

## CADERNOS DO IME – Série Estatística

Universidade do Estado do Rio de Janeiro - UERJ  
Rio de Janeiro - RJ - Brasil  
ISSN 1413-9022 / v. 25, n. p. 18 - 35, 2008

# MODELO INTEGRADO PARA PREVISÃO DE VENDAS COMO UMA FERRAMENTA DE COMPETITIVIDADE: UM ESTUDO DE CASO EM UMA EMPRESA DO SETOR TÊXTIL

Geraldo Girardi  
Universidade de Caxias do Sul  
girardi@cpovo.net

Maria Emília Camargo  
Universidade de Caxias do Sul  
kamargo@terra.com.br

### Resumo

*No ambiente de negócios, o planejamento das atividades organizacionais aliado à previsão de vendas, possibilita a otimização dos recursos envolvidos na empresa. Assim, este artigo teve como objetivo adequar modelos de previsão de vendas de forma a auxiliar o gestor na tomada de decisões, proporcionando maior competitividade para a empresa no mercado de atuação. Para tanto, utilizou-se a metodologia estatística para séries temporais, mais especificamente os modelos Box & Jenkins para a previsão quantitativa. Para a previsão qualitativa, utilizou-se o método de julgamento de valor, ou seja, a opinião dos responsáveis pela previsão de vendas da empresa. Com base nas previsões obtidas pelos dois métodos, encontraram-se modelos combinados, utilizando-se o volume de vendas dos principais produtos produzidos nos últimos cinco anos pelo setor de fabricação de tecidos de malha feitos em máquinas circulares de uma empresa têxtil. Através da análise dos fatores que influenciam as vendas, realizada pelos responsáveis pelo planejamento da empresa, foram calculados os modelos integrados. Vários modelos de previsão foram avaliados, resultando que os modelos integrados para a previsão de vendas a curto prazo, baseados em modelos quantitativos e informações qualitativas foram aqueles que apresentaram maior acurácia no processo de previsão.*

**Palavras-chave:** *Previsão; Competitividade; Modelos Box & Jenkins; Modelo Integrado.*

## **1. Introdução**

O processo de globalização tem pressionado as empresas a buscarem maior competitividade, como forma de sobrevivência no mercado, exigindo decisões eficazes por parte dos gestores. Dessa forma, a previsão de vendas possibilita o planejamento das diversas áreas da empresa, pois mediante análise de dados passados ou históricos combinados com a opinião de especialistas, podem ser realizadas previsões à curto prazo, fornecendo as informações necessárias aos gerentes nas tomadas de decisão.

Em um ambiente de negócios, com mudanças constantes e cada vez mais rápidas, os métodos de previsão têm ajudado na orientação quanto ao direcionamento futuro de variáveis que influenciam os planejamentos de curto, médio e longo prazo (GEORGOFF & MURDICK, 1986).

Previsões de futuro são indispensáveis para o planejamento e formulação de estratégias das empresas. Neste sentido, a previsão de vendas permite verificar tendências futuras que poderão impactar na organização. A integração entre a previsão e o processo de planejamento aumenta a possibilidade da empresa adaptar-se às oportunidades e aos riscos do mercado, aumentando a probabilidade de sucesso da organização (MAKRIDAKIS, 1996).

O artigo está organizado da seguinte forma: na seção 2, apresenta-se o referencial teórico, na seção 3 descreve-se a metodologia utilizada na pesquisa; na seção 4 é apresentado o estudo de caso e na seção 5 descreve-se as considerações finais.

## **2. Referencial Teórico**

### **2.1 Competitividade**

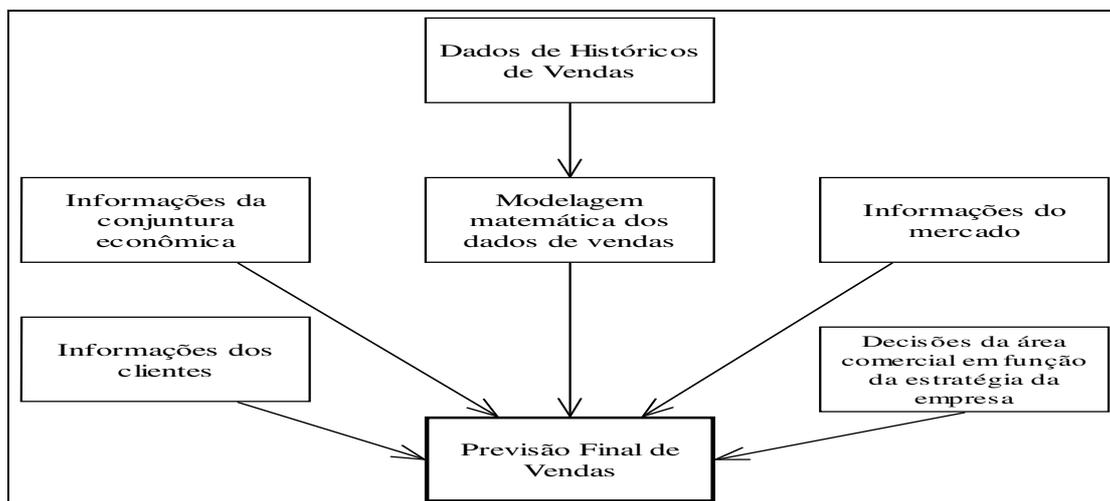
Para Wacker e Cromatic (1979) a função da previsão de vendas é um fator de equilíbrio entre oportunidades mercadológicas e a utilização de recursos, os quais proporcionam lucratividade do negócio e, como consequência, maior competitividade no mercado de atuação.

A utilização de um sistema de previsão preciso representa um fator de competitividade, pois isto proporciona à empresa, uma melhor visão do mercado futuro, podendo assim, articular-se de forma mais eficiente com seus clientes (SILVA, 2001).

## 2.2 Previsão de Vendas

O sistema de previsão de vendas é o conjunto de procedimentos de coleta, tratamento e análise de informações que objetiva gerar uma estimativa de vendas futuras, conforme Figura 1:

Figura 1 – Sistema Genérico de Previsão de Vendas



Fonte: Adaptado de Corrêa, Giansesi e Caon (2001), p. 247

Esse modelo de previsão de vendas inicia com um tratamento estatístico, por meio de séries temporais ou modelos causais dos dados históricos de vendas, que constituem o método quantitativo de previsão. As demais informações sobre o mercado, os clientes e a própria situação econômica afetam a previsão de vendas, fazendo parte do método qualitativo de previsão. A previsão de vendas pode revelar tendências de mercado e contribuir com o planejamento estratégico da empresa, além de auxiliar na solução de problemas de curto prazo (WERNER & RIBEIRO, 2003).

## 2.3 Métodos de Previsão

O método de previsão de vendas que uma empresa pode adotar depende de vários fatores, incluindo: horizonte de previsão (curto, médio ou longo prazo), disponibilidade de dados históricos, precisão desejada, orçamento disponível e disponibilidade de pessoal qualificado para operacionalizar o modelo. Os diversos métodos de previsão de demanda podem ser classificados em duas categorias principais: os métodos qualitativos e os métodos quantitativos (DAVIS; AQUILANO; CHASE, 2001).

Os métodos qualitativos trabalham com opiniões e sentimentos, sendo subjetivos em sua essência. Os métodos qualitativos são normalmente utilizados quando os dados históricos são escassos ou inexistentes e o horizonte de previsão é de médio a longo prazo (GEORGOFF & MURDICK, 1986). A utilização de métodos estruturados no processo de previsão subjetiva melhora significativamente a acurácia dos resultados alcançados pelo método utilizado na previsão (ARMSTRONG, 1988).

Os métodos quantitativos são aqueles que utilizam modelos matemáticos para análise dos dados, como forma de realizar a previsão, permitindo que diferentes especialistas obtenham previsões idênticas (MOREIRA, 2004). Esses métodos são objetivos e fundamentados, podendo trabalhar com grande volume de dados (CHAMBERS; MULLICK; SMITH, 1971).

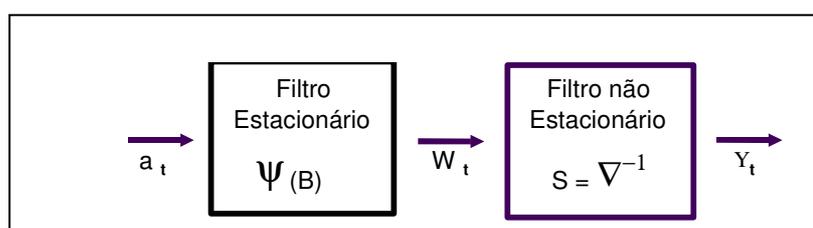
Os métodos quantitativos podem ser divididos em dois grandes grupos: séries temporais e métodos causais. Neste trabalho, em função dos seus objetivos, são abordados os modelos de séries temporais, mais especificamente os modelos de Box & Jenkins.

### 2.3.1 Modelos ARIMA

Nesse trabalho, dentre os vários modelos de séries temporais, escolheu-se trabalhar com os modelos ARIMA de Box & Jenkins, porque quando comparados com os demais métodos de previsão, a metodologia Box & Jenkins apresenta resultados mais precisos e os modelos apresentam um menor número de parâmetros (MORETTIN; TOLOI, 1987).

Os modelos ARIMA (p,d,q), Autoregressivos Integrados a Média Móvel assumem que a série temporal  $Y_t$  é uma realização particular de um processo estocástico gerado pela passagem sucessiva de um processo ruído branco  $a_t$  a uma seqüência de dois filtros lineares: um estável e outro instável, como apresentado na Figura 2.

Figura 2 - Representação teórica de um modelo ARIMA (p,d,q)



Fonte: Elaborado a partir de Box; Jenkins, 1976

Quando se tem uma série não estacionária, deve-se, antes de ajustá-la a um modelo estacionário (MA, AR, ARMA), torná-la estacionária pela remoção de padrões não-estacionários (por exemplo, tendência e sazonalidade) da série temporal analisada. Desta forma, a série temporal deve ser transformada para tornar-se estacionária em relação a sua média, obtida através da diferenciação discreta ( $\nabla^d$ : operador de diferença de ordem  $d$ ), e estacionária em relação à variância, através da transformação geral de Box-Cox, logarítmica, raiz quadrada ou exponencial (MAKRIDAKIS; WHELLWRIGHT; HYNDMAN, 1998).

A segunda 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 ARMA 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.

As funções de autocorrelação (ACF) e autocorrelação parcial (PACF) são funções necessárias para verificar se uma série temporal é estacionária ou não, e também, para a determinação da ordem dos modelos de Box & Jenkins. Para séries temporais estacionárias, ambos os coeficientes ACF e PACF tendem a zero, enquanto que as séries não-estacionárias apresentam coeficientes significativamente diferentes de zero para vários períodos de tempo da série temporal (BOX; JENKINS; REINSEL, 1994).

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

a) 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*  $k$ .

A ordem auto-regressiva  $p$  é determinada pela verificação da função de autocorrelação parcial (FACP),  $\phi_{kk}$ , 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  $\phi_{kk}$  para se verificar até que ordem de defasagem do correlograma desta função ele é estatisticamente significativa. Essa será sua ordem auto-regressiva.

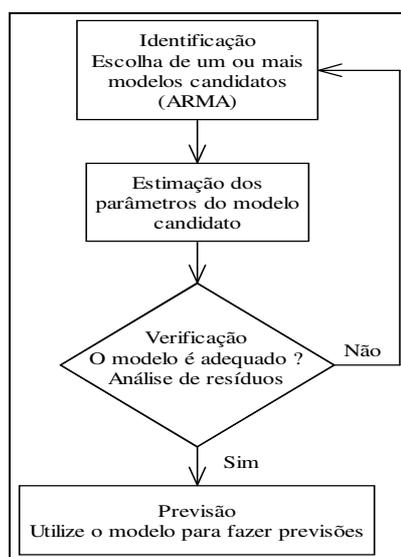
A ordem médias móveis  $q$  é determinada pela verificação da função de autocorrelação (FAC) da série que está sendo analisada. Se a série for unicamente médias móveis ARIMA (0,d,q), sua função de autocorrelação apresentará uma queda rápida após o *lag*  $k$ . Do contrário, analisam-se os outros estimadores  $k$  para se identificar até que ordem de defasagem 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).

b) Estimação dos parâmetros: Esta etapa da metodologia consiste em estimar os parâmetros cada um dos modelos Autoregressivos ( $\Phi$ ), de médias móveis ( $\Theta$ ), e a variância de dos erros. Esta estimação é realizada através do método de máxima verossimilhança.

c) Verificação da adequação do modelo: Esta etapa consiste em avaliar se o ajuste do modelo através do comportamento da função de autocorrelação residual. Caso o modelo não seja adequado, o ciclo é repetido, voltando-se para a fase de identificação.

d) Previsão: É a etapa da extrapolação dos dados históricos através do modelo encontrado. Na Figura 3, apresenta-se o fluxograma do ciclo iterativo de Box & Jenkins.

Figura 3 – Fluxograma do ciclo iterativo de Box & Jenkins



Fonte: Adaptado de Box; Jenkins (1970)

### 2.3.2 Modelo ARMA com intervenção

O modelo estacionário ARMA(p,q) com intervenções pode ser representado

pela equação (BOX ; TIAO, 1975): 
$$\hat{X}_t = \sum_{j=1}^k \frac{\varpi_j(B)B^b}{\delta_j(B)} I_{i,t} + \frac{\theta(B)}{\phi(B)} a_t \quad (1)$$

Onde:

$X_t$  = variável em estudo;

$\hat{X}_t$  = variável estimada pelo modelo no período t;

$\phi(B) = (1 - \phi_1 B - \dots - \phi_p B^p)$ , é o polinômio autoregressivo de ordem p;

$\theta(B) = (1 - \theta_1 B - \dots - \theta_q B^q)$ , é o polinômio de médias móveis de ordem q;

$a_t$  = é uma seqüência de ruído branco que segue uma  $N(0, \sigma_a^2)$ ;

$I_{j,t}$  : representa as variáveis de intervenção para  $j= 1, \dots, k$ ; para a observação (t) onde ocorreu à intervenção.

$\varpi_j(B) = (\varpi_0 - \varpi_1 B - \dots - \varpi_s B^s)$ ;

$\delta_j(B) = (\delta_0 - \delta_1 B - \dots - \delta_r B^r)$ .

### 2.3.3 Combinação de Métodos de Previsão

O artigo de Bates e Granger (1969) é considerado o marco inicial para a extensa produção sobre métodos combinados de previsões, cujo princípio refere-se à possibilidade de aumentar a precisão das previsões, beneficiando-se da complementaridade da informação contida em cada previsão individual. Esse trabalho decorre da proposição de que a variância esperada dos erros de previsão combinada é inferior à menor das variâncias individuais, e requer que as previsões sejam não-viesadas e não apresentem elevada correlação. Neste estudo de caso foram utilizados dois modelos (quantitativo e qualitativo), produzindo previsões pontuais  $\hat{Y}_{t+1}^{(1)}$  e  $\hat{Y}_{t+1}^{(2)}$  respectivamente, a um passo à frente, a previsão combinada  $\hat{Y}_{t+1}^I$  é obtida pela seguinte

combinação linear: 
$$\hat{Y}_{t+1}^I = \alpha \hat{Y}_{t+1}^{(1)} + (1 - \alpha) \hat{Y}_{t+1}^{(2)} \quad (2)$$

Aqui  $\alpha$  é o peso, sendo que o seu cálculo é feito de modo a minimizar a variância do erro de previsão combinada. Bates e Granger (1969), mostram que os pesos obtidos são inversamente proporcionais às variâncias das previsões individuais. Quando

os erros das previsões não estão correlacionados,  $\alpha$  fica reduzido ao valor dado pela seguinte equação:

$$\alpha = \frac{\sigma_2^2}{\sigma_1^2 + \sigma_2^2} \quad (3)$$

Onde:  $\sigma_1^2$  e  $\sigma_2^2$  são as variâncias dos erros das previsões a serem combinadas

Diversos estudos apontam que uma melhor acurácia das previsões é obtida pela combinação de métodos qualitativos e quantitativos, através da utilização do conhecimento contextual nos processos matemáticos de previsão (RINGUEST; TANG, 1987; CLEMEN, 1989; BLATTBERG; HOCH, 1990; COLLOPY; ARMSTRONG, 1992; WRIGHT; LAWRENCE; COLLOPY, 1996). O sucesso no desenvolvimento de sistemas que respaldam a tomada de decisões pelos gestores da empresa tem produzido ambientes nos quais as análises subjetivas e matemáticas podem ser facilmente combinadas (WRIGHT; LAWRENCE; COLLOPY, 1996).

Tão importante quanto a utilização de métodos quantitativos é a estruturação de um processo que trate as questões relativas ao mercado, de forma a combinar o método quantitativo e o qualitativo, com o objetivo de obter maior acurácia na previsão, através da participação e da co-responsabilidade das pessoas tomadoras de decisões na empresa (FLEURY; WANKE; FIGUEIREDO, 2003).

### 2.3.4 Modelo Integrado

O modelo integrado representa o modelo combinado ponderado pelo fator de ajuste obtido pelas informações sobre os produtos, sobre o mercado e sobre a situação econômica do país fornecidas pelos responsáveis pela realização das previsões de vendas na empresa. Os procedimentos para a determinação do coeficiente de ajuste estão baseados em Werner e Ribeiro (2006), onde o ajuste será demonstrado no desenvolvimento do trabalho. Para se determinar o modelo ajustado, seguiu-se as seguintes etapas:

1ª Etapa: Encontrar o melhor modelo de séries temporais;

2ª Etapa: Encontrar o modelo combinado pela equação (4), ou seja: Modelo combinado =  $\alpha$ (Modelo de séries temporais) +  $1-\alpha$  (modelo utilizado pela empresa)

3ª Etapa: Aplicar o coeficiente de ajuste ( $\gamma$ ):

Modelo Integrado = Modelo combinado \* coeficiente de ajuste

### 2.3.5 Verificação da qualidade das previsões

O critério utilizado para verificar a qualidade de previsões foi o Erro Médio Absoluto Percentual de Previsão (MAPE), dado pela seguinte equação:

$$\text{MAPE}\% = \frac{\sum_{t=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right|}{n} \times 100 \quad (4)$$

onde:  $Y_t$  é o valor atual da série;  $\hat{Y}_t$  o valor previsto e  $n$  é o número de observações utilizadas para cálculo do MAPE (%).

## 3. Aspectos Metodológicos

Este artigo está baseado numa pesquisa aplicada quantitativa, que segundo Silva e Menezes (2001), tem como objetivo gerar conhecimentos para aplicação prática dirigida à solução de problemas específicos, com o uso de técnicas de modelagem estatística.

Esta pesquisa foi realizada em nas seguintes etapas:

*Primeira etapa:* Coleta de dados

Nesta etapa foram coletados os dados referentes às vendas dos principais produtos do setor de fabricação de tecidos de malha feito em máquinas circulares, no período de janeiro de 2002 a dezembro de 2006 da empresa têxtil analisada. Foi realizada uma entrevista com os responsáveis pela previsão de vendas, com o objetivo de obter os dados qualitativos.

*Segunda etapa:* Tratamento dos dados e análise dos modelos

Nessa etapa, foi realizada uma análise exploratória (análise de normalidade e de autocorrelação) dos dados referentes às vendas dos seis principais produtos do setor analisado. Foi construído um modelo quantitativo (ARMA) que melhor representasse o comportamento de cada um dos produtos. Após foi encontrado o modelo combinado com base no modelo quantitativo e nas as previsões utilizadas pela empresa. O modelo combinado de previsão foi ajustado com base nas informações qualitativas dos responsáveis pela elaboração das previsões na empresa, obtendo-se o modelo integrado. Após, foi realizada uma comparação das previsões com base no MAPE (%).

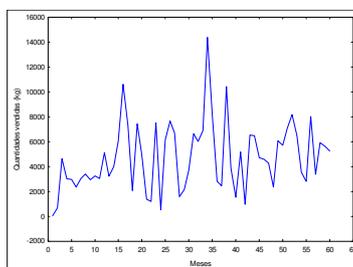
## 4. Estudo de Caso

Nesta pesquisa analisou-se as vendas dos seis principais produtos do setor de máquinas circulares da empresa têxtil do Rio Grande Sul. A modelagem utilizada será demonstrada para o produto C, sendo que a forma da análise é a mesma para os demais produtos.

### 4.1 Modelo ARMA com intervenções

Na Figura 4, apresenta-se o comportamento da série representativa do Produto C, a qual pode-se dizer que ela se desenvolve no tempo aleatoriamente ao redor de uma média, podendo ser considerada estacionária. Quanto à variância, a série não apresenta uma homocedasticidade constante, o que também foi confirmada através do teste F para um nível de significância de 5%, para os subperíodos de 2002 e 2005, cujo valor da estatística calculada foi de 5,02 e a tabelada é de 2,69 para um nível de significância de 5%. Neste caso há a necessidade de se fazer transformações na série original para estabilizar a variância, após várias tentativas, optou-se pela raiz quadrada, pois foi a melhor transformação encontrada.

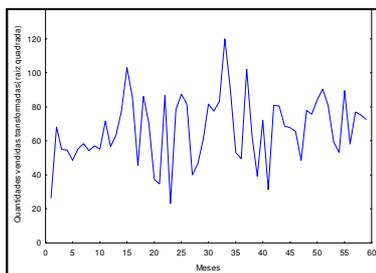
Figura 4: Comportamento da série original do volume mensal de vendas (kg) do Produto C



Fonte: Elaborado pelos autores

A Figura 5 apresenta o comportamento da série transformada. Aplicando-se o teste F para um nível de significância de 5%, cujos valores da estatística calculada para todos os subperíodos encontrados foram 1,98; 1,30; 1,25 e 2,66, e a estatística tabelada foi de 2,69. Assim, pode-se concluir que a transformação aplicada estabilizou a variância, apresentando um *outlier* no período 34 correspondendo ao mês de outubro de 2004.

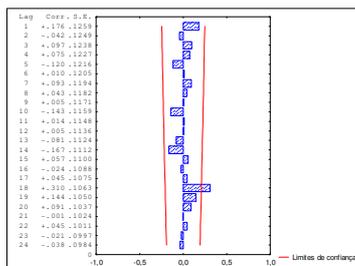
Figura 5: Comportamento da série transformada (raiz quadrada) do volume mensal de vendas (kg) do Produto C



Fonte: Elaborado pelos autores

Nas Figuras 6 e 7 apresenta-se o comportamento das funções de autocorrelação e autocorrelação parcial, necessárias para determinar se a série é estacionária e também para determinar a ordem do modelo.

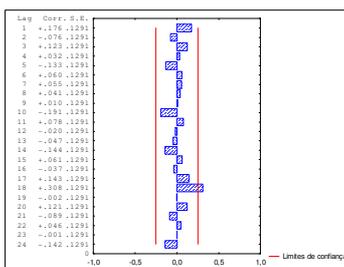
Figura 6: Coeficientes da função de Autocorrelação



Fonte: Elaborado pelo autor

Pela Figura 6, pode-se concluir que a série é estacionária, pois possui um decaimento rápido para zero, apresentando somente um lag  $k=18$  significativo, ou seja, fora dos limites de confiança, indicando que o modelo pode possuir componentes de médias móveis. Da mesma forma, a Figura 7 mostra que os coeficientes de autocorrelação parcial referente ao lag  $k=18$  está fora dos limites de confiança, indicando que a série de vendas mensais do Produto C pode possuir componentes autorregressivos.

Figura 7: Coeficientes da função de Autocorrelação Parcial



Fonte: Elaborado pelos autores

O modelo com intervenção encontrado foi o seguinte:

$$\hat{Y}_t = 4453 + 0,09 Y_{t-1} + 0,16 Y_{t-6} + 0,06 Y_{t-12} + a_t$$

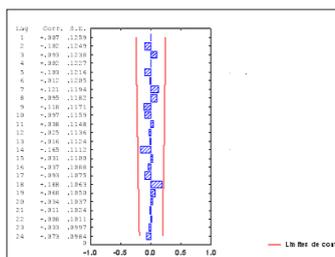
Como os coeficientes autoregressivos  $\phi_1$  e  $\Phi_6$  e  $\Phi_{12}$  não são significativos para  $p < 0,05$ , pois os valores são inferiores ao valor 1,96 correspondente ao nível de significância de 5%, o modelo com intervenção passa a assumir a seguinte forma:

$$\hat{Y}_t = 4453 + 10,764 I_{1,34} + a_t$$

As estatísticas de ajuste foram de  $R^2 = 98\%$  ;  $AIC = -2,78$ ;  $BIC = -2,71$ . O coeficiente de determinação  $R^2$  ficou próximo de 100% ou do valor unitário, que é a situação ideal para a obtenção de uma previsão com acurácia. O Critério de Informação de Akaike (AIC) e o Critério de Schwarz (BIC), que medem a verossimilhança dos modelos e a parcimônia paramétrica apresentaram valores aceitáveis, pois quanto mais próximo estes valores ficarem do zero, melhor será o modelo escolhido para a previsão.

A Figura 8 representa a etapa de verificação, avaliando se o modelo estimado é adequado para fazer as previsões. Conforme pode-se verificar na Figura 8, todos os coeficientes estão dentro dos limites de confiança, demonstrando que a série de resíduos é um ruído branco (aleatório), ou seja, o modelo pode ser utilizado para prever as vendas.

Figura 8: Coeficientes da Função de Autocorrelação dos resíduos do modelo Box & Jenkins



Fonte: elaborado pelos autores

### 4.3 Modelo Combinado

Utilizando-se a equação (2), com as previsões obtidas pelo modelo ARMA com intervenções, as previsões utilizadas pela empresa e com o valor da constante  $\alpha=0,59$ , obtido pela equação (3), encontraram-se as seguintes previsões combinadas para o período de janeiro a abril de 2007:

- Janeiro =  $0,59 \times 4289 + (1 - 0,59) \times 2857 = 3701,9$  kg;

- Fevereiro  $0,59 \times 5078 + (1 - 0,59) \times 5000 = 5046,0$  kg;
- Março =  $0,59 \times 4432 + (1 - 0,59) \times 5200 = 4746,9$  kg;
- Abril =  $0,59 \times 4887 + (1 - 0,59) \times 5000 = 4933,3$  kg.

#### 4.4 Modelo Integrado

Para se determinar o coeficiente de ajuste ( $\gamma$ ), foi realizada uma entrevista com os responsáveis pelo planejamento da empresa, envolvendo o responsável pelo Departamento Comercial e o responsável pelo Planejamento, Programação e Controle da Produção. O Quadro 1, contendo os fatores e os respectivos pesos relativos, que na opinião dos responsáveis, influenciam as vendas ou demanda do mercado. Na primeira coluna do quadro encontra-se o fator que influencia a demanda. Cada responsável colocou a sua opinião, listando quais os fatores que influenciam as vendas. Na segunda coluna, os responsáveis pelas previsões da empresa colocaram o peso que cada fator possui na demanda. Na terceira coluna, calculou-se o peso de cada fator em relação ao total, ou seja, o peso relativo de cada um, denominado Peso Normalizado (PN). Na última coluna, a ser preenchida pelo responsável pela previsão de vendas da empresa, colocou-se a intensidade de manifestação de cada fator que influencia a demanda ou as vendas.

Quadro 1 - Análise Qualitativa com os responsáveis pela previsão de vendas da empresa

Fatores que influenciam a demanda	Responsável 1			Responsável 2		
	P	PN(%)	I	P	PN(%)	I
Preço do Produto	5	11,1 (5/45)	- 1	5	10,2 (5/49)	- 1
Disponibilidade do produto (Rapidez na entrega)	5	11,1 (5/45)	+ 1	5	10,2 (5/49)	+ 1
Concorrência no mercado de atuação	5	11,1 (5/45)	- 1	5	10,2 (5/49)	- 1
Sazonalidade dos produtos (épocas definidas de acordo com a estação)	4	8,9 (4/45)	0	5	10,2 (5/49)	0
Qualidade do produto	3	6,7 (3/45)	0	4	8,2 (4/49)	0
Suporte Técnico Pós-Venda	2	4,4 (2/45)	0	3	6,0 (3/49)	0
Customização dos produtos (clientes montam o produto de acordo com as suas necessidades)	5	11,1 (5/45)	+ 1	5	10,2 (5/49)	0
Inovação nos Produtos (desenvolvimento de novos produtos)	3	6,7 (3/45)	0	3	6,0 (3/49)	0
Atendimento de pedidos pequenos (baixa quantidade a ser produzida e vendida)	3	6,7 (3/45)	0	4	8,2 (4/49)	0
Quantidade de produtos e cores ofertados ao mercado	2	4,4 (2/45)	0	2	4,3 (2/49)	0
Crescimento do setor têxtil	4	8,9 (4/45)	0	4	8,2 (4/49)	0
Situação econômica do País (taxa de câmbio)	4	8,9 (4/45)	0	4	8,2 (4/49)	- 1
Total dos Pesos	45	100 %		49	100 %	

Fonte: Elaborado pelos autores com base em Werner e Ribeiro (2006)

Multiplicando-se o peso normalizado pela intensidade do fator e calculando-se a média ponderada para cada responsável pela previsão, obtém-se o valor que, multiplicado pelo percentual médio de ajuste nos dá o ajuste para cada responsável. Fazendo a média aritmética entre todos os responsáveis, acrescenta-se a unidade, obtém-se o valor do ajuste (no caso, obteve-se para este trabalho, 0,96), que multiplicado pelos valores previstos pelo modelo combinado, nos fornece o modelo integrado.

#### 4.5 Comparação das Previsões

No Quadro 2, apresentam-se os valores das vendas reais, as previsões obtidas pelo modelo ARMA com intervenções, pelo modelo combinado, pelo modelo integrado e as previsões realizadas pela empresa para o período de janeiro a abril de 2007. São apresentados também os valores do Erro Médio Absoluto Percentual de Previsão (MAPE%).

Quadro 2: Comparação das previsões de acordo com o MAPE% para o produto C

Meses/ 2007	Modelo ARMA com intervenções	Modelo Combinado	Modelo Integrado	Previsão da Empresa	Venda Real do Produto C
Janeiro	4289	3701,90	3553,80	2857	3351
Fevereiro	5078	5046,00	4844,20	5000	4876
Março	4432	4746,90	4557,00	5200	4436
Abril	4887	4933,30	4736,00	5000	5910
MAPE (%)	12,38	9,37	7,32	12,60	-----

Fonte: Elaborado pelos autores

Pode-se observar que o modelo integrado apresentou um MAPE (%) menor do que melhor modelo quantitativo (modelo ARMA com intervenções), demonstrando a importância de se utilizar além de dados históricos, informações qualitativas em previsões de vendas.

Para os outros cinco produtos as previsões foram calculadas da mesma forma que o demonstrado para o produto C. Os valores das previsões estão apresentadas no Quadro 3.

##### 4.5.1 Análise das previsões dos seis produtos

O Quadro 3 mostra o comparativo das previsões obtidas pelo modelo ARMA com intervenções, pelo modelo combinado, pelo modelo integrado e as previsões realizadas pela empresa para o período de janeiro a abril de 2007, além do MAPE (%).

Quadro 3 - Comparação dos Métodos de Previsão para todos os produtos analisados através do MAPE

MAPE (%)	Modelo ARMA com intervenções	Modelo Combinado	Modelo Integrado	Previsão da Empresa
Produto A	14,25	13,27	12,75	53,23
Produto C	12,38	9,37	7,32	12,60
Produto D	16,61	16,94	18,26	67,29
Produto E	42,75	44,38	41,50	128,49
Produto H	11,40	12,00	11,52	35,68
Produto M	13,61	12,24	13,81	21,96

Fonte: Elaborado pelos autores

A previsão dos responsáveis pelo planejamento de vendas da empresa, sem dúvida, foi o método com a pior acurácia de todos os métodos analisados. Em todos os produtos analisados, o modelo integrado de previsão apresentou melhores resultados que a previsão dos responsáveis pela empresa. Dos seis produtos analisados, três produtos (A, C e E) apresentaram o valor do MAPE para o modelo integrado menor do que o modelo com intervenção de Box-Jenkins. O modelo combinado apresentou três produtos (A, C e M) com maior acurácia (menor valor do MAPE) quando comparado com o modelo de Box & Jenkins com intervenção.

## 5. Considerações Finais

Os resultados obtidos nesta pesquisa mostram uma boa oportunidade para os gestores aumentarem a competitividade da empresa, através da utilização de uma metodologia de previsão de vendas adequada. A forma atual de previsão de vendas, baseada unicamente na experiência dos responsáveis e alguns dados fornecidos pelos vendedores, foi aquela que apresentou a pior precisão, ou seja, o maior MAPE% em todos os produtos analisados. Desta forma, a aplicação do modelo integrado de previsão, baseado no método quantitativo e qualitativo, apresentou maior precisão na previsão de vendas para todos os produtos, quando comparado com a previsão realizada pela empresa, para o período de janeiro a abril de 2007.

Dos seis produtos analisados, o modelo integrado de previsão de vendas apresentou melhores resultados em três produtos (A, C, e E) quando comparados com os modelos ARMA com intervenções da metodologia de Box & Jenkins. Como o modelo combinado foi calculado através do modelo ARMA com intervenções e da

previsão de vendas realizada pela empresa, e esta última apresentou maior erro de previsão, a previsão por meio do modelo combinado ficou prejudicada, pois incorporou parte deste erro, influenciando assim, o resultado obtido pelo método integrado de previsão de vendas.

### Referências

- ARMSTRONG, J. Scott. **Research Needs in Forecasting. International Journal of Forecasting.** v. 4, n. 3, p. 449-465, 1988.
- BATES, J.M.; GRANGER, C.W.J. **The Combining of Forecasts. Operational Research Quarterly,** v. 20, n. 4, p. 451-468, 1969.
- BLATTBERG, Robert C.; HOCH, Stephen J. Database Models and Managerial Intuition: 50% Model + 50% Manager. **Management Science,** v. 36, n. 8, p. 887-899, 1990.
- BOX, George Edward P. & JENKINS, Gwilym M. **Time Series Analysis: Forecasting and Control. Revised edition.** San Francisco: Holden-Day, 1976.
- BOX, George Edward P.; JENKINS, Gwilym M & REINSEL, Gregory C. **Time series analysis - forecasting and control.** 3. ed. New Jersey: Prentice Hall, 1994.
- BOX, G.E.P. & TIAO, G.C. Intervention analysis with applications to economic and environmental problems. **Journal of the American Statistical Association,** 70, 70-79, 1975.
- CHAMBERS; John C.; MULLICK; Satinder K.; SMITH, Donald D. How to Choose the Right Forecasting Technique. **Harvard Business Review,** jul/agosto, p. 45-74, 1971.
- CLEMEN, Robert T. Combining Forecasts: A Review and Annotated Bibliography. **International Journal of Forecasting.** v. 5, n. 4, p. 559-583, 1989.
- COLLOPY, Fred; ARMSTRONG, J. Scott. Ruled-based Forecasting: Development and Validation of an Expert System Approach to Combining Time Series Extrapolations. **Management Science.** V. 38, n. 10, p. 1394-1414, 1992.
- CORRÊA, Henrique L.; GIANESI, Irineu G.N.; CAON, Mauro. **Planejamento, Programação e Controle da Produção.** 4. ed. São Paulo: Atlas, 2001.
- DAVIS, Mark M.; AQUILANO, Nicholas J.; CHASE, Richard B. **Fundamentos da Administração da Produção.** 3. ed. Porto Alegre: Bookman, 2001.
- FLEURY, Paulo F.; WANKE, Peter; FIGUEIREDO, Kleber F. **Logística e Gerenciamento da Cadeia de Suprimentos: Planejamento do Fluxo de Produtos e dos Recursos.** Coleção Coppead de Administração. Centro de Estudos em Logística (CEL).1 ed. São Paulo: Atlas, 2003.
- GEORGOFF, David M.; MURDICK, Robert G. Manager's Guide to Forecasting. **Harvard Business Review.** v. 64, n. 1, p. 110-120, Jan. 1986.
- MAKRIDAKIS, Spyros. Forecasting: its role and value for planning and strategy. **International Journal of Forecasting.** v. 12, n. 4, p. 513-537, Dec. 1996.
- MAKRIDAKIS, Spyros; WHEELWRIGHT, Steven; HYNDMAN, Rob. **Forecasting: Methods and Applications.** 3. ed. New York: John&Sons, 1998.

MOREIRA, Daniel A. **Administração da Produção e Operações**. São Paulo: Pioneira Thomson Learning, 2004.

MORETTIN, Pedro A.; TOLOI, Clélia M. **Séries Temporais**. 2. ed. São Paulo: Atual, 1987.

RINGUEST, Jeffrey L.; TANG, Kwei. Simple Rules for Combining Forecasts: Some Empirical Results. **Socio-Economic Planning Science**. v. 21, n.14, p. 239-243, 1987.

SILVA, Christian Luiz. Competitividade: mais que um objetivo, uma necessidade. **Revista Faebusiness**, n.1, nov. 2001.

SILVA, E.L. e MENEZES, E.M. **Metodologia da Pesquisa e Elaboração de dissertação**, 2001. 3ª edição revisada. Florianópolis: Laboratório de Ensino a Distância da UFSC. Disponível em:< <http://www.ead.ufms.br/marcelo/orienta/Metodologia>>. Acesso em: 03 abril 2006, 20:30.

WACKER, John G.; CROMATIC, Jane S. Adapting forecasting methods to the small firm. **Journal of Small Business Management**, S.I., p. 1-7, July, 1979.

WERNER, Liane; RIBEIRO, José Luis Duarte. Previsão de Demanda: Uma aplicação dos Modelos Box & Jenkins na Área de Assistência Técnica de Computadores Pessoais. **Revista Gestão & Produção**, v.10, n.1, p.47-67, abr.2003.

\_\_\_\_\_. Modelo composto para prever demanda através da integração de previsões. **Revista Produção**, v. 16, n. 3, p. 493-509, Set./Dez. 2006.

WRIGHT, George; LAWRENCE, Michael; COLLOPY, Fred. The Role and Validity of Judgment in Forecasting. **International Journal of Forecasting**. v. 12, n. 1, p. 1-8, 1996.

## **INTEGRATED MODEL TO SALES PREVISION HOW COMPETITIVENESS INSTRUMENT: A CASE STUDY AT TEXTILE COMPANY**

### **Abstract**

*In the business setting, the planning of the organizational activities along with the sales forecast enables the optimization of the resources involved in the company. The goal of this paper was to fit models of sales forecast to help the manager on the decision taking process seeking for the biggest competitiveness in the company and its competitors. For that purpose, this dissertation proposed the statistic methodology for temporal series, more specifically the Box & Jenkins methods to quantitative method of forecast and planning task specialist opinion of those responsible for the sales forecast of the company to qualitative method. Through the forecast of the both methods, we chose combined models, using as variables the volume of sales of main products produced by the department of knitting cloth manufacturing on the circular machines of the company in the last five years. The integrated models were calculated analyzing the sales influencing factors realized by the responsible for the planning of the company. Many models of sales forecast were evaluated, resulting that the integrated models to sales forecast on a short term, based on quantitative and qualitative methods, had a better accuracy in the forecasting process.*

**Keywords:** *Forecast; Competitiveness; Box & Jenkins Models; Integrated Model*