

Modelagem e análise da produção industrial alimentícia brasileira (2002-2017) a partir de um modelo SARIMA

Ícaro Romolo Sousa Agostino (UFSM) icaroagostino@gmail.com

Cristiano Ziegler (UFSM) cz001097@fahor.com.br

Renan Mitsuo Ueda (UFSM) renan.mitsuo@hotmail.com

Letícia Marasca (UFSM) leticiamarasca@yahoo.com.br

Adriano Mendonça Souza (UFSM) amsouza.sm@gmail.com

Resumo:

A indústria alimentícia brasileira representa uma importante parcela da produção industrial como um todo, tendo forte característica de sazonalidade em seu comportamento. Dessa forma, o objetivo desse artigo é investigar o comportamento temporal da produção industrial alimentícia nacional por meio dos modelos da classe SARIMA. A série temporal utilizada refere-se aos dados mensais da produção da indústria de alimentos brasileira, disponibilizados pelo Instituto de Pesquisa Econômica Aplicada (IPEA), sendo utilizado o período compreendido entre janeiro de 2002 e junho de 2017, totalizando 186 observações. O procedimento metodológico adotado foi o de Box-Jenkins, a partir da modelagem SARIMA. Como resultado o estudo apresenta um modelo ajustado com características de ruído branco, possibilitando a realização da previsão *in-sample*, de acordo com os pressupostos da metodologia utilizada. O processo gerador da série temporal foi um autorregressivo de ordem 2, com filtro de médias móveis de ordem 1, além de um componente autorregressivo sazonal de ordem 12, sendo aplicada uma diferença ($d = 1$) para tornar a série estacionária, portanto o modelo selecionado para representar a série foi o SARIMA (2,1,1) (1,0,0)₁₂. Como discussão, a modelagem possibilitou avaliar o comportamento temporal da indústria de alimentos em relação as características, verificando a influência de curto prazo autorregressivo e sazonal no comportamento seriado do índice.

Palavras chave: Indústria de Alimentos, Box-Jenkins, Produção Industrial.

Modeling and analysis of Brazilian industrial food production (2002-2017) from a SARIMA model

Abstract

The Brazilian food industry represents an important part of the industrial production as a whole, having a strong characteristic of seasonality in its behavior. Thus, the objective of this article is to investigate the temporal behavior of the national food industry through the SARIMA class models. The time series used refers to the monthly data of the production of the Brazilian food industry, made available by the Institute of Applied Economic Research (IPEA), using the period between January 2002 and June 2017, totaling 186 observations. The methodological procedure adopted was that of Box-Jenkins, based on the SARIMA modeling. As a result, the study presents an adjusted model with white noise characteristics, allowing the realization of the in-sample forecast, according to the assumptions of the methodology used. The generative process of the time series was an autoregressive of order 2, with a moving average filter of order 1, besides a seasonal autoregressive component of order 12, a difference ($d = 1$) being applied to make the series stationary, the selected model to represent the series was SARIMA (2,1,1) (1,0,0)₁₂. As a discussion, the modeling made it possible to evaluate the temporal behavior of the food industry in relation to the characteristics, verifying the autoregressive and seasonal short-term influence on the serial behavior of the index.

Key-words: Food Industry, Box-Jenkins, Industrial Production.

1. Introdução

Segundo Almeida e Suhr (2012), o desenvolvimento da indústria no Brasil começa aos poucos, no final do século XIX, cerca de um século depois de países da Europa, que já haviam trocado os produtos artesanais por produtos industrializados. Foi somente no século XX que a industrialização brasileira ganha força, modificando a economia, política e sociedade. Até então o país era basicamente rural, e começa a se transformar em urbano e industrial, alterando os sistemas produtivos, governamentais e financeiros.

Contribuindo com essa perspectiva, Peinado e Graeml (2007), mencionam que a base necessária para a industrialização no Brasil surgiu com o café, sendo esse o responsável pelo desenvolvimento do capital, transporte e mão de obra. No início do século XX, grande parte dos funcionários das indústrias era composta por mulheres e crianças, o que resultou na criação de leis para melhorar a condição do trabalhador industrial ainda nas três primeiras décadas do século. Na década de cinquenta o governo incentivou a vinda de indústrias multinacionais para o Brasil, com financiamentos subsidiados e isenção de impostos. A partir desse momento o país passou a integrar a economia internacional, com empresas que detinham elevado grau de tecnologia.

Nesse contexto, a indústria alimentícia se desenvolveu no Brasil, sobretudo devido a efeitos de exportação do final do século XIX, e da Primeira Guerra Mundial, o setor industrial brasileiro passou a atender uma maior demanda interna de matéria-prima industrial e produtos alimentícios, como carnes. No Século XX, o crescimento da urbanização e a migração da população para as cidades contribuiu para o aumento da demanda por produtos industrializados, auxiliando o crescimento de indústrias desse setor (RATTNER, 1978; CUNHA; DIAS; GOMES, 2006).

Considerando a relevância do tema abordado por esta pesquisa, este artigo tem como objetivo investigar o comportamento da série temporal da produção industrial alimentícia brasileira, assim como ajustar um modelo preditor por meio da metodologia de Box-Jenkins, utilizando modelos da classe geral ARIMA para a série estudada.

Além desta introdução, o presente artigo está organizado em mais cinco seções. Na próxima seção é apresentado o referencial teórico, abordando a indústria alimentícia brasileira e a metodologia de Box-Jenkins; na seção seguinte é apresentada a metodologia utilizada na pesquisa, com apresentação dos dados e os procedimentos metodológicos; na quarta seção são apresentados os resultados e discussões, e por fim, na quinta seção a conclusão da investigação realizada.

2. Referencial Teórico

A seguir apresenta-se a contextualização teórica a respeito do tema do estudo.

2.1. Indústria Alimentícia Brasileira: Surgimento, Importância e Características

A indústria brasileira possui uma grande diversificação, possibilitando um dinamismo para a economia, devido a diferentes setores industriais instalados no país. Em um momento de crise, alguns setores podem ter perdas grandes na produção, já outros, no mesmo período, podem apresentar crescimento. Porém a maioria das indústrias ainda apresenta baixa especialização, tornando-a pouco competitiva no mercado internacional (SARTI; HIRATUKA, 2011).

Flandrin e Montarini (1998), apontam que após a Revolução Industrial, houve grande êxodo rural e expansão para as cidades, modificando os moldes da economia e alavancando o comércio mundial. As mulheres passaram a trabalhar nas fábricas e indústrias, esse também pode ser considerado um fator que contribuiu para a expansão da indústria alimentícia.

Na década de 90, devido a estabilização econômica e inserção do Brasil na economia internacional, indústria de alimentos teve modificações expressivas. Nesse período foi necessária uma maior modernização das empresas, eficiência na produção e melhoria dos produtos, a fim de se manterem competitivas no mercado (CUNHA; DIAS; GOMES, 2006).

Segundo Nespolo *et al.* (2015), a indústria de alimentos tem como principal objetivo transformar a matéria-prima alimentar em um produto apropriado ao consumo, por meio de processos biológicos, químicos e físicos. Através desses processos o alimento tem a possibilidade de apresentar condições antes inexistentes, que possibilita várias vantagens ao produto. As principais vantagens da industrialização alimentícia são: maior tempo de vida útil e armazenamento; melhoramento no sabor, aroma e consistência; produção de produtos especializados (dietética, infantil, etc); baixo custo de beneficiamento; facilidade na logística; entre outras.

O setor industrial de alimentos no Brasil no ano de 2016 teve um faturamento total de US\$ 175,9 bilhões, distribuídos entre exportações com US\$ 36,4 bilhões e mercado interno com US\$ 139,5 bilhões, além de US\$ 4,1 bilhões em importações. As empresas desse setor apresentam grande diversificação nos segmentos, tanto oligopolizados (leite em pó; iogurtes; indústria de café solúvel; entre outros) como concorrenciais (cereais e produtos afins; massas alimentícias e biscoitos; farinhas diversas, entre outros) (DEPEC, 2017).

Silvério *et al.* (2015), destacam que o setor de produção alimentícia possui uma acirrada concorrência entre as empresas, e cabe a cada uma buscar o seu diferencial. Devido a esta grande concorrência, cada vez mais são desenvolvidas novas tecnologias nas indústrias alimentícias, tanto em relação a métodos de produção quanto em relação a produtos diferenciados.

A sazonalidade na indústria alimentícia é uma característica muito comum, devido a variação da frequência da demanda pelos alimentos. Essa variação é causada pelas datas comemorativas, alterações climáticas, além de outros fatores. Contudo é importante utilizar mecanismos para avaliar e prever essas flutuações de demanda durante o ano, para as empresas manterem-se em um mercado competitivo, como é o caso da indústria de alimentos (QUEIROZ; CAVALHEIRO, 2003).

Os meses que apresentam maior sazonalidade na indústria alimentícia são possíveis de serem observados na Figura 1.




Figura 1 – Sazonalidade da Produção Industrial de Alimentos de 2002 a 2016

Fonte: IBGE in: DEPEC, 2017

Na Figura 1 é possível visualizar a sazonalidade mensal da produção industrial de alimentos no período de 2002 a 2016. O mês que apresenta maior produção é o mês de setembro, uma das causas que podem contribuir para essa sazonalidade é o fato desse setor estar ligado ao setor

agropecuário. O setor agropecuário abastece a indústria alimentícia com matérias-primas, como: soja, cana-de-açúcar, milho, leite, carnes, café, trigo, entre outros. Além disso, cada segmento dentro da indústria de alimentos possui uma sazonalidade específica (DEPEC, 2017).

2.2. Metodologia de Box-Jenkins

De acordo com Souza (2016), um método utilizado para o estudo de séries temporais, a fim de se realizar previsões para séries de médio comprimento, são os modelos de classe geral denominado *Autoregressive integrated moving average* (ARIMA), o mesmo se caracteriza por capturar a correlação seriada entre os valores da série ao longo do tempo. Tal metodologia foi desenvolvida por Box-Jenkins (1970).

A utilização da metodologia de Box-Jenkins parte do pressuposto de que a série temporal analisada deve ser estacionária, este pressuposto garante a significância dos parâmetros estimados ao longo das observações. Para tornar uma série com tendência em estacionária, Martin *et al.* (2016) dizem que faz-se necessário a aplicação de diferenças na série original. A princípio, para a verificação da estacionariedade da série é realizada uma análise gráfica. No entanto, a estacionariedade da série é confirmada por meio da aplicação dos testes de raízes unitárias, sendo os testes mais usuais: Augmented Dick-Fuller – ADF (DICKEY, 1984) e Kwiatkowski, Phillips, Schmidt e Shin – KPSS (KWIATKOWSKI *et al.*, 1992). Para a obtenção mais acurada do grau de estacionariedade dos dados, Souza (2016) sugere a utilização conjunta dos testes de raízes unitárias.

Os filtros que fazem parte dos modelos ARIMA são: componente autorregressivo (AR), filtro de integração (I) e o componente de médias móveis (AR). Com base nas características de autocorrelação da série temporal, ao final do ciclo da modelagem de Box-Jenkins é possível determinar qual o melhor modelo predictor. As etapas do ciclo de modelagem Box-Jenkins são: identificação, através da análise da função de autocorrelação (FAC) e autocorrelação parcial (FACP), determina-se o modelo que representará a série; estimação, estima-se os parâmetros autorregressivos e de médias móveis; validação, se verifica a adequação do modelo ajustado ao comportamento real da série; e previsão, realizada somente se as etapas que o antecedem forem executadas (KIRCHNER *et al.*, 2011; NORONHA *et al.*, 2016; Marasca *et al.*, 2017).

De acordo com Souza *et al.* (2011), a representação genérica dos modelos ARIMA (p,d,q) é dada pela equação 2, onde B corresponde ao operador retroativo, ϕ o parâmetro autorregressivo de ordem p , d representa o número de diferenciações, e θ o termo de médias móveis de ordem q .

$$\phi(B) \Delta^d X_t = \theta(B) a_t \quad (1)$$

Além dos filtros autorregressivos e de médias móveis, a investigação da autocorrelação pode indicar correlação entre os períodos da série analisada, apontando presença de sazonalidade, nesse caso os modelos com componentes sazonais são chamados de SARIMA. Os modelos denominados SARIMA são compostos da parte não sazonal, com parâmetros iguais aos modelos ARIMA (p, d, q) e de uma parte com os parâmetros sazonais (P, D, Q)s, em que o “s” indica a ordem da sazonalidade. Dessa forma, a descrição genérica do modelo é escrita SARIMA (p, d, q) (P, D, Q)s (WERNER; RIBEIRO, 2003).

Conforme Souza (2016), a diferença entre os valores da série original com os valores previstos, corresponde aos resíduos provenientes do modelo ajustado. O ruído oriundo desta diferenciação deve ser um ruído branco, isto é, ser não autocorrelacionados, ter média zero e variância constante.

Segundo Moretin (2008), para a seleção do melhor modelo ajustado entre os modelos concorrentes, são utilizados dois critérios penalizadores, o *Akaike Information Criteria* – AIC

(AKAIKE, 1973) e *Bayesian Information Criteria* – BIC (SCHWARZ, 1978). Os mesmos são ditos critérios penalizadores, uma vez que, leva em consideração a variância dos erros gerados, bem como os parâmetros dos modelos, portanto, o melhor modelo ajustado será aquele que obtiver o menor valor para os critérios AIC e BIC. Os critérios de AIC e BIC são definidos pelas seguintes equações:

$$AIC(p, q) = \ln \sigma_{p,q}^2 + \frac{2(p+q)}{n} \quad (2)$$

$$BIC(p, q) = \ln \sigma_{p,q}^2 + (p + q) \frac{\ln N}{N} \quad (3)$$

Onde: p e q são os parâmetros conhecidos, n é o tamanho da amostra, $\ln$ o logaritmo neperiano e σ^2 a variância estimada dos erros.

De acordo com Tubino (2009), alguns mecanismos de medida podem ser utilizados para avaliar a acurácia da previsão de um modelo, ou seja, os valores são apurados por meio da comparação entre os dados reais (série original) e os estimados. Para o estudo, foram utilizados as seguintes medidas de acurácia: *Mean Absolute Error* (MAE), *Mean Absolute Percentage Error* (MAPE) e o coeficiente U-Theil. O coeficiente U-Theil, realiza a medida de acurácia pela comparação entre os dados do modelo previsto e a previsão ingênua, sendo os critérios:

- $U \geq 1$; o erro médio do modelo ajustado é maior ou igual de uma previsão ingênua;
- $U < 1$; o erro médio do modelo ajustado é menor que de uma previsão ingênua.

As equações das medidas de acurácia estão descritas na Tabela 1.

Sigla	Equação	
MAE	$\frac{\sum_{t=1}^n E_t }{n}$	(4)
MAPE	$\frac{\sum_{t=1}^n E_t/Z_t * 100}{n}$	(5)
U-Theil	$\frac{\sqrt{\sum_{t=1}^n (E_t)^2}}{\sqrt{\sum_{t=1}^n (Z_t - Z_{t-1})^2}}$	(6)

Fonte: Adaptado de Tubino (2009)

Tabela 1 – Medidas de Acurácia

Em que: E_t = Erro de previsão no instante t ; n = Número de observações; Z_t = Valor real no tempo t e $t = 1, 2, \dots, n$.

3. Materiais e Métodos

A série temporal utilizada refere-se ao índice de produção industrial alimentício brasileiro, oriundos da pesquisa industrial mensal de produção física (PIM – PF). Os dados foram obtidos do site do Instituto de Pesquisa Econômica Aplicada (<http://www.ipeadata.gov.br/>) correspondente ao período compreendido entre janeiro de 2002 e junho de 2017, totalizando 186 observações mensais.

Para a modelagem ARIMA, seguiram-se as etapas da metodologia de Box-Jenkins (1970). Os passos para o processo de modelagem são apresentados na Figura 2, conforme o fluxo sugerido por Pereira e Requeijo (2008).




Figura 2 – Etapas Metodológicas

Fonte: Adaptado de Pereira e Requeijo (2008)

Passo 1 – Identificação: por meio da inspeção visual e testes de raízes unitárias (ADF e KPSS), verifica-se a estacionariedade da série. É aplicada uma diferença na série original caso a mesma não seja estacionária em nível. Este procedimento é realizado repetidamente até que a série torne-se estacionária em “d” diferenças.

Passo 2 – Estimação: Por meio da análise gráfica da função de autocorrelação e autocorrelação parcial da série, é determinado o número de defasagens dos parâmetros, bem como a estimativa dos parâmetros dos modelos concorrentes. Ainda, é nesta etapa que os resíduos oriundos dos modelos ajustados são analisados.

Passo 3 – Validação: A validação é realizada por meio dos critérios penalizadores AIC e BIC, e pela análise dos resíduos. O modelo concorrente que apresentar o melhor desempenho, será o validado.

Passo 4 – Previsão: Pode ser *in-sample* ou *out-sample*, é nesta etapa que calcula-se as estatísticas de erro MAE, MAPE e U-Theil, a fim de verificar a acurácia do modelo validado.

O *software* utilizado para o tratamento e modelagem da série temporal foi o *Eviews 9 S.V.*

4. Resultados e Discussões

A partir da inspeção visual da série original, Figura 3, pode-se perceber que a série possui sazonalidade, com oscilações anuais, o que será confirmado através da FAC e FACP da série. Pode-se observar ainda que a série é não estacionária. Para comprovação da não

estacionariedade foram realizados os testes de raízes unitárias ADF e KPSS.




Figura 3 – Índice de Produção Industrial Alimentícia

A Tabela 2 contém os resultados dos testes ADF e KPSS, sendo possível verificar que a série se torna estacionária em primeira diferença, pois os dois testes convergiram em seus resultados, indicando a necessidade da aplicação de uma diferença na série temporal original.

	ADF ^a	KPSS ^b
Série em nível	-1,8260 ($p = 0,36$) ^c	0,3708 ^d
Série em 1 ^a diferença	-15,0706 ($p > 0,00$)^c	0,2635^d

Fonte: Elaborado pelos autores; ^a H_0 : a série possui uma raiz unitária; $\alpha = 0,05$;

^b H_0 : a série é estacionária; $\alpha = 0,05$; ^c Valor crítico para o teste ADF: -2,8780;

^d Valor crítico para o teste KPSS: 0,3470

Tabela 2 – Resultado dos Testes de Raízes Unitárias

A Figura 4 ilustra a série original (em azul) e a série transformada (em vermelho) com aplicação de uma diferença ($d = 1$), sendo possível observar por meio da inspeção visual que a série se tornou estacionária, conforme indicado pelos testes de raízes unitárias, possibilitando assim a estabilidade dos parâmetros estimados.




Figura 4 – Série em nível e diferenciada

Por meio da análise da função de autocorrelação (FAC) e da autocorrelação parcial (FACP), buscou-se identificar os possíveis modelos que melhor representem a série temporal em estudo, como pode ser observado na Figura 5.




Figura 5 – FAC e FACP da Série

Na Figura 5 é possível verificar componentes autorregressivos, o decaimento da função de autocorrelação ocorre de forma ondulante, indicando sazonalidade, como já observado no gráfico da série original (Figura 1). Em seguida foram estimados os parâmetros dos modelos concorrentes a fim de encontrar o melhor modelo predictor. Na Tabela 3 estão descritos os modelos concorrentes ajustados, assim como os valores dos parâmetros de cada modelo, o nível de significância dos parâmetros, os critérios penalizadores AIC e BIC e a informação da característica dos ruídos gerados por cada modelo.

SARIMA (2,1,0) (1,0,0) ₁₂				
Parâmetro	<i>p-value</i>	<i>AIC</i>	<i>BIC</i>	Ruído Branco
$\phi_1 = -0,5477$	$p < 0,0000$	6,0706	6,1403	Sim
$\phi_2 = -0,2376$	0,0012			
$\Phi_{12} = 0,9314$	$p < 0,0000$			
SARIMA (2,1,1) (1,0,0) ₁₂				
Parâmetro	<i>p-value</i>	<i>AIC</i>	<i>BIC</i>	Ruído Branco
$\phi_1 = 0,3106$	$p < 0,0000$	5,9340	6,0211	Sim
$\phi_2 = 0,1785$	0,0011			
$\Phi_{12} = 0,9229$	$p < 0,0000$			
$\theta_1 = -0,9969$	$p < 0,0000$			
SARIMA (1,1,1) (1,0,0) ₁₂				
Parâmetro	<i>p-value</i>	<i>AIC</i>	<i>BIC</i>	Ruído Branco
$\phi_1 = 0,3756$	$p < 0,0000$	5,9545	6,0241	Sim
$\Phi_{12} = 0,9183$	$p < 0,0000$			
$\theta_1 = -0,9929$	$p < 0,0000$			

Fonte: Elaborado pelos autores

Tabela 3 – Modelos Concorrentes

A partir dos valores de AIC e BIC e da análise dos resíduos gerados pelos modelos ajustados, foi selecionado o modelo SARIMA (2,1,1) (1,0,0)₁₂, pois o mesmo apresentou os menores valores para os critérios penalizadores AIC e BIC, além de todos os parâmetros apresentarem valores significativos ($p < 0,05$), assim como ter gerado ruído branco.

Portanto, o modelo que melhor se ajustou à série de dados do Índice de Produção Industrial Alimentício Brasileiro evidencia que a série apresenta um comportamento autorregressivo de ordem 2 (2 meses anteriores influenciando o mês atual), com fator de influência positivo (0,1785), representando um aumento nesta atividade, e também um filtro de médias móveis com parâmetro negativo (-0,9969). O modelo captou ainda um efeito sazonal de 12 meses, com parâmetro sazonal positivo (0,9229), voltando a indicar um crescimento neste índice, com valor superior à dependência autoregressiva.

Como pode ser observado na Figura 6, os resíduos gerados não são autocorrelacionados, não apresentando *lags* significativos tanto na FAC quanto na FACP.




Figura 6 – FAC e FACP dos resíduos do modelo ajustado

Ao observar que o modelo selecionado atendeu os requisitos da metodologia de Box-Jenkins, gerando ruídos brancos, foi então realizado a previsão *in-sample*, com intuito de verificar a eficácia do modelo proposto como preditor do comportamento futuro da série temporal modelada, conforme a Figura 7.




Figura 7 – Previsão *in-sample*

O resultado das medidas de acurácia MAE, MAPE e U-Theil foram calculados a partir da previsão *in-sample* realizada, conforme a Tabela 4. Para a estatística de U-Theil o modelo apresentou um valor menor que 1, evidenciando o mesmo como sendo um bom preditor em relação a um preditor ingênuo. Para as estatísticas de MAPE e MAE os resultados calculados foram baixos, qualificando o modelo como um bom preditor do comportamento futuro da série estudada.

SARIMA (2,1,1) (1,0,0) ₁₂	
MAE	5,0534
MAPE	5,4614
U-Theil	0,0301

Fonte: Elaborado pelos autores

Tabela 4 – Medidas de Acurácia do Modelo Ajustado

Desta forma, o modelo ajustado é adequado para a realização de previsões, pois atendeu aos pressupostos estabelecidos na literatura, apresentando as condições necessárias para um modelo adequado, permitindo a realização de previsões acuradas. Seus valores previstos estão dentro do intervalo de confiança de 2 desvios-padrões, permitindo assim que as decisões tomadas sejam com bases científicas.

5. Considerações Finais

O processo gerador da série do Índice de Produção Industrial Alimentício Brasileiro é um autorregressivo de ordem 2, com uma diferença necessária para tornar a série estacionária, filtro médias móveis de ordem 1, e efeito sazonal no *lag* 12. Com base no modelo ajustado à série de

dados, foi possível a realização de previsões *in-sample*. A previsão do Índice de Produção Industrial Alimentício Brasileiro encontra-se de acordo com a realidade, uma vez que continua apresentando os efeitos de sazonalidade, captando os movimentos e características da série em questão, indicando que a série sofre influência dos 2 meses passados, mas com modificações pelo efeito sazonal, dessa forma representa um crescimento ainda maior para este índice.

6. Agradecimentos

Agradecemos ao LAME – Laboratório de Análise e Modelagem Estatística da Universidade Federal de Santa Maria – UFSM, pelo espaço utilizado, assim como *softwares* e equipamentos. Agradecemos à CAPES pelo apoio financeiro na forma de concessão de bolsas de estudo.

Referências

- AKAIKE, H.** *Information theory and an extension of the maximum likelihood principle*. 2nd International Symposium on Information Theory, Tsahkadsor, Armenia, USSR, September 2-8, BudapesT, 1973.
- ALMEIDA, A. C.; SUHR, I. R. F.** *Educação profissional no Brasil: a construção de uma proposta educativa dual*. Revista Intersaberes, [s.l.], v. 7, n. 8, p.81-110, jan. 2012.
- BOX, G. E. P.; JENKINS G. M.** *Time Series Analysis, forecasting and control*. San Francisco: Holden Day, 1970.
- CUNHA, D. A.; DIAS, R. S.; GOMES, A. P.** *Uma análise sistêmica da indústria alimentícia brasileira*. XLIV Congresso da SOBER, Fortaleza, jul. 2006.
- DEPEC.** *Indústria de Alimentos*. Departamento de Pesquisas e Estudos Econômicos. Bradesco. 2017. Disponível em: <https://www.economiaemdia.com.br/EconomiaEmDia/pdf/infset_industria_de_alimentos.pdf> Acesso em: 28 ago. 2017.
- DICKEY, D. A.** *Power of Unit Root Tests. Proceedings of business and economic statistics Sections*. American Statistical Assn. v. 74, 489-493, 1984.
- FLANDRIN, J.; MONTARINI, M.** *História da Alimentação*. Tradução MACHADO, L.; TEIXEIRA, G. São Paulo: Estação Liberdade, 1998.
- INSTITUTO DE PESQUISA ECONÔMICA APLICADA.** *Ipea Data*. Disponível em: <<http://www.ipeadata.gov.br/>> Acesso em: 28 ago. 2017.
- KIRCHNER, R.; SOUZA, A. M.; STUMM, E. M. F.** *A Modelagem Como Ferramenta de Gestão*. Latin American Journal of Business Management. V. 2, N. 1, P. 223. Taubaté, 2011.
- KWIATKOWSKI, D.; PHILLIPS, P. C. B.; SCHMIDT, P.; SHIN, Y.** *Testing the null hypothesis of stationarity against the alternative of a unit root*. Journal of Econometrics, v. 54, 159-178. North-Holland, 1992.
- MARASCA, L.; SANTOS, E. P.; UEDA, R. M.; DAPPER, S. N. SOUZA, A. M.** *Desemprego no Brasil: Uma Análise Política, Econômica e Social*. Revista FSA, Teresina, v. 14, n. 3, p. 86-107, maio 2017.
- MARTIN, A. C.; HENNING, E.; WALTER, O. M. F. C.; KONRATH, A. C.** *Análise de séries temporais para previsão da evolução do número de automóveis no Município de Joinville*. Revista Espacios, v. 37, n. 06, 2016.
- MORETTIN, P. A.** *Econometria Financeira: um curso em séries temporais financeiras*. 1. ed. São Paulo: Blucher, 2008.
- NESPOLO, C. R. et al.** *Práticas em Tecnologia de Alimentos*. Porto Alegre: Artmed, 2015. (Série Tekne).
- NORONHA, M. O.; SOUZA, A. M.; ZANINI, R. R.** *Aplicação Da Metodologia Box & Jenkins Para Modelagem Da Emissão De Certificados Iso 14001 No Brasil*. Revista Espacios. V. 37, N. 12 P. 28. Caracas, 2016.
- PEINADO, J.; GRAEML, A. R.** *Administração da produção: operações industriais e de serviços*. Curitiba: UnicenP, 2007. 750 p.
- PEREIRA, L. P.; REQUEIJO G. J.** *Qualidade: Planeamento e Controlo Estatístico de Processos*. Lisboa: FCT/UNL, 2008.

QUEIROZ, A. A.; CAVALHEIRO, D. *Método de Previsão de Demanda e Detecção de Sazonalidade para o Planejamento da Produção de Indústrias de Alimentos*. XXIII Encontro Nacional de Engenharia de Produção, Ouro Preto, out. 2003.

RATTNER, H. *Aspectos econômicos e tecnológicos da indústria de alimentos brasileira*. Revista de Administração de Empresas, [s.l.], v. 18, n. 3, p.17-36, set. 1978.

SARTI, F.; HIRATUKA, C. *Desenvolvimento industrial no Brasil: oportunidades e desafios futuros*. Texto para Discussão. IE/UNICAMP, Campinas, n. 187, jan. 2011.

SCHWARZ, GIDEON E. *Estimating the dimension of a model*. Annals of Statistics, 6 (2): 461–464, 1978.

SILVÉRIO, G. B. et al. *A importância das inovações para a indústria alimentícia: um estudo de caso da empresa apetitoso alimentos*. Revista Eletrônica Científica Inovação e Tecnologia, Medianeira, v. 2, n. 12, p.86-95, jul. 2015.

SOUZA, A. M.; SOUZA, F. M.; FERREIRA, N.; MENEZES, R. *Electrical Energy Supply for Rio Grande Do Sul, Brazil, Using Forecast Combination of Weighted Eigenvalues*. Gepros - Gestão Da Produção, Operações E Sistemas – Ano 6, Nº 3, P. 23-39, 2011.

SOUZA, F. M. *Modelos De Previsão: aplicações à energia elétrica - ARIMA- ARCH-AI e ACP*. Curitiba: Appris, 2016. ISBN 9788547302481.

TUBINO, D.F. *Planejamento E Controle Da Produção: Teoria E Prática*. 2. Ed. São Paulo: Atlas, 2009.

WERNER, L.; RIBEIRO, J. L. D. *Previsão de demanda: uma aplicação dos modelos Box- Jenkins na área de assistência técnica de computadores pessoais*. G&P – Gestão & Produção, v. 10, n. 1, p. 47 – 67, abr. 2003.

WOOD, T. JR.; CALDAS, M. P. *Empresas brasileiras e o desafio da competitividade*. Revista de Administração de Empresas, FGV, vol. 47, n. 3, 2007.