

Modelagem da Produção Industrial Alimentícia Brasileira (2002-2017) a partir da combinação dos modelos SARIMA e Holt-Winters

Karina Sayuri Ueda (UFGD) karina-ueda@hotmail.com

Silvia Maria Martelli (UFGD) smmartelli@gmail.com

Ícaro Agostino (UFSM) icaroagostino@gmail.com

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

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

Resumo:

As indústrias alimentícias brasileiras compreendem diversas variedades de produtos, estando diretamente ligadas à pecuária e agricultura, movimentando a economia do país. Sendo assim, o presente estudo teve como objetivo a utilização de modelos de previsões para a produção industrial de alimentos no Brasil através dos modelos SARIMA, Holt-Winters e a combinação entre ambos. As séries temporais foram utilizadas para fazer previsões estatísticas, a fim de realizarem uma aproximação real dos acontecimentos futuros referentes aos dados mensais da produção da indústria de alimentos brasileira compreendendo o período de janeiro de 2002 e dezembro de 2017, um total de 192 observações (mensais). Para a combinação das previsões foram adotadas três abordagens: média aritmética (MS), método *Least Squares Weights* (LS), e método *Inverse Mean Squared* (IMS). Pelo fato do método IMS utilizar pesos diferentes para cada horizonte de previsão, o mesmo foi considerado a abordagem mais precisa entre as previsões individuais e combinadas, sendo comprovado por meio da medida de acurácia *Root Mean Squared Error* (RMSE) e o coeficiente U-Theil. Sendo assim, baseado no presente estudo, a combinação de métodos reduziu os erros da previsão, aumentando a sua acurácia.

Palavras chave: Indústria de Alimentos, Box-Jenkins, ARIMA, Combinação de Previsão.

Modeling of Brazilian industrial food production (2002-2017) from the combination of the SARIMA and Holt-Winters models

Abstract

Brazilian food industries comprise several varieties of products, being directly linked to livestock and agriculture, moving the economy of the country. Thus, the present study aimed to use a combination of forecasts of demand for industrial food production in Brazil through the SARIMA, Holt-Winters models and the combination between the two. The time series were used to make statistical forecasts in order to make a real approximation of the future events related to the monthly data of the Brazilian food industry production, covering the period from January 2002 to December 2017, a total of 192 observations (monthly). For the predictions combination, three approaches were adopted: arithmetic mean (MS), Least Squares Weights (LS), and Inverse Mean Squared (IMS) method. Because the IMS method uses different weights for each prediction horizon, it was considered the most accurate approach between the individual and combined predictions, and was verified by means of the Root Mean Squared Error (RMSE) measure and the U-Theil coefficient. Thus, based on the present study, the combination of methods reduces the errors of the forecast, increasing its accuracy.

Key-words: Food Industry, Box-Jenkins, ARIMA, Forecast Combination.

1. Introdução

A industrialização no Brasil ocorreu de maneira tardia se comparado com países europeus que já haviam substituído produtos artesanais por manufaturados. A industrialização trouxe muitos benefícios econômicos para o país, além de transformações políticas, sociais e educacionais (ALMEIDA; SUHR, 2012). Nesse contexto, segundo Suzigan (2000), a indústria de alimentos teve uma parcela de responsabilidade na industrialização do Brasil. Esse processo iniciou-se no século XIX, a partir da economia de expansão e exportação, os setores que disseminaram estavam ligados ao aumento da demanda por matérias primas industriais. A partir do século XX houve o processo de urbanização no Brasil, estando relacionado diretamente com o esvaziamento rural e a industrialização.

No final da década de 1980 e início da década de 1990, começa a ocorrer a abertura comercial, consequentemente há um aumento da competitividade de mercado. Durante esse período houve uma elevação da importação de insumos das indústrias alimentícias, incentivando as empresas a desenvolverem novos processos e técnicas com intuito de aumentar a produtividade e maximizar os lucros. Atualmente, a agropecuária fornece os insumos para as indústrias, ocasionando o processo de sazonalidade da produção e da oferta, assim como outros fatores que influenciam como por exemplo: embalagens, transporte, canais de distribuições, máquinas, entre outros (BENTO; TELES, 2013).

Considerando a importância do tema estudado, este artigo tem como objetivo a utilização de previsões de demanda da produção industrial de alimentos no Brasil através dos modelos ARIMA, Holt- Winters e a combinação entre ambos, a fim de realizar uma aproximação real dos acontecimentos futuros referentes aos dados mensais de produção da indústria. Em inúmeros casos a combinação das previsões individuais se torna eficaz para minimizar as incertezas que envolvem as realizações de previsões. As previsões confiáveis geralmente utilizam mais de uma técnica, pois se torna capaz de captar um número maior de informações (MARTINS e WERNER, 2014).

2. Revisão de literatura

A seguir apresenta-se a contextualização teórica, abordando os temas da indústria brasileira de alimentos, modelos de previsão e combinação de previsão.

2.1. Indústria Brasileira de Alimentos

Nos últimos anos a indústria alimentos têm crescido constantemente devido ao aumento da demanda. Dentro deste contexto, a nanotecnologia surge para transformar e desenvolver o setor agroalimentar por meio do avanço tecnológico, com o potencial de aumentar a produção global de alimentos, qualidade, valor nutricional e segurança alimentar (HANDFORD et al., 2014, PETERS et al., 2016, SEKHON, 2014).

Com o avanço de diversas tecnologias em indústrias alimentícias, surge a necessidade de novas estratégias de mercado. A inovação é um dos principais métodos através dos quais as empresas de processamento de alimentos podem ser inseridas no mercado competitivo (DRIVAS; GIANNAKAS, 2010; KARANTININIS; SAUER; FURTAN, 2010; ALARCON; SANCHEZ, 2013).

A diferenciação de produtos também representa uma grande estratégia de mercado, onde líderes precisam tomar decisões com elevados níveis de incertezas. Essa diferenciação possibilita a

comercialização de produtos com maior valor agregado, proporcionando benefícios econômicos, além de melhorar o produto produzido e consequentemente garantir a satisfação dos consumidores. Davcik (2013) relata que o valor agregado dos alimentos recém desenvolvidos é um fator e pode ser aprimorado através do uso de uma estratégia de marca.

Dessa forma, os métodos de previsões de demanda são de extrema importância para as tomadas de decisões, sendo úteis para o planejamento da organização. Segundo Ismai et al (2016), a previsão de demanda é um processo iterativo que avalia a quantidade de serviço ou produto que um cliente comprará ou consumirá, além de ser empregado também em tomadas de decisões sobre preços. Ou seja, é um processo que estima as possíveis vendas futuras levando em considerações diversas condições, baseadas em métodos estatísticos, matemáticos e séries temporais.

2.2. Modelos de Previsão

Um modelo de previsão de demanda utilizado amplamente em diversas áreas do conhecimento é conhecido como método de suavização exponencial, popularizado por Holt (1957) e Winters (1960), que objetiva o ajuste de uma curva adequada dos dados histórico ao longo do tempo (GUJARATI E PORTER, 2011; MONTGOMERY; JENNINGS; KULAHCI, 2007). Este método denominado de Holt-Winters tem duas abordagens: multiplicativa e aditiva. Conforme Makridakis, Steven e Hyndman (1998), na abordagem multiplicativa, a amplitude da série aumenta a cada ciclo, enquanto que na aditiva, a mesma permanece constante em relação ao tempo. A Tabela 1 a seguir apresenta a equação das duas abordagens:

Abordagem	Equações	
Aditiva	$Z_{t+m} = (L_t + b_t m) + S_{t-s+m} \quad (1)$	$L_t = \alpha(Z_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + b_{t-1})$ $b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1}$ $S_t = \gamma(Z_t - L_t) + (1 - \gamma)S_{t-s}$
Multiplicativa	$Z_{t+m} = (L_t + b_t m)S_{t-s+m} \quad (2)$	$L_t = \alpha(Z_t/S_{t-s}) + (1 - \alpha)(L_{t-1} + b_{t-1})$ $b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1}$ $S_t = \gamma(Z_t/L_t) + (1 - \gamma)S_{t-s}$

L_t representa o valor estimado do nível; b_t representa a estimativa de tendência; α , β e γ são as constantes de suavização no intervalo de 0 a 1; Z_{t+m} corresponde a previsão no período “t+m”, em que “m” representa quantos passos à frente se deseja prever; S_t o índice sazonal da série temporal.

Tabela 1 – Equação do Método de Holt-Winters

Fonte: Elaborado pelos autores

Um outro método para a modelagem de séries temporais desenvolvido por Box e Jenkins (1970) é o modelo autorregressivo integrado de médias móveis (ARIMA). Segundo Montgomery, Jennings e Kulahci (2007), por meio dos modelos ARIMA é possível captar a correlação existente entre os valores da série temporal, permitindo a realização de futuras previsões. Para Gujarati e Porte (2011), as quatro etapas a serem seguidas para o uso deste modelo são: (i) Identificar o modelo que mais que melhor explica o comportamento da série original, a partir da análise das funções de autocorrelação (FAC) e autocorrelação parcial (FACP); (ii) Estimar os parâmetros autorregressivos e de médias móveis; (iii) Validar a adequação do modelo ajustado por meio dos resíduos do modelo; e (iv) Prever o comportamento futuro da série.

A equação do modelo ARIMA (p, d, q) é comumente representado da seguinte forma:

$$\phi(B)\Delta^d Z_t = \theta(B)\varepsilon_t \quad (3)$$

Onde: Z_t corresponde a série temporal analisada, B o operador retroativo, d representa a ordem de integração, ϕ corresponde ao termo do parâmetro autoregressivo de ordem p , θ o parâmetro de médias móveis de ordem q e ε_t a sequência de erros. Onde o erro é denominado de ruído branco caso a variância seja constante e a média dos erros igual a zero (BUENO, 2008; SOUZA, 2016).

Se a série temporal analisada apresentar sazonalidade (repetição de um fenômeno a cada período de tempo idêntico) é utilizado modelos conhecidos como SARIMA. De acordo com Werner e Ribeiro (2003) A descrição genérica deste modelo é SARIMA (p, d, q) (P, D, Q) s , pois apresenta os parâmetros iguais aos dos modelos ARIMA (p, d, q), porém com uma parte sazonal (P, D, Q) s , onde “ s ” representa a ordem da sazonalidade.

A fim de garantir que os parâmetros estimados ao longo do tempo apresentem significância, a metodologia de Box e Jenkins pressupõe que a série temporal estudada seja estacionária. A verificação da estacionariedade da série pode ser realizada por meio de análise gráfica ou testes de raízes unitárias. No presente estudo, os testes de raízes unitárias adotados serão: Phillips e Perron (1988) e Kwiatkowski, Phillips, Schmidt e Shin – KPSS (KWIATKOWSKI et al., 1992). Cabe ressaltar que segundo Souza (2016), a fim de que a análise do grau de estacionariedade da série se torne mais acurada, é aconselhável que os testes de raízes unitárias sejam utilizados de forma conjunta. Caso a série apresente um comportamento não estacionário, aplica-se diferenças na mesma (MARTIN et al., 2016).

Já para a seleção do melhor modelo ajustado levando em consideração dos modelos concorrentes, são utilizados os critérios penalizadores – considera a variância dos erros gerados (MORETTIN, 2008). Os dois critérios penalizadores são: *Akaike Information Criteria* – AIC (AKAIKE, 1973) e *Bayesian Information Criteria* – BIC (SCHWARZ, 1978). O modelo que apresentar o menor valor nos critérios penalizadores AIC e BIC será considerado o mais ajustado, portanto, o melhor. As equações para os cálculos dos valores dos critérios AIC e BIC são apresentados a seguir:

$$AIC(p, q) = \ln \sigma_{p,q}^2 + \frac{2(p+q)}{n} \quad (4)$$

$$BIC(p, q) = \ln \sigma_{p,q}^2 + (p+q) \frac{\ln N}{N} \quad (5)$$

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

Para a avaliação da acurácia do modelo previsto, compara-se os dados da série original com os estimados (TUBINO, 2009). As medidas de acurácia utilizadas neste estudo foram: *Root Mean Squared Error* (RMSE) e o coeficiente U-Theil. As equações para o cálculo de RMSE e U-Theil são apresentados a seguir:

$$RMSE = \frac{\sqrt{\sum_{t=1}^n (\varepsilon_t)^2}}{n} \quad (6)$$

$$U - Theil = \frac{\sqrt{\sum_{t=1}^n (E_t)^2}}{\sqrt{\sum_{t=1}^n (Z_t - Z_{t-1})^2}} \quad (7)$$

Onde E_t representa o erro de previsão no instante t ; n corresponde ao número de observações; Z_t é o valor real no tempo t e $t = 1, 2, \dots, n$. No coeficiente U-Theil a medida de acurácia é realizada por meio da comparação dos dados do modelo previsto e a previsão ingênua. Se o

valor de U-Theil for maior ou igual a 1, então pode-se dizer que o erro médio do modelo ajustado é maior ou igual a previsão ingênua, por outro lado se U-Theil for menor que 1, o erro médio do modelo ajustado é menor que uma previsão ingênua.

2.2. Combinação de Previsão

Objetivando o aumento da precisão nas previsões, pesquisadores tem se esforçado para desenvolverem modelos cada vez mais acurado em diversas áreas do conhecimento, ou seja, com menor erro de previsão (FIRMINO; MATTOS NETO; FERREIRA, 2014). Neste sentido, a combinação entre os melhores modelos previstos se torna uma abordagem interessante, uma vez que ao invés de simplesmente selecionar apenas o melhor modelo para a série analisada, investiga-se quais os modelos que conjuntamente podem aumentar a acurácia da previsão (MARTINS; WERNER, 2014). Portanto, ao utilizar a técnica de combinação de previsões, obtêm-se modelos com maior precisão (SOUZA et al., 2011).

Segundo Martins e Werner (2014) um dos métodos mais utilizados para a realização da combinação de previsões é a média aritmética simples (MS), que consiste em uma combinação linear das previsões individuais, considerando os pesos fixos, de acordo com a equação a seguir:

$$F_c = (F_1 + F_2 + \dots + F_n)/n \quad (8)$$

Na equação anterior F_c representa a previsão combinada e $F_1, F_2, \dots, F_n$ corresponde as previsões individuais; n é entendido como o número de previsões individuais utilizadas na combinação.

Outra abordagem para a combinação de previsões é a *Least Squares Wights* (LS) estimado a partir do uso de Mínimos Quadrados em relação a série original, no caso em que há mais de dois preditores individuais. Neste tipo de abordagem a combinação é a linear utilizando modelos de regressão sem restrição em relação aos pesos (GRANGER; RAMANATHAN, 1984). A equação para a combinação de previsão por meio da LS é dada a seguir:

$$F_c = w_0 + w_1F_1 + w_2F_2 + \dots + w_nF_n \quad (9)$$

Onde F_c representa a previsão combinada; w_0 corresponde ao intercepto da regressão; $w_1, w_2, \dots, w_n$ são os pesos estimados para cada previsão individual; $F_1, F_2, \dots, F_n$ são as previsões individuais; e n representa o número de previsões individuais utilizadas para a realização da combinação.

A terceira abordagem de previsão combinada elaborada por Stock e Watson (2004) e utilizada no presente estudo é o *Inverse Mean Squared* (IMS). Tal método tem como base o inverso do erro quadrático médio de cada uma das previsões, utilizando pesos diferentes para cada horizonte predito. Neste sentido, o cálculo destes pesos é apresentado a seguir na equação (10):

$$w_i = \frac{1/MSE_i^k}{\sum_{j=1}^n 1/MSE_j^k} \quad (10)$$

O peso dado para cada previsão “i” é representado por w_i ; MSE corresponde ao erro quadrático médio cometido por cada previsão individual; k pode ser entendido como o horizonte da previsão; e n representa o número de previsões individuais utilizadas para a realização da combinação das previsões.

3. Metodologia

De acordo com Prodanov e Freitas (2013) e Gil (2010), o estudo classifica-se como sendo aplicado, pois tem como foco a aplicação de conceitos teóricos em casos práticos objetivando a resolução de problemas específicos. Quanto a sua abordagem é classificada como quantitativa,

uma vez que são utilizadas ferramentas matemáticas e apresentado resultados quantitativos. Em relação ao objetivo, o estudo é de caráter exploratório, visto que procura a explicação e a geração de hipótese sobre o problema em questão. A pesquisa em termos de procedimentos técnicos representa um estudo de caso, pois busca o detalhamento e o conhecimento amplo sobre um caso particular.

Os dados utilizados neste estudo foram coletados do site do Instituto de Pesquisa Econômica Aplicada (<http://www.ipeadata.gov.br/>) e corresponde a série temporal do índice de produção industrial alimentício brasileiro (PIM-PF), compreendendo o período de janeiro de 2002 e dezembro de 2017, um total de 192 observações (mensais).

As três etapas seguidas para o desenvolvimento deste estudo são: (1) Ajuste dos modelos concorrentes pelo método de Holt-Winters e de Box-Jenkins; (2) Combinação dos modelos individuais ajustados; e (3) Seleção do melhor modelo por meio da comparação das medidas de acurácia. Na Figura 1 é apresentado as etapas da execução desta pesquisa:




Figura 1 – Etapas para modelagem e combinação das previsões

Fonte: Elaborado pelos autores

Para a modelagem pelo método ARIMA, seguiu-se as etapas propostas por Box-Jenkins (1970), ou seja, primeiramente analisou-se o comportamento da série original em relação a sua estacionariedade e autocorrelação. Utilizando as funções de autocorrelação (FAC), autocorrelação parcial (FACP) e suas defasagens, determinou-se os filtros a serem adotados, e em posteriormente, por meio do Método da Máxima Verossimilhança foi estimado os parâmetros dos modelos concorrentes.

No caso da modelagem pelo método de Holt-Winters, verificou-se a priori se a série original apresentava tendência e sazonalidade para a identificação do tipo de modelo a ser adotado (Suavização simples, linear de Holt, Holt-Winters). Os parâmetros foram estimados e posteriormente realizou-se a previsão, determinando o valor para as medidas de acurácia do modelo.

As três abordagens para a combinação das previsões foram: combinação por média aritmética (MS), método *Least Squares Weights* (LS), e método *Inverse Mean Squared* (IMS). Sendo o melhor modelo de previsão, tanto individual quanto combinado, determinado por meio das medidas de acurácia RMSE e U-Theil.

O software utilizado para tratamento e modelagem dos dados foi o Eviews 9 S.V.

4. Classificação dos artigos

A Figura 2 exhibe o comportamento temporal do índice de produção industrial alimentício (IPIA) brasileiro, a partir da inspeção visual percebe-se um acentuado comportamento sazonal na variável, com ciclos anuais e um crescimento moderado ao longo do tempo de período do estudo.




Figura 2 – Índice de Produção Industrial Alimentício Brasileiro (2002 - 2017)

Fonte: Elaborado pelos autores

Para investigar o comportamento sazonal da variável foi construído o gráfico de médias sazonais, conforme proposto por Hyndman e Athanasopoulos (2018). A partir da Figura 3 percebe-se que existe uma tendência de crescimento da produção iniciando em março e se prolongando até o mês de agosto, e após esse movimento segue-se um decaimento da produção de setembro a fevereiro, tal característica é comum devido a variação da frequência da demanda pelos alimentos. Essa variação é causada pelas datas comemorativas, alterações climáticas, além de outros fatores, conforme discutido por Queiroz e Cavalheiro (2003).




Figura 3 – Gráfico sazonal do IPIA (2002 - 2017)

Fonte: Elaborado pelos autores

A verificação da estacionariedade da série foi realizada a partir da aplicação dos testes PP e KPSS, os resultados dos testes são exibidos na Tabela 2. A série foi considerada estacionária em nível, em que os dois testes convergiram em seus resultados.

	PP ^a	KPSS ^b
Série em nível	-5,6453 ($p = 0,00$) ^c	0,4506 ^d

^a H0: a série possui uma raiz unitária; $\alpha = 0,05$; ^b H0: a série é estacionária; $\alpha = 0,05$;

^c Valor crítico para o teste PP: -2,8780; ^d Valor crítico para o teste KPSS: 0,4630

Tabela 2 – Resultado dos Testes de Raízes Unitárias

Fonte: Elaborado pelos autores

Posteriormente foi investigado as funções de autocorrelação (FAC) e autocorrelação parcial (FACP), a Figura 4 exibe o comportamento das funções. É possível observar o comportamento sazonal com autocorrelação significativa até o terceiro período, voltando a crescer a cada ciclo de 12 meses.




Figura 4 – Função de autocorrelação e autocorrelação parcial

Fonte: Elaborado pelos autores

Foram estimados os modelos concorrentes ARIMA para representar a série, na Tabela 3 estão descritos os componentes dos modelos ajustados, os parâmetros, o nível de significância e os valores para os critérios de AIC e BIC.

Modelo	AR(p)	p-valor	MA(q)	p-valor	AIC	BIC
ARIMA (3,0,0)	$\phi_1 = 1,131$	<0,001	-	-	7,146	7,217
	$\phi_2 = 0,180$	0,085				
	$\phi_3 = -0,320$	<0,001				
ARIMA (0,0,3)	-	-	$\theta_1 = 1,594$	<0,001	9,181	9,252
			$\theta_2 = 1,543$	<0,001		
			$\theta_3 = 0,781$	<0,001		
ARIMA (3,0,3)	$\phi_1 = 2,729$	<0,001	$\theta_1 = -2,496$	<0,001	6,058	6,613
	$\phi_2 = -2,728$	<0,001	$\theta_2 = 2,295$	<0,001		
	$\phi_3 = 0,998$	<0,001	$\theta_3 = -0,771$	<0,001		
SARIMA (3,0,0)(1,0,0) ₁₂	$\phi_1 = 0,398$	<0,001	-	-	5,979	6,068
	$\phi_2 = 0,297$	<0,001				
	$\phi_3 = 0,225$	0,002				
	$\Phi_{12} = 0,953$	<0,001				

Tabela 3 – Modelos concorrentes ARIMA ajustados

Fonte: Elaborado pelos autores

O modelo selecionado foi o SARIMA(3,0,0)(1,0,0)₁₂, pois apresentou todos os parâmetros significativos ($p < 0,05$), assim como menores valores de AIC e BIC. O modelo apresentou três parâmetros autorregressivos, confirmando a autocorrelação verificada anteriormente, assim como um parâmetro sazonal autorregressivo, confirmando a forte presença de movimentos sazonais na série.

Posteriormente foi ajustado o modelo de Holt-Winters, na Tabela 4 é apresentado os modelos ajustados pelo método multiplicativo e aditivo, assim como os erros cometidos por cada modelo e os valores dos critérios de AIC e BIC. O modelo de Holt-Winters pelo método multiplicativo apresentou menores erros, assim como menores valores para os critérios de seleção.

Modelos	RMSE	AIC	BIC
Modelo de Holt-Winters (Método Multiplicativo)	0,03908	1438,59	1483,30
Modelo de Holt-Winters (Método Aditivo)	0,03964	1443,82	1488,52

Tabela 4 – Modelos concorrentes ARIMA ajustados
Fonte: Elaborado pelos autores

A etapa seguinte consistiu na realização da combinação das previsões pelas três abordagens definidas a partir dos modelos individuais ajustados. A combinação pelos métodos da aritmética simples (MS), *Least Squares Weights* (LS), assim como pelo método *Inverse Mean Squared* (IMS), obtendo cinco previsões diferentes. Os resultados da medida de acurácia RMSE e U-Theil para os modelos são apresentados na Tabela 5.

Modelos	RMSE	U-Theil
Holt-Winters (Multiplicativo)	8.620923	0.043909
SARIMA (3,0,0)(1,0,0) ₁₂	7.902275	0.040056
Previsão combinada (média aritmética)	7.955516	0.040428
Previsão combinada (regressão)	7.902275	0.040056
Previsão combinada (IMS)	7.866196	0.039941

Tabela 5 – Medidas de acurácia dos modelos de previsão analisados
Fonte: Elaborado pelos autores

O modelo mais acurado para representar a série foi oriundo da combinação dos modelos SARIMA e Holt-Winters a partir do método IMS. O modelo final ajustado apresentou valores de acurácia de 7.8661 para a medida RMSE, sendo 8.75% mais preciso que o modelo de Holt-Winter individualmente, assim como 0.46% mais acurado que o modelo SARIMA. Para a medida de U-Theil o modelo apresentou o valor aproximado de 0.0399, indicando como um bom predictor em relação a um modelo ingênuo. A Figura 5 ilustra o ajuste do modelo em relação a série original, evidenciando a convergência dos valores estimados em relação aos reais.




Figura 5 – Função de autocorrelação e autocorrelação parcial
Fonte: Elaborado pelos autores

A validação do modelo se deu pela análise dos resíduos, conforme é possível evidenciar na Figura 6 o modelo produziu resíduos independentes, com características de ruído branco, sendo, portanto, adequado para realização de previsões.




Figura 6 – Função de autocorrelação e autocorrelação parcial
Fonte: Elaborado pelos autores

Tais resultados vão de encontro com a literatura, pois a combinação das previsões possibilitou um aumento da precisão dos resultados, gerando previsões estatisticamente superiores comparadas às previsões individuais, pois comumente no processo de realização de previsões, em que são ajustados 2 ou 3 modelos, utiliza-se alguma medida de acurácia para selecionar o melhor e os demais são descartados, muitas vezes perdendo alguma informação capturada pelos modelos não selecionados.

Dessa forma, foi possível evidenciar que os modelos não selecionados como ótimos no processo de ajustes de modelos correntes podem contribuir positivamente na previsão final quando utilizado algum procedimento de combinação capaz de reduzir a perda de informação dos modelos individuais.

Entre os métodos adotados, o método *Inverse Mean Squared* utiliza pesos diferentes para cada horizonte de previsão, o que permitiu uma abordagem mais acurada devido a variabilidade da

série temporal em estudo, em que os modelo de combinação com pesos fixos utilizados não foram eficazes em reduzir os erros gerados pelos modelos individuais.

5. Considerações finais

Os métodos de previsões de demanda são importantes pois auxiliam empresas nas tomadas de decisões a médio e longo prazo. Esses métodos também têm sido desenvolvidos a fim de analisar previamente o comportamento das variáveis que podem influir no planejamento estratégico das empresas, garantindo o atendimento eficaz dos clientes e maximização dos lucros.

Neste trabalho foram comparadas previsões individuais por meio dos modelos ARIMA e Holt-Winters, e três métodos de combinações (média aritmética simples, *Least Squares Wights*, e *Inverse Mean Squared*), objetivando investigar qual o melhor método para a série estudada. O modelo que se ajustou melhor ao histórico da demanda de produção industrial alimentícia brasileira foi o obtido pela combinação dos modelos a partir da abordagem *Inverse Mean Squared*.

Sendo assim, os resultados corroboraram com a literatura, podendo o modelo apresentado ser utilizado por empresas do setor alimentício que possuem sazonalidade, com o objetivo de realizar o planejamento de suas futuras produções.

Referências

- AKAIKE, H.** *Information theory and an extension of the maximum likelihood principle*. 2nd International Symposium on Information Theory, Tsahkadsor, Armenia, USSR, 1973.
- ALARCON, S.S; ANCHEZ, M.** *External and internal R&D, capital investment and business performance in the Spanish agri-food industry*. Journal of Agricultural Economics. v.64, p. 654–675, 2013.
- ALMEIDA, A.C.; SUHR, I.R.F.** *Educação profissional no Brasil: a construção de uma proposta educativa dual*. Revista Intersaberes, v.7, n.8, p. 81-110, 2012.
- BENTO, D.G.C; TELES, F.L.** *A sazonalidade da produção agrícola e seus impactos na comercialização de insumos*. Rio Verde: Revista Científica do Centro Superior Almeida Rodrigues. v.1, n.1, p. 15-19, 2013.
- BOX, G.; JENKINS, G.** *Time Series Analysis, forecast and control*. San Francisco: Holden- Day, 1970.
- BUENO, R. L. S.** *Econometria de séries temporais*. São Paulo: Cengage Learning, 2008.
- DAVCIK, N.** *An empirical investigation of brand equity: drivers and their consequences*. British Food Journal v.115. n.9, p. 1342-1360, 2013.
- DRIVAS, K. GIANNAKAS, K.** *The effect of cooperatives on quality-enhancing innovation*. Journal of Agricultural Economics. v.61, p. 295–317, 2010.
- FIRMINO, P. R. A.; MATTOS NETO, P. S. G.; FERREIRA, T. A. E.** *Correcting and combining time series forecasters*. Neural Networks, v. 50, p. 1-11, 2014.
- GIL, A. C.** *Como elaborar projetos de pesquisa*. São Paulo: Atlas, v. 5, 2010.
- GRANGER, C. W. J.; RAMANATHAN, R.** *Improved Methods of Combining Forecasts*. Journal of Forecasting, v. 3, p. 197-204, 1984.
- GUJARATI, D. N.; PORTER, D. C.** *Econometria Básica*. 5. ed. Porto Alegre: AMGH, 2011.
- HANDFORD, M. et al.** *Implications of nanotechnology for the agri-food industry: Opportunities, benefits and risks*. Trends in Food Science & Technology. v.40, n.2, p. 226-241, 2014.
- HOLT, C. C.** *Forecasting seasonals and trends by exponentially weighted moving averages*. ONR Memorandum, 1957.
- HYNDMAN, R.; ATHANASOPOULOS, G.** *Forecasting: principles and practice*. OTexts, 2018.

- ISMAI, Z.; ABU, N.; SUFAHANI, S.** *New product forecasting with limited or no data.* AIP Conference Proceedings, 2016.
- KARANTININIS, K.; SAUER, J.; FURTAN, W.H.** *Innovation and integration in the agri-food industry.* Food Policy. v.35, p. 112–120, 2010.
- KWIATKOWSKI, D. et al.** *Testing the null hypothesis of stationarity against the alternative of a unit root.* Journal of Econometrics, v. 54, 159-178. North-Holland, 1992.
- MAKRIDAKIS, S.; WHEELWRIGHT, S.; HYNDMAN, R.** *Forecasting Methods and Applications.* 3. ed. New York: John Wiley & Sons, 1998.
- MARTIN, A. C. et al.** *Análise de séries temporais para previsão da evolução do número de automóveis no Município de Joinville.* Revista Espacios, v. 37, n. 06, 2016.
- MARTINS, V. L. M.; WERNER, L.** *Comparação de previsões individuais e suas combinações: um estudo com séries industriais.* Production, v. v. 24, n. 3, p. 618-627, 2014.
- MONTGOMERY, D. C.; JENNINGS, C. L.; KULAHCI, M.** *Introduction to Time Series Analysis and Forecasting.* New Jersey: John Wiley & Sons, 2007.
- MORETTIN, P.A.** *Econometria Financeira: Um curso em séries temporais financeiras.* São Paulo: Blucher, 2008.
- PETERS, R.J. et al. *Nanomaterials for products and application in agriculture, feed and food.* Trends in Food Science & Technology, v. 54, p. 155-164, 2016.
- PHILLIPS, P.; PERRON, P.** *Testing for a unit root in time series regression.* Biometrika, v. 75, n. 2, p. 335-346, 1988.
- PRODANOV, C. C.; FREITAS, E. C.** *Metodologia do trabalho científico: métodos e técnicas da pesquisa e do trabalho acadêmico.* 2. ed. Novo Hamburgo: Universidade Feevale, 2013.
- QUEIROZ, A.; CAVALHEIRO, D.** *Método de previsão de demanda e detecção de sazonalidade para o planejamento da produção de indústrias de alimentos.* Anais do Encontro Nacional de Engenharia de Produção, v. 23, 2003.
- SCHWARZ, G. E.** *Estimating the dimension of a model.* Annals of Statistics, v. 6, p. 461-464, 1978.
- SEKHON, B.S.** *Nanotechnology in agri-food production: An overview.* Nanotechnology, Science and Applications, v.7, p. 31-53, 2014.
- SOUZA, A. M. et al.** *Electrical energy supply for Rio Grande do Sul, Brazil, using forecast combination of weighted eigenvalues.* GEPROS: Gestão da Produção, Operações e Sistemas, v. 6, p. 23, 2011.
- SOUZA, F. M.** *Modelos de Previsão: aplicações à energia elétrica - ARIMA - ARCH - AI e ACP.* Curitiba: Appris, 2016.
- STOCK, J. W.; WATSON, M. W.** *Combination Forecasts of Output Growth in a Seven-Country Data Set.* Journal of Forecasting, v. 23, p. 405-430, 2004.
- SUZIGAN, W.** *Indústria Brasileira: origens e desenvolvimento.* São Paulo: Hucitec, 2000.
- 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.* Gestão & Produção, v. 10, p. 47-67, 2003.
- WINTERS, P. R.** *Forecasting Sales by Exponentially Weighted Moving Averages.* Management Science, p. 324-342, 1960.