



Exacta

ISSN: 1678-5428

ISSN: 1983-9308

geraldo.neto@uni9.pro.br

Universidade Nove de Julho

Brasil

Mitsuo Ueda, Renan; Sousa Agostino, Ícaro Romolo; Marasca, Letícia; Benedito da Silva, Rodolfo; Mendonça Souza, Adriano
Combinação de técnicas de previsão de demanda: aplicação em uma agroindústria de nutrição animal
Exacta, vol. 16, núm. 2, 2018, Abril-Junho, pp. 83-93
Universidade Nove de Julho
Brasil

DOI: <https://doi.org/10.5585/ExactaEP.v16n2.7295>

Disponível em: <https://www.redalyc.org/articulo.oa?id=81058960005>

- Como citar este artigo
- Número completo
- Mais informações do artigo
- Site da revista em redalyc.org

redalyc.org
UAEM

Sistema de Informação Científica Redalyc

Rede de Revistas Científicas da América Latina e do Caribe, Espanha e Portugal

Sem fins lucrativos acadêmica projeto, desenvolvido no âmbito da iniciativa
acesso aberto

Combinação de técnicas de previsão de demanda: aplicação em uma agroindústria de nutrição animal

Combination of demand forecasting techniques: application in an animal nutrition agroindustry

Renan Mitsuo Ueda¹

Ícaro Romolo Sousa Agostino²

Letícia Marasca³

Rodolfo Benedito da Silva⁴

Adriano Mendonça Souza⁵

Resumo

A crescente competitividade dos mercados em que as organizações atuam, tem exigido que elas utilizem cada vez mais métodos acurados de previsão para auxiliar nos processos decisórios. O objetivo do presente trabalho foi analisar o desempenho de técnicas individuais e de combinação de previsões no processo de previsão de demanda da ração de peixe de uma agroindústria de pequeno porte. Desta forma, utilizou-se os modelos de *Box-Jenkins* e de *Holt-Winters*, assim como a combinação de ambos, visando ajustar um modelo com maior acurácia. A combinação das previsões se deu pelos métodos de média aritmética, de regressão e da variância mínima com erros das previsões individuais não correlacionados, resultando em 5 modelos de previsões. Com os resultados obtidos, constatou-se que o modelo de combinação por regressão foi o que apresentou o melhor desempenho, devendo ser utilizado pelos gestores da empresa na obtenção da previsão da demanda futura.

Palavras-chave: Indústria de Alimentos, Modelos Preditivos, *Box-Jenkins*, *Holt-Winters*.

Abstract

The increasing competitiveness of the markets in which organizations operate has required them to increasingly use accurate forecasting methods to aid in decision making processes. The objective of the present work was to analyze the performance of individual techniques and forecast combinations in the process of forecasting the fish feed demand of a small agroindustry. In this way, the Box-Jenkins and Holt-Winters models were used, as well as the combination of both, in order to fit a more accurate model. The combination of predictions was based on the arithmetic mean, regression and minimum variance methods with uncorrelated individual forecast errors, resulting in 5 proposed forecast. With the results obtained, it was verified that the regression model was the one that presented the best performance and should be used by the managers of the company to obtain the forecast of the future demand.

Keywords: Food Industry, Predictive Models, *Box-Jenkins*, *Holt-Winters*.

1 Engenheiro de Produção formado pela Universidade Federal da Grande Dourados (UFGD). Mestrando em Engenharia de Produção (PPGEP – UFSM). Universidade Federal de Santa Maria renan.mitsuo@hotmail.com

2 Engenheiro de Produção (Universidade CEUMA). Mestrando em Engenharia de Produção pela Universidade Federal de Santa Maria (UFSM). Universidade Federal de Santa Maria icaroagostino@gmail.com

3 Graduada em Administração pela Universidade Regional Integrada do Alto Uruguai e das Missões – URI (2006). Mestranda do Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal de Santa Maria – UFSM. Universidade Federal de Santa Maria leticiaarasca@yahoo.com.br

4 Engenheiro de Produção Agroindustrial pela Universidade do Estado de Mato Grosso – UNEMAT (2010). Mestrado em Engenharia de Produção pela Universidade Federal do Rio Grande do Sul – UFRGS (2014). Atualmente é Professor Assistente A no Instituto de Engenharia (IEng) da Universidade Federal de Mato Grosso (UFMT), Campus de Várzea Grande. UFMT rodolfoengenheiro@hotmail.com

5 Graduado em Matemática (FIC), Especialização em Estatística e Modelagem Quantitativa (UFSM). Mestrado em Engenharia de Produção (UFSM). Doutorado em Engenharia de Produção (UFSC). Professor Associado do Departamento de Estatística da Universidade Federal de Santa Maria (UFSM) amsouza.sm@gmail.com

1 Introdução

A competitividade entre as indústrias tem se intensificado nas últimas décadas, expandindo riqueza nacional, incentivando a força produtiva e impulsionando o avanço tecnológico, por meio da otimização da produção, venda e distribuição, abrangendo as características dos fatores internos e externos da organização. Uma empresa é considerada competitiva, quando consegue adaptar-se às mudanças tecnológicas, econômicas e sociais, bem como, outras variáveis do ambiente externo, tendo a competência de garantir e sustentar resultados superiores aos desenvolvidos pela concorrência (Stonehouse & Snowdon, 2007).

Nesse contexto, os métodos de previsão se apresentam como importantes ferramentas para auxiliar no processo de tomadas de decisões, quando aplicadas sobretudo na previsão de demandas, visando otimizar a gestão dos processos organizacionais (Slack, Chambers, & Johnston, 2009). A previsão de demanda pode ser entendida como a busca de informações sobre a venda futura de um bem ou serviço através de um processo racional (Moreira, 2014). Nesse contexto, a previsão de demanda consiste em um processo metodológico que objetiva definir os dados futuros com base em modelos estatísticos, matemáticos, econométricos e/ou subjetivos (Martins & Laugeni, 2009).

Dentre os vários métodos de previsão existentes, o método de *Box-Jenkins* se apresenta como uma abordagem quantitativa poderosa na solução de muitos problemas de projeção, pois pode oferecer previsões acuradas de séries temporais (Souza, 2016). Outro método também quantitativo e relevante nesse contexto é o de *Holt-Winters*, que apresenta fácil compreensão da modelagem e possui elevada precisão em séries temporais que possuem tendência e sazonalidade (Morettin & Toloi, 2006).

A realização de previsões envolve inúmeras incertezas. Deste modo, com o intuito de reduzi-las, a combinação de previsões individuais em diversos casos se mostra eficaz, pois previsões confiáveis comumente exigem utilização de mais de uma técnica, possibilitando captar um maior número possível de informações (Martins & Werner, 2014).

Considerando a relevância do tema abordado, o presente artigo tem como problema de pesquisa: como a utilização de técnicas individuais de previsão e suas combinações podem contribuir na previsão de demanda de uma agroindústria? Tal questionamento há de requerer tanto, uma revisão bibliográfica quanto, a utilização de mecanismos de observação ou coleta de informações capazes de permitirem que, a temática investigada atinja o objetivo geral da pesquisa que é: analisar o desempenho de técnicas individuais e de combinação de previsões na previsão de demanda da ração de peixe em uma agroindústria de pequeno porte.

2 Revisão Teórica

Nesta seção são apresentados os fundamentos teóricos que dão suporte ao estudo, com ênfase nos modelos quantitativos de previsão de *Box-Jenkins* e *Holt-Winters* e também nas técnicas de combinação de previsões.

2.1 Modelos de Previsão

A metodologia *Box-Jenkins* se refere ao modelo de identificação, ajuste, checagem e uso de modelos Autoregressivos Integrados à Média Móvel, também denominado ARIMA (*Auto Regressive Integrated Moving Average*). Tal método é apropriado para o uso em séries temporais de comprimento médio, sendo caracterizado por captar o comportamento da correlação da série entre os valores da série temporal, e assim realizar previsões futuras (Souza, 2016).

Desta forma, a metodologia resulta da combinação dos seguintes componentes, também denominados de filtros: autorregressivo (AR), filtro de integração (I) e o componente de médias móveis (MA). Tais modelos constituem um ciclo interativo, permitindo a escolha do melhor modelo baseado nos dados da série estudada, a partir dos seguintes procedimentos: (i) Identificação, consistindo na determinação do modelo que melhor descreve o comportamento da série, através da análise das funções de autocorrelação e autocorrelação parcial; (ii) Estimação, realizando a estimativa dos parâmetros autorregressivos, assim como de médias móveis; (iii) Validação, consistindo na análise da adequação do modelo ajustado ao comportamento real da série; (iv) Previsão, que somente é realizada, quando as etapas anteriores forem satisfatórias (Kirchner, Souza, & Stumm, 2011; Noronha, Souza, & Zanini, 2016).

Usualmente os modelos ARIMA (p, d, q) são representados pela equação 1, em que B representa o operador retroativo, d a ordem de integração, ϕ é termo que representa o autoregressivo de ordem p , θ é o parâmetro de médias móveis representado pela letra q .

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

Para mensurar o ajuste do modelo escolhido, os critérios *Akaike's Information Criteria* (AIC) e *Bayesian Information Criteria* (BIC) comumente são utilizados como parâmetros para a escolha do melhor modelo entre os modelos ARIMA possíveis. Desse forma, o modelo que apresentar os menores valores para tais parâmetros será o com o melhor ajuste (Morettin, 2008). Os critérios de AIC e BIC são dados 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.

Outro modelo utilizado para realizar previsões de séries temporais que apresentam tendência e sazonalidade, é o de *Holt-Winters*. Para a verificação da sazonalidade, aplica-se uma técnica de amortecimento exponencial. Cabe ressaltar que o modelo possui três constantes de suavização exponencial, sendo elas, α , β e γ . A constante α está relacionada com o nível, β com tendência e γ sazonalidade (Samohyl, Rocha, & Mattos 2001; So & Chung, 2014).

O uso do modelo de *Holt-Winters* possui algumas vantagens, tais como: fácil compreensão da modelagem, viabilidade financeira (pode ser modelado por meio de planilhas do *excel*), além disso, consegue prever de modo preciso séries que apresentam tendência e sazonalidade (Morettin & Toloi, 2006).

O modelo de *Holt-Winters* pode ter duas abordagens distintas: multiplicativa e aditiva, sendo que a principal diferença entre eles é a atuação dos índices sazonais, bem como a forma como ocorre a sazonalidade. Portanto, a abordagem multiplicativa é comumente utilizada em séries temporais onde a amplitude do ciclo sazonal aumenta. Por outro lado, a abordagem aditiva, destina-se a séries temporais na qual a amplitude permanece constante durante os ciclos (Makridakis, Wheelwright, & Hyndman, 1998; Albuquerque & Serra, 2006).

A fim de verificar a precisão dos modelos utilizados, alguns mecanismos são utilizados no processo de previsão da demanda. Tais mecanismos, possibilitam o acompanhamento do desempenho dessas projeções de vendas, confirmando assim, a validade do modelo com base nos dados atuais. As medidas de acurácia utilizadas

Tabela 1: Equações dos modelos de Holt-Winters (multiplicativo e aditivo)

Modelos	Equações
	$F_{t+m} = (L_t + b_t m)S_{t-s+m}$ (4)
Modelo de Holt-Winters (método multiplicativo)	$L_t = \alpha \frac{Y_t}{S_{t-s}} + (1-\alpha)(L_{t-1} + b_{t-1})$ (5)
	$b_t = \beta(L_t - L_{t-1}) + (1-\beta)b_{t-1}$ (6)
	$S_t = \gamma \frac{Y_t}{L_t} + (1-\gamma)S_{t-s}$ (7)
	$F_{t+m} = (L_t + b_t m) + S_{t-s+m}$ (8)
Modelo de Holt-Winters (método aditivo)	$L_t = \alpha(Y_t - S_{t-s}) + (1-\alpha)(L_{t-1} + b_{t-1})$ (9)
	$b_t = \beta(L_t - L_{t-1}) + (1-\beta)b_{t-1}$ (10)
	$S_t = \gamma(Y_t - L_t) + (1-\gamma)S_{t-s}$ (11)

Onde: F é o valor da observação prevista; Y a demanda real; L a estimativa do nível da série temporal; B a estimativa de tendência da série temporal; S o índice sazonal da série temporal; α , β e γ são constantes de suavização; t o instante de observação no tempo; e m a quantidade de períodos à frente que se deseja obter previsões.

Fonte: Adaptado Morettin e Toloi (2006).

nesse trabalho para a avaliação da precisão dos modelos foram: *Mean Absolute Error* (MAE); *Mean Squared Error* (MSE); e *Mean Absolute Percentage Error* (MAPE) (Tubino, 2009). Na Tabela 2 estão contidas as equações de cada uma dessas medidas de acurácia.

Tabela 2: Medidas de Acurácia

Siglas	Fórmulas
MAE	$\frac{\sum_{t=1}^n E_t }{n}$ (12)
MSE	$\frac{\sum_{t=1}^n (E_t)^2}{n}$ (13)
MAPE	$\frac{\sum_{t=1}^n E_t/Y_t * 100}{n}$ (14)

Onde: = Erro de previsão no instante t; n = Número de observações; = Demanda real no tempo t e $t = 1, 2, \dots, n$.

Fonte: Adaptado de Tubino (2009).

2.2 Previsão Combinada

De acordo com os métodos de previsão combinados podem melhorar a precisão das previsões, assim como reduzir a variância do erro. Isto se deve ao fato da escolha de um modelo em detrimento de outro não abrange todas as particularidades que cada modelo contempla. (Rausser & Oliveira, 1976; Costantini & Pappalardo, 2010; Andrawis, Atyia, & El-Shishiny, 2011). Desta forma, a previsão combinada é uma técnica a ser considerada na busca do modelo mais preciso (Souza, Souza, Ferreira, & Menezes, 2011).

A combinação de previsão é uma abordagem atrativa dentre as opções, pois a combinação de métodos pode prover uma melhor acurácia visto que cada técnica captura algum tipo de informação que influencia na previsão realizada (Clemen, 1989; Martins & Werner, 2012)

Para realização da combinação de modelos, Flores e White (1988) sugerem uma estrutura dividida em duas etapas: (i) seleção dos modelos de previsão, que tratará da tarefa de selecionar métodos que se adequem corretamente à série estudada pelos critérios de: acurácia, horizonte, custos, complexidade e dados disponíveis: (ii) consiste na seleção do método de combinação, em que a preocupação estará em definir a forma que as previsões serão combinadas, existindo diversos métodos de propostos.

Granger e Ramanathan (1984) argumentam sobre a realização de combinações de modelos de previsão utilizando uma forma estruturada de regressão, tendo a previsão combinada como variável resposta as previsões individuais como variáveis explicativas. Outra abordagem sugerida por Makridakis e Winkler (1983) é da utilização da média das previsões, pois segundo os autores a utilização da média pode prover maior acurácia da previsão, reduzindo sua variabilidade, pois não existindo informações de dependência entre as previsões, torna-se razoável a utilização

da média, podendo dar origem a resultados melhores que métodos mais sofisticados (Clemen, 1989; Rodrigues & Stevenson, 2013; Graefe, Armstrong, Jones Jr, & Cuzán., 2013; Xiao, Shao, Liang, & Wang, 2016).

Por fim, uma terceira abordagem de combinação de previsão que será considerada, trata-se do método da Variância Mínima, proposto por Bates e Granger (1969), que consiste em realizar uma combinação linear objetiva. A combinação para esse método é obtida pela atribuição de um peso para cada previsão individual, conforme pode ser visto na Equação 15.

$$F_c = wF_1 + (1 - w)F_2 \quad (15)$$

Onde: w é o peso atribuído à previsão e F_1 e F_2 são as previsões originais a serem combinadas.

Para obtenção do valor dos pesos (w) descrito na Equação 16, baseia-se na observação das variâncias dos erros das previsões a serem combinadas. Dessa forma, à previsão com maior variabilidade nos erros deve ser atribuído menor peso, a fim de obter-se maior acurácia. A seguir, é apresentada a Equação 16 para a minimização da variância com erros das previsões individuais correlacionados, onde realiza-se a diferenciação da variação da previsão combinada em relação à w e iguala-se o resultado a zero. Portanto, este método ficou conhecido como método da variância mínima, justamente por buscar a minimização da variância (Bates & Granger, 1969).

$$w = \frac{\sigma_2^2 - \rho\sigma_1\sigma_2}{\sigma_1^2 + \sigma_2^2 - 2\rho\sigma_1\sigma_2} \quad (16)$$

A Equação 17 ilustra a de forma simplificada como é calculado os pesos (w) pelo método da variância mínima com erros das previsões individuais não correlacionados.

$$w = \frac{\sigma_2^2}{\sigma_1^2 + \sigma_2^2} \quad (17)$$

Onde: σ_1^2 e σ_2^2 representam à variância dos erros das previsões de individuais.

3 Materiais e Métodos

Este estudo caracteriza-se quanto à sua natureza, como sendo uma pesquisa aplicada, que conforme Gil (2010), relaciona-se com as pesquisas destinadas para a aquisição de conhecimentos através da aplicação dos conceitos teóricos em uma situação específica. Quanto à abordagem, pode ser classificado como uma pesquisa quantitativa, que busca transformar as informações em números para a análise dos mesmos (Bicudo, 2004). Quanto aos seus objetivos, a pesquisa classifica-se como sendo exploratória, uma vez que, de acordo com Gil (2010), tal pesquisa tem por objetivo explicitar e gerar hipóteses sobre o problema analisado. Quanto aos procedimentos, é classificada como estudo de caso.

Os dados utilizados que formam a série temporal analisada neste estudo são de uma agroindústria de rações localizada na região sul do estado de Mato Grosso do Sul, que atua no mercado desde 1998, fornecendo rações, concentrados e suplementos proteicos e energéticos para bovinos, equinos, ovinos, suíños, aves, peixes e cães.

Para o ajuste do modelo foram utilizadas 63 observações mensais das demandas de ração para peixe, referente ao período de janeiro de 2010 até março de 2015.

3.1 Tratamento dos Dados

Inicialmente foi examinado o comportamento da série estudada, investigando sua estacionariedade e os parâmetros de autocorrelação.

Posteriormente, foram estimadas as previsões *in sample* para os modelos escolhidos. Ambas as previsões apresentaram ruído branco indicando que os erros gerados pelos modelos não são autocorrelacionados, ou seja, constituem a variabilidade natural do processo.

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

3.2 Análise dos Dados

Os modelos utilizados para obter as previsões individuais foram o de *Box-Jenkins*, conforme equação 1, e de *Holt-Winters*, conforme equações de 4 a 11. Após a obtenção das previsões individuais, foram realizadas as combinações delas de três formas distintas, utilizando a Média Simples, Método da Variância Mínima (equação 15) e Regressão Linear.

A primeira forma de combinação foi por média aritmética, como mostrado na Equação 18, em que a previsão combinada (PC) para cada período (i) é dada pela soma das previsões dos modelos individuais (A, B ... Z) dividida pela quantidade de modelos utilizados (n), obtendo para cada período proposto a média aritmética das previsões.

$$PC_i = \frac{A_i + B_i + \dots + Z_i}{n} \quad (18)$$

A segunda forma de combinação se deu por meio da regressão linear simples das previsões individuais de cada modelo como variáveis dependentes e a série original como variável dependente, para um nível de confiança de 95%. A previsão combinada foi obtida utilizando a equação gerada pela regressão.

Por fim, o terceiro método, da Variância Mínima, utilizará a variância dos erros não correlacionados das previsões individuais na atribuição de pesos a fim de combinar ambas. A Figura 1 apresenta as etapas de execução do presente trabalho.

4 Resultados e Discussões

A partir da inspeção gráfica da série, se visualiza a presença de tendência e sazonalidade, Figura 2. Além disso, a mesma caracteriza-se como sendo uma série temporal não estacionária, visto que a média e a variância da mesma não constantes ao longo do tempo.

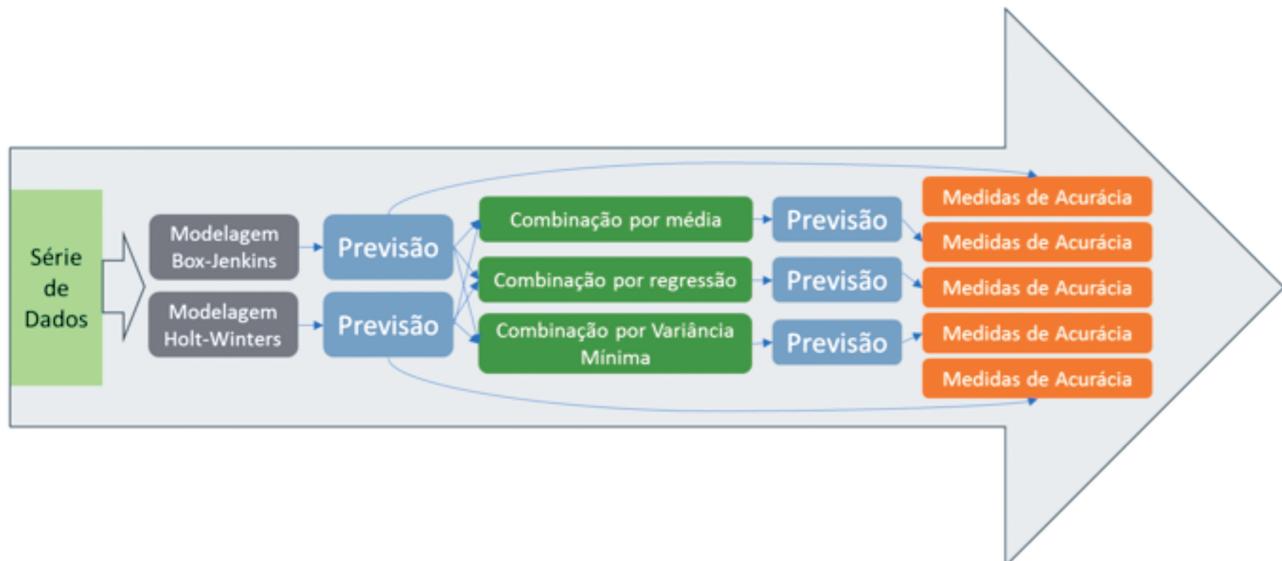


Figura 1: Etapas da análise das previsões

Fonte: Adaptado de Martins e Werner (2014).

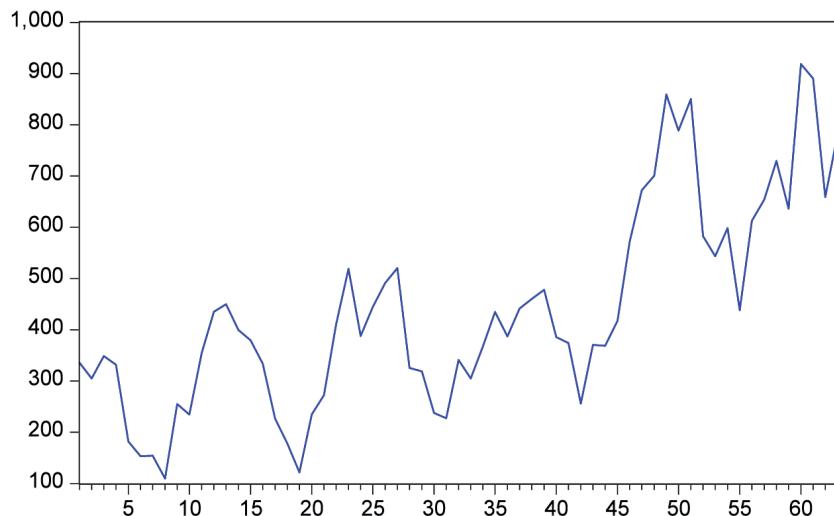


Figura 2: Demanda por rações de peixe, no período de jan/2010 a mar/2015

Fonte: Os autores.

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1	0.844	0.844	46.995 0.000
		2	0.739	0.095	83.650 0.000
		3	0.586	-0.203	107.10 0.000
		4	0.403	-0.253	118.36 0.000
		5	0.293	0.125	124.42 0.000
		6	0.221	0.184	127.94 0.000
		7	0.229	0.250	131.77 0.000
		8	0.247	-0.012	136.30 0.000
		9	0.362	0.293	146.26 0.000
		10	0.433	0.007	160.76 0.000
		11	0.480	-0.060	178.93 0.000
		12	0.477	-0.205	197.20 0.000
		13	0.376	-0.234	208.77 0.000
		14	0.275	-0.009	215.10 0.000
		15	0.115	-0.076	216.23 0.000
		16	0.003	0.037	216.23 0.000
		17	-0.080	0.066	216.80 0.000
		18	-0.148	-0.153	218.78 0.000
		19	-0.143	-0.085	220.68 0.000
		20	-0.104	0.012	221.71 0.000
		21	-0.051	-0.059	221.97 0.000
		22	0.041	0.264	222.13 0.000
		23	0.090	0.007	222.97 0.000
		24	0.099	0.022	223.99 0.000
		25	0.060	-0.106	224.38 0.000
		26	0.008	-0.004	224.38 0.000
		27	-0.073	0.013	224.99 0.000
		28	-0.131	0.090	227.01 0.000

Figura 3: FAC e FACP

Figura 3. TAC

Por meio da análise da função de autocorrelação (FAC) e autocorrelação parcial (FACP), buscou-se identificar o modelo que melhor expressava o comportamento desta série, a partir do decaimento dos valores das funções e do comportamento ondular da autoregressividade.

Pode-se verificar na Figura 3 componentes autoregressivos e sazonais. Em seguida, foi realizada a estimação dos parâmetros dos modelos concorrentes com o intuito de encontrar o melhor modelo para se realizar previsões. Na Tabela 1, estão contidos os modelos utilizados no estudo e os valores dos parâmetros, erro padrão, t-statistic, AIC (*Akaike Information Criteria*) e BIC (*Bayesian Information Criteria*).

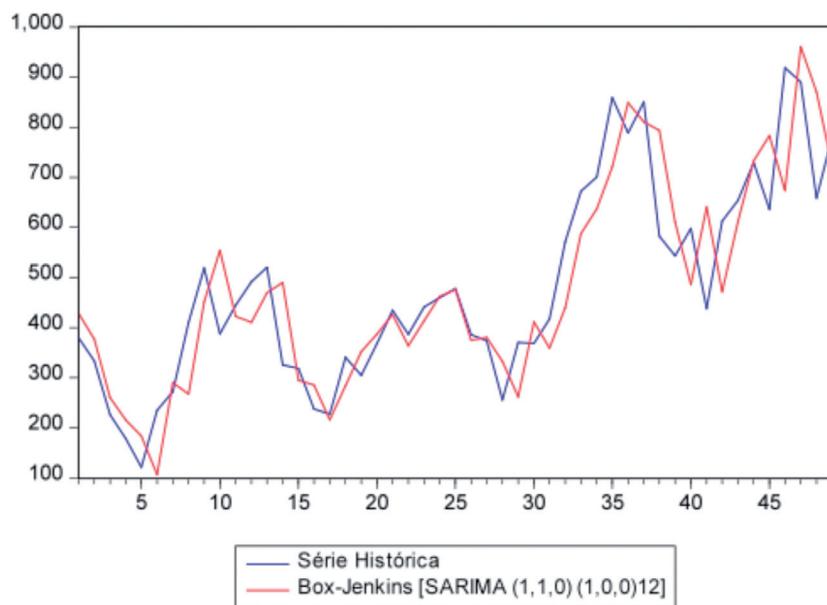
Com base na análise de resíduos e nos critérios de informação AIC e BIC, constatou-se que dentre os quatro modelos de *Box-Jenkins* avaliados, o que melhor representa a série de demanda de ração de peixe é o SARIMA (1,1,0) (1,0,0)12, em destaque na Tabela 1. Na Figura 4 é apresentado a série original com o modelo de *Box-Jenkins* ajustado.

Posteriormente, foi avaliado o modelo de *Holt-Winters* dentro dos modelos multiplicativos e aditivos, visto que a série temporal analisada apresenta tendência e sazonalidade. Na Tabela 4, é

Tabela 3: estatísticas dos quatro modelos analisados

Modelo	Parâmetro	Erro padrão	t-Statistic	Ruído branco
SARIMA $(1,0,0)_C(1,0,0)_{12}$	$c = 448,6872$ $\phi_1 = 0,820361$ $\Phi_{12} = 0,441861$	122,2560 0,072859 0,182017	3,670063 11,25956 2,427574	Sim
AIC = 12,04013 e BIC = 12,17620				
SARIMA $(1,0,0)(1,0,0)_{12}$	$\phi_1 = 0,952285$ $\Phi_{12} = 0,437110$	0,033460 0,184185	28,46069 2,373208	Não
AIC = 12,10885 e BIC = 12,21090				
ARFIMA $(1,d^*,0)$	$d = -0,166238$ $\phi_1 = 0,997427$	0,128864 0,011621	-1,290025 85,83146	Não
AIC = 12,19487 e BIC = 12,29692				
SARIMA $(1,0,0)(1,0,0)_{12}$	$\phi_1 = -0,304052$ $\Phi_{12} = 0,495936$	0,124468 0,167837	-2,442806 2,954871	Sim
AIC = 11,99736 e BIC = 12,10029				

Fonte: Os autores.

**Figura 4: Série Histórica; Modelo Box-Jenkins [SARIMA (1,1,0)(1,0,0)12]**

Fonte: Os autores.

Tabela 4: Medidas de acurácia dos modelos de previsão de Holt-Winters

Modelos	MAE	MSE	MAPE
Modelo de Holt-Winters (Método Multiplicativo)	159	33802,78	24,83%
Modelo de Holt-Winters (Método Aditivo)	95,96	14605,70	15,75 %

Fonte: Os autores.

apresentada as medidas de acurácia das previsões para os modelos de *Holt-Winters*. O modelo que apresentou o menor erro de previsão foi o de *Holt-Winters* (método aditivo).

Na Figura 5 é representada a série original junto do modelo de *Holt-Winters*, sendo possível observar o ajuste do modelo à série.

Cada modelo apresentou diferentes variâncias, capturando características específicas da série estudada, permitindo que as combinações se complementem, resultando em uma maior acurácia. As previsões combinadas, pelos métodos da média aritmética, da regressão e da variância mínima são ilustradas no Figura 6, sendo possível observar que todas se mostraram visualmente ajustadas a série histórica original.

Os resultados das medidas de acurácia para a fase de teste de todos os modelos de previsão são apresentados na Tabela 5. O modelo em destaque foi o que apresentou os menores erros de previsão e que, portanto, será utilizado para a obtenção da previsão de demanda do produto analisado.

Dessa forma, o modelo mais adequado para a demanda de peixe, isto é, que melhor se ajusta

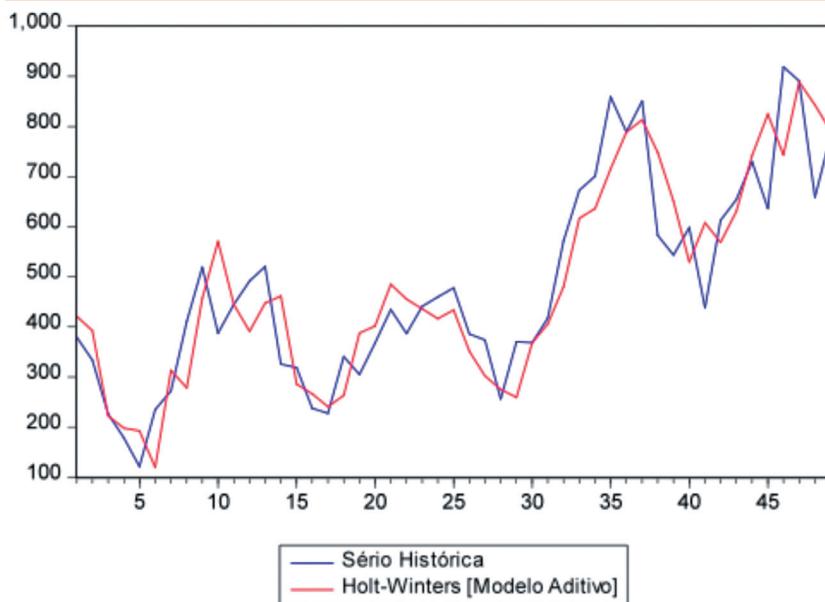


Figura 5: Série histórica, Modelo de Holt-Winters [Modelo Aditivo]
Fonte: Os autores.

Fonte: Os autores.

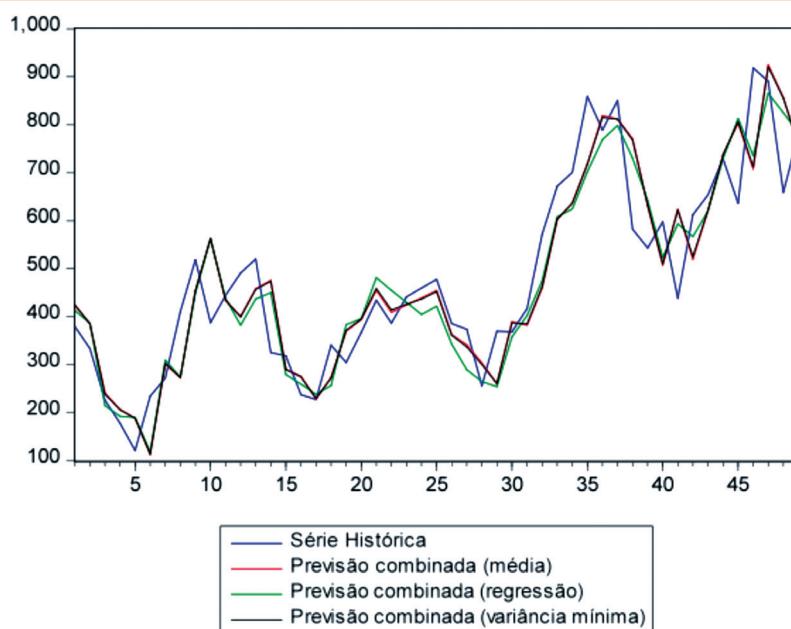


Figura 6: Série histórica e previsões combinadas

Fonte: Os autores

Tabela 5: Medidas de acurácia dos modelos de previsão analisados

Modelo	MAE	MSE	MAPE
Modelo de Holt-Winters (Método Aditivo)	95,96	14605,70	15,75 %
SARIMA (1,0,0) (1,0,0) ₁₂	126,13	21602,18	20,08 %
Previsão combinada (média aritmética)	110,04	17398,63	17,79 %
Previsão combinada (regressão)	92,40	13134,80	15,00 %
Previsão combinada (Variância mínima)	108,34	17036,23	17,54 %

Fonte: Os autores

tou aos dados históricos de venda dos últimos cinco anos, foi o de combinação por regressão. Este resultado vai de encontro com o esperado, tendo em vista que a série temporal apresenta comportamento sazonal com tendência, e os modelos de combinação por regressão buscam um equilíbrio entre cada uma das previsões dos modelos individuais.

Tais resultados vão de encontro com a literatura pesquisada, em que os métodos de previsões combinados apresentam maior acurácia, como no estudo realizado por Martins e Werner (2012), que comparou métodos de previsões individuais e suas combinações em um banco de séries industriais de demandas. Outros estudos recentes como o realizado por Aye, Balcilar, Gupta e Majumdar (2015) chegou em resultados semelhantes combinando preditores individuais, assim como Graefe *et al.* (2014) que utilizou a combinação de previsões para obter resultados mais acurados, encontrando resultados substanciais.

5 Conclusões

Os métodos de previsões de demanda são importantes ferramentas para auxiliar os gestores de uma organização durante as tomadas de decisões, relacionadas ao dimensionamento dos recursos necessários para a produção de um

bem ou serviço, garantindo assim, o atendimento das necessidades e expectativas de seus clientes.

Como contribuição, este artigo apresenta um estudo de caso com aplicação de dois modelos para obtenção das previsões individuais (SARIMA (1,0,0) (1,0,0)₁₂ e Holt-Winters (método aditivo) e três métodos de combinações de previsões (média aritmética, regressão e variância mínima), em um estudo de caso em uma empresa do setor agroindustrial, discutindo os resultados encontrado com resultados prévios expostos na literatura sobre o tema.

Na pesquisa, o modelo que se apresentou mais adequado para este tipo de demanda (ração de peixe), ou seja, que melhor se ajustou aos dados históricos de venda dos últimos cinco anos foi o modelo obtido pelo método de combinação de previsões por regressão, reafirmando a discussão encontrada na literatura científica sobre o tema, em que a combinação de modelos possibilita a redução dos erros, aumentando a acurácia do modelo ajustado.

Desta forma, os resultados capacitam o modelo para ser utilizado pelos gestores da empresa no dimensionamento da produção futura para atender a demanda.

Como sugestão para futuras pesquisas, recomenda-se a utilização de outras técnicas individuais de previsão que possam capturar diferentes características em séries temporais, tais como redes neurais artificiais, assim como métodos de decomposição. Outra sugestão é a agregação de previsões a partir de ajuste de especialista a partir de análises econômétricas.

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.

Agrademos à CAPES pelo apoio financeiro na forma de concessão de bolsas de estudo.

Referências

- Albuquerque, J. C. D. S., & Serra, C. (2006). Utilização de modelos de Holt-Winters para a previsão de séries temporais de consumo de refrigerantes no Brasil. *XXVI ENEGEP, Fortaleza, Anais Eletrônicos do Encontro Nacional de Engenharia de Produção*, Rio de Janeiro: ABEPRO.
- Andrawis, R. R., Atiya, A. F., & El-Shishiny, H. (2011). Combination of long term and short term forecasts, with application to tourism demand forecasting. *International Journal of Forecasting*, 27(3), 870-886.
- Aye, G. C., Balcilar, M., Gupta, R., & Majumdar, A. (2015). Forecasting aggregate retail sales: The case of South Africa. *International Journal of Production Economics*, 160, 66-79.
- Bates, J. M., & Granger, C. W. (1969). The combination of forecasts. *Journal of the Operational Research Society*, 20(4), 451-468.
- Bicudo, M. A. V. (2004). Pesquisa qualitativa e pesquisa qualitativa segundo a abordagem fenomenológica. *Pesquisa qualitativa em educação matemática*. Belo Horizonte: Autêntica, 99-112.
- Clemen, R. T. (1989). Combining forecasts: a review and annotated bibliography. *International journal of forecasting*, 5(4), 559-583.
- Costantini, M., & Pappalardo, C. (2010). A hierarchical procedure for the combination of forecasts. *International journal of forecasting*, 26(4), 725-743.
- Flores, B. E., & White, E. M. (1988). A Framework for the combination of forecasts. *Journal of the Academy of Marketing Science*, 16(3-4), 95-103.
- Gil, A. C. (2010). *Como elaborar projetos de pesquisa* (5a ed.). São Paulo: Atlas.
- Graefe, A., Armstrong, J. S., Jones Jr, R. J., & Cuzán, A. G. (2014). Combining forecasts: an application to elections. *International Journal of Forecasting*, 30(1), 43-54.
- Granger, C. W., & Ramanathan, R. (1984). Improved methods of combining forecasts. *Journal of Forecasting*, 3(2), 197-204.
- Kirchner, R. M., Souza, A. M., & Stumm, E. M. F. (2011). A modelagem como ferramenta de gestão. *Latin American Journal of Business Management*, 2(1).
- Makridakis, S., Wheelwright, S. C., & Hyndman, R. J. (1998). *Forecasting methods and applications*. New York: John Wiley & Sons.

- Makridakis, S., & Winkler, R. L. (1983). Averages of forecasts: some empirical results. *Management Science*, 29(9), 987-996.
- Martins, P. G., & Laugeni, F. P. (2009). *Administração da produção* (2a ed.). São Paulo: Saraiva.
- Martins, V. L. M., & Werner, L. (2012). Forecast combination in industrial series: a comparison between individual forecasts and its combinations with and without correlated errors. *Expert Systems with Applications*, 39(13), 11479-11486.
- Martins, V. L. M., & Werner, L. (2014). Comparação de previsões individuais e suas combinações: um estudo com séries industriais. *Produção, Porto Alegre*, 24(3), 618-627.
- Moreira, D. A. (2014). *Administração da produção e operações* (2a ed.). São Paulo: Cengage Learning.
- Morettin, P. A., & Toloi, C. M. C. (2006). *Análise de séries temporais* (2a ed.). São Paulo: Blucher.
- Morettin, P. A. (2008). *Econometria financeira: um curso de séries temporais financeiras*. São Paulo: Blucher.
- Noronha, M. O., Souza, A. M., & Zanini, R. R. (2016). Aplicação da metodologia Box & Jenkins para modelagem da emissão de Certificados ISO 14001 no Brasil. *Revista ESPACIOS*, 37(12).
- Rausser, G. C., & Oliveira, R. A. (1976). An econometric analysis of wilderness area use. *Journal of the American Statistical Association*, 71(354), 276-285.
- Rodrigues, B. D., & Stevenson, M. J. (2013). Takeover prediction using forecast combinations. *International Journal of Forecasting*, 29(4), 628-641.
- Samohyl, R. W., Rocha, R., & Mattos, V. L. D. D. (2001). Utilização do método de Holt-Winters para previsão do leite entregue às indústrias catarinenses. *Anais do Encontro Nacional de Engenharia de Produção*. Recuperado em 09 abril, 2018, de http://www.abepro.org.br/biblioteca/ENEGETP2001_TR66_0742.pdf
- Slack, N., Chambers, S., & Johnston, R. (2009). *Administração da produção* (3a ed.). São Paulo: Atlas.
- So, M. K., & Chung, R. S. (2014). Dynamic seasonality in time series. *Computational Statistics & Data Analysis*, 70, 212-226.
- Souza, A. M., Souza, F. M., Ferreira, N., & Menezes, R. (2011). Eletrical energy supply for Rio Grande do Sul, Brazil, using forecast combination of weighted eigenvalues. *GEPROS: Gestão da Produção, Operações e Sistemas*, 6(3), 23.
- Souza, F. M. (2016). *Modelos de previsão: aplicações à energia elétrica*. Appris: Curitiba.
- Stonehouse, G., & Snowdon, B. (2007). Competitive advantage revisited: Michael Porter on strategy and competitiveness. *Journal of Management Inquiry*, 16(3), 256-273.
- Tubino, D. F. (2009). *Planejamento e controle da produção: teoria e prática* (2a ed.). São Paulo: Atlas.
- Xiao, L., Shao, W., Liang, T., & Wang, C. (2016). A combined model based on multiple seasonal patterns and modified firefly algorithm for electrical load forecasting. *Applied energy*, 167, 135-153.

Recebido em 6 abr. 2017 / aprovado em 21 ago. 2017

Para referenciar este texto

Ueda, R. M., Agostino, Í. R. S., Marasca, L., Silva, R. B., & Souza, A. M. Combinação de técnicas de previsão de demanda: aplicação em uma agroindústria de nutrição animal. *Exacta*, São Paulo, v. 16, n. 2, p. 83-93, 2018.

