

Combinações de Métodos Quantitativos na Previsão de Demanda de Vendas de Eletrodomésticos

Combinations of Quantitative Methods in the Forecast for Demand for Sales of Home Appliances

Wílian Assmann Ferro¹ - Universidade Tecnológica Federal do Paraná
José Donizetti de Lima² - Universidade Tecnológica Federal do Paraná
Marcelo Gonçalves Trentin³ - Universidade Tecnológica Federal do Paraná

RESUMO

No atual ambiente globalizado, o aumento da competitividade e a pressão para diminuir custos, tem estimulado as indústrias em aplicar métodos de previsão de demanda mais acurados. Nesse sentido, o objetivo desse estudo é aplicar métodos individuais de previsão de demanda das famílias ARIMA e Suavização Exponencial e posteriormente combinar os melhores a fim de verificar se a acuracidade das previsões é melhorada. Para isso, são utilizadas séries históricas de três famílias de produtos de uma indústria do ramo de eletrodomésticos. Foram seguidos os passos metodológicos: (i) obtenção dos dados históricos e tratamento preliminar; (ii) aplicação das técnicas de previsão de demanda individuais; (iii) aplicação dos métodos de combinação; e (iv) escolha do modelo de combinação mais acurado. Como resultado, evidenciou-se que somente para família alfa os métodos de combinação aumentaram a acuracidade. Porém, para as famílias beta e gama não foi observado melhorias na acurácia das previsões. Apesar disso, surge como oportunidade de pesquisa a integração de previsões via julgamento de especialistas.

Palavras-chave: Previsão de demanda. Métodos quantitativos. Suavização exponencial. ARIMA. Combinação de métodos de previsão de demanda.

Editor Responsável: Prof.
Dr. Hermes Moretti Ribeiro da
Silva

ABSTRACT

In today's globalized environment, increased competitiveness and pressure to lower costs have stimulated industries to apply more accurate forecasting methods. In this vein, the objective of this study is to apply individual methods of demand forecasting of the ARIMA families and Exponential Smoothing and then combine the best ones to verify if the accuracy of the forecasts is improved. For this, a historical series of three families of products of a home appliance industry are used. These methodological steps were followed: (i) obtaining historical data and preliminary treatment; (ii) application of individual demand forecasting techniques; (iii) application of the combination methods; and (iv) choosing the most accurate combination model. As a result, it was found that only in the case of the alpha families did the combination methods increase accuracy. However, for the beta and gamma families, no improvement was observed in the accuracy of the predictions. In spite of this, the integration of forecasts through expert judgment emerges as a research opportunity.

Keywords: Forecast of demand. Quantitative methods. Exponential smoothing. ARIMA. Combination of demand forecasting methods.

1. Via do Conhecimento, s/n - KM 01 - Fraron, Pato Branco - PR, 85503-390, engqmc_wilian@hotmail.com; 2. donizetti@utfpr.edu.br; 3. marcelo@utfpr.edu.br

FERRO, W.A.; LIMA, J.D.; TRENTIN, M.G. Combinações de Métodos Quantitativos na Previsão de Demanda de Vendas de Eletrodomésticos. **GEPROS. Gestão da Produção, Operações e Sistemas**, v. 14, n. 5, p. 67 - 88, 2019.

1. INTRODUÇÃO

A previsão de demanda está diretamente associada em antever as ocorrências futuras, é indispensável na definição da estratégia, tomada de decisões e planejamento das organizações (MOON *et al.*, 1998; MAKRIDASKIS *et al.*, 1998). Nesse sentido, segundo Kotler e Armstrong (1998), pode-se entender a demanda como procura por produtos específicos respaldado, no poder de compra que um determinado mercado consumidor possui. Logo, para a empresa captar este potencial de compra, necessita mensurar a previsão da demanda.

De acordo com Pelegrini e Fogliatto (2001) e Morettin e Toloí (2004), a previsão de demanda pode ser feita utilizando diversos métodos matemáticos e a aplicação destes modelos estão diretamente relacionados com o comportamento da série temporal a ser analisada. Logo, a aplicabilidade de um sistema de *forecasting* quantitativo depende de três condições básicas: (i) disponibilidade de dados históricos; (ii) possibilidade de quantificar os dados históricos em informações numéricas; e (iii) presumir que os padrões observados no passado possam repetir-se no futuro (MAKRIDAKIS *et al.*, 1998).

Assim, apresenta-se como alternativa, para prever a demanda a abordagem quantitativa que pode ocorrer por meio do emprego de: (i) métodos causais; e (ii) análise de séries temporais (MONTGOMERY *et al.*, 1990; WERNER, 2004; MAKRIDAKIS *et al.*, 1998). Nesse sentido, Pellegrini e Fogliatto (2001) destacam que as técnicas de previsão individual que comumente são utilizadas e tem como base séries temporais são as seguintes: (i) as técnicas da família Suavização Exponencial (Simples, Holt e Holt-Winters); (ii) e as técnicas da família ARIMA.

Para corroborar esse entendimento, Gooijer e Hyndman (2006) realizaram uma ampla revisão da literatura sobre previsões com séries temporais, entre os anos de 1985 a 2005, e dentre vários apontamentos mencionam a ampla utilização por parte dos pesquisadores das técnicas de SE e ARIMA. Além disso, autores como Sanders e Ritzman (1995); Sanders (1997); Goodwin e Fildes (1999) e Goodwin (2000) fizeram uso das técnicas de SE em suas pesquisas. Já, com relação as técnicas ARIMA os seguintes autores fizeram uso Lobo e Nair (1990); Wolfe e Flores (1990) e Flores *et al.* (1992).

Dentro dessa perspectiva, as previsões por não serem perfeitas são passíveis de apresentar erros e segundo Armstrong (2001) a fim de mitigar os efeitos dos erros de previsão

oriundos de ambientes de incerteza e alta instabilidade uma alternativa seria empregar diferentes técnicas de previsão combinando-as de forma adequada. Na literatura, diversos autores, ao longo dos anos, destacaram que a combinação de previsão, apresenta melhora na acurácia das previsões quando comparados com os métodos de previsões individuais (CLEMEN, 1989; WERNER, 2004; MARTINS; WERNER, 2012; MANCUSO, 2013).

Portanto, o fato de existir um elevado número de publicações sobre metodologias e formas de combinar métodos de previsão, ainda existem lacunas a serem preenchidas, assim surge o questionamento da pesquisa: como avaliar de forma comparativa o desempenho das técnicas individuais Suavização Exponencial (SE) e *Autoregressive Integrated Moving Average* (ARIMA) e suas combinações que melhor descrevem o perfil de demanda em indústrias do ramo de eletrodomésticos?

Com base na questão proposta, este estudo, tem como objetivo ajustar um modelo matemático que melhor explique os dados de demanda de vendas de eletrodomésticos nas indústrias, de forma a combinar a previsão de demanda das famílias ARIMA e SE. Esse melhor ajuste pode auxiliar os gestores na tomada de decisão.

2. MODELOS DE PREVISÃO

Dentre as técnicas de previsão individual, já consagrados na literatura, serão utilizados neste trabalho, duas famílias SE e a ARIMA de Box-Jenkins.

2.1 Técnicas de Suavização Exponencial (SE)

A família de técnicas de SE, consiste em aplicar uma média ponderada nas observações de uma série temporal. Os pesos maiores são dados para as informações mais recentes, em contrapartida os dados mais antigos recebem pesos menores. Apresentam-se como vantagens a praticidade de utilização aliado ao baixo custo de aplicação, além disso, possuem grande rapidez na geração de resultados, logo é indicado para previsões de grande quantidade de produtos ou itens (MAKRIDAKIS *et al.*, 1998; MORETTIN; TOLOI, 2004).

De acordo com Makridakis *et al.* (1998) e Morettin e ToloI (2004) as técnicas de SE, dividem-se em: (i) Suavização Exponencial Simples (SES); (ii) Suavização Exponencial linear de Holt (SEH); e (iii) Suavização Exponencial de Holt-Winters (SEHW). Sendo que a

aplicação de cada técnica é determinada por meio das características que cada série temporal apresenta (tendência ou sazonalidade).

A técnica SES é utilizada para os casos em que a série temporal se mantém constante sob um valor médio. Dessa forma, é possível calcular a previsão de demanda por meio da previsão anterior somada com o próprio erro gerado e corrigido pelo coeficiente alfa (α). Segundo Morettin e Toloi (2004), a SES é considerada uma média ponderada que atribui pesos maiores as observações mais recentes.

Assim, se o valor de α é próximo de zero mais estáveis serão as previsões finais. Por outro lado, quando o valor de α fica próximo de um a técnica enfatiza demandas recentes e é mais sensível a mudanças. Portanto, quanto mais aleatória for a série de dados menores serão os valores de α (MORETTIN; TOLOI, 2004). Já a técnica de SEH é uma expansão da SES, pois além de suavizar o nível também suaviza por meio de uma nova constante a tendência linear (positiva ou negativa) da série.

Com relação a SEHW, que descreve as séries temporais, em que se verifica a ocorrência de tendência linear e um componente de sazonalidade. Dividem-se em aditivo (SEHWa) e multiplicativo (SEHWm), em que no primeiro caso a aplicação está relacionada com a amplitude da variação sazonal ser constante ao longo do tempo, já no segundo caso pode-se aplicar quando a amplitude de variação diminui ou aumenta ao longo do tempo. Conforme destaca Makridakis *et al.* (1998), as únicas diferenças entre a previsão da SEHWm e SEHWa são os índices sazonais que podem ser multiplicados ou divididos e no nível que podem ser somados ou subtraídos. Para mais detalhes sobre os cálculos das técnicas de SE sugere-se consultar Makridakis *et al.* (1998).

2.2 Modelos de Box-Jenkins

Box-Jenkins, nos anos 70, difundiram o modelo ARIMA (*Autoregressive Integrated Moving Average*). Esta metodologia resulta da combinação dos componentes: autorregressivo (AR) que é a parte que modela a relação dos valores atuais com os valores do passado e (p) que é a ordem máxima dos parâmetros de autorregressão; de Integração (I) em que remove a tendência da série temporal e (d) que é o número de diferenciações para tornar a série estacionária; de Médias Móveis (MA) o qual assume que os valores presentes dependem dos

erros de previsão de períodos anteriores e (q) que representa a ordem máxima da MA (BOX *et al.*, 2016).

Além desses possíveis componentes apresentados, outro utilizada é o modelo SARIMA (*Seasonal Autoregressive Integrated Moving Average*) que considera a parte sazonal da série de dados, em que: (P) representa a ordem máxima dos parâmetros autorregressão sazonal; (D) é o número de diferenciações sazonais para tornar a série estacionária; e (Q) é a ordem máxima dos parâmetros de média móvel sazonal. Estes componentes visam captar o comportamento de autocorrelação existente nas séries temporais e a partir destes realizar previsões futuras (BOX *et al.*, 2016).

Para a aplicação dos modelos de Box-Jenkins, deve-se inicialmente dispor de no mínimo 50 observações da série temporal. Além disso, deve-se analisar se a série temporal é estacionária ou não, posteriormente, identificar se o modelo apresenta autocorrelações e autocorrelações parciais, essa etapa é a mais crítica pois é possível encontrar modelos diferentes para a mesma série de dados, na sequência, deve-se estimar os parâmetros do modelo e por fim verificar se o modelo é adequado ou não por meio da análise de resíduos (MONTGOMERY *et al.*, 1990; PELEGRINI; FOGLIATTO, 2001; BOX *et al.*, 2016).

2.3 Combinções de previsões

A previsão de demanda via combinações de técnicas individuais quantitativas teve forte influência dos autores Bates e Granger (1969), pois são considerados pioneiros no assunto (CLEMEN, 1989). Desde então trabalhos científicos mostram que a combinação de técnicas de previsão individuais pode proporcionar aumento na acuracidade das previsões. Isso é possível devido à agregação de informações independentes da série temporal que diminuem os erros de cada previsão individual (CLEMEN, 1989; GOODWING, 2002; WALLIS, 2011; SONG *et al.*, 2013).

Dessa forma, a abordagem quantitativa empregada neste trabalho toma como base o método proposto por Bates e Granger (1969). O método utilizado consiste em combinar duas previsões individuais não viciadas em que o peso maior se dá para a previsão que possui os menores erros, logo tem-se pesos distintos entre a primeira e segunda técnica de previsão. A Equação 1, descreve o método:

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

no qual, F_c é o valor da previsão combinada, w é o peso atribuído da previsão F_1 e $(1 - w)$ é o peso complementar da previsão F_2 . Uma alternativa para encontrar o peso (w), segundo Newbold e Bos (1994), é por meio da utilização do erro quadrático médio (EQM, ou em inglês MSE) conforme destacado na Equação 2.

$$w = \frac{1/MSE_1}{(1/MSE_1 + 1/MSE_2)} \quad (2)$$

em que o MSE_1 se refere a previsão F_1 e o MSE_2 corresponde a previsão F_2 .

Nesse sentido, é possível também atribuir pesos iguais às previsões individuais e assim gerar previsões combinadas via média aritmética. Em razão disso, para $w = 0,5$ é possível rescrever a Equação 3.

$$F_c = 0,5F_1 + 0,5F_2 \quad (3)$$

Essa é a maneira mais simples de combinar previsões e pode apresentar resultados superiores de acuracidade em relação à combinação de modelos complexos (CLEMEN, 1989; ARMSTRONG; COLLOPY, 1998; WERNER, 2004). Também partilham desse entendimento Gooijer e Hyndman (2006) e acrescentam ainda que os métodos de combinações simples são os mais utilizados.

Dentro dessa perspectiva, o trabalho desenvolvido por Lima *et al.* (2016) vai de encontro a esse entendimento, uma vez que na implementação de 14 métodos de combinações, dentre as técnicas de (SE, SARIMA e RNA), para prever o consumo de água em municípios do Sudoeste do Paraná, os autores evidenciaram que os ganhos de acuracidade não apresentaram diferenças significativas entre as combinações simples e complexas, assim sugere-se que o uso de técnicas de combinação simples apresentem resultados satisfatórios em comparação aos métodos de combinação complexos. Diante disso, optou-se por trabalhar com combinações mais simples, são elas: média aritmética, ponderada, geométrica e harmônica.

3.3 Medidas de acurácia

Para efetuar a escolha das melhores técnicas e métodos de combinações de previsão é necessário estabelecer quais medidas de acurácia utilizar, pois essas possuem forte influência na quantificação e qualidade da previsão obtida (MANCUSO, 2013). Como forma de controle da acuracidade das técnicas individuais de previsão das famílias SE e ARIMA, tem-se o Critério de Informação de Akaike (CIA, ou em inglês AIC – *Akaike's Information Criterion*), visto que é amplamente utilizado na literatura para escolha da melhor técnica de previsão (WALTER *et al.*, 2013; BOX *et al.*, 2016; LIMA *et al.*, 2016; MACHADO *et al.*, 2016).

Segundo Bueno (2011), o AIC é útil, pois efetua a comparação de duas ou mais técnicas e a que apresentar menor valor é escolhida. Isto é, os menores valores indicam que as técnicas são parcimoniosas e que os resíduos são os menores possíveis, logo deverá gerar menos imprecisão nas estimativas. De acordo com Gujarati e Potter (2011), a Equação 4 expressa matematicamente o critério AIC:

$$\ln AIC = \left(\frac{2k}{n}\right) + \ln\left(\frac{SQR}{n}\right) \quad (4)$$

no qual: $\ln AIC$ = logaritmo natural de AIC, $\left(\frac{2k}{n}\right)$ = fator de correção, e $\ln\left(\frac{SQR}{n}\right)$ = soma dos quadrados dos resíduos.

Por outro lado, para avaliar a acuracidade das técnicas individuais e dos métodos de combinação (apresentados na Tabela 1), pode-se utilizar como medida de acurácia: MAPE (*Mean Absolute Perceptual Error*), MSE (*Mean Square Error*) e MAE (*Mean Absolute Error*) NEWBOLD; BOS, 1994; WERNER e RIBEIRO, 2006).

Paliwal e Kumar (2009) observaram a utilização das medidas MAPE, MSE e MAE em uma revisão de trabalhos entre técnicas de Redes Neurais Artificiais (RNA) e técnicas estatísticas de predição como principal forma de medir o desempenho das modelagens. Contudo, a medida mais utilizada é o MAPE (KAHN, 1998) representada pela Equação 5:

$$MAPE = \frac{100}{N} \sum_{t=1}^N \frac{|e_t|}{|z_t|} \quad (5)$$

na qual e = erro de previsão; n = número de observações e Z_t = valor observado no tempo t , $t-1$, $t-2$, ..., $t-n$.

Werner e Ribeiro (2006), desenvolveram uma modelagem que contemplou a utilização de duas formas de integração de previsões – combinação de previsões e ajuste baseado na opinião – e teve como base de informação, dados históricos, econômicos e de especialistas em uma empresa de assistência técnica de computadores pessoais. Observou-se que o modelo composto ajustado apresentou os menores erros (ME, MAPE e MSE) conseqüentemente maior acurácia que o modelo combinado ou as previsões individuais (estatística, econométrica e de especialistas).

Outro trabalho relevante é apresentado por Martins e Werner (2014) que verificou a diferença entre a acurácia das previsões de demanda individuais e combinadas, por meio da modelagem das séries industriais do *M3-Competition* que possuíam tendência e sazonalidade. Para as previsões individuais foram utilizadas as técnicas ARIMA e RNA, já para as combinações das previsões individuais foram feitas por meio dos métodos de combinação via média aritmética e variância mínima simplificada. As medidas de acurácia utilizadas foram MAPE, MSE e MAE, sendo que a variância mínima se apresentou como melhor técnica de combinação. Para as técnicas de previsão individual o método de RNA mostrou melhores previsões.

3. PROCEDIMENTOS METODOLÓGICOS

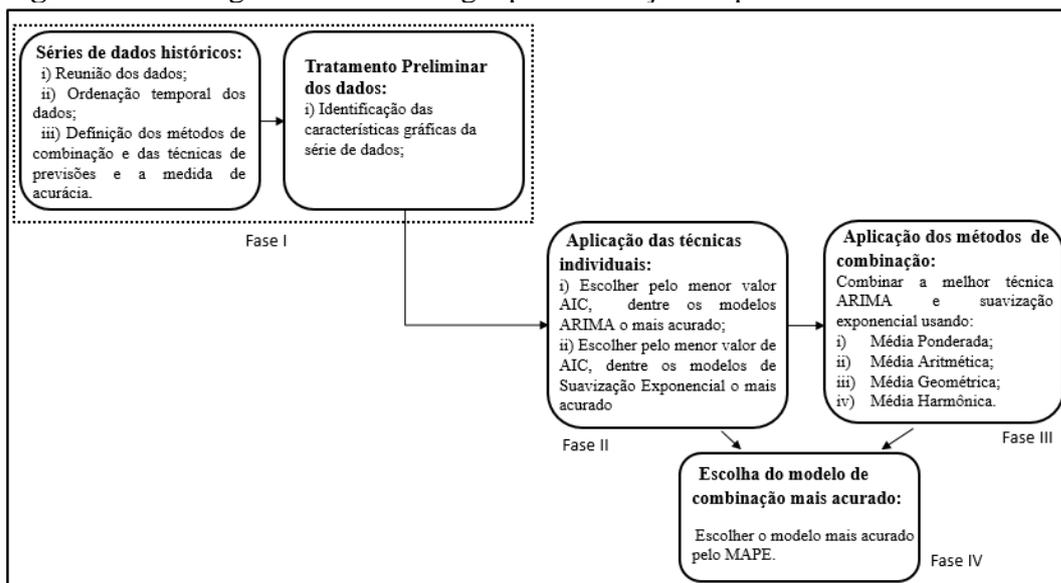
De acordo com Marconi e Lakatos (2003), a pesquisa é “um procedimento formal, que requer um tratamento científico e se constitui no caminho para conhecer a realidade ou para descobrir verdades parciais”. Na classificação adotada por Silva e Menezes (2005), a presente pesquisa é aplicada, pois objetiva gerar conhecimentos para aplicação prática dirigida à solução de problemas específicos. No tocante a forma de abordagem do problema, esta pesquisa é quantitativa e qualitativa, pois utiliza-se de técnicas e recursos padronizados já existentes na literatura. É bibliográfica quanto aos procedimentos técnicos, portanto, elaborada a partir de materiais já publicados em livros e artigos de periódicos, teses, dissertações e congressos científicos.

Neste trabalho faz-se o uso das técnicas de séries temporais (SE e ARIMA) para prever a venda futura de eletrodomésticos. O fundamento destas técnicas baseia-se nos padrões existentes nos dados históricos da própria série de temporal. Conseqüentemente, essas técnicas

não utilizam observações causais para explicar o comportamento passado ou futuro dos dados. Diante disso, na Figura 1, observa-se a proposta metodológica.

Inicialmente na construção do modelo estatístico, foi realizada a análise das séries temporais para identificar o comportamento e selecionar duas técnicas que melhor se ajustam aos dados (uma entre a família ARIMA e outra da família SE). Posteriormente foram obtidas as previsões de demanda por meio destas duas técnicas individuais e realizou-se a combinação destas duas previsões.

Figura 1 - Visão geral da metodologia para obtenção da previsão de demanda combinada



Fonte: Adaptado de Lima *et al.*, (2016).

Para atingir o objetivo proposto, conforme destaca a Figura 1, são executadas quatro fases. Inicialmente, na primeira fase, caracteriza-se pela coleta dos dados que posteriormente são tratados e organizados a fim de possibilitar a obtenção de modelos de previsão. Para o presente estudo foram utilizados dados históricos de venda de uma empresa de eletrodomésticos localizada no Brasil. Do portfólio de produtos que a empresa trabalha, selecionou-se três famílias (alfa, beta e gama) em que cada uma sintetiza respectivamente a soma de três produtos, assim as três famílias em conjunto representam 85,87% das vendas totais da empresa.

A coleta de dados ocorreu na base de dados da referida empresa e abrangeu o período de janeiro de 2010 até dezembro de 2016, totalizando assim um conjunto com três séries temporais em que cada uma possui 84 períodos mensais. Os doze registros do ano de 2016, 12 passos à frente, foram reservados para posterior comparação das previsões das técnicas e métodos ajustados, restando 72 períodos para a fase de ajuste. As análises dos dados foram realizadas no *software Statgraphics*[®] (2016).

Ainda dentro da primeira fase, construiu-se o gráfico temporal das três famílias (alfa, beta e gama), permitindo assim identificar visualmente se há ou não presença de padrões (tendência ou sazonalidade) nas séries. Por fim, utilizou-se o teste estatístico não-paramétricos Cox-Stuart para verificar a existência de tendência, sendo que se o p-valor $> 0,05$ ocorre a presença da tendência. Por outro lado, para verificar a existência da sazonalidade utilizou-se o teste Kruskal-Walis, sendo que se o p-valor $> 0,05$ ocorre a presença de sazonalidade (ARTHUS *et al.*, 2016; MACHADO *et al.*, 2016).

A segunda fase, objetiva determinar qual método de previsão presentes nas famílias ARIMA e SE melhor se ajusta aos dados da série histórica. Para isso utilizou-se o *software Statgraphics*[®] (2016) por meio do qual utilizou-se o modo de seleção automático para determinar os melhores parâmetros dentro de cada família de técnicas (SE e ARIMA). Ademais, adotou-se o critério de informação de Akaike (AIC) em que o menor valor determina a melhor técnica. Após o cálculo das previsões individuais realizou-se a análise de resíduos aleatórios por meio do teste de Box-Pierce. Neste teste, um p-valor $> 0,05$ determina que os métodos individuais conseguiram uma boa adequação às informações da série histórica, ou seja, os resíduos não são correlacionados.

Na terceira fase, após definidos as técnicas de previsão, realizou-se a combinação delas utilizando os métodos: (i) média ponderada; (ii) média aritmética; (iii) média geométrica e (iv) média harmônica, conforme descrito na Tabela 1. Esses métodos foram implementados utilizando o *software MS-Excel*[®].

Tabela 1 - Métodos de combinações de previsões

Média	Aritmética	Ponderada	Geométrica	Harmônica
Equações	$F_c = (0,5 * F_1) + (0,5 * F_2)$	$F_c = w * F_1 + (1 - w) * F_2)$	$F_c = \sqrt{F_1 * F_2}$	$F_c = \frac{2}{(1/F_1 + 1/F_2)}$

Fonte: Elaborado pelos autores.

Na quarta fase, utilizou-se o MAPE como medida de acuraria das previsões combinadas e individuais. Sendo considerada, a mais acurada e recomendada para uso por parte da organização a previsão que apresentar o menor MAPE.

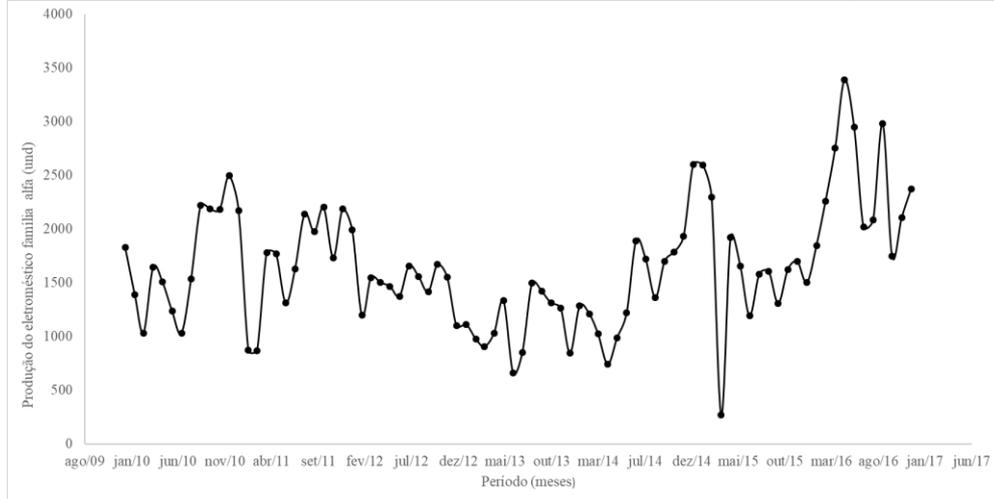
4. RESULTADOS E DISCUSSÕES

Segundo Hyndman e Athanasopoulos (2016), a primeira etapa de uma análise de série temporal consiste na elaboração do gráfico, que por meio de uma análise empírica poderá apresentar propriedades importantes.

4.1 Fase I: Série de dados histórica

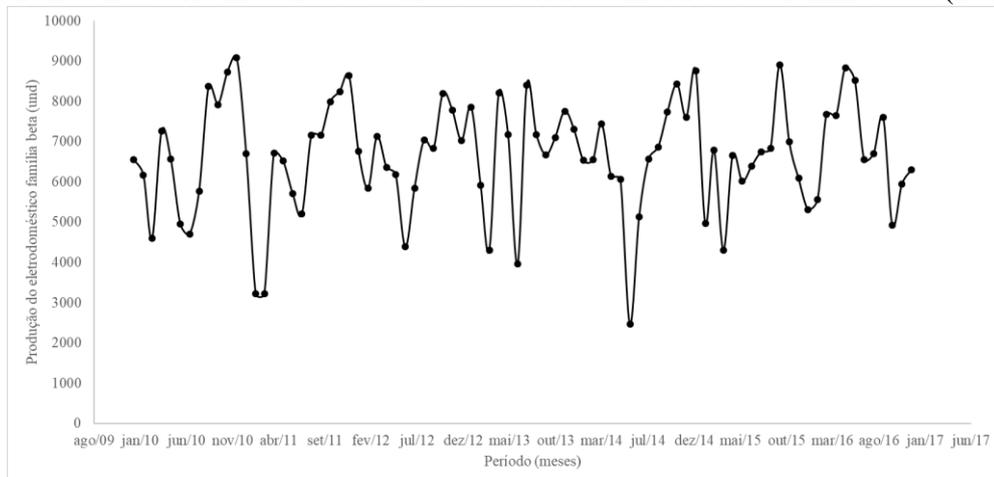
Os gráficos 1, 2 e 3, apresentam as séries históricas de venda de eletrodoméstico (2010-2016), objeto do presente estudo. Por meio delas tem-se um indicativo da presença de sazonalidade para as três famílias. Ademais, as família alfa e gama sugerem uma tendência de crescimento moderado sendo que para a família beta isso não é identificado.

Gráfico 1 - Série histórica de venda dos eletrodomésticos da família alfa (2010-2016).



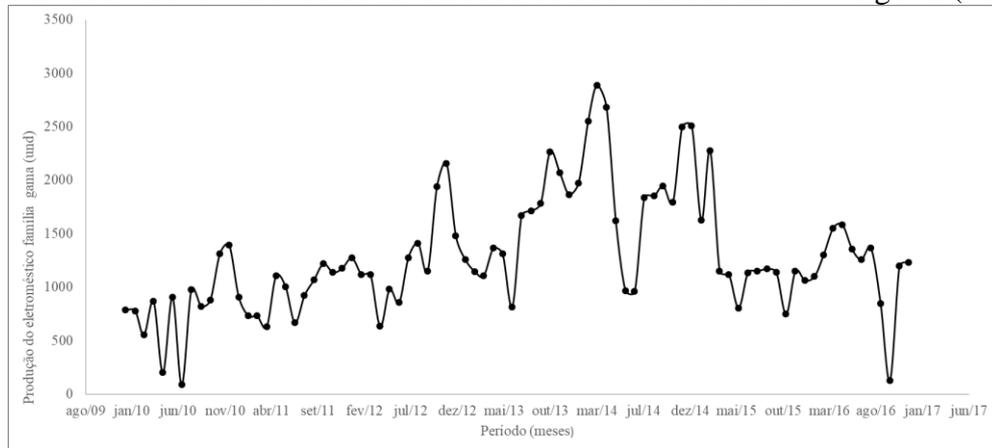
Fonte: Elaborado pelos autores.

Gráfico 2 - Série histórica de venda dos eletrodomésticos da família beta (2010-2016).



Fonte: Elaborado pelos autores.

Gráfico 3 - Série histórica de venda dos eletrodomésticos da família gama (2010-2016)



Fonte: Elaborado pelos autores.

4.2 Fase I: Tratamento preliminar dos dados

Por meio da análise empírica dos gráficos 1, 2 e 3 e de acordo com a direção da empresa: (i) no último quadrimestre de cada ano, entre 2010 a 2015, ocorre um aumento nas vendas de eletrodomésticos causado pelo período de compras do final de ano que sugere a presença de sazonalidade nas três famílias; (ii) na família alfa sugere-se a ocorrência de uma leve tendência de crescimento entre os anos de 2013 a 2014, que é interrompida no ano de 2015, e posteriormente é retomada no ano de 2016, por outro lado a família beta não apresenta indícios de tendência; com relação a família gama sugere-se a ocorrência de uma tendência crescente entre os anos de 2012 a 2014, quando analisa-se os anos de 2015-2016, observa-se que ocorre uma mudança de nível, com queda nas vendas retomando ao mesmo patamar de vendas de 2010-2011, uma possível justificativa é a reconfiguração dos produtos que compõem essa família e (iii) após o último quadrimestre de cada ano observa-se uma diminuição acentuada nas vendas, que provavelmente é causada pela diminuição das vendas no varejo nos primeiros quatro meses de cada ano.

Tabela 2: Testes estatísticos não-paramétricos

Característica	Testes	Hipótese Nula	Hipótese Alternativa ($p < 0,05$)	p-valor (Linhas)		
				Alfa	Beta	Gama
Tendência	Cox-Stuart	Aleatório	Tendência Crescente	0,08207	0,3220	0,0218
		Aleatório	Tendência Decrescente	0,95580	0,7796	0,9902
Sazonalidade	Kruskal-Wallis	Não existe sazonalidade	Existe sazonalidade	$1,712 \times 10^{-5}$	0,9842	$1,357 \times 10^{-5}$

Fonte: Dados da pesquisa.

Diante disso, com o intuito de confirmar ou não a presença de tendência e sazonalidade nos dados, utilizou-se *software* livre R para calcular os testes estatísticos não-paramétricos de Cox-Stuart e Kruskal-Wallis. A Tabela 2 apresenta os resultados obtidos.

De acordo com os resultados apresentados na Tabela 2, observa-se que: (i) na família alfa, o teste de Cox-Stuart não confirmou a presença de tendência, conforme sugere a análise visual, uma vez que a hipótese nula não foi rejeitada tanto para tendência crescente quanto para tendência decrescente. Com relação a sazonalidade, o teste de Kruskal-Wallis rejeitou a hipótese nula, pois o p-valor encontrado é de $1,712 \times 10^{-5}$ logo ocorre a presença de sazonalidade; (ii) na família beta tanto o teste de Cox-Stuart quanto o Kruskal-Wallis não rejeitaram a hipótese nula e assim não ocorre a presença de tendência e sazonalidade, uma possível justificativa pode ser alta variabilidade dos dados; (iii) na família gama o teste de Cox-Stuart não rejeitou a hipótese nula para tendência decrescente (p-valor 0,9902), já para tendência crescente rejeitou a hipótese nula (p-valor 0,0218), portanto confirma a presença de tendência crescente conforme evidenciado na análise visual. No caso da sazonalidade o teste de Kruskal-Wallis rejeitou a hipótese nula (p-valor $1,357 \times 10^{-5}$) portanto ocorre a presença de sazonalidade.

4.3 Fase II: Aplicação das técnicas individuais

O critério de seleção do modelo foi o melhor ajuste aos dados da série histórica, sendo mensurado pelo critério de informação de Akaike (AIC). Dentro da família de métodos de SE e ARIMA, as técnicas que apresentaram o menor AIC podem ser visualizados na Tabela 3.

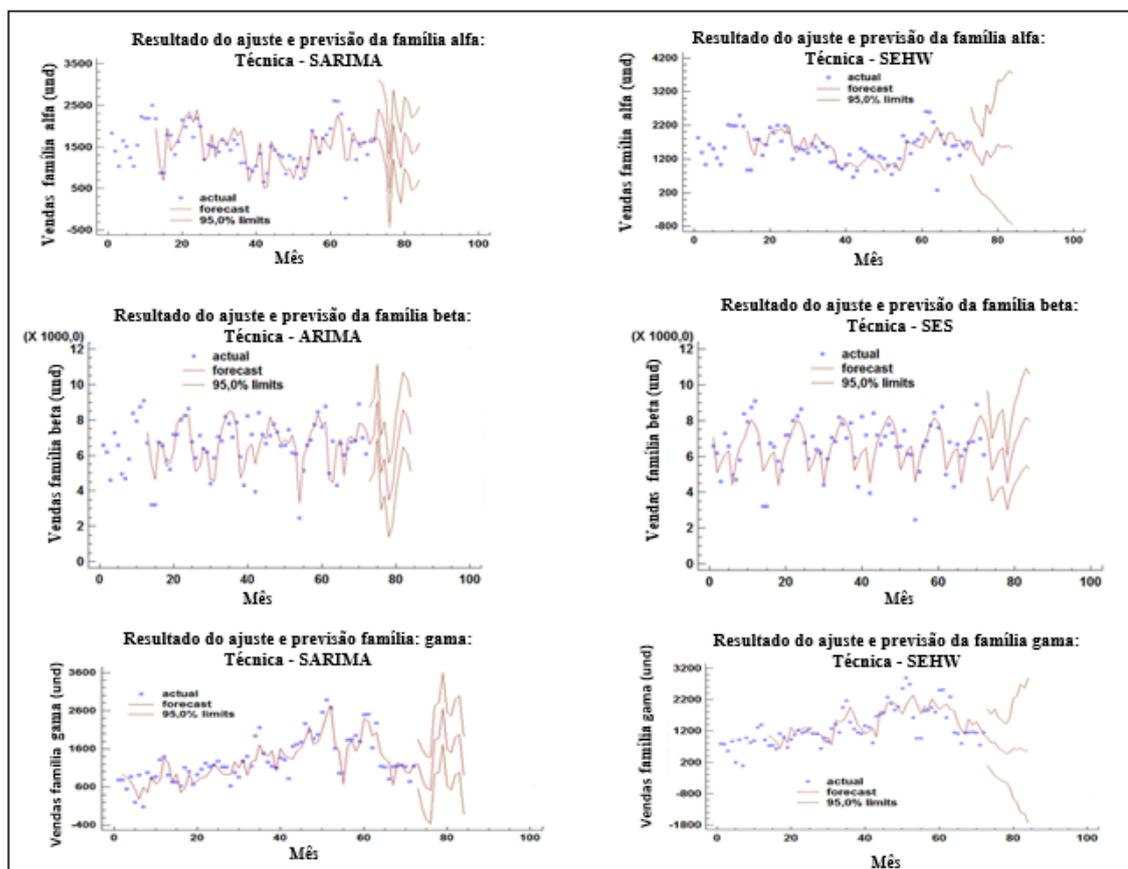
Tabela 3 - Melhores modelos segundo critério AIC

Linha	Método	AIC
Alfa	SARIMA (1,0,2)x(2,1,2) ₁₂	11,7554
	Suavização Exponencial de Holt-Winter com $\alpha = 0,3304$, $\beta = 0,0743$, $\gamma = 0,2164$	12,3191
Beta	ARIMA (2,1,2) ₁₂	13,8504
	Suavização Exponencial Simples com $\alpha = 0,0283$	14,3206
Gama	SARIMA (1,1,1)x(2,0,2) ₁₂	11,6450
	Suavização Exponencial de Holt-Winter com $\alpha = 0,3359$, $\beta = 0,0583$, $\gamma = 0,2299$	12,1417

Fonte: Dados da pesquisa.

Por meio da Tabela 3, é possível evidenciar que os modelos da família ARIMA obtiveram os menores AIC em comparação com os modelos da família SE.

Figura 2 - Resultados das previsões individuais das séries temporais alfa, beta e gama



Fonte: Elaborado pelos autores.

A partir do modo automático do *software Statgraphics*[®] foi plotado o gráfico com intervalo de confiança de 95%, considerando as técnicas apresentadas da Tabela 3, da previsão de demanda das três famílias alfa, beta e gama, conforme exposto na Figura 2.

De acordo com a Figura 2, as técnicas ARIMA, apresentaram-se mais adequadas para as séries históricas estudadas quando comparados com as técnicas de SE, pois AIC obtidos foram, respectivamente: 11,7554 para a técnica SARIMA (1,0,2)x(2,1,2)₁₂; 13,8504 para a técnica ARIMA (2,1,2)₁₂; e 11,6450 para a técnica SARIMA (1,1,1)x(2,0,2)₁₂.

Para corroborar a adequação dos métodos tanto da família ARIMA quanto da SE, efetuou-se a análise dos resíduos aleatórios por meio do teste estatístico de Box-Pierce. A Tabela 4, sintetiza os valores obtidos para cada técnica utilizada nas previsões individuais.

Tabela 4 - Análise dos resíduos pelo teste de Box-Pierce

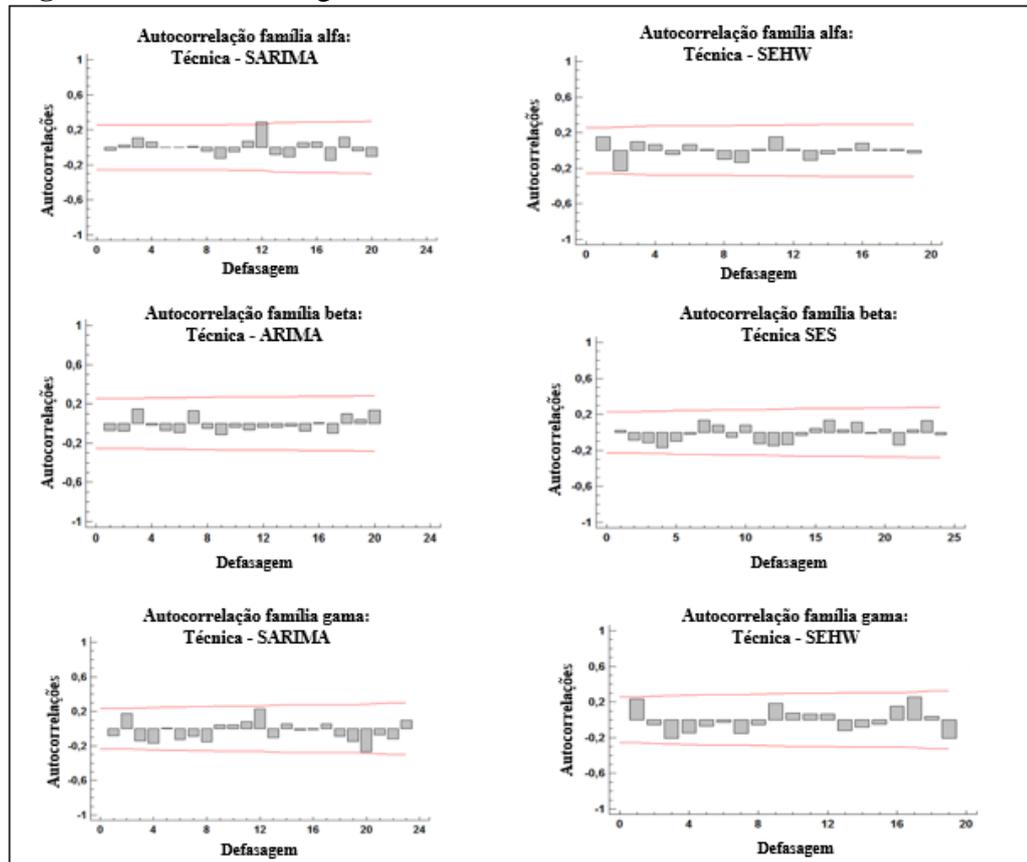
Linha	Método	Box-Pierce (p)
Alfa	SARIMA(1,0,2)x(2,1,2) ₁₂	0,544718
	Suavização Exponencial de Holt-Winter com alfa = 0,3304, beta = 0,0743, gama = 0,2164	0,871869
Beta	ARIMA (2,1,2) ₁₂	0,948104
	Suavização Exponencial Simples com alfa = 0,0283	0,834992
Gama	SARIMA(1,1,1)x(2,0,2) ₁₂	0,117784
	Suavização Exponencial de Holt-Winter com alfa = 0,3359, beta = 0,0583, gama = 0,2299	0,174456

Fonte: Dados da pesquisa.

Para confirmar, se as técnicas de previsão individuais utilizadas conseguiram extrair o máximo de informação das séries históricas de dados é necessário a satisfação da hipótese nula, caso contrário a técnica exibe falta de ajuste. Hipótese nula: o modelo não exibe falta de ajuste; Hipótese alternativa (p-valor < 5%): o modelo exibe falta de ajuste. Assim, de acordo com a Tabela 4, é possível evidenciar que a hipótese nula não foi rejeitada, pois todos os valores do teste de Box-Pierce estão acima de p-valor > 0,05.

Além disso, a fim de confirmar a adequação dos métodos ARIMA e SE escolhidos, plotou-se conforme Figura 3, os autocorrelograma dos resíduos das famílias alfa, beta e gama com as respectivas técnicas de previsão individual. Assim, por meio da Figura 3, verifica-se que as técnicas individuais não apresentam falta de ajuste confirmando os resultados do teste de Box-Pierce.

Figura 3 - Autocorrelograma dos resíduos



Fonte: Elaborado pelos autores.

Dessa forma, de acordo com a Tabela 5, efetuou-se os cálculos das previsões de demanda para cada série temporal tendo como base as melhores técnicas individuais das famílias ARIMA e SE e considerando também os respectivos MAPE.

Tabela 5 - MAPE das técnicas individuais de previsão

Família	Alfa		Beta		Gama	
Medida de Acurácia	SARIMA (1,0,2)x(2,1,2) ₁₂	Suavização Exponencial de Holt-Winter com alfa = 0,3304, beta = 0,0743, gama = 0,2164	ARIMA (2,1,2) ₁₂	Suavização Exponencial Simples com alfa = 0,0283	SARIMA (1,1,1)x(2,0,2) ₁₂	Suavização Exponencial de Holt-Winter com alfa = 0,3359, beta = 0,0583, gama = 0,2299
MAPE (%)	39,64	36,67	31,08	24,83	159,89	76,01

Fonte: Dados da pesquisa.

Observa-se por meio da Tabela 5, que ao contrário do esperado, as técnicas de SE apresentaram melhores resultados nas previsões que as técnicas ARIMA. Assim, deu-se início as combinações das previsões com base nas técnicas da Tabela 5.

4.4 Fase III e IV: Aplicação dos métodos de combinação e escolha do melhor

Inicialmente, com auxílio do software Microsoft Excel[®], realizou-se as combinações propostas, conforme descritas na Tabela 1 (média ponderada, aritmética, harmônica e geométrica). Por meio da Tabela 6, é possível visualizar o MAPE das respectivas combinações.

Ao comparar o MAPE dos métodos de previsão combinada, verifica-se que para família alfa tanto a média aritmética quanto à média ponderada apresentaram o menor MAPE de 36,53%, isto se deve ao fato de pesos via média ponderada ficarem próximos ao peso fixo de 0,5 da média aritmética. Com relação a família beta o menor MAPE foi obtido pela combinação da média ponderada. Por fim, para a família gama a média harmônica obteve melhor acurácia.

Tabela 6 - MAPE das previsões combinadas

Método de Combinações	MAPE			
	Família Alfa	Família Beta	Família Gama	
Média	Ponderada	36,53%	25,55%	89,48%
	Aritmética	36,53%	26,22%	99,60%
	Harmônica	37,66%	26,45%	85,52%
	Geométrica	37,11%	26,22%	89,95%

Fonte: Dados da pesquisa.

Quando se compara os MAPE obtidos via métodos de combinação, Tabela 6, com as previsões via técnicas individuais, Tabela 5, constata-se: (i) na família alfa que as combinações (média ponderada e aritmética) apresentaram um MAPE de 36,53% contra um MAPE de 36,67 % da melhor previsão individual SEHW; (ii) que na família beta ocorreu o mesmo efeito da família gama, em que a previsão individual, SES apresentou melhor MAPE que as previsões combinadas; (iii) que na família gama a SEHW obteve MAPE de 76,01% menor que os MAPE obtidos com as combinações;

Apesar da literatura indicar que os métodos de combinações de previsões melhoram a

acurácia, só foi possível identificar essa melhoria, menor MAPE, para a família alfa. Já, para as famílias beta e gama, não foi evidenciado tal ganho, uma vez que as técnicas individuais SES e SEHW, respectivamente, tiveram melhor desempenho que as combinações. Uma possível justificativa pode ser encontrada na existência de uma moderada correlação entre as melhores previsões individuais das técnicas SE e ARIMA tanto para a família beta quanto para gama.

Por fim, com o intuito de visualizar de forma mais ampla o comportamento conjunto das famílias alfa, beta e gama, realizou-se a soma das melhores previsões de cada família gerando a previsão global. Assim, observa-se que o MAPE obtido é de 24,96%, ou seja, valor muito próximo do MAPE obtido pela família beta que é de 24,83%.

5. CONCLUSÃO

A adoção de boas práticas no planejamento e controle da produção de uma empresa, passa primeiramente em prever a demanda de mercado. Nesse sentido, realizou-se uma previsão de demanda em uma indústria do ramo de eletrodomésticos por meio da combinação de métodos quantitativos de previsão de demanda.

Para atingir esse objetivo, utilizou-se dados reais históricos de três famílias de produtos de uma indústria de eletrodomésticos localizada no Brasil. Os modelos de SE, ARIMA e quatro tipos de combinações das previsões individuais foram utilizados de forma comparativa, por meio da medida de acurácia MAPE.

No tocante as técnicas individuais, a SE apresentou medidas de acurácia superiores a família ARIMA. A técnica de SEHW apresentou um MAPE menor para as famílias gama (76,01%) e alfa (36,37%). Por outro lado, a SES foi a mais adequada para a família beta, apresentando um MAPE de 24,83%. Em relação as combinações entre as técnicas das famílias SE e ARIMA, somente para a família alfa as combinações apresentaram ligeira vantagem. Por outro lado, nas famílias beta e gama, não houve diferença relevante, isto é, as combinações para essas famílias não melhoraram a qualidade das previsões.

Os MAPEs foram elevados para as três famílias avaliadas. Nesse contexto, uma alternativa de estudo, é a aplicação da integração de métodos de combinação quantitativa com o ajuste de especialistas buscando minimizar os erros de previsão (WEBBY E O' CONNOR,

1996; GOODWIN, 2002; WERNER; RIBEIRO, 2006; SONG *et al.*, 2013; SILVA; WERNER, 2015; STAUDT *et al.*, 2016).

Referências

ARMSTRONG, J. S.; COLLOPY, F. **Integration of statistical methods and judgment for time series forecasting**: principles from empirical research. In G. Wright & P. Goodwin (Eds.), *Forecasting with judgment*. New York: John Wiley & Sons, 1998.

ARTHUS, M. G.; CAMATTI, J. A.; BORTOLETTO, W.; ARRUDA, P. S.; JUNIOR, I. O. F. Planejamento da safra de soja no Oeste do Paraná. **Produto & Produção**, v.17, n.4, p.80-93, 2016.

BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C.; LJUNG, G. M. **Times Series Analysis – Forecasting and Control**. 5 ed. New Jersey: Wiley, 2016.

BUENO, R. L. S. **Econometria de séries temporais**. 2 ed. São Paulo: Cengage Learning, 2011.

CLEMEN, R.T. Combining forecasts: A review and annotated Bibliography. **International Journal of Forecasting**, v.5, p.559-583, 1989.

GOODWIN, P. Integrating management judgment and statistical methods to improve short-term forecast. **Omega**, v.30, n.2, p.127-135, 2002.

GOOIJER, J. G.; HYNDMAN, R. J. 25 years of time series forecasting. **International Journal of Forecasting**, v.22, p.443-473, 2006.

GUJARATI, D. N.; PORTER, D. C. **Econometria básica**. 5 ed. Porto Alegre: Mc Graw Hill, p. 923, 2011.

HYNDMAN, R. J.; ATHANASOPOULOS, G. **Forecasting: principles and practice**. 2016. Disponível em: <http://otexts.org/fpp/>. Acesso em: 20 mai. 2018.

LIMA, J. D.; BATISTUS, D. R.; ADAMCZUK, G. O.; TRENTIN, M. G.; POZZA, C. B. A study of the performance of individual techniques and their combinations to forecast urban water demand. **Espacios**, v.37, n.22, p.5, 2016.

KOTLER, P.; ARMSTRONG, G. **Princípios de Marketing**. Editora Prentice-Hall do Brasil, 7ª ed., Rio de Janeiro, 1998.

MACHADO, R. H. S.; LIMA, J. D.; BATISTUS, D. R.; ADAMCZUK, G. O.; TRENTIN, M. G. Estudo comparativo de modelos clássicos e técnicas de Combinação para a previsão do

volume de captação de água para uso urbano – um estudo de caso. **Enciclopédia Biosfera, Centro Científico Conhecer - Goiânia**, v.13 n.23, p.1778, 2016.

MANCUSO, A. C. B.; WERNER, L. Review of combining forecasts approaches. **Independent Journal of Management & Production (IJM&P)**, v.4, n.1, 2013.

MAKRIDAKIS, S.; WHEELWRIGHT, S.; HYNDMAN, R. J. **Forecasting methods and applications**. 3. ed. New York: John Wiley & Sons, 1998.

MARCONI, M. A.; LAKATOS, E. M. **Fundamentos de metodologia científica**. 5. ed. São Paulo: Atlas, 2003.

MARTINS, V. L. M.; WERNER, L. Forecast combination in industrial series: A comparison between individual forecasts and its combinations with and without correlated errors. **Expert Systems with Applications**, n.39, 2012.

MARTINS, V. L. M.; WERNER, L. Comparação de previsões individuais e suas combinações: um estudo com séries industriais. **Production**, v.24, n.3, p.618-627, 2014.

MONTGOMERY, D.; JOHNSON, L.; GARDINER, J. **Forecasting and time series analysis**. New York: McGraw-Hill, 1990.

MOON, M.; MENTZER, J.; SMITH, C.; GARVER, M. Seven keys to better forecasting. **Business horizons**, v.41, n.5, p.44-52, 1998.

MORETTIN, P. A.; TOLOI, C. M. DE C. **Análise de séries temporais**. Edgard Blucher, 2004.

NEWBOLD, P.; BOS, T. **Introductory Business & Economic Forecasting**. 2 ed., South-Western Publishing, Cincinnati. Ohio. 1994.

PALIWAL, M.; KUMAR, U. A. Neural networks and statistical techniques: A review of applications. **Expert Systems with Applications**, v.36, p.2-17, 2009.

PELLEGRINI, F. R.; FOGLIATTO, F. S. Passos para implantação de sistemas de previsão de demanda – Técnicas e estudo de caso. **Revista Produção**, v.11, n.1, p.43-64, 2001.

SILVA, E. L.; MENEZES, E. M. **Metodologia da Pesquisa e Elaboração de Dissertação**. 4 ed, Universidade Federal de Santa Catarina. Florianópolis, 2005.

SILVA, R. B; WERNER, L. Previsão de demanda no setor de suplementação animal usando combinação e ajuste de previsões. **Espacios**, v.36, n.9, p.13, 2015.

STAUDT, F. H.; GONÇALVES, M. B.; RODRIGUEZ, C. M. T. Procedimento para implantar um modelo de previsão de demanda com incorporação de julgamento de especialistas. **Production**, v.26, n.2, p.459-475, 2016.

SONG, H.; GAO, B. Z.; LIN, V. S. Combining statistical and judgmental forecasts via a web-based tourism demand forecasting system. **International Journal of Forecasting**, v.29, p. 295-310, 2013.

WALLIS, K. F. Combining forecasts – forty years later. **Applied Financial Economics**, v.21, p.33-41, 2011.

WALTER, O. M. F. C; HENNING, E.; MORO, G.; SAMOHY, R. W. Aplicação de um modelo SARIMA na previsão de vendas de motocicletas. **Exacta – EP**, v.11, n.1, p.77-88, 2013.

WERNER, L. **Um modelo composto para realizar previsão de demanda através da integração da combinação e de previsões e ajustes baseados na opinião**. Tese. 166f. 2004. (Doutorado em Engenharia de Produção) - Universidade Federal do Rio Grande do Sul. Porto Alegre, 2004.

WERNER, L.; RIBEIRO, J. L. D. Modelo composto para prever demanda através da integração de previsões. **Prod. [online]**, v.16, n.3, p.493-509, 2006.

WEBBY, R.; O’CONNOR, M. Judgmental and Statistical Time Series Forecasting: A review of the Literature. **International Journal of Forecasting**, v.2, n.1, p.91-118, 1996.