

MODELANDO O PROCESSO GERADOR DA INFLAÇÃO NO BRASIL

MODELING THE INFLATION GENERATING PROCESS IN BRAZIL

Cayo Rômulo Queiroz de França

Bacharel em Ciências Econômicas (DEC/FACEM/UERN)

<https://orcid.org/0000-0001-7885-256X>

E-mail: crq0223@gmail.com

Fábio Lúcio Rodrigues

Professor Adjunto – Departamento de Economia (FACEM/UERN)

Doutorando em Economia Aplicada (PPGE/UFPB)

<https://orcid.org/0000-0001-5809-4044>

E-mail: prof.fabiolucio@gmail.com

Resumo

O presente trabalho buscou identificar o processo gerador da série temporal do Índice Nacional de Preços do Consumidor Amplo (IPCA) no Brasil, no período que compreende entre janeiro de 1999 a julho de 2018 e posteriormente realizar a previsão dos valores percentuais da inflação para 6 (seis) períodos a frente. A série mostrou possuir características sazonais e, portanto, foi ajustado um modelo SARIMA. Após alguns testes foi identificado que a série era estacionária, e, portanto, na checagem de estimação dos modelos, o que mais se ajustou a previsão segundo os testes foi o modelo SARIMA (1,0,0) X (1,0,1).

Palavras-chave: Inflação. Sazonalidade. Previsão.

Abstract

The present work sought to identify the generative process of the time series of the Índice Nacional de Preços do Consumidor Amplo (IPCA) in Brazil, during the period between January 1999 and July 2018 and then to carry out the forecast of the inflation percentage values for 6 (six) periods ahead. The series showed to have seasonal characteristics and, therefore, a SARIMA model was adjusted. After some tests it was identified that the series was stationary, and therefore, in the estimation check of the models, what most fitted the forecast according to the tests was the SARIMA model (1,0,0) X (1,0,1).

Keywords: Inflation. Seasonality. Forecast.

1 INTRODUÇÃO

Quando o brasileiro que já passou dos 40 anos ouve quaisquer notícias sobre inflação, já vem à sua memória os idos dos anos de 1980 e início da década de 1990, onde o “dragão” da inflação tirava o sono dos trabalhadores e provocava corridas desesperadas às prateleiras dos supermercados.

Para os mais jovens, nascidos após o ano de 1994 e, conseqüentemente, no período após a implantação do Plano Real, esse monstro já não assusta mais, visto que a nova moeda, e todo o processo de estabilização monetária que se seguiu, levou os índices inflacionários a patamares minimamente aceitáveis. Após quase uma dezena de planos econômicos fracassados em menos de uma década, o Plano Real finalizou um período de instabilidade monetária e altas taxas de inflação, que chegaram a atingir 5.000% ao ano, de julho de 1993 a junho de 1994.

A estabilização monetária, por sua vez, tornou factível a possibilidade de previsão dos índices inflacionários e, assim, profissionais do mercado e estudiosos nas academias puderam

se deter em compreender todas as determinantes do comportamento dos índices inflacionários, aplicando modelos e técnicas na busca de realizar previsões cada vez mais próximas aos dados empíricos.

No Brasil existem diversos índices utilizados para mensurar a inflação. Os diferentes índices utilizam em seus cálculos critérios distintos, tais como faixas de renda diferentes, regiões diferentes, itens diferentes e até períodos diferentes. Isso contribui para tornar mais segura a medição da inflação no país. Todavia, o índice oficial, isto é, aquele índice utilizado pelo Banco Central do Brasil (BCB) para o acompanhamento dos objetivos estabelecidos no sistema de metas de inflação, é o Índice Nacional de Preços do Consumidor Amplo (IPCA).

Desenvolvido e divulgado pelo Instituto Brasileiro de Geografia e Estatística (IBGE) a partir de janeiro de 1980, desde junho de 1994 o IPCA é considerado o índice oficial de inflação do país e mede a variação dos custos dos gastos relacionados à sua constituição no período do primeiro ao último dia de cada mês de referência e no período compreendido entre o dia cinco e doze do mês seguinte

Dessa forma, compreender a forma como o IPCA é gerado no contexto da economia brasileira parece ser um fator imprescindível para agentes econômicos, sejam eles institucionais ou não, ajustarem suas previsões para os demais contextos e agregados econômicos. Nesse sentido, o presente trabalho tem como foco principal identificar o processo gerador da série temporal do IPCA e realizar a previsão dos valores percentuais da inflação oficial no Brasil para 6 (seis) períodos a frente. Para tanto, será necessário analisar o comportamento do IPCA ao longo do período objeto da análise a fim de entender seu comportamento, em seguida realizar a identificação do processo gerador da série temporal e, por fim, executar a previsão do IPCA, verificando se o modelo estimado se ajusta aos dados empíricos.

2 REVISÃO DE LITERATURA

O IPCA pode ser sinteticamente entendido como um aumento generalizado dos preços. Seguindo esse conceito, é compreensível que a moeda de um país que sofre com altas taxas de inflação perca seu valor e o consumidor, por sua vez, sofre com a redução do seu poder de compra.

Segundo Schiozer (2015) a inflação é um dos mais importantes agregados macroeconômicos de uma economia. Ela realiza a amostra da variação média dos preços de uma economia. A princípio a importância do IPCA não é pelo fato de sua variação representar algo positivo para o bem-estar social ou desenvolvimento de uma economia. Afinal, variações positivas dela representam uma redução do poder de compra da moeda de um determinado país, e sua persistência, ou acelerações, indicam uma contínua redução do poder aquisitivo. Por outro lado, variações baixas, ou mesmo negativas, de inflação podem indicar recessão ou uma redução na atividade econômica.

Identificar o tipo de processo que gera o IPCA tem sido objeto de estudo de diversos trabalhos. Com essa preocupação, Rodrigues et al (2018) aplica um modelo sazonal univariado para identificar o tipo de processo gerador do IPCA e realizar previsões, obtendo resultados com boa qualidade de ajuste para o curto prazo. O autor teve como objetivo realizar uma previsão dos valores percentuais do IPCA acumulado para doze meses, para o período compreendido entre junho de 2018 a dezembro de 2018, utilizando modelos de séries temporais univariados, obtendo resultados por meio de métodos estatísticos. O trabalho prova que a previsão dos valores percentuais do IPCA acumulado para doze meses pode ser realizada. Com isso se obteve diversos resultados mostrando que o modelo estimado se ajusta aos dados empíricos.

O trabalho de Braga e Summa (2016) teve a intenção de estimar um modelo desagregado para a inflação de custos, através dos modelos ARMAX e GARCH. Buscando

modelar a dinâmica da inflação brasileira desagregada sob a ótica da inflação de custos, os autores utilizaram procedimentos econométricos para obterem resultados significativos e de relevância, entre eles destaca-se, por exemplo, que ao contrário do que se imagina no senso comum o estudo mostrou que a inflação externa afeta também os preços dos serviços que em sua maioria, não são comercializáveis, ainda que de forma indireta, uma vez que o canal de transmissão se dá, unicamente por via de custos.

Por sua vez, Bonno (2014) utiliza o modelo SARIMAX através da metodologia Box-Jenkins, como método de estimação da inflação, decompondo a série em seus componentes não observáveis: tendência, sazonalidade e irregularidade e acrescentado variáveis explicativas, utilizando esse modelo o trabalho obteve bons resultados demonstrando bom desempenho na previsão do IPCA.

De forma semelhante a outros autores, Coelho Júnior (2014) realizou estudo de alguns indicadores relacionados ao câmbio como; IBOVESPA, IPCA e SELIC que possuem grande impacto na maioria dos ativos de renda fixa e renda variável. O trabalho analisou as séries temporais em determinados períodos e utilizou a metodologia Box-Jenkins para a realização das previsões. Os modelos estimados foram capazes de prever com moderação os movimentos do mercado, em relação ao ajuste das previsões obtidas.

Gomes (1989) analisa os modelos autoregressivos de médias móveis e faz a comparação com os métodos tradicionais denominados de "análise técnica". Utilizando a abordagem de Box-Jenkins apresenta as quatro etapas do método; identificação, estimação, verificação e previsão. Finalmente, mostra como esta técnica pode ser usada alcançando excelentes resultados na modelagem e previsão do Índice da Bolsa de Valores de São Paulo (BOVESPA).

As previsões são de extrema importância para que os pesquisadores, produtores, empresários, economistas e investidores formem suas expectativas sobre o comportamento dos preços futuros das commodities, para prever eventuais oscilações no IPCA, na taxa de juros, nos preços e etc. Ademais, os resultados obtidos utilizando o método ARIMA, confirmaram a tendência apresentada pelas variáveis reais que foram analisadas. Demonstrando a eficácia dos modelos univariados em prever valores futuros a partir da própria história (PINTO ET AL, 2008).

O estudo que foi elaborado por Campos e Cordeiro (2006) teve como objetivo demonstrar um modelo de previsões para o preço do frango inteiro resfriado no atacado do estado de São Paulo, utilizando o método ARIMA ou a metodologia Box-Jenkins, de previsões de séries temporais, em seu formato univariado. O trabalho utilizou a série histórica mensal correspondente aos anos de 1996 a 2005. Realizando testes de previsão *ex-post* para os anos de 2004 e 2005. Todos os preços da série foram atualizados pelo IGP-DI da Fundação Getúlio Vargas (FGV) para o mês de dezembro de 2005, como forma de eliminar o impacto causado pela inflação. Após os testes foram determinados 4 modelos que demonstraram consistência estatística e um bom desempenho nas previsões. Os testes realizados foram testes de previsões trimestrais anuais para 2 anos, e todos os modelos apresentaram boa performance, o que não era esperado na pesquisa para os testes correspondentes a 2 anos, já que a metodologia ARIMA univariada é reconhecidamente eficiente, para realizar previsões no curto prazo. Os bons resultados alcançados pelo modelo trazem boas expectativas para seu uso, como apoio a profissionais de diferentes áreas, como planejamento, orçamento, investimentos e algumas outras.

Uma das principais ferramentas de estimação referenciada na literatura são os modelos ARIMA (p, d, q), que procuram estimar modelos matemáticos que descrevem o comportamento de uma variável ao longo do tempo, tendo em vista basear-se em seu processo autoregressivo, tendo como principal objetivo a previsão de seu comportamento futuro. Gujarati (2011) reforça

que estes modelos são usualmente utilizados pela sua capacidade de previsão, ou seja, eles são eventualmente utilizados para a previsão do comportamento das variáveis não estacionárias.

Previsões apoiadas em um modelo podem facilitar todo processo, detectando qual comportamento a série teve no passado e extrapolando a mesma para o futuro. Cabe ao gestor a crítica da adequação dos resultados e acréscimos pessoais resultante das informações conjunturais ou até mesmo interna da própria empresa, que provavelmente, nenhum modelo estatístico será capaz de absorver (CORDEIRO; CAMPOS, 2006).

A previsão da inflação utilizando a metodologia Box-Jenkins com um modelo ARMA, com ou sem *dummy*, levou a pesquisa de Lorthiois (2009) a obter resultados positivos. O trabalho concluiu que a previsão de inflação encontrada para os próximos seis meses utilizando a metodologia Box-Jenkins, com um modelo ARMA tem maior poder previsão do que o Relatório de Mercado Focus. As previsões são muito parecidas quando é utilizada variável *dummy*. Além disto, o autor acrescenta que, o erro quadrático médio na previsão é levemente inferior quando não é utilizado variáveis como *dummies*. A inflação acumulada de janeiro a junho de 2008 foi de 3,81% sendo que a previsão estática do trabalho era de 3,64% contra 2,22% da previsão dos que mais acertam no mercado. Isto é, o modelo estimado antecipou a elevação da inflação antes dos próprios analistas de mercado.

3 PROCEDIMENTOS METODOLÓGICOS

A série temporal escolhida para objeto de estudo será o Índice Nacional de Preços ao Consumidor Amplo (IPCA), expresso em termos percentuais, calculado pelo Instituto Brasileiro de Geografia e Estatística (IBGE) e coletado via Sistema Gerador de Séries Temporais do Banco Central do Brasil (BCB). A série temporal tem periodicidade mensal e os dados coletados compreendem o período de janeiro de 1999 a julho de 2018, contendo 235 observações para utilização no processo gerador e posteriormente na previsão para seis meses à frente. A escolha da periodicidade inicial da série se justifica pela mudança no regime cambial e a periodicidade final pela proposta do projeto desse presente trabalho.

3.1 ESTACIONARIEDADE

Os Modelos que são conhecidos como, estacionários são aqueles que têm como característica ou assumem que o processo está em “equilíbrio”. Um processo é considerado fracamente estacionário se suas médias e variância se mantiverem constantes ao longo do tempo e a função de autocovariância depende apenas da defasagem que ocorre entre os instantes de tempo. Um processo é reconhecido como fortemente estacionário, se todos os momentos são invariantes a translações no tempo (ENDERS, 1995)

Para reforçar o entendimento sobre o conceito de estacionariedade, podemos dizer que o assunto em questão é uma das ideias principais que se deve ter para realizar a estimação de uma série temporal. É fundamental constatar se a série é estacionaria ou não, isso permitirá proceder a inferências estatísticas sobre os parâmetros estimados com base na realização de um processo estocástico. Portanto, se nem a esperança e nem a autocovariância dependem do tempo, então y_t é fracamente estacionário. Por definição, temos que o processo estocástico, ou a serie temporal, $\{y_t, t \in \mathbb{Z}\}$, $\mathbb{Z} = \{0, \pm 1, \pm 2, \dots\}$ é fracamente estacionário se: $E|y_t|^2 < \infty$; $E(y_t) = \mu$, para todo $t \in \mathbb{Z}$ e $E(y_t - \mu)(y_{t-j} - \mu) = \gamma_j$.

A primeira condição apenas nos dá a afirmação que o segundo momento não centrado deve ser finito, mesmo que desigual em diferentes períodos. A segunda condição assegura que a média é igual para todo período, mesmo que a distribuição da variável aleatória se altere ao longo de certo período de tempo. A terceira condição estabelece que a variância seja sempre

igual para todo período, e que, portanto, a autocovariância não depende do tempo, mas depende da distância temporal entre as observações (Bueno, 2015).

3.2 TESTE DE RAIZ UNITÁRIA

O teste de Raiz Unitária tem a finalidade de determinar a estacionariedade (ou não) da série temporal. Para testar a estacionariedade da série utiliza-se o teste de *Dickey-Fuller Aumentado* (teste ADF). Conforme Gujarati (2011) e Enders (1995), a condição de Raiz Unitária parte do processo estocástico definido por:

$$Y_t = \rho Y_{t-1} + u_t \quad -1 \leq \rho \leq 1 \quad (1)$$

Onde u_t é um termo de ruído branco. Quando $\rho = 1$, a série tem raiz unitária e o modelo segue um processo estocástico não-estacionário. Dessa forma, para realizar o teste de Raiz Unitária basta simplesmente simular uma regressão de Y_t em relação à sua primeira defasagem e verificar se o ρ é estatisticamente igual a 1. Ou seja:

$$\Delta Y_t = \delta Y_{t-1} + u_t \quad (2)$$

Onde $\delta = (\rho - 1)$ e Δ é o operador de primeira diferença. Sob a hipótese nula de que $\delta = 0$, o valor t estimado do coeficiente de Y_{t-1} segue a estatística τ .

Outros testes foram utilizados para a identificação de raiz unitária na série, como por exemplo, o teste *Dickey-Fuller aumentado* (ADF), *Philippe-Perron* (PP) e o teste KPSS. No caso do teste KPSS a uma mudança na hipótese, que pode ser observada nos resultados desse presente trabalho.

3.3 O MÉTODO BOX-JENKINS

Conforme Morettin e Toloi (2006), para descrever o comportamento de séries onde os erros observados são autocorrelacionados e influenciam o processo de evolução no tempo da variável são utilizados modelos autoregressivos integrados de médias móveis (ARIMA). Séries univariadas do tipo Box-Jenkins estão baseadas somente sobre suas próprias informações passadas para fins de previsões, ou seja, não são fundamentadas sobre qualquer teoria ou quaisquer outras variáveis. Sendo assim, a melhor estratégia para a construção do modelo será concebida pelas próprias informações passadas da série temporal. Informações essas que influenciam os valores futuros de uma série temporal.

Segundo consta em Gujarati (2011), a metodologia Box-Jenkins consiste em analisar uma série temporal e avaliar se ela segue um processo autoregressivo puro (AR), ou um processo de média móvel puro (MA), ou se se trata de um processo autoregressivo de médias móveis (ARMA), ou ainda, de um processo autoregressivo integrado de médias móveis (ARIMA).

De modo geral, um processo autoregressivo de ordem p ou $AR(p)$, pode ser expresso por:

$$(Y_t - \delta) = \alpha_1 (Y_{t-1} - \delta) + \alpha_2 (Y_{t-2} - \delta) + \dots + \alpha_p (Y_{t-p} - \delta) + u_t \quad (3)$$

O processo MA, que também pode gerar uma série temporal é simplesmente uma combinação linear de termos de erro de ruído branco. Um processo $MA(q)$ generalizado pode ser expresso por:

$$Y_t = u + \beta_0 u_t + \beta_1 u_{t-1} + \beta_2 u_{t-2} + \dots + \beta_q u_{t-q} \quad (4)$$

É provável que a série temporal em análise tenha características tanto de *AR* quanto de *MA* seguindo, portanto, um processo *ARMA*. De modo geral, uma série temporal segue um processo *ARMA* (1, 1), se puder ser representada por:

$$Y_t = \theta + \alpha_1 Y_{t-1} + \beta_0 u_t + \beta_1 u_{t-1} \quad (5)$$

Sendo assim, em um processo *ARMA* (p, q), haverá p termos autoregressivos e q termos de média móvel.

Algumas séries temporais não apresentam estacionariedade quando avaliadas em seus valores originais ou em nível. Portanto, “se tivermos de diferenciar uma série temporal d vezes para torná-la estacionária e então aplicar-lhe o modelo *ARMA* (p, q), dizemos que a série temporal é *ARIMA* (p, d, q)” (GUJARATI, 2011).

Neste contexto, a solução para o modelo consiste em determinar os valores de (p, d, q) que melhor se ajustam às informações da série temporal. O método Box-Jenkins busca apresentar a resposta para esse problema e é composto por quatro etapas: identificação, estimação, verificação e previsão.

3.4 IDENTIFICAÇÃO

Esta etapa consiste em escolher (p, d, q) do modelo *ARIMA*. Neste caso, analisam-se a função de autocorrelação (FAC) e a função de autocorrelação parcial (FACP) e tenta-se identificar o modelo que melhor se ajusta aos dados. O processo busca determinar a ordem de (p, d, q) tomando por base o comportamento das FAC e FACP, assim como também seus respectivos correlogramas.

Segundo Greene (2003), a autocorrelação é a correlação entre membros de uma série de observações ordenadas no tempo. Assim, a FAC que calcula a correlação entre y_t e y_{t-p} é definida por:

$$\rho_p = \frac{\gamma_p}{\gamma_0} = \frac{Cov(y_t, y_{t-p})}{Var(y_t)} \quad (6)$$

Mais especificamente,

$$r_p = \frac{\hat{\gamma}_p}{\hat{\gamma}_0} = \frac{\sum_{t=1}^{n-p} (y_t - \bar{y})(y_{t-p} - \bar{y})}{\sum_{t=1}^n (y_t - \bar{y})^2} \quad (7)$$

A Função de Autocorrelação Parcial (FACP) mede a correlação entre y_t e y_{t-p} , depois de eliminada a influência dos y's intermediários, sendo definida por:

$$\phi_{pp} = \rho_p, \text{ se } p = 1 \text{ ou } \phi_{pp} = \frac{|P_p^*|}{|P_p|}, \text{ se } p > 1 \quad (8)$$

Onde P_p é a matriz de autocorrelação e P_p^* é a matriz P_p com a última linha substituída pelo vetor de autocorrelações ρ_p . Matricialmente tem-se:

$$\rho_p = \begin{bmatrix} \rho_1 \\ \rho_2 \\ \dots \\ \rho_p \end{bmatrix} \quad P_p = \begin{bmatrix} 1 & \rho_1 & \rho_2 & \dots & \rho_{p-1} \\ \rho_1 & 1 & \rho_1 & \dots & \rho_{p-2} \\ \dots & \dots & \dots & \dots & \dots \\ \rho_{p-1} & \rho_{p-2} & \rho_{p-3} & \dots & 1 \end{bmatrix} \quad \phi_p = \begin{bmatrix} \phi_{p1} \\ \phi_{p2} \\ \dots \\ \phi_{pp} \end{bmatrix}$$

Onde:

$$\rho_p = P_p \phi_p$$

Isto é:

$$\rho_p = \begin{bmatrix} 1 & \rho_1 & \rho_2 & \dots & \rho_{p-1} \\ \rho_1 & 1 & \rho_1 & \dots & \rho_{p-2} \\ \dots & \dots & \dots & \dots & \dots \\ \rho_{p-1} & \rho_{p-2} & \rho_{p-3} & \dots & 1 \end{bmatrix} \begin{bmatrix} \phi_{p1} \\ \phi_{p2} \\ \dots \\ \phi_{pp} \end{bmatrix}$$

A representação gráfica de $\hat{\phi}_{pp}$ contra “p” é conhecida como correlograma amostral da FACP. Neste sentido, procuram-se semelhanças entre as funções de autocorrelação teóricas e amostrais que sejam boas sugestões dos processos AR, MA e ARMA que possam melhor explicar a dinâmica no tempo da série em estudo.

3.5 ESTIMAÇÃO

Depois de identificado a quantidade de interações que cada processo do modelo (AR, MA, ARMA, etc.) deve realizar, passa-se a fase de estimação, onde os modelos são ajustados e examinados. Depois de realizada a estimação baseada na identificação, serão simulados, também, modelos alternativos com a quantidade de “regressores” diferente daquelas identificadas como ótimas. Desta forma, serão selecionados cinco modelos distintos com base nos métodos de *Akaike Information Criterion (AIC)* e no *Schwartz Bayesian Criterion (SBC)*, definidos por:

$$AIC = T \ln(SQR) + 2n \qquad SBC = T \ln(SQR) + n \ln(T) \qquad (9)$$

Onde: n é o número de parâmetros estimados, T expressa o número de observações utilizadas e SQR é a soma dos quadrados dos resíduos.

Geralmente, quando se trabalha com variáveis defasadas perdem-se informações sobre a série temporal em estudo. Neste sentido, segundo Albuquerque e Morais (2007), “para se comparar modelos alternativos (ou concorrentes) deve-se manter fixo o número de informações utilizadas (T) para todos os modelos em comparação”. Na utilização dos critérios definidos por (10) a avaliação se dá comparando os valores obtidos com cada um dos modelos concorrentes e escolhendo aqueles com menores AIC e SBC .

3.6 VERIFICAÇÃO

A verificação pretende avaliar se o modelo já identificado e estimado descreve o comportamento da série temporal adequadamente. Essa etapa se dá pela análise dos resíduos dos modelos concorrentes, na busca do melhor ajuste para a explicação da série temporal em estudo.

Para a verificação dos modelos candidatos será utilizado o teste de Ljung-Box. Esse teste utiliza a estatística Q para verificar se um determinado conjunto de autocorrelações de resíduos é estatisticamente diferente de zero. Essa estatística possui distribuição Qui-Quadrado

e o teste é realizado comparando-se os valores de Q estimado com o Q tabelado (distribuição Qui-Quadrado). Os valores de Q são estimados usando-se:

$$Q = n(n+2) \sum_{k=1}^m \left(\frac{r_k^2}{n-k} \right) \quad (10)$$

Onde n é o número de observações e k é o número de parâmetros estimados. Ressalta-se que para o modelo ser “aceito” é necessário que o erro produzido pela sua estimação seja independente e identicamente distribuído, ou seja, tenha característica de *ruído branco*.

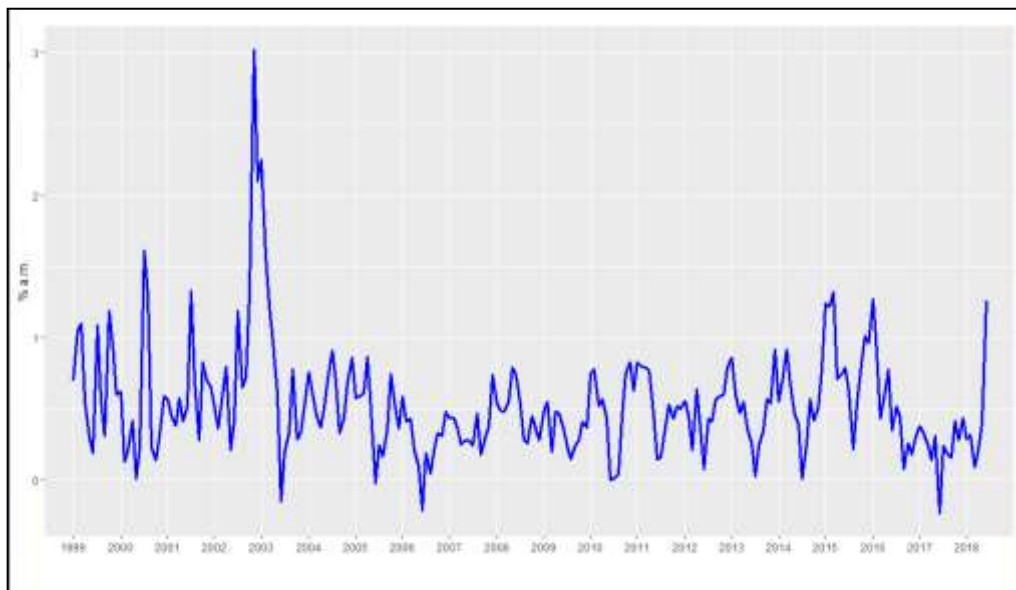
3.7 PREVISÃO

Segundo Gujarati (2011), essa é a etapa que torna a modelagem ARIMA tão popular, em virtude do seu sucesso nas previsões de séries temporais, principalmente no curto prazo. O autor ainda enfatiza que, no curto prazo, “*as previsões obtidas por esse método são mais confiáveis que aquelas obtidas pela modelagem econométrica tradicional*”.

4 APRESENTAÇÃO E ANÁLISE DOS RESULTADOS

A Figura 1 apresenta o comportamento da série ao longo do período estabelecido para análise.

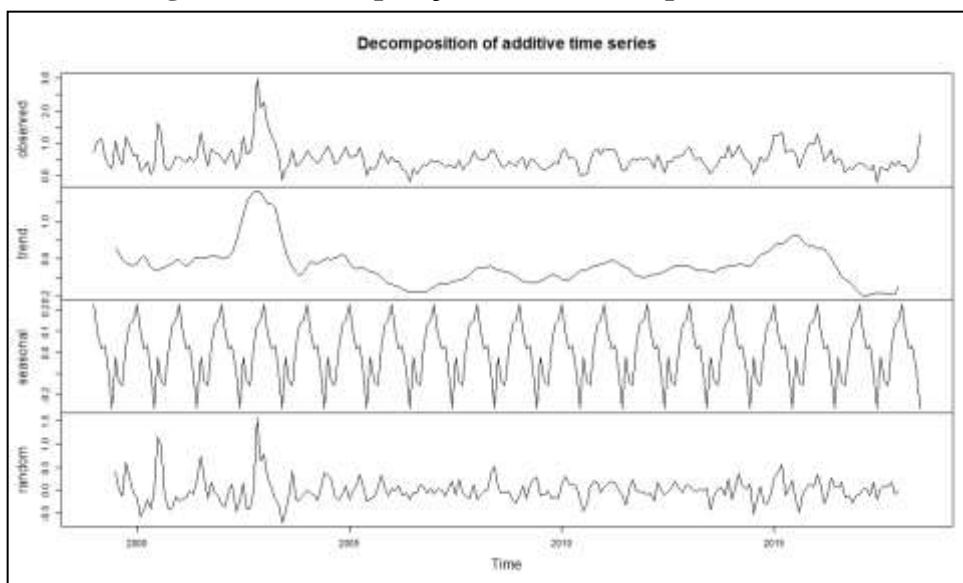
Figura 1: Índice Nacional de Preços ao Consumidor Amplo (IPCA) – Evolução Mensal



Fonte: Elaboração própria com base nos dados do IBGE

Percebe-se, na Figura 1, que a série do IPCA parece se comportar de forma sazonal, apresentando quedas no primeiro semestre, seguida de elevações após a primeira metade da maioria dos anos de análise. Como descreve Lamounier (2007) a sazonalidade está relacionada a movimentos que ocorrem para cima e para baixo em torno de uma determinada média, porém, sazonalidade pode possuir um comprimento constante de 12 meses. Repetindo-se nesta base constante as variações sazonais também podem ser observadas tendo-se por base períodos menores de tempo no médio e no curto prazos. Para identificar a possibilidade de sazonalidade, a Figura 2 apresenta a decomposição da série temporal.

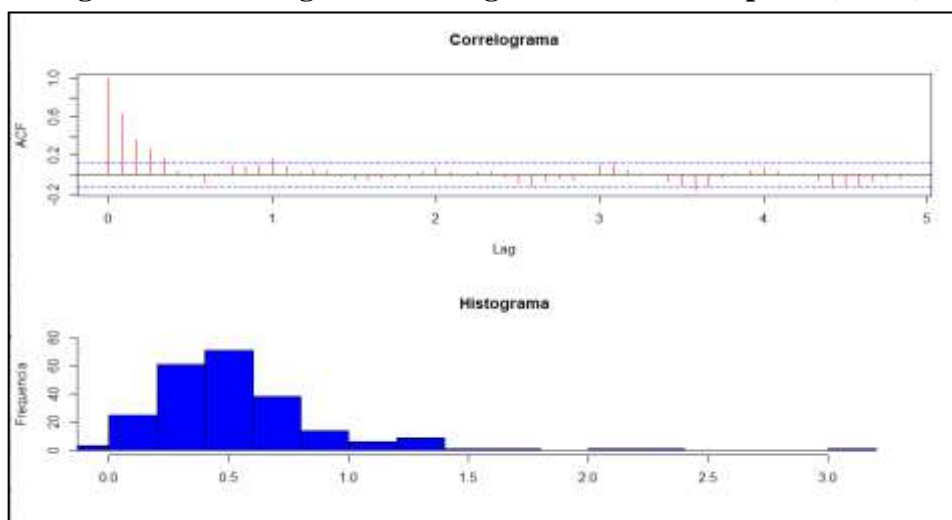
Figura 2 - Decomposição da Série Temporal (IPCA)



Fonte: Elaboração própria com base nos resultados das simulações.

Note que através da linha *seasonal* é possível identificar a existência de efeitos de sazonalidade na série temporal. Uma melhor compreensão do comportamento da série pode ser visualizada na Figura 3.

Figura 3 - Correlograma e histograma da série temporal (IPCA)



Fonte: Elaboração própria com base nos resultados das simulações.

O histograma da Figura 3 aponta uma forte assimetria na série e nos leva ao entendimento de que, possivelmente, a série não segue uma distribuição de probabilidades normal. Do correlograma podemos perceber que a série temporal tem um decaimento bastante lento, caracterizando um processo de memória longa e, possivelmente não-estacionário, além de demonstrar os efeitos de sazonalidade da série. A seguir, serão demonstradas na Tabela 1, algumas estatísticas da série em estudo.

Tabela 1 - Estatísticas descritivas da série temporal (IPCA)

Média	Variância	Desvio-Padrão	Coef. de Variação	Assimetria	Curtose
0,5321	0,148	0,384	72,353	2,148	12,153

Fonte: Elaboração própria com base nos resultados das simulações.

Os valores encontrados da média, variância e desvio-padrão comprovam que a série se enquadra nos limites do regime de metas de inflação, que foram adotados pela autoridade monetária no ano de 1999. A Tabela 1 segue apresentando os valores da assimetria e curtose, que comprovam que os formatos da distribuição de probabilidades da série são diferentes da distribuição normal. Por fim o coeficiente de variação estimado, muito acima de 15, expressa a possibilidade de a série não apresentar comportamento estacionário.

Portanto, diante do que mostra o comportamento da série temporal, lidaremos não com uma modelagem ARIMA, mas com um modelo SARIMA, que pode ser representado como $ARIMA(p, d, q) X (P, D, Q)$ onde m representa o número de períodos. Nesse caso será necessário realizar a identificação na parte onde não há sazonalidade e na parte sazonal da série.

Seguindo com a análise dos resultados obtidos, apresentamos os testes de normalidade da série que visam identificar se os comportamentos das observações seguem uma distribuição de probabilidades normal ao longo do tempo. Isso é requisito necessário para a estabilidade da série temporal. A Tabela 2 apresenta alguns testes e seus resultados.

Tabela 2 - Testes de normalidade da série temporal (IPCA)

Teste	Hip. Nula (H0)	Estatística	P- Valor
Jarque – Bera	Normalidade	992,772	0,000
Shapiro - Wilk	Normalidade	0,854	0,000
Box - pierce	Normalidade	168,36	0,000
Kolmogorov-Smirnov	Normalidade	0,131	0,000

Fonte: Elaboração própria com base nos resultados das simulações.

Todos os testes demonstrados na Tabela 2 apontam para rejeição da hipótese nula e, portanto, sugerem evidências de que o comportamento da série temporal não segue uma distribuição de probabilidades normal. Com isso, temos a indicação de que a série, em nível, pode ser não estacionária. Diante dessa possível condição, será necessário aplicar testes de raiz unitária na série temporal, no intuito de confirmar a condição de não estacionariedade da série e, possivelmente, aplicar diferenças na busca da condição de estacionariedade, necessária à modelagem proposta. A tabela 3 apresenta os testes de raiz unitária mais utilizados na literatura.

Considerando um nível de significância de 5%, podemos observar na Tabela 3 que todos os testes apontam para a hipótese que considera a série estacionaria em nível. Sendo assim, para as simulações da série temporal em estudo utilizaremos dados da série temporal em nível, ou seja, o d do modelo $ARIMA(p, d, q) X (P, D, Q)$ será igual a um ($d = 0$).

Tabela 3 - Teste de raiz unitária na série temporal (IPCA) em nível

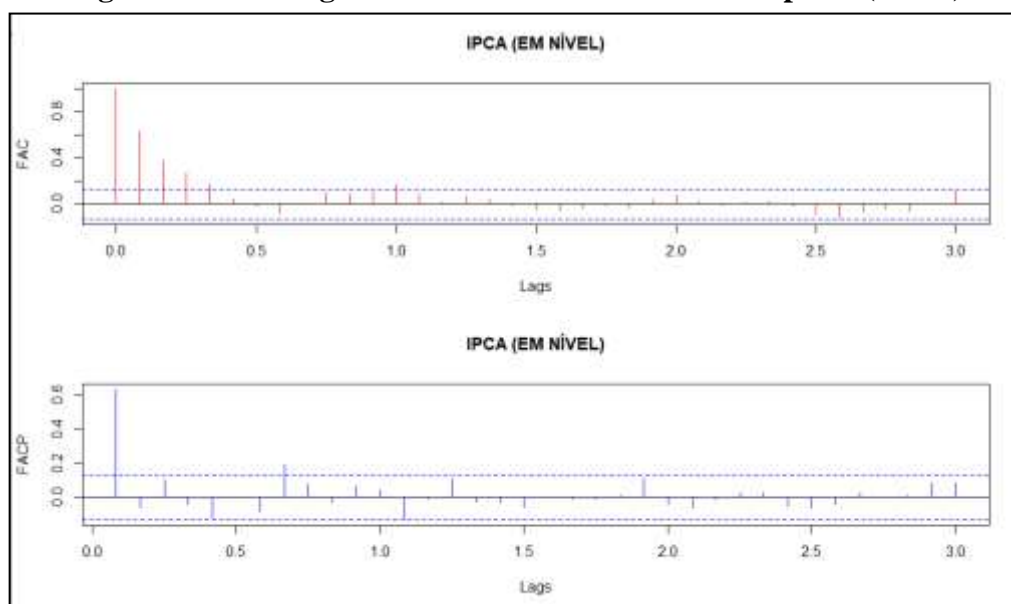
Teste	Hip. Nula (H0)	Série em Nível	
		Estatística	P-Valor
Dickey-Fuller (DF)	Não Estacionária	-2,652	0,010
Dickey-Fuller Aumentado (ADF)	Não Estacionária	-5,548	0,010
Philipe-Perron (PP)	Não Estacionária	-87,505	0,010
KPSS	Estacionária	0,341	0,100

Fonte: Elaboração própria com base nos resultados das simulações.

Identificado o parâmetro d , é necessário identificar o número de interações autoregressivas (AR) e o número de interações de médias móveis (MA). Para essa identificação foram utilizados os correlogramas construídos a partir das estimações da Função de Autocorrelação Amostral (FAC) e da Função de Autocorrelação Parcial Amostral ($FACP$) da série em nível, apresentados na Figura 4.

A Figura 4 apresenta a série com uma diferença sazonal que consistem em uma variação anual, ou seja, apresenta a mesma com uma diferenciação de ordem 12, e os correlogramas (FAC e $FACP$). Percebe-se que o maior valor da autocorrelação está em 12, além de valores positivos altos em múltiplos de 12, confirmando, portanto, o padrão de sazonalidade mensal. Não é perceptível comportamento decrescente dos valores de autocorrelação, fato que denota a falta de tendência na série como apresentando na decomposição anteriormente.

Figura 4 - Correlogramas FAC e FACP da série temporal (IPCA)



Fonte: Elaboração própria com base nos resultados das simulações.

As quatro primeiras autocorrelações na FAC amostral são significativas, o que sugere um modelo autoregressivo (AR) de ordem 1. Já a $FACP$, possui autocorrelações significativas nas defasagens sazonais e nas de ordem 1, 7 e 11, o que sugere um modelo de médias móveis de ordem 3. Seguindo a metodologia *Box-Jenkins*, outros modelos serão avaliados visando melhorar a identificação do processo de interação dos parâmetros. Serão utilizados quinze modelos concorrentes, os mesmos têm seus parâmetros estimados e expostos na Tabela 4 juntamente com seus respectivos valores para o teste de *Box-Pierce* nos resíduos de cada modelo, além de seus valores estimados para os critérios *Akaike Information Criterion (AIC)* e

Schwartz Bayesian Criterion (SBC). Os modelos concorrentes apresentaram entre 3 e 14 parâmetros. Os menores valores *AIC* e *SBC* foram encontrados no modelo *SARIMA (1,0,0) X (1,0,1)*.

Tabela 4 - Modelos candidatos ao melhor ajuste

Resumo dos Modelos				
Modelo	Análise dos Resíduos			
	Q (16)	P(Q)	AIC	SBC
SARIMA (1,0,0) X (1,0,1)	12,950	0,676	<u>86,739</u>	<u>103,995</u>
SARIMA (0,0,1) X (1,0,1)	48,211	0,001	118,835	136,091
SARIMA (1,0,1) X (2,0,1)	11,397	0,784	89,835	113,992
SARIMA (1,0,2) X (2,0,2)	10,596	0,833	92,622	123,681
SARIMA (1,2,1) X (1,0,2)	26,742	0,044	130,153	150,807
SARIMA (1,2,2) X (2,0,1)	26,574	0,046	134,700	158,797
SARIMA (2,0,2) X (2,0,2)	10,436	0,842	94,777	129,287
SARIMA (2,0,1) X (1,2,2)	8,276	0,940	158,372	181,768
SARIMA (2,2,0) X (2,3,1)	58,434	0,001	408,993	428,631
SARIMA (2,4,2) X (2,1,3)	51,361	0,000	253,792	287,591
SARIMA (3,0,1) X (1,3,2)	9,771	0,878	267,144	293,410
SARIMA (3,0,2) X (2,1,2)	7,191	0,963	106,951	140,877
SARIMA (3,3,0) X (1,2,3)	68,706	0,001	360,613	387,236
SARIMA (4,0,1) X (1,4,1)	26,459	0,047	570,103	595,866
SARIMA (3,3,1) X (1,4,0)	83,628	0,000	772,222	791,447

Fonte: Elaboração própria com base nos resultados das simulações.

Encontrado o melhor modelo a ser utilizado, realizamos as previsões, que são calculadas no horizonte de seis meses à frente, ou seja, para o período correspondente entre os meses de julho e dezembro de 2018.

A Tabela 5 apresenta os valores previstos do IPCA para este período e seus respectivos intervalos de confiança, com 50%, 75% e 90% de probabilidades.


Tabela 5 - Previsão estimada para o IPCA mensal – fora da amostra

PREVISÃO		IC 50%		IC 75%		IC 90%	
		lower	upper	lower	upper	lower	upper
2018.7	1,02	0,82	1,21	0,69	1,35	0,55	1,49
2018.8	0,79	0,56	1,02	0,40	1,19	0,23	1,36
2018.9	0,67	0,43	0,92	0,25	1,09	0,07	1,27
2018.10	0,68	0,43	0,93	0,25	1,11	0,06	1,29
2018.11	0,61	0,36	0,87	0,18	1,05	-0,01	1,24
2018.12	0,64	0,39	0,90	0,20	1,08	0,02	1,27

Fonte: Elaboração própria com base nos resultados das simulações.

Para uma melhor visualização das previsões geradas pelo modelo escolhido, a Figura 5 expressa as informações da Tabela 5 em formato de gráfico.

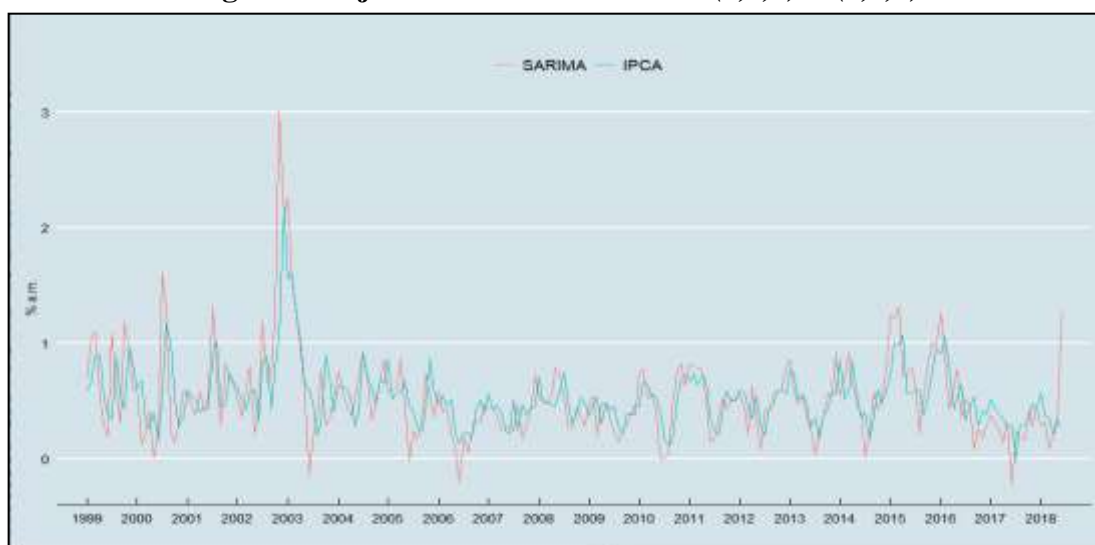
Figura 5 - Projeções do Modelo SARIMA (1,0,0) X (1,0,1)



Fonte: Elaboração própria com base nos resultados das simulações.

Por fim, a Figura 6 demonstra o ajuste visual em formato gráfico. Essa demonstração é proporcionada pelas previsões obtidas com o modelo SARIMA (1,0,0) X (1,0,1) estimado.

Figura 6 - Ajuste do modelo SARIMA (1,0,0) X (1,0,1)



Fonte: Elaboração própria com base nos resultados das simulações.

5 CONSIDERAÇÕES FINAIS

No Brasil a implantação do regime de metas para o combate a inflação, levou o índice a uma queda e também a uma mudança das expectativas. Quando comparadas com a inflação anterior as expectativas do mercado melhoraram nos últimos anos. O objetivo deste trabalho foi mostrar que existem modelos simples que conseguem prever o comportamento da inflação para seis períodos a frente.

No Brasil existem vários índices utilizados para medir a inflação. Os diferentes índices utilizam em seus cálculos critérios distintos como, várias faixas de renda, diversas regiões e até períodos diferentes. Isso contribui para tornar mais segura a medição da inflação no país. Porém

o índice oficial, utilizado pelo Banco Central do Brasil (BCB) para o acompanhamento dos objetivos estabelecidos no sistema de metas de inflação, é o Índice Nacional de Preços do Consumidor Amplo (IPCA), objeto de estudo do presente trabalho.

Dessa forma, compreender a forma como o IPCA é gerado no contexto da economia se tornou um fator relevante para a elaboração desse trabalho, levando em conta que isso é um fator imprescindível para os agentes econômicos, sejam eles institucionais ou não, ajustarem suas previsões para os demais contextos e agregados econômicos.

Nesse sentido, o presente trabalho identifica o processo gerador da série temporal do IPCA e realiza a previsão dos valores percentuais da inflação oficial no Brasil para 6 (seis) períodos a frente, utilizando um modelo SARIMA. Após rodar todos os modelos concorrentes, como descrito nos resultados o menor valor AIC foi do modelo SARIMA (1,0,0) X (1,0,1), de igual forma para o valor de SBC, encontramos o menor valor no modelo SARIMA (1,0,0) X (1,0,1). Com isso concluímos que com o resultado encontrado, não existe a necessidade de realizar um diagnóstico para testar o melhor modelo a ser utilizado nas previsões, tendo em vista que já encontramos o modelo que melhor se ajusta a previsão nas análises dos resíduos.

Após encontrar os modelos, os objetivos, desse trabalho que consistia em identificar o processo gerador da inflação e encontrar o melhor modelo econométrico, para enfim realizar a previsão mais ajustada possível foram alcançados. Encontrado o modelo SARIMA (1,0,0) X (1,0,1), que segundo os testes se mostrou o melhor modelo a ser utilizado, realizamos as previsões, que são calculadas no horizonte de seis meses à frente, ou seja, para o período correspondido entre os meses de julho e dezembro de 2018, como já citado anteriormente nos resultados.

REFERÊNCIAS

ALBUQUERQUE, A. P.; MORAES, M. C. Modelagem econométrica para a previsão do preço futuro do cacau: Abordagem ARIMA. **Revista Ciências Administrativas**, Fortaleza, v. 13, n. 2, p. 193-207, 2007. Disponível em:

<https://periodicos.unifor.br/rca/article/view/269/pdf>.

BUENO, R. L. S. **Econometria de Series Temporais**. São Paulo: Cengage Learning, 2015.

BRAGA, J. M; SUMMA, R. Estimación de um modelo desagregado de inflação de custo para o Brasil. **Ensaio FEE**, Porto Alegre, v. 37, n. 2, p. 399-430, 2016. Disponível em:

<https://revistas.fee.tcche.br/index.php/ensaio/article/view/3482/3766>.

CAMPOS, P. A. C; CLEMENTE, A.; CORDEIRO, A. A. L. Aplicação do modelo ARIMA para previsão do preço do frango inteiro resfriado no grande atacado do Estado de São Paulo. *In*: CONGRESSO BRASILEIRO DE CUSTOS, 13., 2006, Belo Horizonte. **Anais ...** Belo Horizonte: ABC, 2006. Disponível em:

<https://anaiscbc.emnuvens.com.br/anais/article/view/1871/1871>.

ENDERS, W. **Applied Econometric Time Series**. New York: Wiley and Sons, 1995.

GUJARATI, D. N.; PORTER, D. C. **Econometria Básica**. Porto Alegre: AMGH, 2011.

GREENE, W. H. **Econometric Analysis**. New Jersey: Prentice Hall, 2003.

GOMES, F. C. Os Modelos ARIMA e a abordagem de Box-Jenkins uma aplicação na previsão do IBOVESPA a curtíssimo prazo. **Revista de Administração de Empresas**, São Paulo, v. 29, n. 2, 1989. Disponível em; <https://rae.fgv.br/rae/vol29-num2-1989/modelos-arima-abordagem-box-jenkins-aplicacao-na-previsao-ibovespa-curtissimo> .

BONNO, S. J. P. **Previsão de inflação utilizando modelos de séries temporais**. Rio de Janeiro: FGV, 2014, 62 p. Dissertação (Mestrado em Finanças e Economia Empresarial) – Escola de Pós-Graduação em Economia, Fundação Getúlio Vargas, Rio de Janeiro, 2014. Disponível em: <http://bibliotecadigital.fgv.br/dspace/handle/10438/11750?show=full> .

LORTHIOIS, A. D. E. **Modelo de Previsão de Inflação no Brasil**. São Paulo: FGV, 2009, 40 p. Dissertação (Mestrado Profissional em Finanças e Economia Empresarial) – Escola de Economia de São Paulo, Fundação Getúlio Vargas, São Paulo, 2009. Disponível em: <http://bibliotecadigital.fgv.br/dspace/handle/10438/2622>.

LAMOUNIER, W. M. Tendência, Ciclos e Sazonalidade nos preços spot do café brasileiro na NYBOT. **Gestão de Produção**, São Carlos, v.14, n.1, p.13-23, 2007. DOI: <https://doi.org/10.1590/S0104-530X2007000100003>.

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

COELHO JÚNIOR, N. **Utilização do método Box-Jenkins para Previsão de indicadores econômicos (IPCA, SELIC, CÂMBIO E IBOVESPA)**. Curitiba: UFPR, 2014, 21 p. Monografia (Especialização em Macroeconomia e Finanças) – Programa de Pós-Graduação em Macroeconomia e Finanças, Universidade Federal do Paraná, Curitiba, 2014. Disponível em: <https://acervodigital.ufpr.br/bitstream/handle/1884/42778/R%20-%20E%20-%20NAOR%20COELHO%20JUNIOR.pdf?sequence=1&isAllowed=y>

PINTO, P. A. L. A.; PEREIRA, E. S.; OLIVEIRA, M. C.; SANOTS, J. M.; MAIA, S. F. Aplicação do modelo ARIMA à previsão do preço das commodities agrícolas brasileiras. In: CONGRESSO DA SOCIEDADE BRASILEIRA DE ECONOMIA, ADMINISTRAÇÃO E SOCIOLOGIA RURAL, 46., 2008, Rio Branco. **Anais ...** Rio Branco: SOBER, 2008. Disponível em: https://ideas.repec.org/cgi-bin/get_doc.pl?urn=RePEc%3Aags%3Asbrfsr%3A109197&url=http%3A%2F%2Fageconseach.umn.edu%2Frecord%2F109197%2Ffiles%2F596.pdf.

RODRIGUES, F. L.; OLIVEIRA, K. C.; LACERDA, M. A. D.; PRADO, A. G. S. A anatomia da inflação: modelando o processo gerador do IPCA no Brasil. In: ENCONTRO NACIONAL DE ECONOMIA DO VALE DO AÇU, 2018, Assu. **Anais ...** Assu: ECONAÇU, 2018. Disponível em: <http://www.econassu.com.br> .

SCHIOZER, N. A. V. B. **A inflação brasileira de 1999 até 2014: Interpretações Pós-Keynesianas**. Campinas: UNICAMP, 2015, 56 p. Monografia (Bacharelado em Ciências Econômicas) – Instituto de Economia, Universidade Estadual de Campinas, Campinas, 2015. Disponível em: <http://www.bibliotecadigital.unicamp.br/document/?code=000967885&opt=1>.