestre de 2016.

Através do teste de comparação de previsão Diebold-Mariano, a decisão não foi homogênea ao longo das regiões metropolitanas estudadas. O modelo SARIMA $(4,1,4) \times (1,0,0)_{12}$ é o mais adequado para a região metropolitana de Porto Alegre para os anos de 2015 e o primeiro semestre de 2016 e o modelo VEC (9) é o mais adequado para o ano de 2014. Para a região metropolitana de São Paulo o teste inferiu que o modelo VEC (9) é o mais adequado em 2014 e 2016 e VEC (8) em 2015. O modelo SARIMA $(9,1,9) \times (0,0,1)_{12}$ foi inferido como o modelo mais adequado para a região metropolitana de Salvador para todo o período.

Para trabalhos futuros, uma sugestão seria incorporar nos modelos outras variáveis econômicas. Outra sugestão seria trabalhar com diferentes defasagens de cada variável, podendo assim identificar alguma relação de tempo entre os indicadores previstos e as covariáveis.

REFERÊNCIAS BIBLIOGRÁFICAS

BASTOS, R., O mercado de trabalho da Região Metropolitana de Porto Alegre teve intensa deterioração em 2015. *Indicadores Econômicos FEE*. Porto Alegre: FEE, v. 43, n. 4, p. 109-118, 2016.

BANCO CENTRAL DO BRASIL, BCB, Metodologia do Índice de Atividade Econômica do Banco Central, Relatório de Inflação, pp. 24-28, 2010.

BANCO CENTRAL DO BRASIL, Taxa Selic, Fatores Acumulados. Disponível em: <<http://www.bcb.gov.br/htms/selic/selicacumul.asp>>. Acesso em 19 ago. 2016.

BANCO CENTRAL DO BRASIL, Índice de Atividade Econômica do Banco Central Regional, Disponível em: <<http://www.bcb.gov.br/pt-br/#!/n/SERIESTEMPORAIS>>. Acesso em 19 ago. 2016.

BIALOWOLSKI, P.; KUSZEWSKI, T.; WITKOWSKI, B.; Macroeconomic Forecast in Models with Bayesian Averaging of Classical Estimates, *Contemporary Economics*; 2011, pp. 60-69.

BLANCHARD, OLIVIER, Macroeconomia, *São Paulo - Pearson Prentice Hall*, 2011, 5. ed.

DIEBOLD, F.X., MARIANO, R. S., Comparing predictive accuracy. *Journal of Business and Economic Statistics*, 1995, 13: 253–263.

DIEESE, Taxa de Desemprego das Regiões Metropolitanas, Disponível em: <<http://www.dieese.org.br/analiseped/ped.html>>. Acesso em 5 ago. 2016.

DIEESE / Fundação SEADE, Pesquisa de Emprego e Desemprego (PED): conceitos, metodologia e operacionalização, *Departamento Intersindical de Estatística e Estudos Socioeconômicos; Fundação de Sistema Estadual de Análise de Dados – São Paulo, DIEESE*, 2009.

ENDERS, WALTER, Applied econometric time series. *University of Alabama*, 2015, 4. ed.

DUARTE, Felipe Machado, Acuracia de previsões para vazão em redes: um comparativo entre ARIMA GARCH e RNA, *Universidade Federal de Pernambuco*, 2014.

FROYEN, RICHARD T., Macroeconomia, *São Paulo - Saraiva*, 2002

HYLLEBERG, S., Engle, R.F., Granger, C.W.J., and Yoo, B.S. (1990) Seasonal integration and cointegration. *Journal of Econometrics*, 44, 215-238.

HYNDMAN, ROB, Forecasting Functions for Time Sires and Linear Models, version 7.3, Package forecast R, 2016.

IBGE, Instituto Brasileiro de Geografia e Estatística, Pesquisa Industrial Mensal Regional, Disponível em: < <http://www.sidra.ibge.gov.br/bda/indust>>. Acesso em 2 set. 2016.

JOHANSEN, S. Likelihood-based inference in cointegrated vector auto-regressive models. New York: Oxford University Press, 1995. 267 p. (Advanced Texts in Econometrics).

KEILIS-BOROK, V., SOLOVIEV, A. A., INTRILIGATOR, M.D., WINBERG, F.E. Pattern of Macroeconomic Indicators Preceding the End of an American Economic Recession. *Journal of Pattern Recognition Research*, pp. 40-53, 2008.

LAVINAS, Lena *et al.* Evolução do desemprego feminino nas áreas metropolitanas. *Instituto de Pesquisa Econômica Aplicada*. Texto para discussão, IPEA, n. 756, set. 2000.

MORETTIN, P. A., *et. al.*, Análise de Séries Temporais, Blucher, 2006, 2. ed, pg 564.

SIMIONESCU, M. B., Predicting Macroeconomic Indicators in the Czech Republic Using Econometric Models and Exponential Smoothing Techniques, *South East European Journal of Economics and Business*, 2012.

PFAFF, BERNHARD, Analysis of Integrated and Cointegrated Time Series with R. *Springer*, 2008, 2. ed.

WEI, WILLIAM W. S., Times series analysis: univariate and multivariate methods, *Pearson Education*, 2006, 2. ed.

ZUANAZZI, Pedro T., ZIEGELMANN, Flávio A., Previsões para o crescimento do PIB trimestral brasileiro com séries financeiras econômicas mensais: Uma aplicação de MIDAS, *Economia Aplicada*, 2014.

APÊNDICE A

Na Fig. A.1 são apresentadas as funções de autocorrelação e funções parciais de autocorrelação para as três regiões metropolitanas de Porto Alegre, São Paulo e Salvador

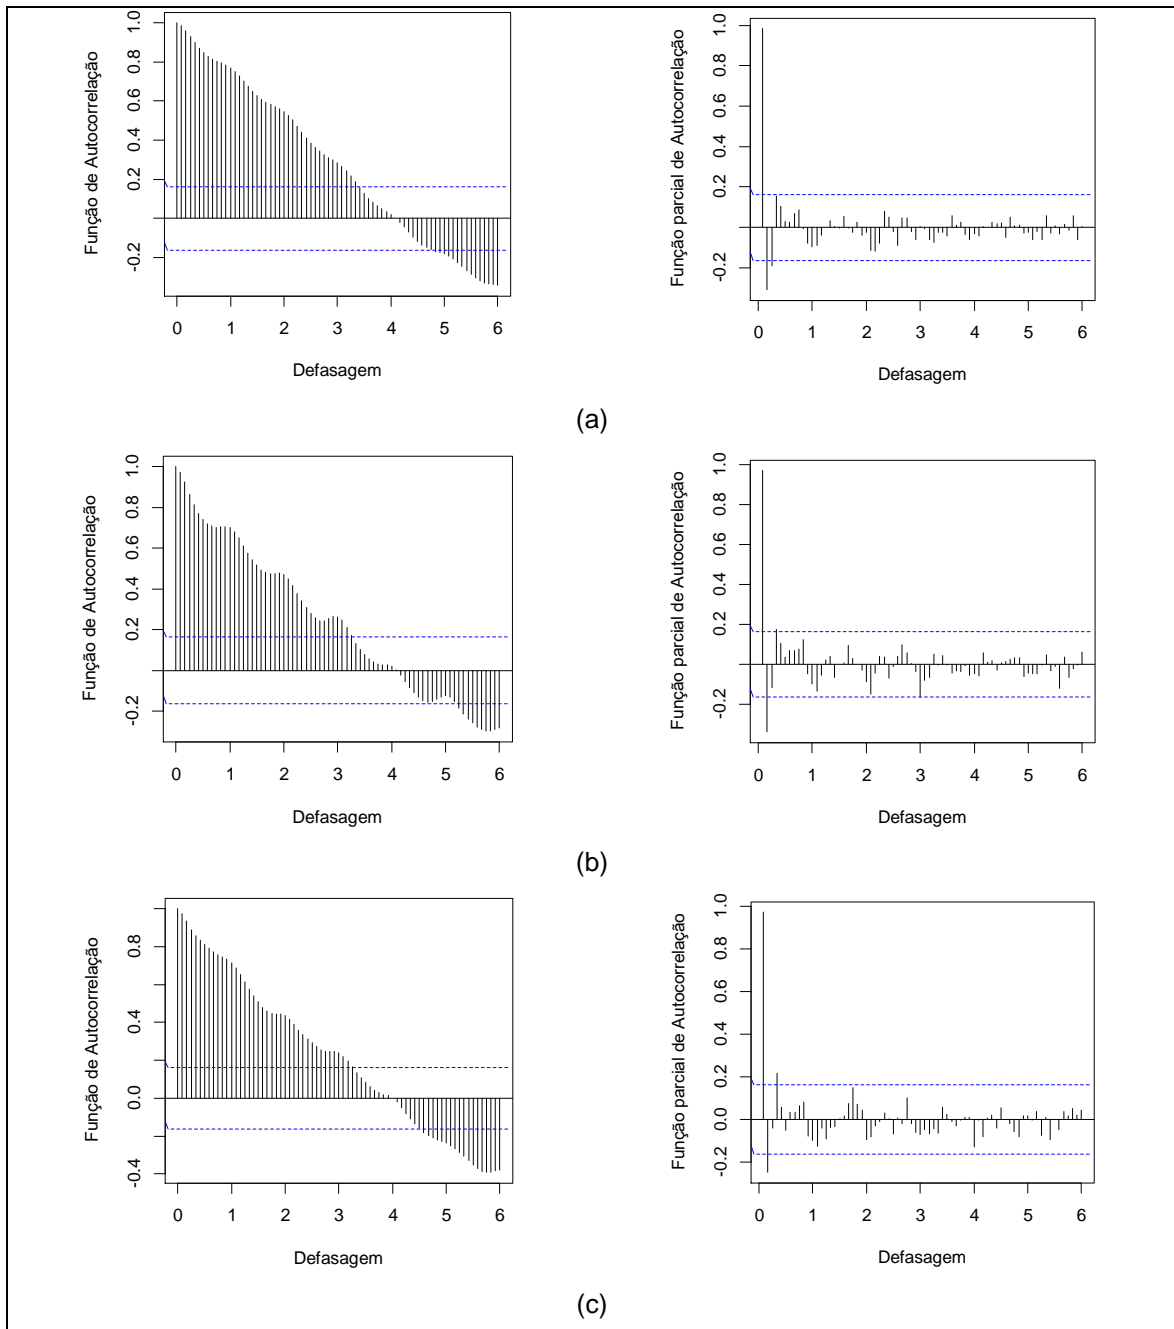


Figura A.1. - Função de autocorrelação e função parcial de autocorrelação da série temporal da taxa de desemprego das Regiões Metropolitanas entre 2004 e 2016.

(a) Porto Alegre. (b) São Paulo. (c) Salvador.

Através da Fig. A.1 é possível observar a função de autocorrelação tem decaimento lento, indicando que as séries não são estacionárias. A função parcial de autocorrelação, tem a primeira defasagem alta em todas as séries como habitual, mas não tende a ser constantemente zero, ou seja, todas as séries têm sazonalidade em algum período.

Na Fig. A.2, é mostrado a primeira diferença das séries de taxa de desemprego das três regiões metropolitanas, Porto Alegre, São Paulo e Salvador.

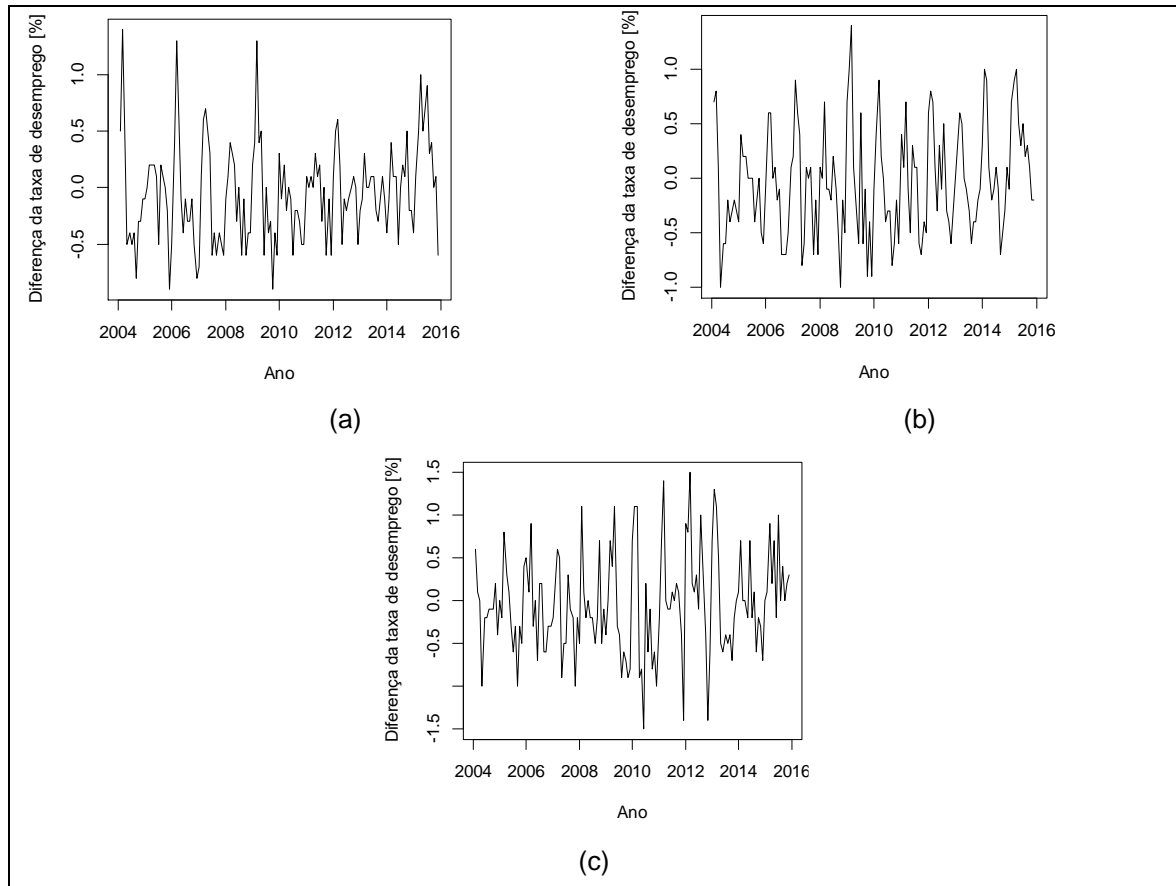


Figura A.2 – Primeira diferença das séries temporal da taxa de desemprego das Regiões Metropolitanas entre 2004 e 2016.

(a) Porto Alegre. (b) São Paulo. (c) Salvador.

As séries temporais apresentadas na Fig. A.2 são mensais e possuem cento e cinquenta e uma observações no período dos 12 anos.

Na Fig. A.3 são apresentadas as funções de autocorrelação e funções parciais de autocorrelação da primeira diferença para as três regiões em análise.

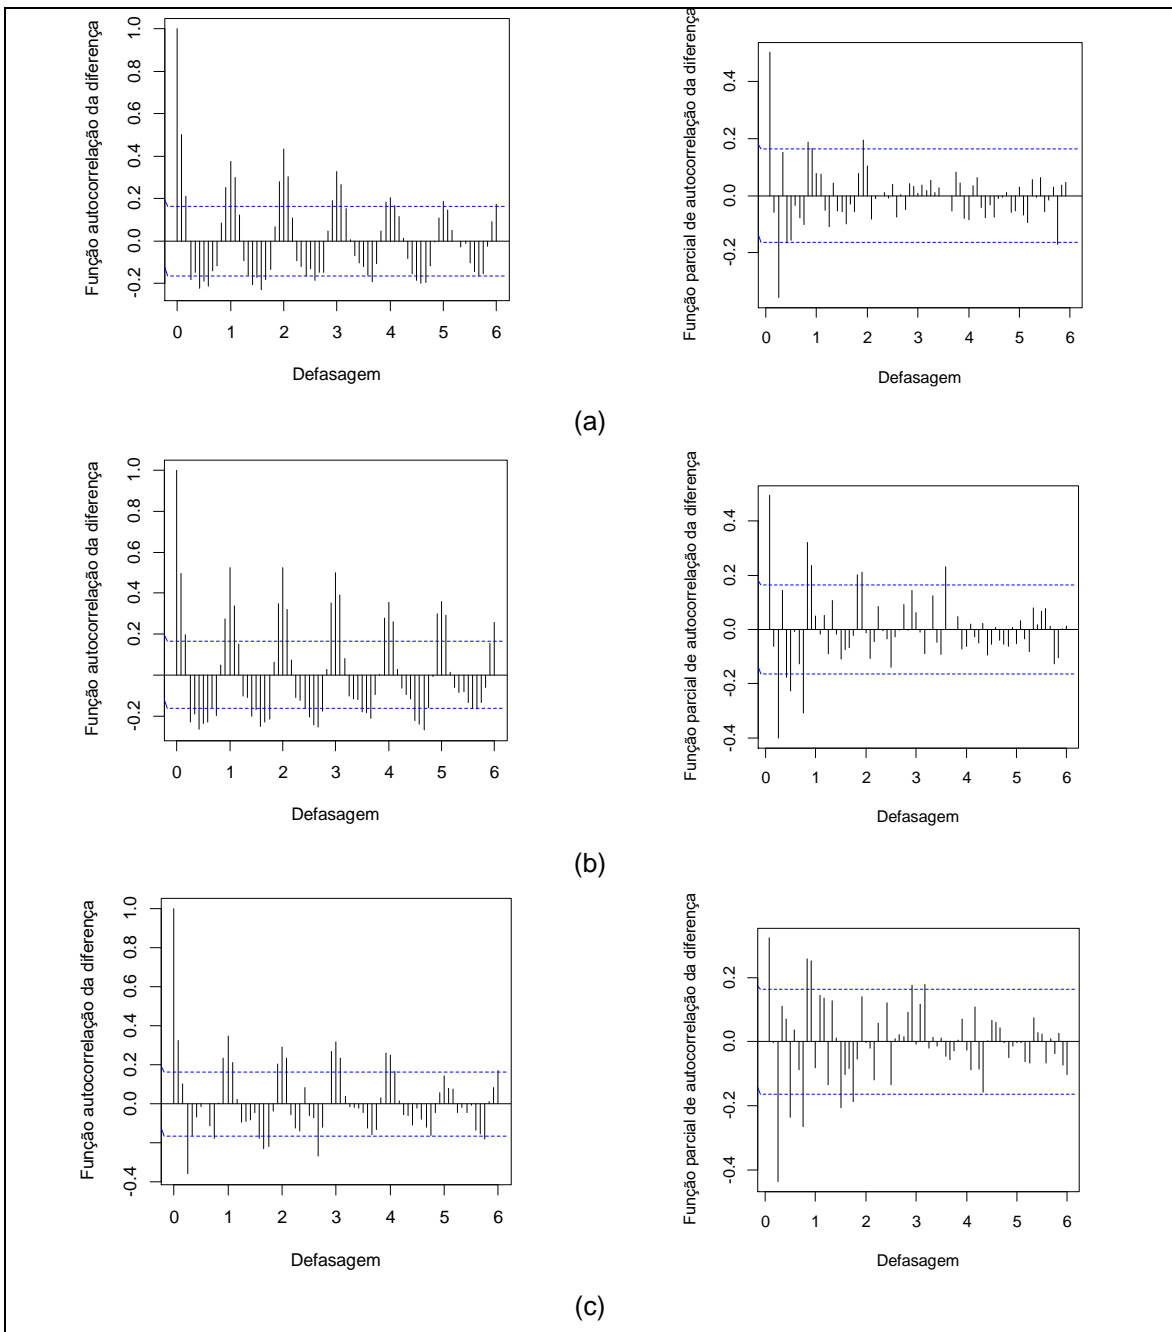


Figura A.3 - Função de autocorrelação e função parcial de autocorrelação da primeira diferença das séries temporal da taxa de desemprego das Regiões Metropolitanas entre 2004 e 2016. (a) Porto Alegre. (b) São Paulo. (c) Salvador.

É possível observar na Fig. A.3 que a função de autocorrelação da primeira diferença tem decaimento rápido, e sazonalidade de doze meses. Ou seja, tem forte indicio de que as séries são estacionária com a primeira diferença da taxa de desemprego.

APÊNDICE B

As Fig. B.1, Fig. B.2 e Fig. B.3, mostram as séries e as funções de autocorrelação das variáveis macroeconômicas. As covariáveis macroeconômicas apresentam tendência e aparentemente possuem sazonalidade, e com análise visual poderíamos concluir que possivelmente as séries macroeconômicas sejam $I(1)$. Mas visualmente através da função de autocorrelação não temos como concluir que realmente sejam não estacionárias, pois apresentam um decaimento não lento como nas séries analisadas anteriormente.

Pelo teste da raiz unitária de Dickey-Fuller o p-valor resultou em maior que 0.05, o que não é rejeitada a hipótese nula, logo as variáveis macroeconômicas não são estacionárias, $I(1)$. Realizamos a primeira diferença das séries e a função de autocorrelação das mesmas, como é possível ver no apêndice B, nas Fig. B.4, Fig. B.5 e Fig. B.6. Para a primeira diferença, as séries aparentam ser estacionárias a partir de uma análise visual. Entretanto, novamente é realizado o teste da raiz unitária de Dickey-Fuller. Rejeitamos a hipótese nula, que há raiz unitária na série, pois o p-valor resultou em menos que 0.05, ou seja, as séries da primeira diferença das variáveis macroeconômicas são estacionárias, $I(0)$, com 95% de confiança.

Na Fig. B.1 são apresentadas a série da taxa de juros e a função de autocorrelação da taxa de juros.

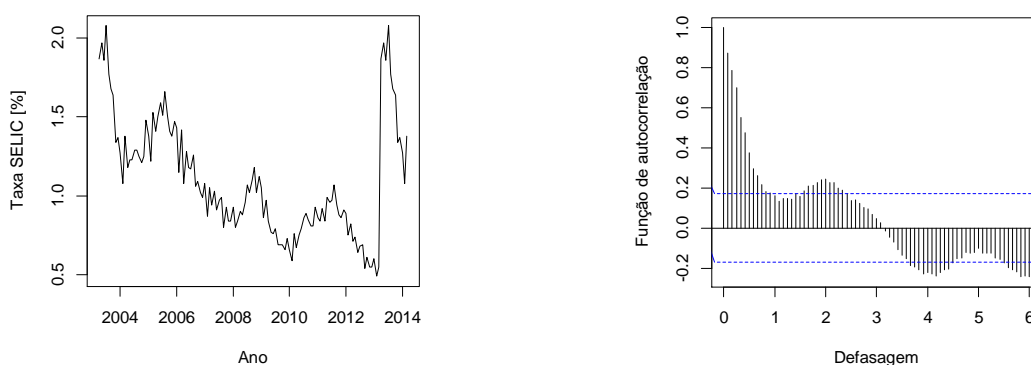


Figura B.1. Série da taxa de juros (SELIC) e a função de autocorrelação da da taxa de juros (SELIC) entre 2003 e 2016.

Na Fig. B.2 são apresentadas as séries do índice de atividade econômica (IBC) e a função de autocorrelação do IBC dos estados Rio Grande do Sul, São Paulo e Bahia.

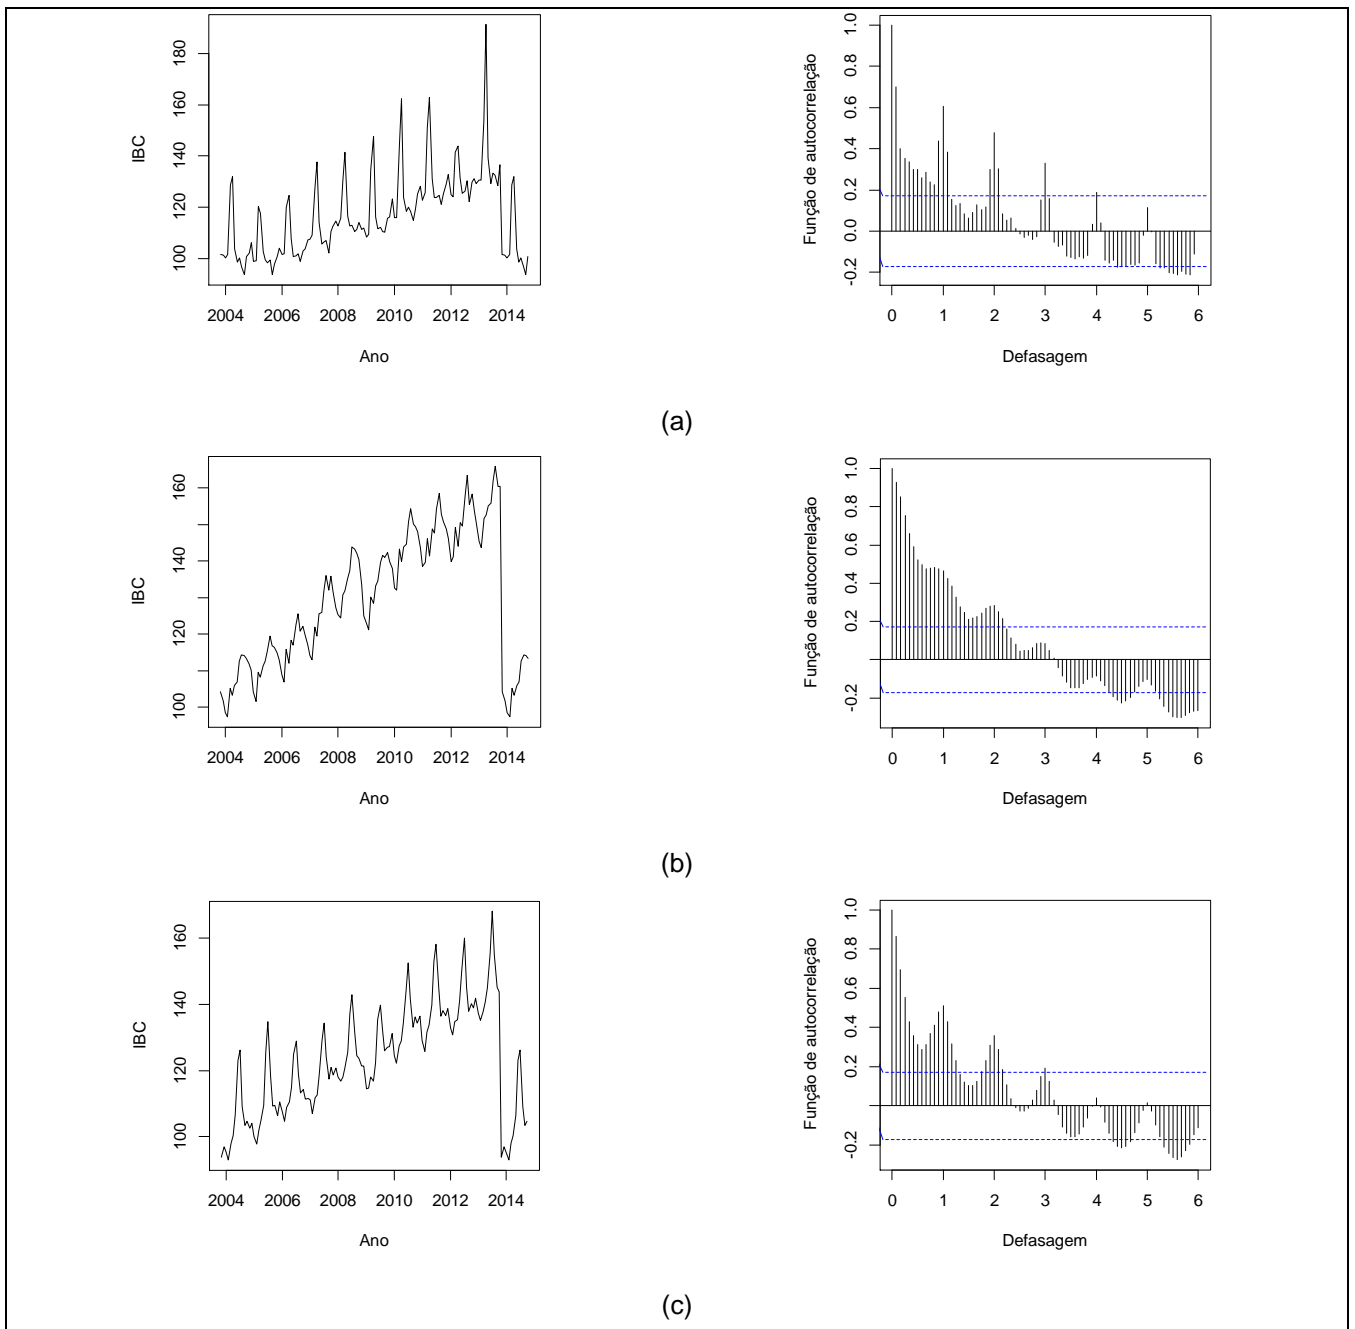


Figura B.2. Série do IBC e a função de autocorrelação do IBC entre 2003 e 2016.

(a) Rio Grande do Sul. (b) São Paulo. (c) Bahia.

Na Fig. B.3 são apresentadas as séries do índice de produção industrial (PIM) e a função de autocorrelação da PIM dos estados Rio Grande do Sul, São Paulo e Bahia.

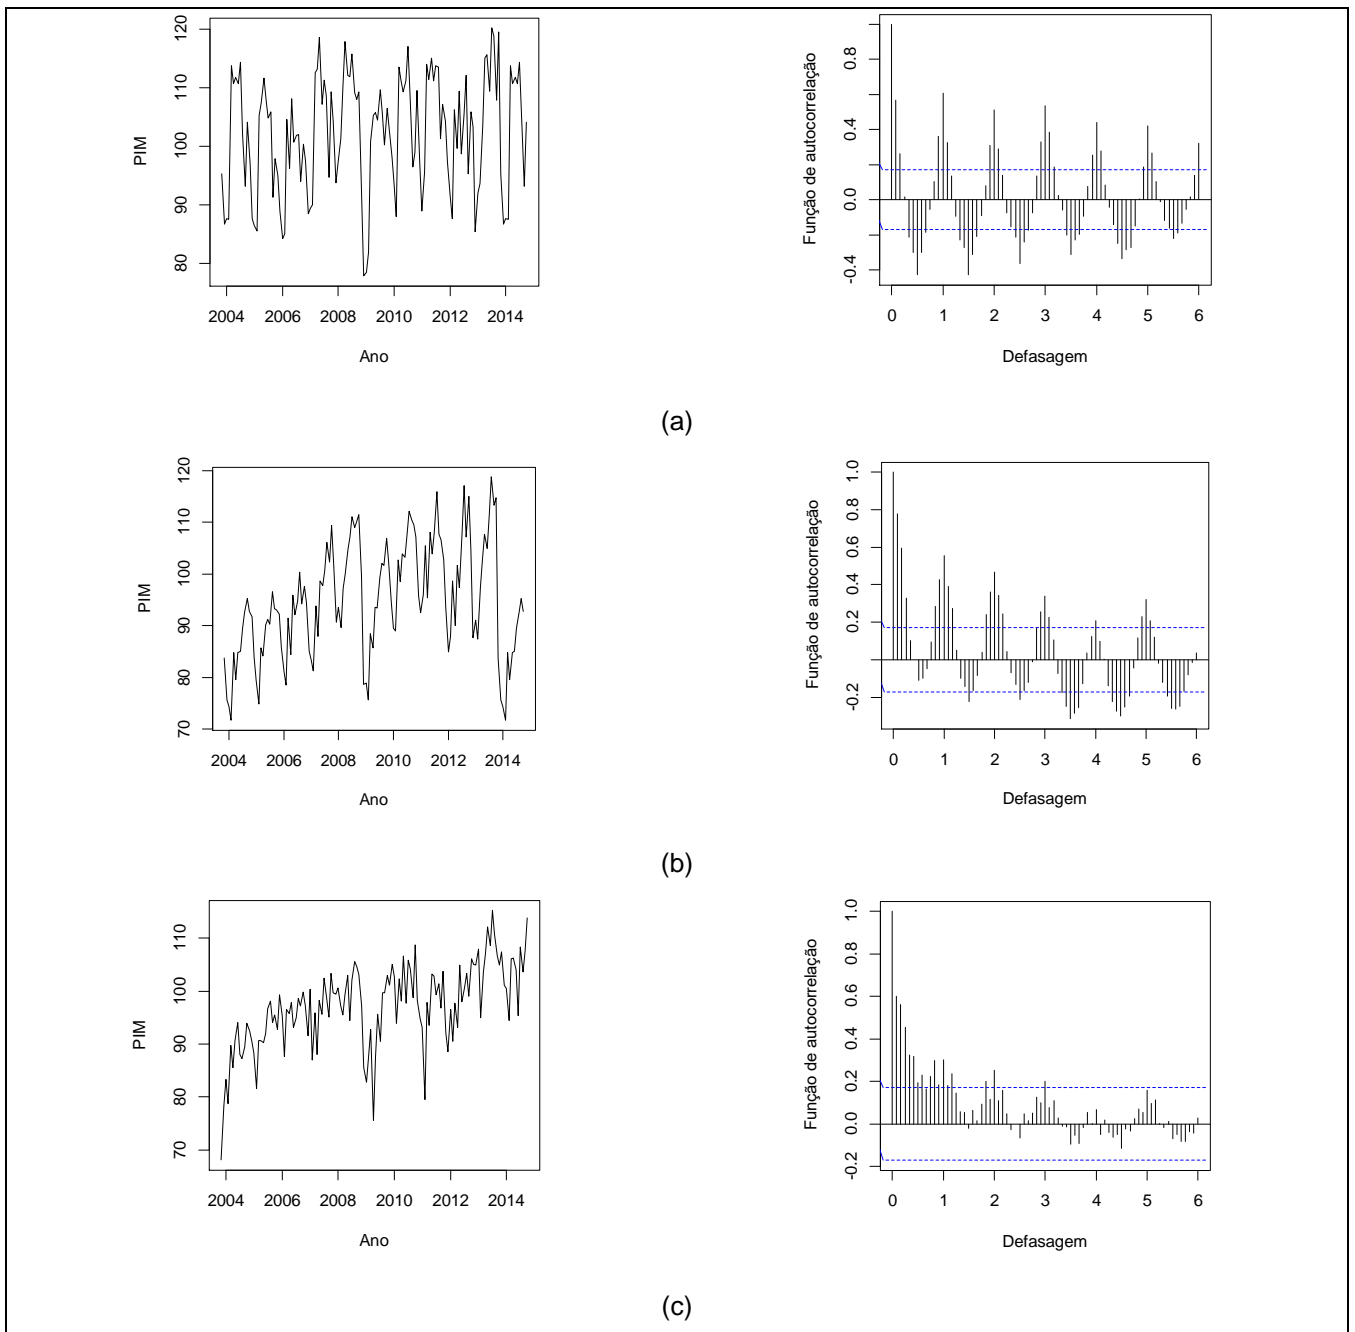


Figura B.3. Série da PIM e a função de autocorrelação da PIM entre 2003 e 2016.

(a) Rio Grande do Sul. (b) São Paulo. (c) Bahia.

Na Fig. B.4 são apresentadas a série da primeira diferença da taxa de juros e a função de autocorrelação da primeira diferença da taxa de juros.




Figura B.4. Primeira diferença da taxa de juros (SELIC) e a função de autocorrelação da primeira diferença da taxa de juros (SELIC) entre 2003 e 2016.

Na Fig. B.5 são apresentadas as séries da primeira diferença do índice de atividade econômica (IBC) e a função de autocorrelação da primeira diferença do IBC dos estados Rio Grande do Sul, São Paulo e Bahia.

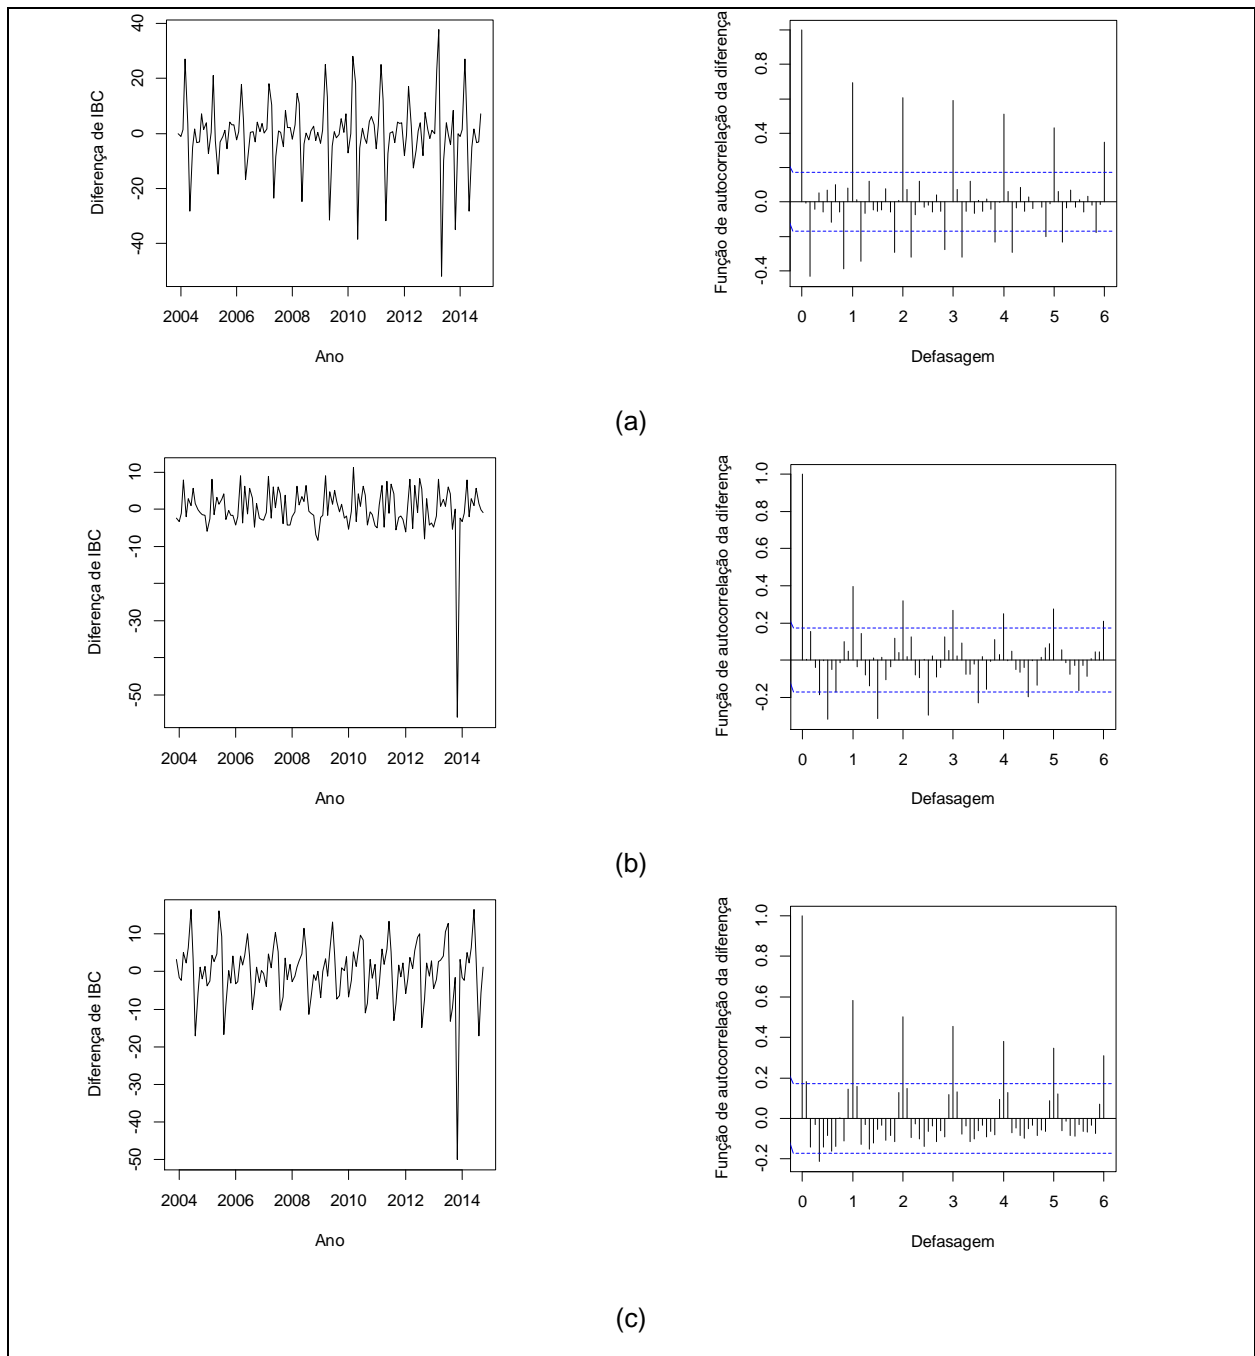


Figura B.5. Primeira diferença do IBC e a função de autocorrelação da primeira diferença do IBC entre 2003 e 2016. (a) Rio Grande do Sul. (b) São Paulo. (c) Bahia.

Na Fig. B.6 são apresentadas as séries da primeira diferença do índice de produção industrial (PIM) e a função de autocorrelação da primeira diferença da PIM dos estados Rio Grande do Sul, São Paulo e Bahia.

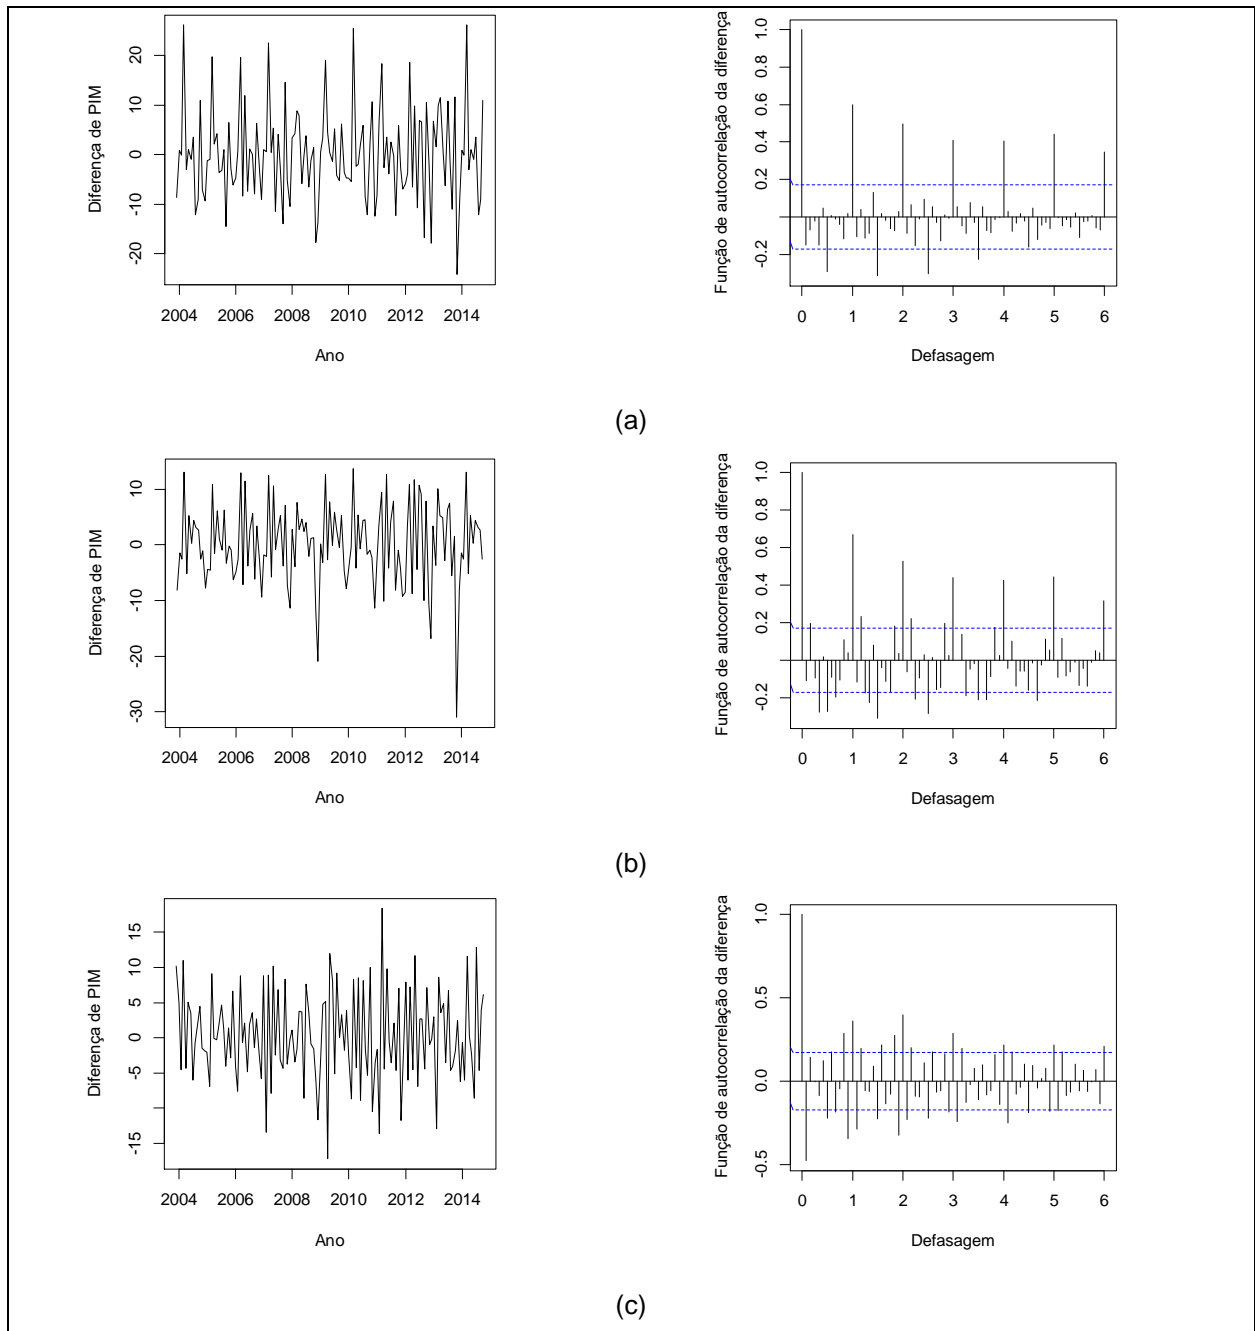


Figura B.6. Primeira diferença da PIM e a função de autocorrelação da primeira diferença da PIM entre 2003 e 2016.

(a) Rio Grande do Sul. (b) São Paulo. (c) Bahia.

APÊNDICE C

Nas Tabelas C.1, C.2, C.3 são apresentados os erros da previsão para cada modelo das regiões metropolitanas do estudo para os anos 2014, 2015 e o primeiro semestre de 2016.

Tabela C.1 – Erros da previsão dos modelos SARIMA, VAR e VEC para os anos de 2014, 2015 e 2016 para a região metropolitana de Porto Alegre.

RMPA	SARIMA			VAR			VEC		
	2014	2015	2016	2014	2015	2016	2014	2015	2016
1	0.289	0.262	0.253	0.270	0.270	0.273	0.269	0.259	0.276
2	0.288	0.259	0.253	0.267	0.266	0.279	0.266	0.259	0.279
3	0.296	0.259	0.254	0.263	0.268	0.282	0.264	0.259	0.28
4	0.285	0.257	0.252	0.264	0.267	0.278	0.260	0.259	0.285
5	0.284	0.257	0.253	0.268	0.271	0.281	0.256	0.274	0.279
6	0.292	0.256	0.252	0.263	0.271	0.279	0.256	0.276	0.279
7	0.291	0.253	0.253	0.266	0.273	0.278	0.255	0.276	0.278
8	0.290	0.253	0.252	0.262	0.279	0.282	0.256	0.279	0.279
9	0.288	0.254	0.251	0.267	0.282	0.284	0.255	0.280	0.280
10	0.281	0.252	0.248	0.262	0.278	0.285	0.253	0.285	0.281
11	0.289	0.253	0.247	0.273	0.281	0.292	0.267	0.279	0.278
12	0.289	0.252	0.246	0.270	0.279	0.298	0.263	0.279	0.281
13	0.288	0.253	0.247	0.270	0.270	0.273	0.269	0.259	0.276
14	0.285	0.252	0.246	0.267	0.266	0.279	0.266	0.259	0.279
15	0.283	0.251	0.248	0.263	0.268	0.282	0.264	0.259	0.280
16	0.281	0.248	0.246	0.264	0.267	0.278	0.260	0.259	0.285
17	0.282	0.247	0.252	0.268	0.271	0.281	0.256	0.274	0.279
18	0.279	0.246	0.251	0.263	0.271	0.279	0.256	0.276	0.279
19	0.287	0.247	0.250	0.266	0.273	0.278	0.255	0.276	0.278
20	0.276	0.246	0.248	0.262	0.279	0.282	0.256	0.279	0.279
21	0.276	0.248	0.247	0.267	0.282	0.284	0.255	0.280	0.280
22	0.284	0.246	0.246	0.262	0.278	0.285	0.253	0.285	0.281
23	0.277	0.252	0.262	0.273	0.281	0.292	0.267	0.279	0.278
24	0.283	0.251	0.261	0.270	0.279	0.298	0.263	0.279	0.281
25	0.277	0.250	0.260	0.270	0.270	0.273	0.269	0.259	0.276
26	0.270	0.248	0.281	0.267	0.266	0.279	0.266	0.259	0.279
27	0.275	0.247	0.280	0.263	0.268	0.282	0.264	0.259	0.280
28	0.276	0.246	0.280	0.264	0.267	0.278	0.260	0.259	0.285
29	0.274	0.262	0.282	0.268	0.271	0.281	0.256	0.274	0.279
30	0.275	0.261	0.290	0.263	0.271	0.279	0.256	0.276	0.279
31	0.275	0.260	0.281	0.266	0.273	0.278	0.255	0.276	0.278
32	0.274	0.281	0.285	0.262	0.279	0.282	0.256	0.279	0.279
33	0.275	0.280	0.284	0.267	0.282	0.284	0.255	0.280	0.28
34	0.276	0.280	0.284	0.262	0.278	0.285	0.253	0.285	0.281
35	0.280	0.282	0.283	0.273	0.281	0.292	0.267	0.279	0.278
36	0.277	0.290	0.283	0.270	0.279	0.298	0.263	0.279	0.281

Tabela C.2 - Erros da previsão dos modelos SARIMA, VAR e VEC para os anos de 2014, 2015 e 2016 para a região metropolitana de São Paulo.

RMSP	SARIMA			VAR			VEC		
	2014	2015	2016	2014	2015	2016	2014	2015	2016
1	0.287	0.277	0.278	0.279	0.280	0.285	0.246	0.393	0.386
2	0.289	0.277	0.272	0.276	0.284	0.289	0.247	0.384	0.396
3	0.283	0.278	0.278	0.279	0.279	0.287	0.249	0.382	0.400
4	0.286	0.276	0.280	0.277	0.283	0.288	0.251	0.381	0.399
5	0.281	0.275	0.279	0.282	0.282	0.294	0.247	0.383	0.398
6	0.279	0.273	0.278	0.278	0.290	0.291	0.247	0.387	0.394
7	0.278	0.272	0.277	0.285	0.285	0.291	0.244	0.386	0.405
8	0.277	0.272	0.275	0.282	0.289	0.293	0.242	0.396	0.408
9	0.277	0.278	0.280	0.285	0.287	0.293	0.240	0.400	0.411
10	0.275	0.280	0.283	0.282	0.288	0.295	0.238	0.399	0.405
11	0.274	0.279	0.294	0.282	0.294	0.291	0.240	0.398	0.415
12	0.272	0.278	0.292	0.281	0.291	0.293	0.237	0.394	0.417
13	0.277	0.277	0.298	0.279	0.280	0.285	0.246	0.393	0.386
14	0.277	0.275	0.281	0.276	0.284	0.289	0.247	0.384	0.396
15	0.278	0.280	0.276	0.279	0.279	0.287	0.249	0.382	0.400
16	0.276	0.283	0.278	0.277	0.283	0.288	0.251	0.381	0.399
17	0.275	0.294	0.283	0.282	0.282	0.294	0.247	0.383	0.398
18	0.273	0.292	0.295	0.278	0.290	0.291	0.247	0.387	0.394
19	0.272	0.298	0.296	0.285	0.285	0.291	0.244	0.386	0.405
20	0.272	0.281	0.294	0.282	0.289	0.293	0.242	0.396	0.408
21	0.278	0.276	0.300	0.285	0.287	0.293	0.240	0.400	0.411
22	0.280	0.278	0.300	0.282	0.288	0.295	0.238	0.399	0.405
23	0.279	0.283	0.292	0.282	0.294	0.291	0.240	0.398	0.415
24	0.278	0.295	0.294	0.281	0.291	0.293	0.237	0.394	0.417
25	0.277	0.282	0.284	0.279	0.280	0.285	0.246	0.393	0.386
26	0.275	0.296	0.283	0.276	0.284	0.289	0.247	0.384	0.396
27	0.280	0.294	0.304	0.279	0.279	0.287	0.249	0.382	0.400
28	0.283	0.300	0.298	0.277	0.283	0.288	0.251	0.381	0.399
29	0.294	0.292	0.286	0.282	0.282	0.294	0.247	0.383	0.398
30	0.292	0.294	0.285	0.278	0.290	0.291	0.247	0.387	0.394
31	0.298	0.284	0.286	0.285	0.285	0.291	0.244	0.386	0.405
32	0.281	0.283	0.287	0.282	0.289	0.293	0.242	0.396	0.408
33	0.276	0.304	0.298	0.285	0.287	0.293	0.240	0.400	0.411
34	0.278	0.298	0.300	0.282	0.288	0.295	0.238	0.399	0.405
35	0.283	0.286	0.284	0.282	0.294	0.291	0.240	0.398	0.415
36	0.295	0.285	0.283	0.281	0.291	0.293	0.237	0.394	0.417

Tabela C.3 - Erros da previsão dos modelos SARIMA, VAR e VEC para os anos de 2014, 2015 e 2016 para a região metropolitana de Salvador.

RMS	SARIMA			VAR			VEC		
	2014	2015	2016	2014	2015	2016	2014	2015	2016
1	0.364	0.372	0.353	0.430	0.443	0.442	0.395	0.393	0.386
2	0.372	0.371	0.350	0.433	0.440	0.449	0.390	0.384	0.396
3	0.371	0.370	0.366	0.425	0.437	0.451	0.376	0.382	0.400
4	0.370	0.368	0.362	0.429	0.441	0.445	0.387	0.381	0.399
5	0.350	0.367	0.360	0.431	0.445	0.448	0.378	0.383	0.398
6	0.363	0.366	0.360	0.434	0.447	0.439	0.373	0.387	0.394
7	0.349	0.353	0.344	0.444	0.442	0.441	0.378	0.386	0.405
8	0.348	0.350	0.342	0.452	0.449	0.443	0.377	0.396	0.408
9	0.378	0.366	0.341	0.453	0.451	0.441	0.387	0.400	0.411
10	0.376	0.362	0.347	0.450	0.445	0.443	0.378	0.399	0.405
11	0.377	0.360	0.345	0.448	0.448	0.435	0.378	0.398	0.415
12	0.375	0.360	0.336	0.441	0.439	0.444	0.388	0.394	0.417
13	0.372	0.344	0.347	0.430	0.443	0.442	0.395	0.393	0.386
14	0.371	0.342	0.349	0.433	0.440	0.449	0.390	0.384	0.396
15	0.370	0.341	0.353	0.425	0.437	0.451	0.376	0.382	0.400
16	0.368	0.347	0.352	0.429	0.441	0.445	0.387	0.381	0.399
17	0.367	0.345	0.348	0.431	0.445	0.448	0.378	0.383	0.398
18	0.366	0.336	0.347	0.434	0.447	0.439	0.373	0.387	0.394
19	0.353	0.347	0.345	0.444	0.442	0.441	0.378	0.386	0.405
20	0.350	0.349	0.348	0.452	0.449	0.443	0.377	0.396	0.408
21	0.366	0.353	0.353	0.453	0.451	0.441	0.387	0.400	0.411
22	0.362	0.352	0.346	0.450	0.445	0.443	0.378	0.399	0.405
23	0.360	0.348	0.346	0.448	0.448	0.435	0.378	0.398	0.415
24	0.360	0.347	0.350	0.441	0.439	0.444	0.388	0.394	0.417
25	0.344	0.345	0.347	0.430	0.443	0.442	0.395	0.393	0.386
26	0.342	0.348	0.352	0.433	0.440	0.449	0.390	0.384	0.396
27	0.341	0.353	0.355	0.425	0.437	0.451	0.376	0.382	0.400
28	0.347	0.346	0.352	0.429	0.441	0.445	0.387	0.381	0.399
29	0.345	0.346	0.351	0.431	0.445	0.448	0.378	0.383	0.398
30	0.336	0.350	0.360	0.434	0.447	0.439	0.373	0.387	0.394
31	0.347	0.347	0.355	0.444	0.442	0.441	0.378	0.386	0.405
32	0.349	0.352	0.367	0.452	0.449	0.443	0.377	0.396	0.408
33	0.353	0.355	0.369	0.453	0.451	0.441	0.387	0.400	0.411
34	0.352	0.352	0.374	0.450	0.445	0.443	0.378	0.399	0.405
35	0.348	0.351	0.377	0.448	0.448	0.435	0.378	0.398	0.415
36	0.347	0.360	0.375	0.441	0.439	0.444	0.388	0.394	0.417

APÊNDICE D

O código no programa R utilizado para análise estatística do modelo SARIMA.

```
library("fUnitRoots")
library(forecast)
windows()
acf(ypoa, lag=72, main='Porto Alegre',xlab='Defasagem',ylab='Função de
Autocorrelação')
acf(yssp, lag=72, main='São Paulo',xlab='Defasagem',ylab='Função de
Autocorrelação')
acf(yssa, lag=72, main='Salvador',xlab='Defasagem',ylab='Função de
Autocorrelação')
pacf(ypoa, lag=72, main='Porto Alegre',xlab='Defasagem',ylab='Função
parcial de Autocorrelação')
pacf(yssp, lag=72, main='São Paulo',xlab='Defasagem',ylab='Função parcial
de Autocorrelação')
pacf(yssa, lag=72, main='Salvador',xlab='Defasagem',ylab='Função parcial
de Autocorrelação')
# Teste raiz unitária
adfTest(ypoa)
adfTest(yssp)
adfTest(yssa)
dsypoa = diff(ypoa) #diferença sazonal
dsysp = diff(yssp) #diferença sazonal
dsyssa = diff(yssa) #diferença sazonal
adfTest(dsypoa)
adfTest(dsysp)
adfTest(dsyssa)
#SARIMA(4,1,4)(1,0,0)
sar4.4 = print(arima(ypoa, order=c(4,1,4)),seasonal = list(order = c(1, 0, 0),
period = 12))
sar4.4.r = residuals(sar4.4)
Box.test(sar4.4.r, lag=24)
prev1 = predict(sar4.4, n.ahead=12)
#SARIMA(9,1,9)(0,0,1)
sar9.9 = print(arima(yssp, order=c(9,1,9)),seasonal = list(order = c(0, 0, 1),
period = 12))
sar9.9.r = residuals(sar9.9)
Box.test(sar9.9.r, lag=24)
prev1 = predict(sar9.9, n.ahead=12)
#SARIMA(9,1,9)(0,0,1)
sar9.9 = print(arima(yssa, order=c(9,1,9)),seasonal = list(order = c(0, 0, 1),
period = 12))
sar9.9.r = residuals(sar9.9)
Box.test(sar9.9.r, lag=12)
prev1 = predict(sar9.9, n.ahead=12)
```