

PREVISÃO EM MRP USANDO A TRANSFORMAÇÃO DE BOX-COX ATRAVÉS DO APLICATIVO GLIM, COM APLICAÇÃO.

Edson Marcos Leal Soares Ramos

Doutorando em Engenharia de Produção e Sistemas – UFSC. Florianópolis – SC.
edson@eps.ufsc.br

Andréa Cristina Konrath

Mestranda em Engenharia de Produção e Sistemas – UFSC. Florianópolis – SC
andrea@eps.ufsc.br

Robert W. Samohyl, Ph.D.

Professor do Programa de Pós-Graduação em Engenharia de Produção e Sistemas - UFSC. Florianópolis SC.
samohyl@eps.ufsc.br

Abstract

The principal objective of this paper is to offer a quantitative methodology for making forecasts to be used as an essential ingredient for MRP. The forecasts are for an individual product and for the very short-term, which is usually one or two weeks before the delivery date. The forecasting equation is estimated through regression analysis, transforming the dependent variable through a Box-Cox transformation and taking into account tendency and several kinds of seasonality, in the week, the month and the year. The resulting equation is shown to be easy to program and place directly within the MRP computational software.

Key Words: Box e Cox - Forecasting – MRP

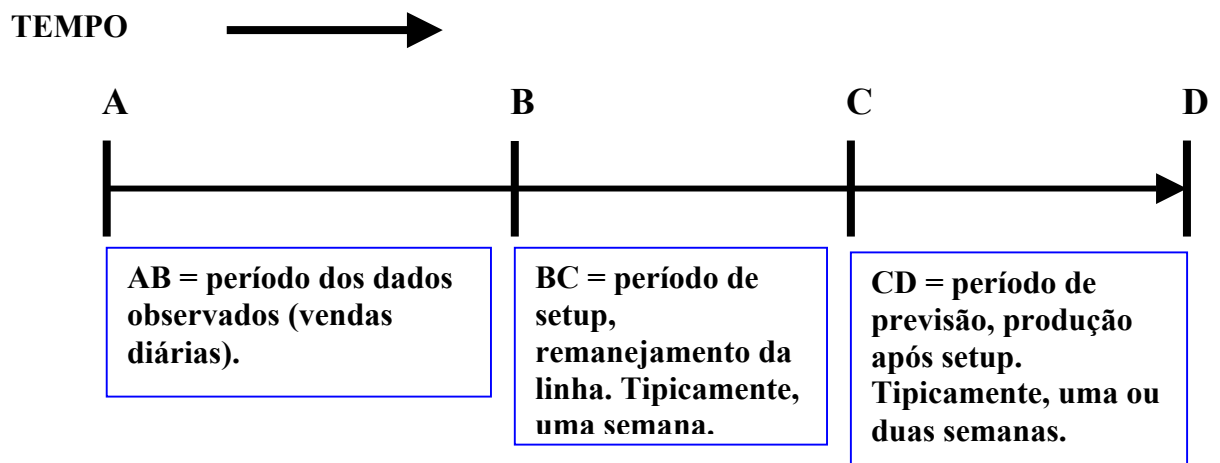
1. Introdução.

A crescente competitividade na economia brasileira certamente melhora a qualidade dos produtos e das operações da linha de produção, mas um dos maiores problemas causados pela competitividade é a dificuldade de prever o futuro das empresas. É impossível dizer hoje onde uma empresa vai atuar nos próximos cinco anos, em termos da sua combinação de produtos oferecidos para o mercado e até mesmo quais mercados serão mais utilizados, quais regiões no Brasil ou exportação para quais regiões do mundo. O planejamento estratégico anual construído entre os diretores e gerentes da empresa e, talvez, com representação dos operários é uma ferramenta imprescindível para definir, e se for possível moldurar, o futuro da empresa nos próximos anos (ver HYNDMANN, et all, 1998). Mas também no curtíssimo prazo, aquele prazo que manda no dia a dia da fábrica, quanto que será produzido hoje, amanhã e na semana que vem e ainda quais produtos, é relevante ter previsões desses prazos mínimos para melhor vincular as operações fabris com as exigências do mercado.

Um dos aspectos mais importantes de Materials Requirements Planning (MRP) é muitas vezes dado um papel menor no processamento dos dados é uma metodologia para a previsão de vendas de bens específicos. A realidade é que as previsões são feitas por um gerente de vendas ou uma equipe e, sem uma metodologia explícita e consistente, nem qualitativa nem quantitativamente. É muito comum a utilização de estimativas de vendas baseadas nas previsões dos próprios vendedores e representantes no mercado. Nossa experiência com este tipo de previsão, indicam que estas são sistematicamente viesadas com forte tendência de superestimar as vendas observadas. Não poderia ser diferente considerando o otimismo inerente na personalidade de um bom vendedor. Esse viés pode continuar durante anos sem ser notado e sem a sua correção periódica. O resultado para a unidade fabril é o acúmulo de estoques muitas vezes em períodos de pagamento de hora-extra seguido por períodos de férias coletivas. Fica muito claro que a instabilidade da produção leva a uma baixa lucratividade da empresa.

Nosso objetivo neste trabalho é oferecer uma metodologia quantitativa para a previsão diária de vendas de peças específicas. No exemplo, dados atuais de uma empresa fabricante de escapamentos são analisados. A metodologia deve incluir a estimativa de tendenciosidade e sazonalidade dos dados, onde sazonalidade é definida numa forma muito geral. A variável vendas sofre vários tipos de sazonalidade. Pode ocorrer a sazonalidade do dia da semana, onde, talvez, segunda-feira exiba mais vendas do que os outros dias da semana. Também, pode ocorrer a sazonalidade dentro do mês que privilegia o final do mês em comparação com o início do mês. O mesmo tipo de resultado pode ocorrer com o ano inteiro, onde vendas tendem a acumular-se sempre em dezembro. Uma segunda característica importante da metodologia é a sua simplicidade. As equações de previsão precisam ser simples para não confundir o programador responsável para a operacionalização do MRP, e a sua estimação também tem que ser simples para que as atualizações sejam feitas periodicamente sem muito perda de tempo.

A montagem de um modelo de previsão e a sua execução e cálculo é apenas uma primeira etapa na utilização de previsões na linha de produção. Para não perder tempo considerando como as previsões devem ser inseridas nos procedimentos fabris, a metodologia quantitativa da estimação das previsões precisa ser de fácil compreensão pelo gerente e de formato pronto e simples para entrar no MRP. Com esse propósito, é necessário em primeiro lugar definir alguns termos comuns à área de previsão e MRP. A figura embaixo representa as séries temporais incorporadas na análise de previsão especificamente para MRP.



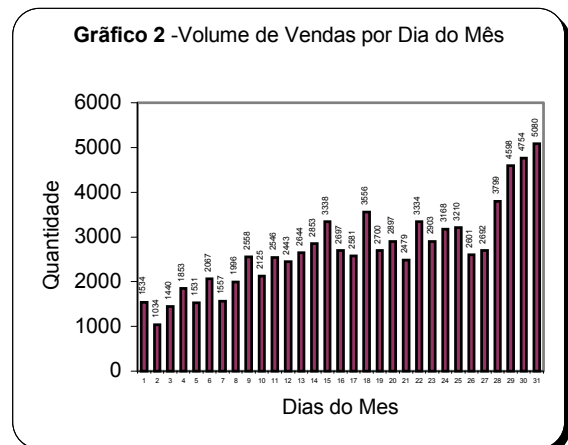

O período dos dados observados é do dia A até dia B. Por exemplo, na aplicação da metodologia oferecida abaixo, temos dois anos de dados diários de vendas. O período BC é o tempo necessário para o remanejamento da linha de produção. Incluído aqui é o setup da maquinaria e a aquisição de matéria prima. Os pontos C e D definem o último dia de setup e o último dia das previsões de vendas, respectivamente. Assim, para ilustrar o uso das previsões, precisamos fixar o tamanho de BC, o período de setup requerido pela fábrica em, por exemplo, 6 dias (uma semana), e o tamanho de CD, o período de previsões, em também 6 dias. Em consequência, se nenhuma previsão for feita e produção for baseada somente em pedidos realizados, o comprador teria que esperar o tempo necessário para a unidade fabril montar a linha de produção e adquirir o material requerido para a produção da peça, neste exemplo o tempo necessário seria de uma semana. Quando as necessidades do tempo de entrega do comprador são menores que o ciclo de tempo da fábrica, a regra e no atual estado de concorrência e não na exceção, aparece assim à necessidade das metodologias de previsão. Operacionalmente, o procedimento da unidade fabril poderia seguir os seguintes passos. O gerente de produção receberá as previsões numa quinta-feira, e teria dois ou três dias de circular as estimativas entre outros gerentes da empresa para serem discutidas e talvez modificadas se for necessário. Na segunda-feira, pode começar o remanejamento da linha de produção (BC) e, na outra segunda-feira, então, a produção da semana (CD) pode se iniciar.

2. Análise Descritiva

A Tabela 1 mostra a grande desuniformidade dos valores observados da variável volume de vendas, apresentando dias onde o número de escapamentos vendidos variou de 0 até 1787. A média diária de vendas ficou em torno de 149 escapamentos, tendo a comprovação da alta variabilidade pelo seu respectivo desvio padrão de 147 escapamentos. Os Gráficos 1 e 2, indicam que segunda-feira e 31 são o dia da semana e o dia do mês, respectivamente, que mais se venderam escapamentos no período observado. Outro fato importante a ser observado é que não existe uma diferença grande de vendas entre os dias da semana. Entretanto, apesar de uma tendência de crescimento, parece ocorrer um aumento de vendas em torno do meio e do fim do mês.

Tabela 1 – Estatísticas do Volume de Vendas Diários

Estatística	Valor
Média	149,15
Mediana	117,00
Desvio Padrão	147,24
Máximo	1787,00
Mínimo	0,00
Assimetria	4,13
Curtose	33,26
Total	84568,00



3. O Modelo

A grande instabilidade do volume de vendas e ainda a existência de sazonalidade e tendenciosidade nos obrigou a uma transformação desta variável. Dentre as diversas opções, optamos pela transformação de Box-Cox (ver Box & Cox, 1964). A transformação de Box-Cox aqui proposta, foi obtida através de um programa desenvolvido no pacote estatístico GLIM (Generalized Linear Interactive Modelling) de propriedade da Numerical Algorithms Group Limited (Oxford, Inglaterra.)

A transformação de Box-Cox é dada pela seguinte expressão

$$Y_1 = \frac{Y^\lambda - 1}{\lambda}, \quad (1)$$

onde, Y = variável observada, Y₁ = variável transformada, λ = parâmetro de transformação.

Para efetuar a transformação de Box-Cox, precisamos estimar o valor do parâmetro desconhecido λ. Assim, através do GLIM (ver Cordeiro(1997) e Aitkin & Anderson(1989)), obtivemos o valor de λ que maximizasse a função, isto é, minimizasse os erros de previsão, via estimativas de máxima verossimilhança.

Após estimado o valor de λ, digamos $\hat{\lambda} = -0,4$, realizamos a transformada de Box-Cox, utilizando a Equação (1) e o pacote estatístico GLIM. Ainda, para a formulação do modelo que melhor explicasse o comportamento da variável dependente volume de vendas, foram consideradas as covariáveis dia da semana (SEM), dia do Mês (MÊS), dia do ano (ANO) e valor da série (SER).

4. Resultados

Vários modelos foram testados, com diversas combinações das covariáveis, entretanto o modelo mais adequado aos valores de vendas observados e, cujo desvio de

92,99 foi bem menor que seu respectivo valor crítico de Qui-Quadrado ($\chi^2_{727; 0.05} = 790,84$), foi representado pela seguinte expressão:

$$\hat{Y} = \{1 - 0.4(\beta_0 + \beta_1 \text{Sem} + \beta_2 \text{Mes} + \beta_3 \text{Ano} + \beta_4 \text{Ser})\}^{-2.5},$$

onde \hat{Y} é o volume de vendas estimado.

As estimativas dos parâmetros, são mostradas abaixo.

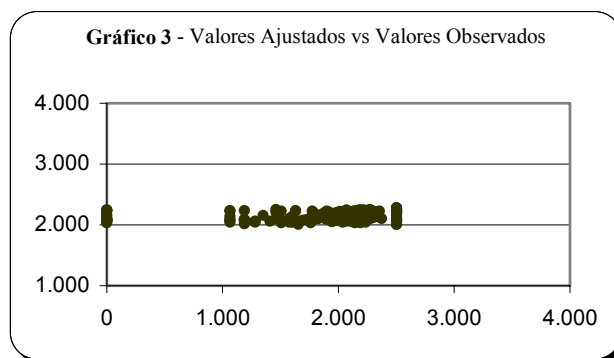
	estimate	s.e.	parameter
1	2.188	0.04671	β_0
2	-0.02673	0.006614	β_1
3	0.001522	0.001509	β_2
4	0.0001651	0.0001258	β_3
5	-4.846e-05	0.00006257	β_4
scale parameter taken as			0.1279

A matriz de correlação, obtida a partir das diretivas do GLIM, indica independência entre as covariáveis.

Correlations of parameter estimates

1	1.0000				
2	-0.5728	1.0000			
3	-0.4693	0.0241	1.0000		
4	-0.4379	-0.0109	-0.0916	1.0000	
5	0.3698	-0.0019	0.0205	0.0066	1.0000
	1	2	3	4	5


Após a transformada de Box-Cox construímos, também, o Gráfico 3- valores observados versus valores ajustados, o qual mostrou uma tendência de linearidade, que é um indicativo de linearidade do modelo obtido.



Obtivemos, também, os resíduos de Pearson através das diretivas do GLIM, os quais mostraram-se dispostos de maneira aleatória, não apresentando outliers. Tais características confirmam o bom ajuste do modelo escolhido aos dados.

O Gráfico 4, resíduos de Pearson ordenados versus os quantis da normal e o Gráfico 5, adequação da função, mostram uma tendência de linearidade indicando, via Gráfico 4, que a distribuição normal, com uma transformação de Box- Cox na variável dependente, utilizada para adequação do modelo, foi escolhida corretamente e que o

modelo é linear e, via Gráfico 5, que também, a ligação identidade foi escolhida corretamente.



Finalmente, o teste de linearidade do modelo, também realizado no GLIM, mostrou abaixo, indicou que houve uma redução de 0,263, isto é, houve uma redução não significativa do desvio, pois é menor que $\chi^2_{1,0.05} = 3,841$ o que significa que o modelo proposto é Linear.

```

$c Teste de Linearidade do Modelo $
$c
$Cal Z=%LP**2 $
$Fit +Z $
deviance = 92.729 (change = -0.2629)
d.f. = 726 (change = -1 )

```

5. Conclusões

Este trabalho é uma primeira tentativa de ilustrar as vantagens da metodologia proposta para a estimação de previsões nos meios empresariais. Como foram constatadas acima, as previsões utilizando nesta metodologia são superiores a outros métodos que não leva em conta a tendenciosidade dos dados e nem a sazonalidade. E a sua aplicação é razoavelmente simples. No entanto, duas ressalvas devem ser enfatizadas:

- Sempre será necessária uma reunião de gerentes da empresa para periodicamente revisar as previsões matemáticas baseado na sua experiência no mercado e até mesmo na própria intuição do momento. No final das contas, depois esgotadas todas as possibilidades técnicas para tomar uma decisão importante, o que faz a diferença entre empresas é o “feeling” dos tomadores de decisão.

- Existem muitas outras técnicas de previsão melhores que a metodologia proposta aqui, no entanto bem mais complicadas e, portanto, mais demoradas e mais caras para implantar na empresa. É recomendável a empresa começar com as metodologias mais simples e lentamente crescer para as metodologias mais complexas e mais completas. Estamos pensando aqui nas metodologias não lineares na análise de séries temporais com a inclusão na equação de variáveis econômicas e financeiras como o crescimento da economia brasileira e suas regiões, taxa de juro, cambio, entre outras, fazendo com que a tomada de decisão se coloca dentro de possíveis cenários nacionais e internacionais.

6. Referência Bibliográfica

AITKIN, Murray, ANDERSON, Doraty et all. **Statistical Modelling in Glim**. United States, Oxford, 1989.

BOX, G.E.P., and COX, D.R. (1964). **An Analysis of Transformation**. J. R. Statist. Soc. 26, pag. 211-252.

CORDEIRO, Gauss. **Modelos Lineares Generalizados**. Universidade Estadual de Maringá, 1997.

HYNDMANN, Rob J. MAKRIDAKIS, Spyros, WHEELWRIGHT, Steven. **Forecasting Method and Applications**. Third edition, United States of America, John Wiley & Sons Inc, 1998.

7. Agradecimento

Este trabalho foi apoiado pelo Núcleo de Normalização e Qualimetria (NNQ) do Programa de Pós-Graduação em Engenharia de Produção e Sistemas (PPGEP) da Universidade Federal de Santa Catarina (UFSC). <http://www.qualimetria.ufsc.br>