



Aplicação do Modelo SARIMA na Previsão de Demanda no Setor Calçadista

José Eduardo de Carvalho Lima¹; Lucas Ferreira de Castro²; Glauber Araujo Alencar Cartaxo³

Resumo: A indústria brasileira de calçados sofreu forte queda nos últimos anos. Porém, devido a variação da demanda a que esse setor está exposto, a crise econômica vivenciada, a preferência dos consumidores, e a concorrência, intensificou-se a necessidade de realizar previsões de demandas mais efetivas e acuradas que garantam tomadas de decisões estratégicas e uma nova dinâmica de alocação de recursos no setor calçadista. (ABICALÇADOS, 2018). Neste estudo, tem-se como objetivo analisar um modelo de previsão de demanda de séries temporais por meio da metodologia Box-Jenkins que se adequa as necessidades da empresa. Sendo utilizada a série de demanda mensal de calçados de uma família do portfólio de produtos de uma empresa, classificado como salto PVC. O modelo de previsão escolhido foi um Autorregressivo Integrado de Média Móvel (SARIMA) $(0,0,0)(1,0,0)_{12}$, tendo como critério de validação os valores do erro MAD, MAPE, TS e o BIC.

Palavras-chave: Previsão de demanda. Box-Jenkins. Construção de modelos ARIMA. Setor de calçados.

Application of the SARIMA Model in the Forecast for Demand in the Footwear Sector

Abstract: The Brazilian footwear industry has suffered a sharp fall in recent years. However, due to the variation in the demand to which this sector is exposed, the economic crisis experienced, consumer preference, and competition, the need to forecast more effective and accurate demands has been intensified to ensure strategic decision-making and a new dynamics of resource allocation in the footwear sector. (ABICALÇADOS, 2018). In this study, the objective is to analyze a model of demand forecast of time series using the Box-Jenkins methodology that adjusts the needs of the company. Being used the series of monthly demand of footwear of a family of the product portfolio of a company, classified as PVC jump. The predicted model was an Integrated Autoregressive Average of Mobile (SARIMA) $(0,0,0)(1,0,0)_{12}$, with MAD, MAPE, TS and BIC as validity criteria.

Keywords: Forecast of demand. Box-Jenkins. Construction of ARIMA models. Footwear industry

Introdução

Atualmente a indústria calçadista brasileira passa por um processo de reestruturação na produção, depois de um longo período de queda desde o ano de 2014, passando em 2013 de

¹ Professor da Faculdade Paraíso - FAP e Doutorando em Engenharia de Produção e Sistemas pela Universidade do Vale do Rio dos Sinos - UNISINOS, Rio Grande do Sul. eduardo.doutoradounisinos@gmail.com;

² Graduação em Licenciatura em Ciências (Licenciatura Curta em Matemática) pela Universidade Regional do Cariri, Ciências Contábeis pela Faculdade Leão Sampaio e Mestre em Economia com concentração em Finanças pelo CAEN UFC. Professor titular da Faculdade Paraíso do Ceará - FAPCE

³ Possui graduação em Engenharia de Produção Mecânica pela Universidade Regional do Cariri, mestrado em Engenharia Ambiental Urbana (Construção Civil) pela Universidade Federal da Bahia. Professor titular da Faculdade Paraíso do Ceará - FAPCE.

uma produção de 1.036 milhões de pares para 908,9 milhões de pares em 2017, com uma estimativa que gira em torno de 0,4% (pessimista) a 3,5% (otimista) de aumento para o ano de 2018, próximo do ocorrido para a indústria de transformação brasileira. No entanto, esse resultado da produção de calçados passa pelas dificuldades intrínsecas da crise econômica encarada pelo país, e pela fragilidade da competitividade da economia nacional no mercado externo (ABICALÇADOS, 2018).

Com o dinamismo e a complexidade dos mercados, tomar decisões tornou-se uma tarefa ainda mais difícil para os gestores. A busca por mecanismos capazes de responder rapidamente as necessidades e preferências dos consumidores, a concorrência, as características de mercado e a capacidade interna da organização, tornou-se extremamente indispensável na definição de uma estratégia eficiente para a empresa. O conhecimento sobre essas características pode fornecer subsídios para prever a demanda, uma importante informação estratégica. (ABICALÇADOS, 2017).

Com isso, a previsão de demanda e os modelos formais de previsão ajudam as organizações empresariais a avaliarem a quantidade de produtos que irão produzir, de modo que possam atender o mercado a contento. Sendo parte integrante do processo decisório, a previsão de demanda tem sua importância na determinação dos recursos necessários que são bases para o planejamento estratégico da produção, das vendas e das finanças empresariais. E quanto mais acurada for a previsão, melhor para todos os setores da cadeia de suprimentos. (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998; CHOPRA; MEINDL, 2016).

Os modelos de previsão de séries temporais por diversas vezes exibem fortes tendências e variações sazonais que apresentam desafios no desenvolvimento de modelos de previsão efetivos. Como efetivamente modelar séries temporais para melhorar a qualidade das previsões ainda é um desafio. (SHUMWAY; STOFFER, 2011).

Diante desse contexto de um ambiente de incertezas e considerando a importância dos modelos de previsão de demanda aplicados a séries temporais, o artigo tem como objetivo analisar um modelo de previsão de demanda de séries temporais por meio da metodologia Box-Jenkins, que se adequa às características da empresa do setor calçadista, verificando estatisticamente se o modelo é apropriado para se realizar a previsão. Os objetivos específicos foram: (i) escolher uma família de produtos do portfólio da empresa; (ii) verificar os erros e a acurácia do modelo; e (iii) definir o melhor modelo de previsão a ser aplicado.

Inicialmente se estabelece uma breve descrição abordando os temas previsão de demanda, séries temporais, avaliação dos modelos de previsão e a descrição da metodologia Box-Jenkins, em seguida apresenta-se os procedimentos metodológicos para previsão de demanda e, por fim, a análise dos resultados e considerações finais.

Previsão de Demanda

A previsão de demanda exerce um papel fundamental nas organizações empresariais, em geral, permite aos gestores tomarem decisões estratégicas e de planejamento em uma cadeia de suprimento, sendo um dos elementos mais importantes na determinação de um sistema de produção, permitindo estimar adequadamente os recursos da empresa. As previsões têm um papel fundamental na produção, distribuição, marketing, vendas, finanças e pessoal - o uso adequado das máquinas, a reposição de materiais, o tempo e a quantidade, a programação certa de outras atividades essenciais ao processo industrial, fluxo de caixa, vendas, estoques, mão de obra e compras (CHOPRA; MEIDNL, 2016; TUBINO, 2017).

Com o poder da matemática, o avanço da tecnologia e dos pacotes computacionais disponíveis, prever com exatidão as demandas é quase impossível. Entretanto, a simples utilização dos métodos e pacotes computacionais não são suficientes para assegurar uma previsão com bons resultados. A compreensão clara dos processos e um bom nível de experiência profissional do planejador sobre o mercado são fundamentais para que as previsões sejam mais assertivas. (FERNANDES; GODINHO, 2010).

Conforme Chase, Jacobs e Aquilano (2005), a abordagem dos métodos de previsão pode ser classificada como qualitativo, causal, séries temporais e simulação. Apresentando diferenças na precisão e acurácia conforme o horizonte de previsão, nível de sofisticação do modelo e base de dados necessária.

Os modelos de séries temporais usam uma abordagem estatística, em que o histórico dos dados é utilizado para prever os valores futuros da demanda. Baseado na ideia de que observações passadas possuem informações sobre padrões de comportamento da série. Adequado quando a demanda não sofre variações expressivas de um ano para outro. Devido à natureza quantitativa elas exigem um grande número de dados. (LUTKEPOHL; KRATZIG, 2004).

As etapas de implementação de um modelo de previsão seguidas por autores como: Stevenson (2002); Fernandes e Goldinho (2016); Tubino (2017), são apresentadas a seguir: Primeiramente, define-se e identifica o objetivo da previsão, que servirá de base para a segunda etapa, a coleta e análise dos dados, na sequência seleciona-se uma abordagem de previsão e dentro o método mais apropriado, em seguida elabora-se e calcula-se a previsão de demanda, e, por fim, como forma de feedback, a previsão é monitorada, interpretada e atualizada em seus parâmetros baseada na análise dos erros de previsão.

O modelo de previsão adotado nesse artigo é o modelo autorregressivo integrado de médias móveis – ARIMA, baseado em séries temporais que será mais detalhado a seguir.

Séries Temporais

Entende-se por séries temporais, ou histórica, um conjunto sequenciado de observações no tempo, fundamentadas na concepção de que os acontecimentos passados podem ser usados para prever o futuro. A principal característica inerente aos métodos de séries temporais é que usam o comportamento passado da variável de um único fenômeno ao longo do tempo e, baseada nele fazem previsões. (SLACK; JONES; JOHNSTON, 2013).

As séries temporais são decompostas em componentes como: tendência (analisa o deslocamento da série ao longo dos anos), ciclo (verifica o movimento ondulatório que tende a ser periódico ao longo do tempo), sazonalidade (é a análise do movimento ondulatório no curto prazo, geralmente inferior a 12 meses) e aleatoriedade (fatos ocorridos aleatoriamente durante a série, picos e vales fora da média). (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

Conforme Tubino (2017), as previsões de demandas baseadas em séries temporais partem do princípio de que a demanda atual projetará a demanda futura, sem a influência de outras variáveis. E que os métodos estatísticos de previsão de séries temporais buscam caracterizar padrões de comportamento e usá-los na previsão dos valores futuros.

Em estudos comparativos realizados por Slack, Johnston, Jones (2015) e Martins, Laugeni (2015) sobre previsões realizadas por métodos econométricos, mostram-se mais utilizados e possuem uma maior acurácia no longo prazo relacionado a outros métodos de séries temporais.

Destaca-se que dentre os diversos métodos de previsão nenhum prevê o futuro com exatidão, sempre haverá erros envolvidos nos processos, e que existem outros fatores internos e externos que influenciam a previsão. Nesse contexto, é de fundamental importância testar o comportamento dos dados da série antes de seguir com a previsão. Neste caso, utilizando testes estatísticos para avaliar o comportamento e as características da série. Os testes mais utilizados com o objetivo de avaliar as características são: Normalidade (teste de Kolmogorov-Smirnov; Anderson-Darling e Shapiro-Wilk), Sazonalidade (Kruskal-Wallis e Friedman), Tendência (Wald-Wolfowitz; Cox-Stuart; Mann-Kendall e Cuzik), Correlação (Pearson; Spearman e Durbin-Watson) e Estacionariedade (Dickey-Fuller Aumentado; Phillips-Perron e KPSS). (FARREL; STEWART, 2006; SOUZA; SAMOHYL; MIRANDA, 2008).

De acordo com Morettin, Tolo (2006), a previsão não constitui um fim em si, mas apenas uma forma de viabilizar informações para uma tomada de decisões futura mais assertiva, visando a objetivos específicos.

Modelos ARIMA

O modelo Autorregressivo Integrado de Média Móvel - *Autoregressive Integrated Moving Average* (ARIMA) é um dos métodos estatísticos de análise de séries temporais mais robusto e difundido. Publicado por George Box e Gwilyn Jenkins, o *Box - Jenkins de Time series analysis: forecasting and control*, na década de 70, deram um novo alento a pesquisa e conduziram a uma nova geração de ferramentas de previsão. Estes autores mostraram que o domínio do tempo permitia que as análises e modelagens tivessem um poder preditivo maior. Com origem na combinação de termos autorregressivos (AR), termos de médias móveis (MA) e integrando as diferenciações da série caso seja essencial (LEE; KO, 2011; ROSSI; NEVES, 2014).

O método ARIMA é apropriado para séries com dados menos perturbados, ou seja, estacionários que se desenvolve no tempo ao redor de uma média constante. Explora a correlação temporal entre os dados e são tidos como modelos univariados por incluírem apenas uma série temporal. (LUTKEPOHL; KRÄTZIG, 2004; CRYER; CHAN, 2008).

Gujarati e Porter (2011), ressaltam que estes métodos podem modelar séries isoladamente ou conjuntamente. O destaque está na forma de análise probabilística ou estocástica, das propriedades características da própria série, sob o conceito de que os dados falam por si, não havendo outros regressores.

Modelos autorregressivos (AR)

É comum, dados de uma série temporal em alguns pontos no tempo estarem fortemente correlacionados com os valores que os antecedem. O modelo AR(ρ) modela uma autorregressão da variável usando o seu próprio valor do período anterior, defasada para “ ρ ” períodos em que a autocorrelação das variáveis é significativa. O valor atual da série depende muito do que ocorreu em t-1, ou, alternativamente, o que ocorrerá em t+1 será estabelecido pelo comportamento da série no tempo atual t. (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998; SHUMWAY, R.H.; STOFFER, 2011). O modelo autorregressivo de ordem ρ é expresso matematicamente:

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_\rho Z_{t-\rho} + \mu_t \quad (1)$$

onde,

ρ - é a ordem de AR;

Z_t - é série temporal observada em t;

μ_t - é o termo de erro aleatório não correlacionado com média zero e variância constante (*ruído branco*);

ϕ_ρ - são os parâmetros a serem estimados em AR(ρ).

Ao incluir o operador de defasagem (*lag*) B, definindo $Z_{t-1} = BZ_t$, portanto, $Z_{t-\rho} = B^\rho Z_t$, a equação (1) pode ser reescrita por

$$\phi_\rho(B)Z_t = a_t \quad (2)$$

onde, $\phi_\rho(B)$ é o operador de AR(p), definido por

$$\phi_\rho(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_\rho B^\rho \quad (3)$$

Os coeficientes autorregressivos (ϕ_ρ) são parâmetros que caracterizam como um valor atual relaciona-se com seus valores passados, sendo estimados pelo método dos mínimos quadrados ordinários.

Para determinar a quantidade ideal do número de defasagens pode-se usar os critérios de informação de Akaike e de Schwarz ou analisar o exame dos valores da função de autocorrelação parcial. (BOX; JENKINS, 1976; EHLERS, 2007; ROSSI; NEVES, 2014).

Modelos de Médias Móveis (MA)

Os modelos de médias móveis $MA(q)$ apresentam os valores de cada observação de determinada série como combinação linear do valor corrente e valores passados dos resíduos aleatórios de previsão. São gerados por intermédio de uma média ponderada das perturbações aleatórias ou erros aleatórios de defasagem q . (ASTERIOU; HALL, 2007; KIRCHGÄSSNER; WOLTER, 2007). Este método é descrito algebricamente pela equação:

$$Z_t = \mu_t - \theta_1\mu_{t-1} - \theta_2\mu_{t-2} - \dots - \theta_q\mu_{t-q} \quad (4)$$

A série também é escrita utilizando o operador de defasagem B , logo, o modelo descrito acima pode ser reescrito

$$Z_t = \theta_q(B)\mu_t \quad (5)$$

$$\theta_q(B) = 1 - \theta_1B - \theta_2B^2 - \dots - \theta_qB^q \quad (6)$$

onde,

q – é a ordem de $MA(q)$;

θ_q – são os parâmetros do modelo $MA(q)$.

Os modelos MA são similares aos modelos AR , onde, diferentemente dos valores passados da série, neste método, as informações consideradas são os valores correntes dos erros aleatórios e seus q valores passados. O termo ideal de defasagens é determinado com base nos valores da autocorrelação (FAC), ou da pelos critérios de seleção de Akaike ou Schartz. (BOX-JENKINS, 1976; MATOS, 2000; EHLERS, 2007).

Modelos Autorregressivos de Médias Móveis (ARMA)

Devido à complexidade de modelar séries temporais, construir modelos mistos que utilizem a combinação de dois ou mais métodos com o intuito de aumentar a flexibilidade na adaptação de séries temporais e melhorar os resultados da previsão, são extremamente usados nos dias de hoje. Os modelos ARMA (p,q) são resultados da combinação dos modelos autorregressivos – AR(p) e os modelos de médias móveis – MA(q). (KITAGAWA, 2010; MONTGOMERY; JENNINGS; KULAHCI, 2015). A especificação mais simples de um modelo ARMA(p,q) é dada pela adaptação de séries temporais às equações (2) e (5) são combinadas por um processo misto para obtenção do modelo dado por

$$\phi_p(B)Z_t = \theta_q(B)\mu_t \quad (7)$$

Segundo Gujarati e Porter (2011), os modelos AR, MA e ARMA são usados quando suas propriedades estatísticas, como média, variância permanecem constantes e sua covariância é invariante no tempo, em outras, quando a série é estacionária.

Modelos Autorregressivos Integrados de Médias Móveis (ARIMA)

Inicialmente, diversas séries temporais não são estacionárias, isto é, são integradas. Entretanto, quando a série não é estacionária, a mesma é transformada em estacionária mediante o processo de diferenciação de dados. Desse modo, além das componentes descritas nos modelos AR e MA, é usada a componente de integração I(d), resultando no modelo Autorregressivo Integrado de Médias Móveis – ARIMA(p, d, q), em que p denota os números dos termos autorregressivos, d o número de vezes que a série deve ser diferenciada para se tornar estacionária e q o número de termos de média móvel, sendo que, se d = 0, a série é estacionária para ARMA(p,q). (ASTERIOU; HALL, 2007; CRYER; CHAN, 2008; MONTGOMERY; JENNINGS; KULAHCI, 2015).

O modelo ARIMA possui um conjunto de equações características para previsão de demanda:

$$AR = c + \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} \quad (8)$$

$$MA = c + \theta_1 \varepsilon_{t-1} - \dots - \theta_p \varepsilon_{t-p} \quad (9)$$

$$I_1 = Y'_t = Y_t - Y_{t-1} \quad (10)$$

$$I_2 = Y''_t = Y'_t - Y'_{t-1} = (Y_t - Y_{t-1}) - (Y_{t-1} - Y_{t-2}) \quad (11)$$

$$\text{ARIMA} = F_t = \text{AR} + \text{I} + \text{MA} \quad (12)$$

onde:

Y_t = valor observado no período t ;

F_t = os valores previstos para o período t ;

c = constante ou intercepto;

ϕ_p = coeficiente do fator regressivo;

θ_p = coeficiente do fator de média móvel;

Y'_t = componentes das diferenças tomadas da série;

ε_t = erros da série;

a = valor do intercepto do eixo Y ;

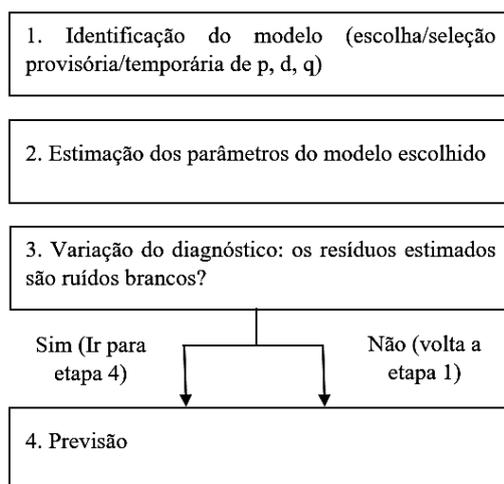
b = coeficiente angular que minimiza os quadrados dos erros.

O método ARIMA também conhecido como Box-Jenkins é utilizado tanto em uma série temporal estacionária quanto em uma série que passa a ser estacionária após o processo de diferenciação. (MORETTIN; TOLOI, 2006; GUJARATI; PORTER, 2011).

Etapas do Método ARIMA

O método Box-Jenkins é útil para responder como verificar se a série segue um processo AR, MA, ARMA, puro, e caso isso ocorra, qual o valor de p , q ou p e q , ou, se usamos um processo ARIMA. O método consiste de três etapas: identificação do modelo, estimação dos parâmetros, verificação do diagnóstico e previsão, representados na Figura 1.

Figura 1 – O método Box-Jenkins



Fonte: Gujarati, Potter (2011), p. 772

Inicialmente, na fase de identificação, busca-se encontrar os valores apropriados de p, d e q. Ou seja, identificar se esta série foi desenvolvida por um processo AR, MA, ARMA ou ARIMA. A identificação do modelo que melhor descreva a série temporal ocorre por intermédio da observação das funções de autocorrelação (FAC) e autocorrelação parcial (FAPC).

Uma vez identificado o modelo e seus valores de p, d e q, o passo seguinte é estimar os parâmetros dos termos autorregressivos e dos termos de média móvel incluídos no modelo. Os parâmetros do processo AR as vezes podem ser estimados pelo método dos mínimos quadrados, quando o filtro MA não estiver presente. Caso o MA esteja envolvido, a estimação dos parâmetros para este modelo é quantificada pelo uso de métodos de estimação não linear. (ASTERIOU; HALL, 2007; CRYER; CHAN, 2008).

O próximo passo na construção do modelo é a verificação de sua adequação através do diagnóstico. Esta fase divide-se em duas etapas: a de análise dos resíduos e a de avaliação do modelo. Escolhido o modelo ARIMA específico, e seus parâmetros estimados, verifica-se se o modelo se ajusta aos dados.

Na sequência aplica-se um teste ao modelo e verifica se os resíduos estimados baseados no modelo são do tipo ruídos brancos, se sim, aceita-se o ajuste específico, caso contrário, o processo deve ser iniciado novamente com a identificação de um novo modelo, seguido das mesmas etapas, até que seja encontrado um modelo apropriado. Dessa forma, com a seleção e validação do modelo, a previsão dos valores futuros da série temporal modelada pode ser encontrada. (GUJARATI; PORTER, 2011; MONTGOMERY; JENNINGS; KULAHCI, 2015).

Avaliação do Modelo de Previsão

Os modelos de previsão possuem incertezas associados aos mesmos, sendo de extrema relevância a quantificação destes. Existem diversos indicadores de desempenho que são utilizados na avaliação da validade do modelo de previsão e que são úteis também na comparação entre modelos. Toda demanda observada pode ser desmembrada entre um componente sistemático que mede o valor esperado da demanda, e um aleatório que é a parte da previsão desviada da sistemática. Sendo que o componente aleatório se manifesta na forma de um erro de previsão. (RITZMAN; MALHORTA; KAJEWSKI, 2008).

O ponto de partida para gerar diversas medidas de erros de previsão é o indicador básico de erro de previsão para o período t (E_t) que é a diferença ou desvio entre o valor real (D_t) e o valor previsto da demanda (F_t , forecast) para o período (LUSTOSA, L. et al., 2008).

$$E_t = D_t - F_t \quad (13)$$

Desse modo, são estabelecidos alguns indicadores para se avaliar a precisão de um modelo, por exemplo, o desvio absoluto médio (MAD) e o erro absoluto médio percentual (MAPE). Sendo que apenas o indicador erro percentual médio é um indicador de viés, todos os outros medem de alguma forma a amplitude do erro. Para todas essas medidas quanto menor for o indicador, melhor é a previsão (SOUZA; SAMOBYL; MIRANDA, 2008).

Desvio Absoluto Médio – MAD

O MAD (*Mean Absolute Deviation*) mede a dispersão dos erros de previsão do componente aleatório e apresenta a acurácia na mesma unidade da informação, o que facilita o entendimento gerencial do impacto do erro de previsão. Se o MAD é pequeno, a previsão está próxima do valor real da demanda.

$$MAD = \frac{\sum_{t=1}^n |E_t|}{n} \quad (14)$$

onde n é o número de valores coletados.

Erro Absoluto Médio Percentual – MAPE

O MAPE (*Mean Absolute Percent Error*) revela a acurácia da previsão como uma porcentagem. Relaciona o erro da previsão ao nível de demanda. É útil, pois permite a comparação entre previsões independente dos dados.

$$\text{MAPE} = \frac{\sum_{t=1}^n \left| \frac{E_t}{D_t} \right| 100}{n} \quad (15)$$

onde D_t é o valor da demanda real no período t .

Critério de informação bayesiano - BIC

O critério de informação bayesiano (*Bayesian information criterion - BIC*), também conhecido como critério de informação de Schwarz (CIS, do inglês SIC – *Schwarz's information criterion*), desenvolvido por Gideon E. Schwarz, é um critério utilizado na seleção de modelos. Baseia-se, em parte, na função de probabilidade e está intimamente relacionado ao Critério de Informação Akaike (AIC).

O valor do critério para um determinado modelo é definido matematicamente por

$$\text{BIC} = -2\log f(x_n|\theta) + p \log n \quad (16)$$

onde, $f(x_n|\theta)$ é o modelo escolhido, p é o número de parâmetros a serem estimados e n é o número de observações da amostra.

O BIC parte do pressuposto que existe um “modelo verdadeiro” que descreve a relação entre a variável dependente e as diversas variáveis explanatórias entre os diversos modelos sob seleção. Desse modo, o critério procura maximizar a probabilidade de se identificar o verdadeiro modelo dentre os avaliados. O modelo com menor valor para o BIC é considerado o de melhor ajuste. (BOX; TIAO, 1992; KONISHI; KITAGAWA, 2008).

Razão de viés (TS)

Também conhecido como sinal de rastreamento, é uma métrica que determina se um método de previsão está predizendo com precisão alterações reais da demanda. É dada pela razão do viés e o MAD.

$$TS_t = \frac{viés_t}{MAD} \quad (17)$$

Se a razão do viés em qualquer período oscilar fora da faixa ± 6 , sinaliza que a previsão está enviesada. Pode estar sub (razão do viés menor que -6) ou superestimada (razão do viés maior que +6). Com essa situação a empresa deve priorizar pela seleção de um novo modelo de previsão (CHOPRA; MEIDNL, 2016; RITZMAN; MALHORTA; KAJEWSKI, 2008).

Metodologia

A série temporal estudada é apresentada no Quadro 1 com um registro mensal de 56 observações da demanda de um produto pertencente à família do portfólio de produtos da empresa classificado como salto PVC. Sendo selecionados para estudo os produtos que apresentaram maior rotatividade nas vendas no período de janeiro de 2013 a agosto de 2017. As informações referentes à demanda para o período estudado, foram colhidas *in loco*, a partir de registros organizados em planilhas eletrônicas e sistemas de controle de informações da empresa.

A pesquisa caracteriza-se como um estudo de caso, definido por Gil (2017) como a pesquisa que se concentra no estudo profundo e exaustivo permitindo seu amplo e detalhado conhecimento. Buscando a aplicação prática de conhecimentos para a solução de problemas. Tendo como cenário uma indústria do setor calçadista da cidade de Juazeiro do Norte, município brasileiro do estado do Ceará, localizado na região metropolitana do Cariri.

A empresa objeto deste trabalho produz uma variedade de modelos de calçados feminino. O estudo da previsão da demanda dedica-se a uma família do portfólio de produtos classificado como salto PVC. O quadro 1 mostra os valores da demanda da família de produtos analisados.

Quadro 1 – Demanda da família de produtos

Período	Produção (unid.)						
1	9236	15	13180	29	18723	43	11771
2	12630	16	11487	30	10886	44	11319
3	15946	17	11687	31	12231	45	14574
4	13032	18	12108	32	15590	46	25497
5	13274	19	14931	33	19756	47	28431
6	14936	20	15990	34	28551	48	18381
7	14241	21	16562	35	27389	49	4251
8	13642	22	18818	36	9570	50	11461
9	16934	23	17700	37	9337	51	11381
10	18132	24	14533	38	10764	52	8440
11	16223	25	9131	39	9209	53	6438
12	13601	26	15674	40	8046	54	9744
13	8112	27	11338	41	10200	55	12960
14	15717	28	13025	42	10210	56	13907

Fonte: Elaborado pelos autores (2019)

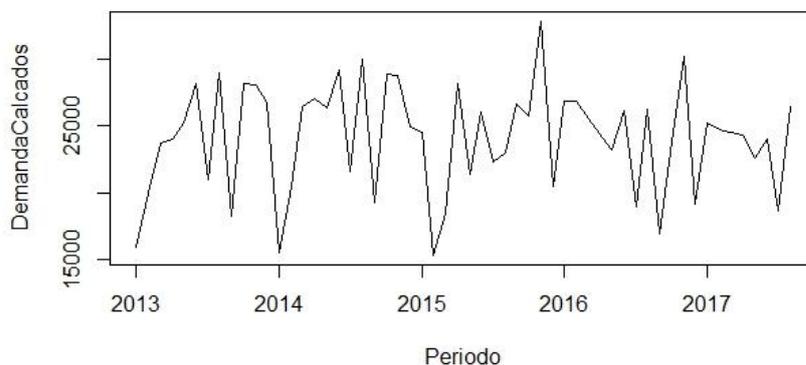
A análise dos dados foi realizada por meio da aplicação do Modelo autorregressivo integrado de média móvel (ARIMA) aos dados da série histórica em estudo. O cálculo de previsões foi realizado com o uso do *software* estatístico R (R DEVELOPMENT CORE TEAM), com o auxílio do pacote *forecast*. (HYNDMAN; KHANDAKAR, 2008).

Por fim, com o intuito de validar o modelo, foi determinado a acurácia. E como medidas de erro de previsão, foram considerados o Desvio Absoluto Médio - MAD (*Mean Absolute Deviation*) e o Erro Absoluto Médio Percentual – MAPE (*Mean Absolute Percent Error*), Razão de viés (TS) e o (*Bayesian information criterion*) BIC.

Análise e discussão dos resultados

Para identificação do modelo, inicialmente foi gerado o gráfico da série temporal original estudada e calculada as medidas da estatística descritiva da série. O Gráfico 1 mostra os dados da demanda de calçados entre o período de janeiro/2013 a agosto/2017.

Gráfico 1 – Série temporal em estudo



Fonte: Elaborado pelos autores (2019)

A série temporal usada para estimar o modelo possui 56 observações, sendo que 75% da série será usada para treinamento e 25% para teste, com uma média estimada em $\bar{Z} = 24.097$.

Tabela 1 - Análise descritiva da série

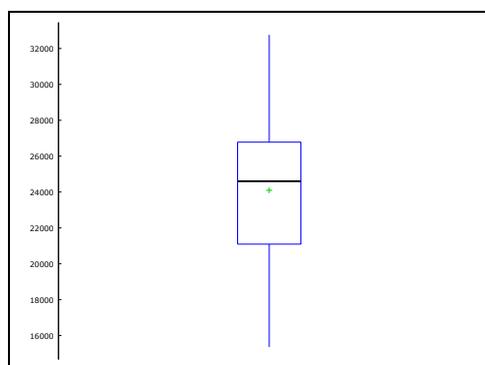
N	56
Média	24097
Desvio padrão	4022.1
Mínimo	15362
Máximo	32761
Amplitude	17399
Curtose	-0.46147
Coefficiente de variação	0,16691

Fonte: Elaborado pelos autores (2019)

Na sequência, foram analisadas as configurações dos dados da série, verificado a possibilidade de existência de tendência, sazonalidade, *outliers* ou estacionariedade relevantes.

Os *outliers* foram verificados por meio da análise gráfica Box-Plot conforme gráfico 2.

Gráfico 2 – Box-Plot da série temporal



Fonte: Elaborado pelos autores (2019)

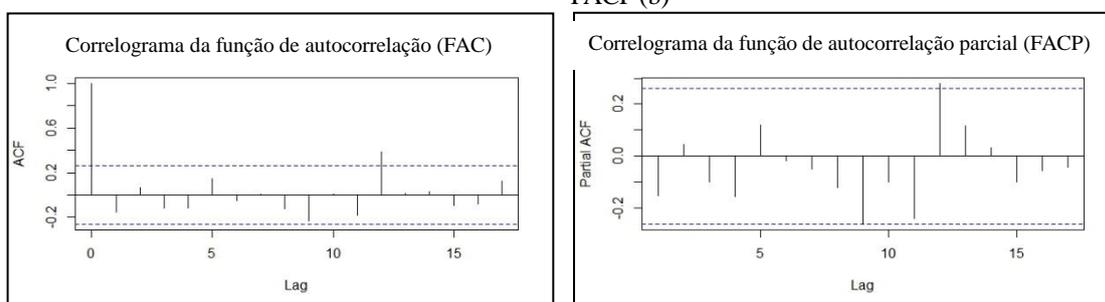
Observa-se que nenhum dos dados da série ultrapassou os limites *outliers* determinados, portanto, recusa-se qualquer tratamento aos valores da série histórica.

Realizou-se o teste de Shapiro-Wilk, para verificar se a série é oriunda de uma distribuição normal, com estatística de teste $W = 0,969267$ e p-valor igual a $0,162694$. Sendo assim, aceita-se a hipótese de que os dados são distribuídos normalmente com um nível de confiança de 95%.

Quanto à sazonalidade, o gráfico 1 não é muito claro, porém sugere um comportamento sazonal, com picos e vales em períodos específicos. Na sequência analisa-se a série é sazonal. Aplicando-se o teste de Kruskal-Wallis, a estatística aponta que a série de dados possui sazonalidade determinística. A estatística gerou um valor de teste de $31,3130$ com p-valor de $0,001765$. Em consequência, rejeita-se a hipótese da não existência de sazonalidade.

Com o intuito de averiguar a tendência executou-se o teste de Cox-Stuart. Aplicando este teste obtém-se uma estatística $T = 11$ e um p-valor = $0,3449$ indicando a aceitação da hipótese nula “da não existência de tendência” com nível de significância de 5%.

Figura 2 – Correlograma da função de autocorrelação – FAC (a) e Correlograma da função de autocorrelação parcial – FACP (b)



Fonte: Elaborado pelos autores (2019)

Observa-se no gráfico 1 que não é possível identificar se a série de dados é estacionária ou não. Desse modo, segue-se para observação dos correlogramas (Figura 2(a) e 2(b)). Analisando a figura 2(a) da função de autocorrelação amostral (FAC), nota-se que a série pode não ser estacionária, priorizando a realização de um teste estatístico específico, o teste KPSS para analisar a possibilidade da série ser estacionaria. O valor de teste encontrado foi de $Z = 0,067369$ com p-valor = $0,1$. Logo, rejeita-se a hipótese nula e evidencia-se que a série é estacionária com 5% de nível de significância. Já a Figura 2(b) da função de autocorrelação parcial (FACP), indica um comportamento aproximadamente senoidal, e a FAC não mostra defasagem significativa.

Neste caso, percebe-se, que a série não tem *outliers*, possui distribuição normal, há vestígios de sazonalidade determinística, não há sinais de tendência e é estacionária.

A partir da estimação dos valores de p , d , q , P , D e Q , para a série analisada, o modelo identificado foi escolhido mediante uso da função automática *auto.arima* do pacote *forecast*, disponível no *software* estatístico R. O pacote retornou um modelo SARIMA (0,0,0)(1,0,0)₁₂ apresentando a melhor performance (BIC = 803,51). O parâmetro P indica autoregressividade sazonal de ordem 1, assim, infere-se que o modelo é capaz de descrever o comportamento sazonal da série, já demonstrado pelo teste de Sazonalidade de Kruskal-Wallis.

Observa-se na tabela 2 que o modelo apresentou razão de viés (TS) oscilando entre -4,562296 e 2,206514, demonstrando a estabilidade do modelo, que conforme Chopra e Meindl, 2016, se a razão do viés em qualquer período oscilar fora da faixa ± 6 , sinaliza que a previsão está enviesada.

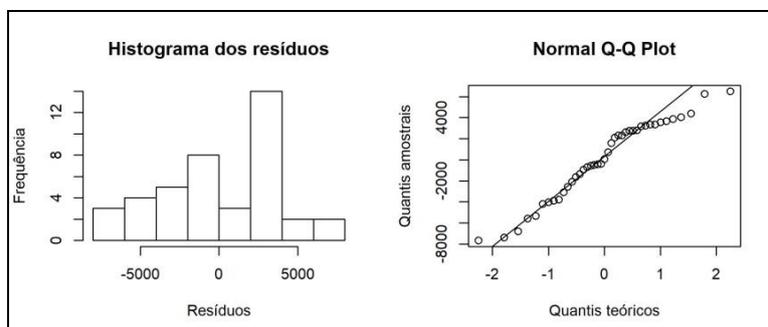
Tabela 2 – Medidas dos erros de previsão do modelo SARIMA(0,0,0)(1,0,0)₁₂

MAPE	14.0235
MAD	3134.94
BIC	803.51
Intervalo da Razão do viés	-4.562296~2.206514
Razão do viés	0.8499373

Fonte: Elaborado pelos autores (2019)

Na sequência, efetuou-se a análise dos resíduos para a adequação do modelo. Para averiguação da normalidade foi elaborado um histograma dos resíduos (Figura 3), indicando que os resíduos seguem uma distribuição normal, corroborado pelo teste de Normalidade de Shapiro-Wilk (Tabela 3).

Figura 3 – Histograma e gráfico de probabilidade normal dos resíduos do modelo SARIMA(0,0,0)(1,0,0)₁₂



Fonte: Elaborado pelos autores (2019)

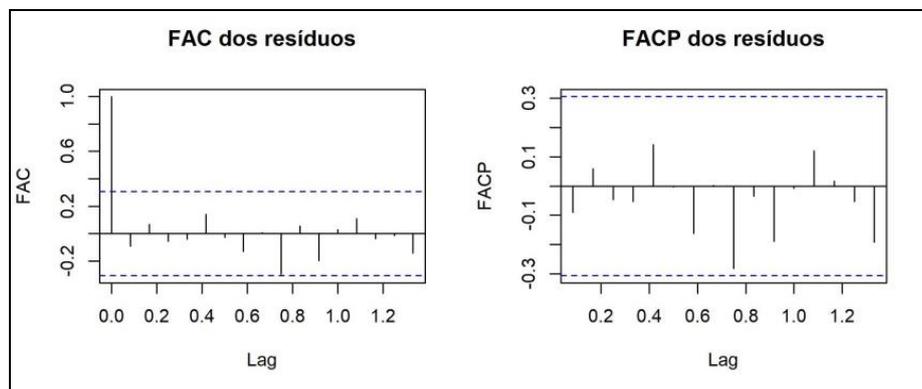
Tabela 3 - Análise residual do modelo SARIMA(0,0,0)(1,0,0)₁₂

Teste	Estatística	Valor <i>p</i>
Shapiro-Wilk	0.9519	0.0814
Ljung-Box	0.36474	0.5459

Fonte: Elaborado pelos autores (2019)

Os resíduos do modelo não apresentam autocorrelações conforme Figuras 4(a) e (b), reforçado pelo teste estatístico de Ljung-Box. Conclui-se que os resíduos são não autocorrelacionados, confirmando a boa adequação do modelo à série em questão.

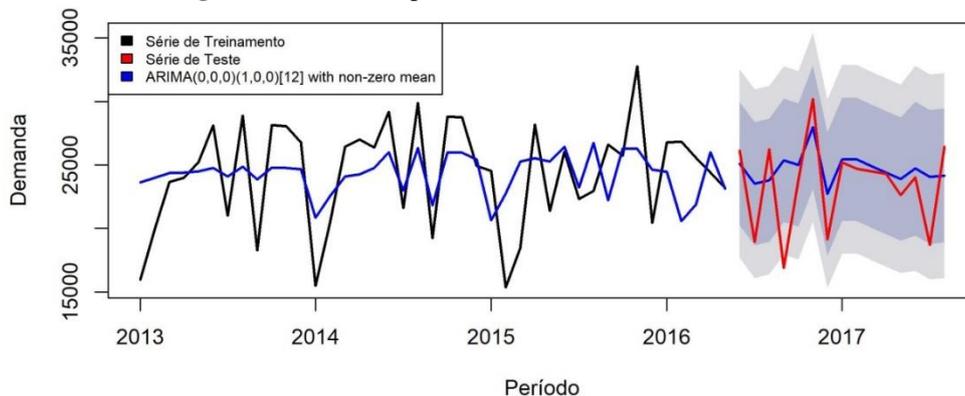
Figura 4 – Gráfico da FAC (a) e da FACP (b) dos resíduos do modelo SARIMA(0,0,0)(1,0,0)₁₂



Fonte: Elaborado pelos autores (2019)

A Figura 5 apresenta um gráfico com os valores de demanda, em conjunto com os valores ajustados pelo modelo. Verifica-se que as previsões geradas pelo modelo fornecem estimativas razoáveis.

Figura 5 - Previsão a partir do modelo SARIMA(0,0,0)(1,0,0)₁₂



Fonte: Elaborado pelos autores (2019)

Tabela 4 – Previsão para os próximos 6 meses

Período	Previsão de vendas	Limite inferior 80%	Limite superior 80%	Limite inferior 95%	Limite superior 95%
Set/2017	16.898	11.684	22.112	8.924	24.872
Out/2017	23.797	18.583	29.011	15.823	31.771
Nov/2017	30.187	24.973	35.401	22.213	38.161
Dez/2017	19.124	13.910	24.338	11.150	27.098
Jan/2018	25.210	19.996	30.424	17.236	33.184
Fev/2018	24.685	19.471	29.899	16.711	32.658

Fonte: Elaborado pelos autores (2019)

Conclusão e Considerações Finais

A previsão de demanda tem se apresentado como uma ferramenta indispensável para tomada de decisão estratégica, de planejamento e controle de produção das organizações empresariais. Nesta pesquisa, teve-se como objetivo analisar um modelo de previsão de demanda de séries temporais por meio da metodologia Box-Jenkins, que se adequa às características da empresa do setor calçadista. O uso de métodos adequados para prever as oscilações desse produto é fundamental, visto que esse mercado apresenta um dinamismo ocasionado por diversos fatores. Desse modo, com as previsões realizadas, entende-se que será possível mensurar de forma mais adequada a disponibilidade de recursos para a produção.

Dentre os modelos de séries temporais, a metodologia Box-Jenkins pode ser uma alternativa viável na previsão de demanda na indústria calçadista. O modelo estimado com sazonalidade, SARIMA(0,0,0)(1,0,0)₁₂, mostrou-se apropriado para a série estudada. No entanto, reitera-se que outros métodos mais avançados e robustos sejam aplicados, a fim de obter previsões mais assertivas e que fatores internos e externos que envolve a demanda possam ser considerados.

É importante salientar que, devido ao dinamismo dos dados, é necessário implementar o monitoramento do modelo obtido, e, caso não seja mais adequado à realidade da empresa, deve ser determinado um novo modelo.

Referências

ABICALÇADOS. Associação Brasileira das Indústrias de Calçados. **Relatório Setorial Indústria de Calçados do Brasil 2018**. Disponível em: <<https://drive.google.com/file/d/18atEww9qvlQeMu3EutWURtHdTcXFNCnQ/view>>. Acesso em 16 jul. 2018.

ABICALÇADOS. Associação Brasileira das Indústrias de Calçados. **Relatório Setorial Indústria de Calçados do Brasil 2017**. Disponível em: <<http://www.abicalcados.com.br/>>. Acesso em 08 jan. 2018.
<https://drive.google.com/file/edit?id=0B0WGSAb1N6BiV0FzZEVsS2FacVE>

ASTERIOU, D. and HALL, S.: **A Modern Approach**. Palgrave Macmillan, New York, 2007.

BOX, G. E. P.; JENKINS, G. M. **Time series analysis forecasting and control**. San Francisco: H. Day, 1976.

BOX, G. E. P.; TIAO, G. C. **Bayesian Inference in statistical analysis**. S.I.: Wiley Classics Library, 1992. 588p.

CHASE R. B.; JACOBS, F. R.; AQUILANO, N. J. **Administração da Produção para Vantagem Competitiva**. 10 ed. Porto alegre: Bookman, 2005.

CHOPRA, S.; MEINDL, P. **Gestão da Cadeia de Suprimentos**. 6 ed. São Paulo: Pearson. 2016.

CRYER, J. D.; CHAN, K. **Time Series Analysis: With Applications in R**. 2 ed. New York: Springer, 2008.

EHLERS, R. S. **Análise de séries temporais**. Laboratório de Estatística e Geoinformação. Universidade Federal do Paraná, 2007.

FARREL, P. J. STEWART, K. R. **Comprehensive Study Of Tests For Normality And Symmetry: Extending The Spiegelhalter Test**. Journal of Statistical Computation and Simulation. v. 76, n. 9, pp. 803–816, 2006.

FERNANDES, F. C. F. & GODINHO, F. M. **Planejamento e controle da produção: dos fundamentos ao essencial**, Editora Atlas. 2010

GIL, A. C. **Como elaborar projetos de pesquisa**. 6ª ed. São Paulo: Atlas, 2016.

GUJARATI, D. A.; PORTER, D. C. **Econometria Básica**. 5ª ed. São Paulo: Mc Graw Hill/Bookman, 2011.

HYNDMAN, R. J.; KHANDAKAR, Y. **Automatic time series forecasting**: the forecast package for R. *Journal of Statistical Software*, v. 27, n. 3, p.1-22, 2008.

KITAGAWA, G. **Introduction to Time Series Modeling**. Tokyo. Chapman & Hall/CRC, 2010.

KIRCHGÄSSNER, G.; WOLTER, J. **Introduction to Modern Time Series Analysis**, Springer-Verlag, Berlin Heidelberg, 2007.

KONISHI, S.; KITAGAWA, G. **Information criteria and statistical modeling**. New York: Springer, 2008.

LEE, Cheng-Min; KO, Chia-Nan. **Short-term load forecasting using lifting scheme and ARIMA models**. *Expert Systems with Applications* , v. 38, p. 5902-5911, 2011.

LUSTOSA, L. et al. **Planejamento e Controle da Produção**. 1 ed. Elsevier, 2008.

LUTKEPOHL, H.; KRATZIG A. **Applied time series Econometrics**. Cambridge, New York, Melbourne, Madrid, Cape Town, Singapore, São Paulo: Cambridge University Press, 2004

MAKRIDAKIS, S.; WHEELWRIGHT, S.; HYNDMAN, R. **Forecasting: Methods and Applications**, 3rd ed.; JohnWiley & Sons: New York, NY, USA, 1998.

MARTINS, P. G.; LAUGENI F. P. **Administração da produção**. 3 ed. São Paulo: Saraiva, 2015.

MONTGOMERY, D. C.; JENNINGS, C. L.; KULAHCI, M. **Introduction to Time Series Analysis and Forecasting**. 2 ed. New Jersey e Canadá: Wiley, 2015.

MORETTIN, P. A.; TOLOI, C. M. **Análise de Séries Temporais**. 2 ed. São Paulo: Blucher, 2006.

R DEVELOPMENT CORE TEAM. **R: a language and environment for statistical computing. R Foundation for Statistical Computing**, Vienna, Austria, 2017. Disponível em: <<http://www.R-project.org>>. Acesso em: 18 set. 2017.

RITZMAN, L. P.; MALHORTA, M.; KAJEWSKI, L. **Administração de Produção e Operações**. 8 ed. São Paulo: Prentice Hall, 2008.

ROSSI, J. W; NEVES, C. **Econometria e Séries Temporais** com Aplicações a Dados da Economia Brasileira. 1 ed. Rio de Janeiro: LTC, 2014.

SHUMWAY, R. H.; STOFFER, D. S. **Time Series Analysis and Its Applications: With R Examples**, 3rd ed; Springer: New York, NY, USA, 2011.

SLACK, N.; JONES, A. B.; JOHNSTON; R. **Administração da produção**. 4 ed. São Paulo: Atlas, 2015.

SOUZA, G. P.; SAMOBYL, R. W.; MIRANDA, R. G. **Métodos simplificados de previsão empresarial**. Rio de Janeiro: Ciência Moderna, 2008. 181 p.

SLACK, N.; JONES, B. A.; JOHNSTON, R. **Operations Management**. 7 ed. London: Pearson, 2013.

STEVENSON, W. J. **Administração das operações de produção**. São Paulo: LTC, 2002.

TUBINO, D. F. **Planejamento e Controle da Produção teoria e prática**. 3 ed. São Paulo: Atlas, 2017.



Como citar este artigo (Formato ABNT):

LIMA, José Eduardo de Carvalho; CASTRO, Lucas Ferreira de; CARTAXO, Glauber Araújo Alencar. Aplicação do Modelo SARIMA na Previsão de Demanda no Setor Calçadista. **Id on Line Rev.Mult. Psic.**, 2019, vol.13, n.46, p. 892-913. ISSN: 1981-1179.

Recebido: 07/06/2019;

Aceito: 25/07/2019.