



PREVISÃO DE VENDAS ATRAVÉS DA METODOLOGIA DE BOX & JENKINS: UM ESTUDO DE CASO

Maria Emília Camargo (UCS)

kamargo@terra.com.br

Walter Priesnitz Filho (UCS)

walterp@via-rs.net

Suzana Leitão Russo (UFS)

suzanarusso@ufs.br

O mercado consumidor está cada vez mais exigindo das empresas um grau máximo de racionalização, competitividade e modernização. Assim, o ambiente empresarial vem passando, nos últimos tempos, por um período de consideráveis modificações. O dinamismo e a crescente competitividade no mundo dos negócios colocam em risco a vida das empresas que não questionarem seus métodos tradicionais de gerenciamento, desenvolvimento de novos produtos e serviços, produção, qualidade, dimensionamento das suas vendas, etc. Assim, neste trabalho aplicou-se a metodologia de Box & Jenkins (1976), para a previsão de vendas de sacos de rafia no período de janeiro a dezembro de 2005, de uma indústria têxtil, que está preocupada em aumentar a sua capacidade produtiva, com base na análise de suas vendas reais. Após a aplicação da metodologia, o modelo que melhor se ajustou aos dados das vendas de sacos foi o modelo ARIMA (0,0,2) com um MAPE = 2,68%.

Palavras-chaves: Previsão de Vendas, Modelo ARIMA, Capacidade Produtiva

1. Introdução

As grandes mudanças que vem ocorrendo no mundo dos negócios, principalmente pela ocorrência da abertura de mercado, faz com que as empresas enfrentem concorrência acirrada, principalmente por parte de produtores e fornecedores com estruturas muito enxutas provenientes do exterior.

Assim, as empresas para evitarem a perda de mercado ou mesmo para garantir a permanência no mercado em condições competitivas, devem estar preparadas para acompanhá-las. Este é um momento adequado para se implantar técnicas que possam auxiliá-las em suas tomadas de decisões e formulações de estratégias competitivas.

Conforme Porter(1980), essas estratégias devem ser elaboradas de forma que possam fazer face as cinco forças competitivas, ou seja, ameaça de entrada, ameaça de substituição, poder de negociação dos fornecedores, poder de negociação dos compradores e grau de rivalidade entre os atuais concorrentes. Com esta preocupação é que a empresa em estudo quer fazer um acompanhamento semanal do volume de vendas, a fim de avaliar a necessidade de aumentar a sua capacidade produtiva. Para que este objetivo seja alcançado a empresa pretende implantar um método de previsão a curto prazo que seja capaz de captar os reais movimentos do mercado.

Segundo Ballou (2001), a previsão dos níveis de vendas possui grande importância para a empresa como um todo, pois fornece as entradas básicas para o planejamento e o controle de todas as áreas funcionais, incluindo a logística, o marketing, a produção e as finanças. Os níveis de vendas e seu sincronismo atingem de forma significativa os níveis da capacidade, as necessidades financeiras e a estrutura geral dos negócios da empresa. A previsão de vendas diz respeito à natureza temporal, bem como espacial, das vendas, à extensão de sua variabilidade e ao seu grau de aleatoriedade.

Para Mintzberg (1987) as organizações que pretendem gerenciar o futuro devem compreender o passado, pois, através do conhecimento dos padrões anteriores é que serão capazes de conhecer suas capacidades e seus potenciais. Portanto, o processo de previsão de vendas envolve uma análise do passado, do presente e uma extrapolação para o futuro.

A previsão de vendas é utilizada para que as empresas possam elaborar estimativas das quantidades demandadas pelo mercado consumidor, em um intervalo de tempo pré-definido (Krajewski & Ritzman, 1994). Assim, quanto maior a precisão da previsão, menor será o risco no processo de tomada de decisão, como no caso da empresa em estudo de aumentar a sua capacidade produtiva, ou seja, adquirir mais máquinas de tecer.

Assim, com base nestas colocações pode-se dizer que o objetivo principal deste estudo foi encontrar um modelo de previsão capaz de captar os movimentos das vendas de sacaria de rafia, e prever as vendas com o menor erro de previsão, com base em dados históricos registrados na empresa, utilizando-se a metodologia de Box & Jenkins (1976),

Este trabalho está organizado da seguinte forma: na seção 2, descreve-se a metodologia; na seção 3 encontra-se a fundamentação teórica; na seção 4 é apresentado o estudo de caso e na seção 5 descreve-se as considerações finais.

2. Metodologia

O método de pesquisa científica do ponto de vista da natureza e da forma de abordagem do problema proposto utilizado neste estudo enquadra-se, de acordo com Menezes & Silva (2001), na categoria de pesquisa aplicada quantitativa. A pesquisa aplicada quantitativa tem como objetivo gerar conhecimentos para aplicação prática dirigida à solução de problemas específicos com o uso de recursos e técnicas estatísticas, que no caso é de encontrar um modelo de previsão que represente as vendas de sacaria de rafia de uma indústria têxtil, a qual produz sacarias para farinha, ração, sementes, cereais, frigoríficos, sal e outros.

Os dados foram coletados, nos registros semanais da empresa e referem-se a quantidade em m² de sacos de rafia vendidos semanalmente no período de janeiro a dezembro de 2005.

Para a construção do modelo representativo das vendas semanais, utilizou-se a metodologia de Box & Jenkins (1976). No próximo item, apresenta-se a fundamentação teórica para a aplicação desta metodologia.

3. Fundamentação teórica

Uma série temporal é um conjunto de observações de uma dada variável ordenadas segundo o parâmetro tempo, geralmente em intervalos equidistantes. Se o processo estocástico que gerou a série de observações é invariante com respeito ao tempo, diz-se que o processo é estacionário. Se as características do processo se alteram no decorrer do tempo, é chamado de não estacionário (Box & Jenkins (1976); Souza & Camargo(1996)).

A importância do conhecimento da série ser ou não estacionária reside no fato de que quando se trabalha com uma série estacionária, se está em presença de uma função amostral do processo que tem a mesma forma em todos os instantes do tempo $t \in \mathbb{N}$, acarretando na facilidade de obtenção de estimativa das características do processo.

Ao considerar-se a evolução temporal do processo, mede-se a magnitude do evento que ocorre em determinado instante de tempo. A análise no domínio do tempo é baseada em um modelo paramétrico, utilizando-se as funções de autocovariância e autocorrelação. A autocorrelação é a autocovariância padronizada, que serve para medir a extensão de um processo para o qual o valor tomado no tempo t , depende daquele tomado no tempo $(t-k)$.

Define-se a autocorrelação de ordem k como:

$\rho_k = \frac{\gamma_k}{\gamma_0} = \frac{\text{Cov}[Z_t, Z_{t+k}]}{\sqrt{\text{Var}(Z_t)\text{Var}(Z_{t+k})}}$	(1)
---	-----

onde:

$$\text{Var}(Z_t) = \text{Var}(Z_{t+k}) = \gamma_0 = \text{variância do processo}$$

$$\rho_0 = 1 \text{ e } \rho_k = \rho_{-k}.$$

A autocorrelação pode ser estendida. Se for medida a correlação entre duas observações seriais Z_t e Z_{t+k} , eliminando-se a dependência dos termos intermediários, Z_{t+1} , Z_{t+k-1} , tem-se a autocorrelação parcial, representada por:

$$\text{Cor}(Z_t, Z_{t+k} | Z_{t+1}, \dots, Z_{t+k-1}).$$

A função de autocorrelação pode ser obtida considerando-se um modelo de regressão para um processo estacionário com média zero. A variável dependente Z_{t+k} depende das variáveis $Z_{t+k-1}, Z_{t+k-2}, \dots$. Assim,

$$Z_{t+k} = \phi_{k1} Z_{t+k-1} + \phi_{k2} Z_{t+k-2} + \dots + \phi_{kk} Z_t + a_{t-k}$$

onde:

ϕ_{ki} - i-ésimo parâmetro da regressão;

a_{t+k} - é o termo de erro descorrelatado com Z_{t+k-j} para $j \geq 1$.

A autocorrelação parcial é estimada por:

$$\hat{\phi}_{k+1,k+1} = \frac{\hat{\phi}_{k+1} \sum_{j=1}^k \hat{\phi}_{kj} \hat{\phi}_{k+1-j}}{1 - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\phi}_j} \tag{2}$$

$$\hat{\phi}_{k+1,j} = \hat{\phi}_{kj} - \hat{\phi}_{k+1,k+1} \hat{\phi}_{k,k+1-j}, j = 1, \dots, k$$

3.1 Modelos ARIMA(p,d,q) de Box & Jenkins

Box & Jenkins (1976) assumem que a série temporal Z_t é uma realização particular de um processo estocástico gerado pela passagem sucessiva de um processo ruído branco a_t à uma seqüência de dois filtros lineares; um estável e outro instável como apresentado na Figura 1.




FIGURA 1 - Representação teórica de um Modelo ARIMA(p,d,q)

Quando se tem uma série não estacionária, deve-se antes de ajustar um modelo estacionário (MA, AR, ARMA) torná-la estacionária, para isto, uma das formas é utilizar o método da diferenciação discreta (∇^{-1} : operador de diferença).

Esta 2ª filtragem é repetida quantas vezes forem necessárias, até que se obtenha na saída um processo com as características necessárias para representar o processo não-estacionário homogêneo. Uma condição necessária para aplicação dos modelos ARIMA, é de que o processo que gerou a série temporal seja estacionário de segunda ordem, ou seja, que sua média e variância sejam constantes no tempo.

Se $w_t = \nabla^{-1} Z_t$ é estacionária, pode-se representar w_t por um modelo ARMA(p,q), ou seja,

$$\Phi(B) w_t = \Theta(B) a_t \tag{3}$$

Se w_t é uma diferença de Z_t , então Z_t é uma integral (soma) de w_t , daí diz-se que Z_t segue um modelo Auto-Regressivo-Integrado-Médias Móveis, ou modelo ARIMA(p,d,q), assim:

$$\Phi(B) = \nabla^d Z_t = \Theta(B) a_t \text{ de ordem } (p,d,q) \quad (4)$$

Os modelos auto-regressivos puros AR(p,0) são aqueles cujo polinômio $\Theta(B) = 1$, e os modelos médias móveis puros MA(0,q), têm seu polinômio $\Phi(B) = 1$. Para que o polinômio $\Phi(B)$ seja estacionário, suas raízes têm de estar fora do círculo unitário, e para que $\Theta(B)$ seja inversível, suas raízes devem se encontrar dentro do círculo unitário.

3.1.1 Etapas para construção de um modelo de previsão

As etapas de análise para determinação do modelo que melhor explica a dinâmica da série temporal em análise, através da metodologia Box-Jenkins (1976), são apresentadas a seguir.

i) Identificação

Para a construção dos modelos ARIMA, é necessário identificar a ordem dos parâmetros p, d, q. O primeiro parâmetro a ser identificado é o grau de diferenciação d necessário à estabilização dos dados. Isto é feito através da análise do comportamento do correlograma, ou seja, do diagrama da função de autocorrelação (FAC), no qual são apresentados os valores das autocorrelações em relação aos lags k. Se as autocorrelações decrescerem de forma linear, realizam-se diferenciações na série, até que o diagrama apresente um corte abrupto para um valor qualquer de autocorrelação, quando a série será considerada estacionária.

A ordem auto-regressiva p é determinada pela verificação da função de autocorrelação parcial (FACP), ϕ_{kk} , da série que está sendo analisada. Se a série for unicamente auto-regressiva ARIMA (p,d,0), sua função de autocorrelação parcial apresentará uma queda rápida após o lag k. Se não, efetua-se uma análise dos estimadores ϕ_{kk} para se verificar até que ordem de defazagem do correlograma desta função ele é estatisticamente significativa. Essa será sua ordem auto-regressiva.

A ordem médias móveis q é determinada pela verificação da função de autocorrelação (FAC), ρ_k , da série que está sendo analisada. Se a série for unicamente médias móveis ARIMA (0,d,q), sua função de autocorrelação apresentará uma queda rápida após o lag k. Se não, analisa-se os outros estimadores ρ_k para se identificar até que ordem de defazagem do correlograma desta função é estatisticamente significativa. Essa será ordem de médias móveis. Quando o modelo apresentar uma combinação do comportamento dos coeficientes auto-regressivos e de médias móveis, pode-se identificar um modelo ARIMA(p,d,q).

ii) Estimação dos parâmetros

Esta etapa da metodologia consiste em estimar os parâmetros cada um dos modelos Autoregressivos (Φ), de médias móveis (Θ), e a variância de dos erros. Esta estimação é realizada através do método de máxima verossimilhança.

iii) Verificação: Esta etapa consiste em avaliar se o ajuste do modelos através do comportamento da função de autocorrelação.

iv) Previsão: É a etapa da extrapolação dos dados históricos através do modelo encontrado.

3.1.2 Critério de Decisão

Um dos critérios utilizados para se escolher o melhor modelo para realizar previsões é o critério do Erro Médio Absoluto percentual de Previsão (MAPE).

O valor do MAPE é encontrado:

$$\text{MAPE (\%)} = \left| \frac{\sum \left(\frac{Z - \bar{Z}_t}{Z} \right)}{n} \right| \times 100 \quad (5)$$

onde Z é o valor atual da série, \bar{Z}_t o valor previsto e n a quantidade de elementos previstos.

4. Estudo de Caso

O presente estudo foi realizado em uma indústria têxtil que produz sacaria de rafia. Os dados analisados referem-se a demanda semanal de sacaria de rafia no período de janeiro a dezembro de 2005, conforme Figura 2. Inicialmente foi realizada uma análise gráfica dos dados, onde suspeitou-se que as observações não eram independentes, e a série não era estacionária. Através da análise da função de autocorrelação, apresentada na Figura 3, foi confirmada esta suspeita.




Figura 2 - Representação da série de vendas semanais de sacaria de rafia




Figura 3 - Coeficientes da função de autocorrelação

Analisando-se a Figura 3, pode-se afirmar que a série de vendas semanais de sacaria de rãfia é estacionária, pois apresenta um decaimento rápido para zero a partir do lag $k=2$, apresentando uma indicação inicial de que o modelo verdadeiro contém componentes de médias móveis. Para confirmar esta hipótese, calculou-se os coeficientes da função de autocorrelação parcial representado na Figura 4.




FIGURA 4 - Coeficientes da função de autocorrelação parcial

Através da Figura 4, observa-se que somente $\phi_{kk}= 1$ apresenta valor significativo, indicando que a série de vendas semanais de sacos de rãfia possui um componente auto-regressivo de ordem 1. Assim, analisando o comportamento conjunto das funções de autocorrelação e autocorrelação parcial, existem dois modelos que podem ser ajustados, um modelo ARIMA (1,0,2) e um modelo ARIMA(0,0,2). Na Tabela 1, apresenta-se os parâmetros estimados e o erro padrão das estimativas para o modelo ARIMA(0,0,2), pois o coeficiente auto-regressivo

de ordem 1, não foi significativo, portanto foi retirado do modelo.

	Parâmetros	Erro padrão
	μ	4666E2
	θ_1	-0,4272
	θ_2	-0,4904

Fonte: Elaborada pelos autores

TABELA 1 - Parâmetros estimados e o erro padrão da estimativa

Os coeficientes de autocorrelação dos resíduos estão apresentados na Figuras 7.

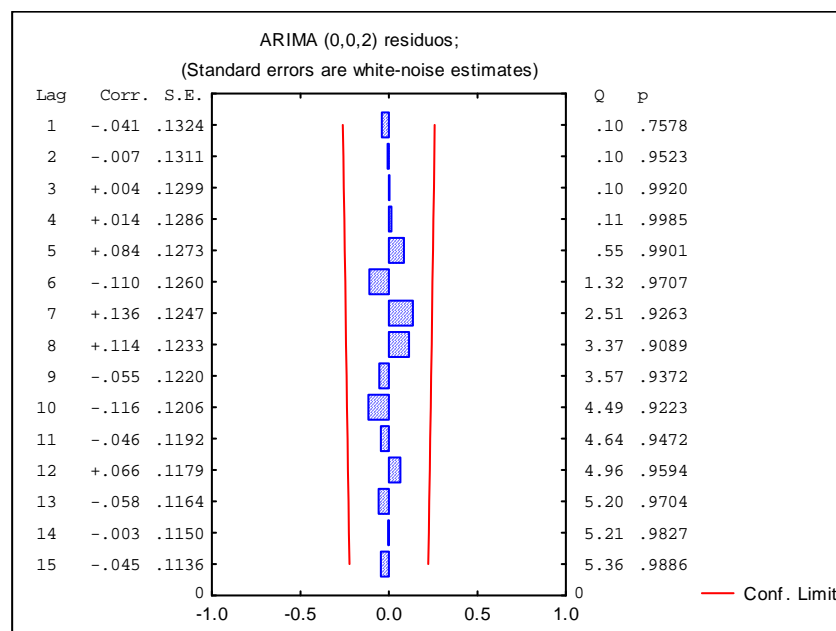


FIGURA 7 - Coeficientes da função de autocorrelação dos resíduos

Como todos os coeficientes estão dentro dos limites ± 2 erros padrões, pode-se concluir que modelo ARIMA(0,0,2) é representativo das observações originais e pode ser utilizado para fazer previsão das vendas semanais de sacaria de rãfia. Com o modelo encontrado foram realizadas previsões, para o período de janeiro a março de 2006, encontrando-se um MAPE de 2,68%. Assim, pode-se concluir que o modelo ARIMA(0,0,2) mostrou um excelente desempenho, pois os valores previstos estão bem próximos dos valores reais de vendas para o período de janeiro a março de 2006.

5. Considerações Finais

O presente trabalho encontrou bases na metodologia desenvolvida por Box & Jenkins (1976). A referida metodologia é uma ótima abordagem para solucionar problemas de ajuste e previsão, pois proporciona modelos extremamente preciso. Após a análise do comportamento dos dados originais e das funções de autocorrelação e autocorrelação parcial, constatou-se que a série de vendas semanais de sacos de rãfia era estacionária, assim ajustou-se dois modelos

ARIMA(1,0,2), e o modelo ARIMA(0,0,2), sendo que o modelo de médias móveis, é o que foi escolhido, tendo em vista que o componente auto-regressivo não foi significativo. Assim, este modelo mostrou-se adequado na remoção da autocorrelação, e permitiu encontrar uma previsão com um erro percentual médio absoluto muito pequeno. Estas informações são de grande importância para a Empresa que poderá aumentar a sua capacidade produtiva de acordo com as necessidades das demandas do mercado.

Referências

- BALLOU, Ronald H.** *Gerenciamento da cadeia de suprimentos: planejamento, organização e logística empresarial*. 4ª ed. Porto Alegre: Bookmann, 2001.
- BOX, G. E. P. and JENKINS, G. M.** *Time series analysis: forecasting and control., revised edition*. San Francisco: Holden-day. 1976.
- KRAJEWSKI, L. & RITZMAN, L.** *Operations Management, Strategy and Analysis*. 5. ed., New York: Addison-Wesley, 1999.
- MENEZES, E. M. & SILVA, E. L.** (2001). Metodologia da Pesquisa e Elaboração de dissertação. 3ª edição revisada. Florianópolis: Laboratório de Ensino a Distância da UFSC. Disponível em www.ead.ufms.br/marcelo/orienta/Metodologia. Acesso em: 03 abril de 2006.
- MINTZBERG, H.** *A criação Artesanal da Estratégia*. São Paulo: Editora Campos, 1987.
- PORTER, M.** *Estratégia Competitiva – Técnicas para a análise de indústrias e da concorrência*. Ed. Campos, 1980