

## **Método SARIMA Aplicado Para Previsão De Demanda Em Uma Loja Varejista De Alimentos Naturais**

Álvaro de Aquino Santos  
Daiane Ferreira Arantes Beraldo  
Henrique Dhoni de Oliveira  
Marcos Antônio Alves  
Sara Emília da Silva

### **Resumo**

A procura por produtos visando uma alimentação saudável vem crescendo ano após ano. Todavia, em virtude da variação da demanda a que seu mercado está exposto, intensificou-se a necessidade de previsões de vendas que possam garantir as tomadas de decisões estratégicas e alocação de recursos das empresas do ramo. Esta pesquisa visa criar um modelo de previsão mensal de demanda baseado no método Box-Jenkins (SARIMA), levando em consideração a série temporal, tratada e analisada com auxílio dos softwares Gretl e Excel, dos produtos classe A de uma empresa que trabalha com a venda de produtos saudáveis, situado na região centro oeste de Minas Gerais. Os produtos foram escolhidos por meio de classificação ABC. A metodologia utilizada no presente trabalho iniciou-se com a coleta de dados, que foi realizada com base em informações acerca de preços, custos e demandas cedidas por um representante da empresa. Para a classificação ABC do mix de produtos da empresa baseou-se como critério, a seleção dos produtos com maior giro no estoque, outro parâmetro utilizado para seleção dos produtos foi o lucro que os mesmos proporcionaram para a empresa no período de abril de 2016 a agosto de 2018. A partir disto foi escolhido os produtos que teriam a demanda analisada. Após análise das curvas ABC foi realizado a seleção dos produtos, que consistem em 99 diferentes tipos de “Barras de Cereais”. E por fim, a realização de testes e análises identificou o modelo SARIMA como o mais adequado, para a série temporal da demanda do produto classe A para o próximo semestre.

**Palavras-chave:** Previsão de demanda; SARIMA; Produtos saudáveis.

### **1 Introdução**

Nos últimos anos, os produtos saudáveis tornaram-se um dos insumos de maior destaque no cenário econômico nacional. De acordo com o texto Mercado (2018) um estudo da agência *Euromonitor International*, realizado no ano de 2017, afirmou que nos cinco anos anteriores, o ramo de produtos que visam a alimentação saudável cresceu 12,3%, em média, ao ano.

A empresa objeto de estudo comercializa produtos saudáveis e está localizada no centro oeste de Minas Gerais e realiza vendas para as regiões próximas. A mesma possui uma filial que produz vários de seus produtos. A empresa teve uma grande evolução em relação à procura de seus produtos desde sua fundação em 2013, entretanto, ela está situada em um mercado instável, sendo necessário um maior planejamento para conseguir atender esta demanda sem sofrer com estoques demasiados.

Com intenção de atender à crescente demanda, as organizações deste segmento devem possuir um controle pertinente das quantidades necessárias do produto, que seja suficiente para atender as necessidades do mercado. De Souza et al. (2013), descreve que em qualquer empresa que tenha um pouco de organização, tal controle é feito pelo

setor de planejamento e controle da produção (PCP) que utiliza várias técnicas para tal gerenciamento. Por meio de técnicas de PCP, é possível realizar a estimativa de futuras demandas baseados em métodos quantitativos ou qualitativos, ou seja, a prever a demanda de determinado produto.

A previsão de demanda no setor empresarial pode ser considerada como um diferencial, pois se trata de uma maneira de relacionar-se com as influências do mercado. Uma previsão de demanda eficaz, faz com que todo o processo produtivo se integre aos processos de produção, o que resulta na minimização dos custos com a estocagem.

De acordo com Miranda et al. (2011) e Moreira (2008), as previsões de demanda são essenciais para as organizações, pois servem de ponto de partida, direto ou indireto, para praticamente todas as decisões.

Diante do exposto, o presente estudo tem como objetivo geral: propor a utilização do método Box - Jenkins (SARIMA) para prever a demanda dos produtos mais relevantes da empresa. Como ferramenta de auxílio do estudo foram utilizados o software Gretl, um aplicativo desenvolvido pela The Gretl Team que compila e interpreta dados econométricos, e o Excel, programa incluso no pacote Office desenvolvido pela Microsoft.

A realização da pesquisa se faz necessária para auxiliar uma empresa que se encontra em um ramo que apresenta um crescimento, gradativo, entretanto exposto a variações da demanda deste mercado, reforçando assim a necessidade de previsões de vendas para o auxílio nas tomadas de decisões estratégicas e alocação de recursos.

## **2 Referencial Teórico**

### **2.1 Previsão de demanda**

Compreende-se por demanda um produto como volume total que pode ser comprado por um grupo definido de clientes, em uma área geográfica definida, num determinado período de tempo, em um médio ambiente definido e sob um apropriado plano de marketing (KOTLER; KELLER, 2006).

Diante de algumas situações é possível observar que a demanda adota certa medida. Lutosa et al. (2008) afirma que itens com demanda repetitiva podem ser considerados como dependentes (quando relacionada à demanda de outro produto) e independentes (relacionada ao “ciclo de vida” do produto).

A demanda independente pode ser considerada como estacionária ou com aptidão, sendo primeiramente relacionado à fase da maturidade dentro do ciclo de vida do produto, segundo é pertinente a fase de crescimento ou declínio das vendas (DE SOUZA et al., 2013). Por fim, o que pode considerar em relação aos padrões da demanda é a sazonalidade, que consiste em transformações constantes da demanda ao longo do ano ou do “ciclo sazonal” (LUSTOSA et al., 2008).

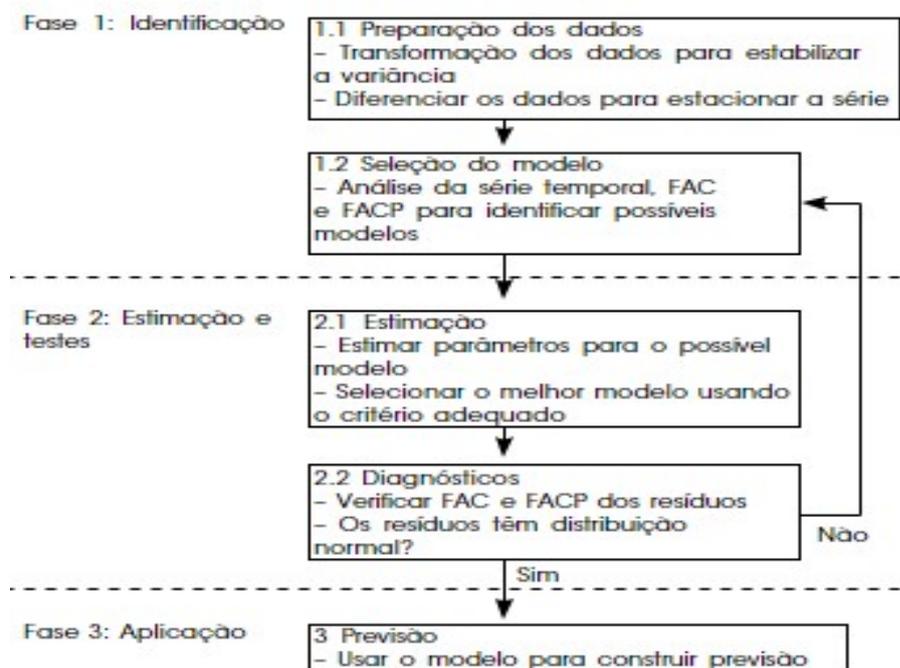
A previsão de demanda em si, refere-se a uma técnica metodológica para determinação de dados futuros baseado em modelos estatísticos, matemáticos e econométricos ou ainda em modelos subjetivos auxiliados em uma metodologia de trabalho clara e anteriormente definida (MARTINS; LAUGENI, 2005).

Segundo Martins e Laugeni (2005), ainda com a importância da previsão de demanda para o bom planejamento da empresa, essas previsões apontam vários erros em suas estimativas, pois o mercado, sendo ativo, está sujeito a modificações. No entanto, isso não subestima a sua importância na tomada de decisão do planejamento estratégico de uma organização.

## 2.2 Box e Jenkins

De acordo com Walter et al. (2013) a metodologia Box-Jenkins pode ser representada por um ciclo formado de três etapas iterativas que consistem na identificação do modelo, estimativa de parâmetros e aplicação, como pode ser visto na Figura 1 a seguir:

Figura 1- Etapas da construção do modelo de previsão via metodologia Box-Jenkins



Fonte: Walter et al. (2013)

Na primeira etapa deve-se fazer a preparação dos dados, no qual se realiza a diferenciação para estacionar a série, caso haja necessidade. Posteriormente, faz-se a seleção do modelo, que é realizada por meio das análises gráficas (correlogramos) das funções de auto correlação (FAC) e das funções de auto correlação parciais (FACP) (MORETTIN e TOLOI, 1987). Após a identificação do modelo faz-se a estimativa dos parâmetros. A última etapa para a construção do modelo é a verificação de sua adequação, realizada mediante diagnóstico, em seguida é realizada a análise dos resíduos do modelo com objetivo de identificar seu comportamento como o de uma distribuição normal e como um ruído branco e caso o modelo selecionado não for adequado, deve-se fazer a identificação de um novo, refazendo as mesmas etapas, as quais podem se repetir até que o melhor modelo for selecionado, partindo assim para a realização da previsão.

## 2.3 Modelo Sazonal SARIMA

Os modelos que consideram as séries que apresentam autocorrelação sazonal são conhecidos como modelo sazonal SARIMA. O modelo SARIMA contém uma parte não sazonal com parâmetros  $(p, d, q)$  e uma sazonal com parâmetros  $(P, D, Q)$  (ESPINOSA, 2010).

De acordo com BOX e JENKINS (1974) o modelo SARIMA pode ser definido por:

$$\phi(B)\Phi(Bs)Wt = \theta(B)\Theta(Bs)at \quad (1)$$

Sendo que  $Wt = \nabla s d \nabla d X t$ , o auto regressivo não sazonal -  $\phi(B)$  é igual a  $(1 - \alpha_1 B - \dots - \alpha_p B^p)$ ; o auto regressivo sazonal -  $\Phi(Bs)$  é a mesma coisa que  $(1 - \phi_s B s - \dots - \phi_p B^p s^p)$ ; a média móvel sazonal representada por  $\Theta(Bs)$  pode ser representada por  $(1 + \beta_1 B s + \dots + \beta_q B^q s^q)$ ; o operador  $\nabla d$  representa a diferença não sazonal de ordem  $d$  e  $\nabla d$  significa a diferença sazonal de ordem  $D$ . (XAVIER, 2016).

## 2.4 Curvas ABC

Em se tratando de gestão de estoques, é fundamental determinar a relevância de cada mercadoria para que a maior parte dos esforços da gestão seja destinada aos mais importantes, sendo esta uma prática eficiente (LUSTOSA et al, 2008). Essa prática é baseada na lei que afirma que poucas causas são importantes para a maioria das consequências de Vilfredo Pareto, também conhecida como lei 80/20 ou curva ABC, a, também denominada, lei de Pareto institui que 80% dos efeitos estão associados a apenas 20% das causas. (DE SOUZA et al., 2013)

Segundo Lustosa et al. (2008), a aplicação desse princípio na gestão de estoques possibilita ao gestor concentrar seus esforços nos principais itens (itens A), aplicando um controle menos severo aos itens de média importância (itens B), e menos ainda ao numeroso grupo dos itens de menor importância (itens C) (DE SOUZA et al, 2013).

De acordo com Pozo (2002) na parte administrativa, a classificação ABC se tornou de grande utilidade nas mais diferentes áreas em que se necessita tomar decisões, envolvendo grande quantidade de informações e a ação torna-se imediato, sendo constantemente usada para análise dos estoques, produção, vendas, salários entre outros.

A realização da curva ABC não é tão complexa é parcialmente simples, bastando ordenar os produtos de acordo com a sua representatividade econômica para a organização, além disso, ela pode ser calculada utilizando o preço de custo, preço de venda ou até mesmo o lucro. (DALMAS, 2011).

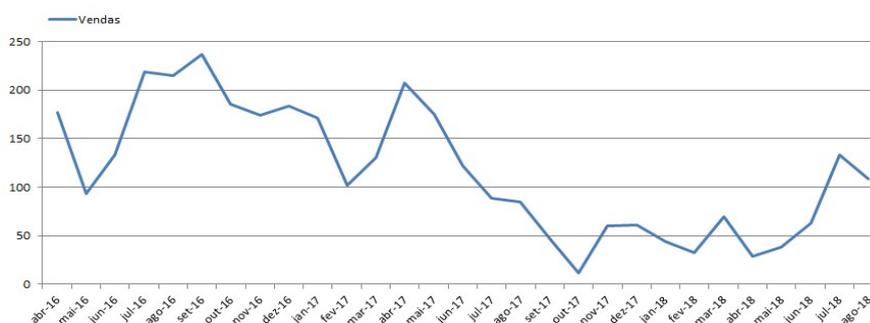
## 3 Materiais e Métodos

### 3.1 Descrição dos dados

A metodologia utilizada no presente trabalho iniciou-se com a coleta de dados, que foi realizada com base em informações acerca de preços, custos e demandas cedidas por um representante da empresa. Para a classificação ABC do mix de produtos da empresa utilizou-se como critério, a seleção dos produtos com maior giro no estoque, outro parâmetro utilizado para seleção dos produtos foi o lucro que os mesmos proporcionaram para a empresa no período de abril de 2016 a agosto de 2018. A partir disto foi escolhido os produtos que teriam a demanda analisada.

Após análise das Curvas ABC foi realizado a seleção dos produtos, que consistem em 99 diferentes tipos de “Barras de Cereais” catalogados (Apêndice A). Sendo determinado os produtos, fez-se a seleção dos dados referente às vendas mensais de abril de 2016 a agosto de 2018 (29 meses), os dados foram cedidos por colaboradores da empresa e seu comportamento pode ser visto representado graficamente na Figura 2.

Figura 2 - Vendas mensais de abril de 2016 a agosto de 2018



Fonte: Elaborado pelos autores, 2018.

Após seleção dos dados foi utilizada a metodologia de Box-Jenkins (1970) com o objetivo de selecionar o melhor modelo para o material considerado. Para tal seleção, foi empregado o programa estatístico GRETL V 2018b, tendo sido o modelo SARIMA (1,1,0) (0,1,0) 4 o mais adequado, após a análise de vários modelos.

### 3.2 Métricas para avaliação do modelo

Para avaliação e validação do modelo, foram utilizados os seguintes testes:

- R-Square: Coeficiente de determinação, quanto mais perto de 100%, melhor.
- Ljung-Box- Estatística que testa o ajuste de um modelo de série temporal. O teste pode ser definido como:  
Ho: hipótese nula - não existência de auto correlação conjunta dos resíduos (não existe falha de ajuste)  
Ha: hipótese alternativa - existência de auto correlação conjunta dos resíduos (existe falha de ajuste)  
Se o valor P for maior que 0,95; então, a hipótese nula deve ser rejeitada em favor da hipótese alternativa.
- AIC (Critério de Informação de Akaike): “é uma medida relativa da qualidade de ajuste de um modelo estocástico estimado” (EMILIANO, 2013 p. 26). O modelo com menor valor e AIC é considerado o modelo de melhor ajuste
- BIC (Bayesian Information Criterion): De acordo com Lopez e Oliveira (2016), o critério é conhecido como Critério de Schwartz, e é um critério baseado na função de probabilidade para a seleção de modelos entre um conjunto finito deles. “Ajustando os modelos, é possível aumentar a probabilidade inserindo parâmetros, mas pode acontecer um sobre ajuste” (LOPEZ e OLIVEIRA, 2016). Está diretamente relacionado com o Critério AIC (AIKE, 1974). E quanto menor for, melhor.
- Teste Dickey-Fuller Aumentado: Teste utilizado para verificar a estacionariedade da série, o teste pode ser definido como:  
Ho: hipótese nula – a série possui raiz unitária (estacionária)

Ha: hipótese alternativa – a série não possui raiz unitária (não estacionária)  
Se o valor P for maior que 0,95; então, a hipótese nula deve ser rejeitada em favor da hipótese alternativa. Sendo que em virtude da evidência de não estacionariedade da série, é necessário tomar a tomar a diferença.

- Teste de Kruskal –Wallis: Também conhecido como ANOVA by ranks test, o teste é utilizado quando se deseja testar a hipótese de que várias amostras têm a mesma distribuição de valores, ou seja, para verificar se o modelo apresenta sazonalidade. O teste pode ser definido como:  
Ho: hipótese nula - os grupos têm a mesma distribuição de valores. (apresenta sazonalidade)  
Ho: hipótese nula - os grupos não têm a mesma distribuição de valores. (não apresenta sazonalidade)  
Sendo que, segundo o texto Todas... (2017) se o valor-p for menor ou igual ao nível de significância, rejeite a hipótese nula e conclua que nem todas as medianas da população são iguais, já se o valor-p for maior do que o nível de significância, não há provas suficientes para rejeitar a hipótese nula.

## 4 Resultados e Discussões

### 4.1 Teste para tendência

Para o teste de previsão foi retirado da série os últimos 6 meses de dados, que é referente a algo próximo de 20% da série (março de 2018 agosto de 2018).

O teste de Dickey-Fuller Aumentado apontou que a série é não estacionária (Tabela 1), ou seja, não rejeitou a hipótese nula de que a série possui raiz unitária, o que sugere que seja calculada a primeira diferença.

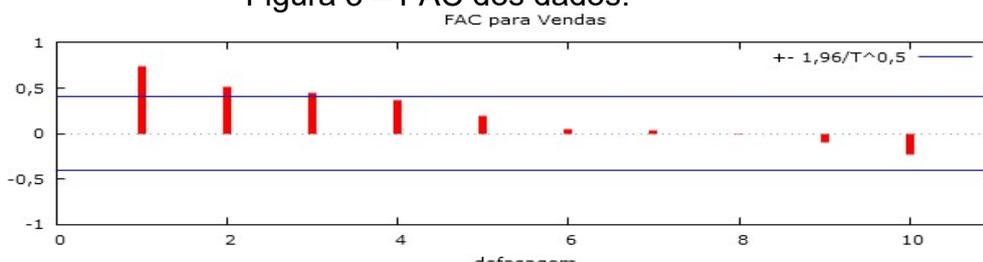
Tabela 1 – Teste Dickey-Fuller Aumentado.

	Resultado	Valor-P
<b>Teste com Constante</b>	Não rejeita H0	0,91
<b>Teste sem Constante</b>	Não rejeita H0	0,63

Fonte: Elaborado pelos autores, 2018.

Para se conseguir identificar o modelo apropriado para a série deve-se inicialmente determinar o correlograma da série original, mostrado a seguir na Figura 3.

Figura 3 – FAC dos dados.



Fonte: Elaborado pelos autores, 2018.

O decaimento lento ao decorrer das defasagens da FAC também sugere que seja calculada a primeira diferença na variável.

## 4.2 Teste para sazonalidade determinística

Após acrescentar a primeira diferença na variável, foi feito o teste de Kruskal-Wallis para o teste da hipótese sujeito a  $H_0 =$  Sazonalidade Determinística. Foi feito o teste para duas defasagens (Um bimestre) quatro defasagens (Dois bimestres), três defasagens (Um trimestre) e seis defasagens (Dois trimestres ou um semestre) e o resultado pode ser visto na Tabela 2 a seguir.

Tabela 2 – Teste de Kruskal-Wallis da primeira diferença da variável.

Teste de Kruskal-Wallis	Número de Defasagens	Valor-p	Resultado para 0,05 de Significância
Um Bimestre	2	0,895456	Não Rejeita a Hipótese Nula
Dois Bimestres	4	0,048064	Rejeita a Hipótese Nula
Um Trimestre	3	0,638683	Não Rejeita a Hipótese Nula
Dois Trimestres	6	0,961752	Não Rejeita a Hipótese Nula

Fonte: Elaborado pelos autores, 2018.

Com o teste de Kruskal-Wallis foi possível rejeitar a hipótese nula com 0,05 de significância para 4 defasagens, e, portanto, podemos dizer que não se rejeita a possibilidade de sazonalidade determinística nos dados na defasagem 4, ou seja, dois bimestres.

## 4.3 Proposta de Modelos

Assim temos alguns modelos candidatos para utilizar para fazer a previsão dos dados retirados da série (Tabela 3).

Tabela 3 – Modelos candidatos.

	Estrutura	Ljung-Box	BIC	AIC
<b>Modelo 1</b>	SARIMA(1,1,0)(0,1,0) <sub>4</sub>	0,4284	201,3493	199,5686
<b>Modelo 2</b>	SARIMA(0,1,1)(0,1,0) <sub>4</sub>	0,5228	201,1163	199,3355
<b>Modelo 3</b>	SARIMA(0,1,0)(1,1,0) <sub>4</sub>	0,2019	198,1470	196,3663
<b>Modelo 4</b>	SARIMA(0,1,0)(0,1,1) <sub>4</sub>	0,3838	195,6953	193,9145

Fonte: Elaborado pelos autores, 2018.

Com o resultado do BIC e AIC, podemos dizer que o modelo 4 teve os melhores resultados, porém, para a escolha do modelo com a melhor capacidade de previsão será comparado os valores reais e preditos, e mensurado os erros de previsão por meio da raiz do erro de previsão quadrático médio (REPQM). O resultado de cada modelo pode ser visto na Tabela 4 a seguir.

Tabela 4 – REPQM dos modelos.

	Estrutura	ERRO - REPQM
<b>Modelo 1</b>	SARIMA(1,1,0)(0,1,0)4	28,55
<b>Modelo 2</b>	SARIMA(0,1,1)(0,1,0)4	29,09
<b>Modelo 3</b>	SARIMA(0,1,0)(1,1,0)4	73,26
<b>Modelo 4</b>	SARIMA(0,1,0)(0,1,1)4	59,14

Fonte: Elaborado pelos autores, 2018.

#### 4.3.1 Modelo 1

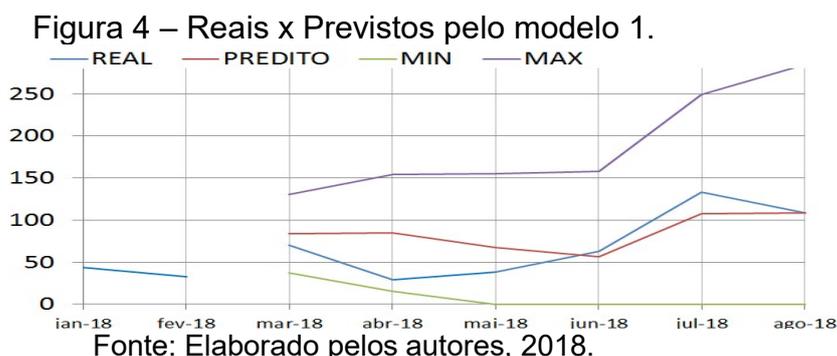
Com o resultado da REPQM o modelo 1 foi escolhido como o modelo de melhor capacidade de previsão. Feito isso partiu-se para a comparação dos valores previstos pelo modelo 1 com a demanda real existente dentro o período abordado para análise, como pode ser visto na Tabela 5 a seguir.

Tabela 5 – Reais versus Previstos

	Mar 18	Abr 18	Mai 18	Jun 18	Jul 18	Ago 18
<b>Real</b>	70	29	38	63	133	109
<b>Modelo 1</b>	84	85	68	57	108	109

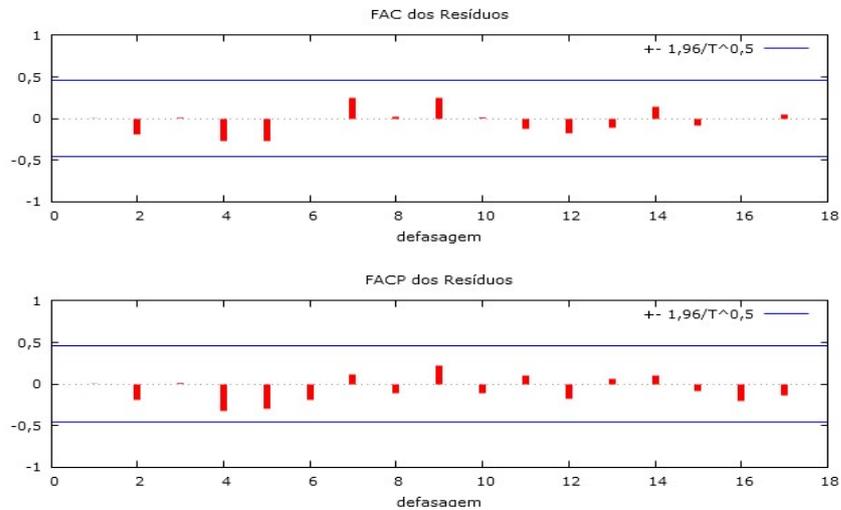
Fonte: Elaborado pelos autores, 2018.

Com o auxílio do gráfico exposto na figura 4, consegue-se perceber como a previsão conseguiu acompanhar algumas variações da demanda, sendo abordado no gráfico também as variações para demanda máxima e demanda mínima com 60% de confiança (O modelo conseguiu prever os dados com 60% de confiança).



Na Figuras 6 são apresentados os gráficos das funções de autocorrelação e autocorrelação parcial dos resíduos.

Figura 5 – FAC e FACP dos resíduos



Fonte: Elaborado pelos autores, 2018.

O teste demonstrou que não há problema na autocorrelação dos resíduos. Sendo então o modelo adequado para a realização da previsão de demanda da empresa para os próximos meses. Partindo dos resultados anteriores, encontrou-se que a previsão utilizando o modelo SARIMA (1,1,0) (0,1,0)<sub>4</sub>, segue abaixo o gráfico da previsão realizada pelo modelo 1 na figura 7 exposta a seguir.

Figura 6 – Previsão



Fonte: Elaborado pelos autores, 2018.

Os valores previstos podem ser vistos de forma exata na tabela 5 a seguir.

Tabela 6 - Previsão

	<b>Set 18</b>	<b>Out 18</b>	<b>Nov 18</b>	<b>Dez 18</b>	<b>Jan 19</b>	<b>Fev 19</b>
<b>PREVISÃO</b>	120	146	216	192	203	228
<b>MIN</b>	78	82	136	98	73	66
<b>MAX</b>	162	209	295	285	333	390

Fonte: Elaborado pelos autores, 2018.

## 5 Considerações Finais

A previsão de demandas tem se mostrado como uma importante ferramenta para o planejamento e controle da produção de uma empresa, bem como para o gerenciamento de seu estoque. Nesta pesquisa, a previsão foi realizada para o produto barra de cereal, escolhido a partir da classificação ABC como o que gera o maior percentual da receita mensal para a empresa, ou seja, classe A.

Após a realização de testes e análises, se identificou o modelo SARIMA (1,1,0) (0,1,0) 4 como o mais adequado, para a série temporal da demanda do produto Classe A para o próximo semestre. Este método gerou uma demanda prevista de 120 unidades para o mês de setembro de 2018, 146 para o mês de outubro, 216 para o mês novembro, 192 para o mês de dezembro, 203 para o mês de janeiro de 2019 e 228 de unidade para o mês de fevereiro de 2019.

Essa previsão pode ser de grande utilidade para a empresa já que permite a antecipação quanto as tomadas de decisão em relação as estratégicas e alocação de recursos sobre diversos aspectos da organização, permitindo com que a empresa se planeje da melhor forma possível para o próximo semestre.

## Referências

AKAIKE, H. **A new look at the statistical model identification**. Automatic Control, IEEE Transactions on, 19(6), 716-723, 1974.

ARAGÃO, A. M. S. et al. **Aplicação da curva ABC em uma empresa do setor atacadista no estado de Sergipe**. *Anais do Encontro Nacional de Engenharia de Produção-Enegep*, 2016.

BALLOU, Ronald H.; **Logística Empresarial: Transportes, Administração de materiais e Distribuição Física**; São Paulo, Editora Atlas, p. 97, 2011.

BOX, G. E. P.; JENKINS, G. M.; MACGREGOR, J. F. **Some recent advances in forecasting and control**. Applied Statistics, p. 158-179, 1974.

DALMAS, Daniele Marques. **Gestão de estoques através da classificação ABC de materiais na CEEE-D**. 2011.

DE SOUZA, A. E. C. et al. **Utilização do método Box-Jenkins (ARIMA) na previsão de demandas de um produto de uma empresa de beneficiamento de açaí**. XXXIII Encontro Nacional de Engenharia de Produção, 2013.

TODAS as estatísticas para teste de kruskal-wallis, 2017 Disponível em:

<<https://support.minitab.com/pt-br/minitab/18/help-and-how-to/statistics/nonparametrics/how-to/kruskal-wallis-test/interpret-the-results/all-statistics/>>.

Acesso em: 21 nov. 18

MERCADO de alimentos naturais continua a crescer no brasil, 1 mar. 2018. Disponível em: <<https://g1.globo.com/sc/santa-catarina/especial-publicitario/cia-da-saude/noticia/mercado-de-alimentos-naturais-continua-a-crescer-no-brasil.ghtml>>. Acesso em: 20 nov. 18.

EMILIANO, P. C. Critérios de informação: como eles se comportam em diferentes modelos. **Doutoramento em Estatística e Experimentação Agropecuária**, 2013.

ESPINOSA, M. M.; PRADO, S. M.; GHELLERE, M. **Uso do modelo SARIMA na previsão do número de focos de calor para os meses de junho a outubro no Estado de Mato Grosso**. *Ciência e Natura*, v. 32, n. 2, p. 07-21, 2010.

KOTLER, P.; KELLER, K. L. **Administração de marketing**. São Paulo: Pearson Prentice Hall, 2006.

LUSTOSA, L. et al. **Planejamento e controle da produção**. Rio de Janeiro: Elsevier, 2008.

MARTINS, P. G.; LAUGENI, F. P. **Administração da produção**. São Paulo: Saraiva, 2005.

MARTINS, P. G.; LAUGENI, F. P. **Administração da produção**. 2.ed. rev., aum. e atual. São Paulo: Saraiva, 2005.

MIRANDA, R. G.; GERBER, J. Z.; BORNIA, A. C.; FREIRES, F. G. M. **Método estruturado para o processo de planejamento da demanda nas organizações**. In: Congresso Internacional de Administração, 2011. **Anais eletrônicos...** Ponta Grossa, 2011.

MOREIRA, D. A. **Administração da Produção e Operações**. 2. ed. São Paulo: Cengage Learning, 2008. 624 p.

MORETTIN, P. A.; TOLOI, C. M; **Previsão de Séries Temporais**. 2ª Ed. São Paulo: Editora Atual: 1987.

POZO, H. **Administração de recursos materiais e patrimoniais: uma abordagem logística**. 2. ed. São Paulo: Atlas, 2002.

WALTER, O. M; F. C. et al. **Aplicação de um modelo SARIMA na previsão de vendas de motocicletas**. *Exacta*, São Paulo, v. 11, n. 1, p.77-88, 28 maio 2013.

XAVIER, J. M. N. **Análise e previsão de séries temporais com modelos ARIMA e análise espectral singular**. Tese de Doutorado. 2016.