

3 Previsão da demanda

Este capítulo estuda o processo de previsão da demanda através de métodos quantitativos, assim como estuda algumas medidas de erro de previsão. Num processo de previsão de demanda, o modelo de previsão deve ser definido e, em seguida, seus parâmetros devem ser determinados de modo a reduzir o erro de previsão. As demandas previstas dos itens para o horizonte de planejamento são parâmetros a serem considerados em problemas de planejamento desagregado da produção.

3.1 A importância da previsão

Planejar é decidir agora o que fazer no futuro. Segundo Martins e Laugeni (2005), planejamento é o processo que descreve atividades necessárias para ir da realidade ao objetivo final estipulado. Quando os gerentes planejam, eles determinam no presente quais cursos de ação serão tomados no futuro. O primeiro passo no planejamento é, portanto, prever, ou estimar a demanda futura por produtos e serviços e os recursos necessários para produzi-los. As estimativas da demanda futura comumente são chamadas de previsões de vendas, elas são o ponto de partida para todas as outras previsões na gestão da produção e operações (Gaither e Frazier, 2001).

Atribui-se elevada importância às previsões de vendas, pois suas informações contribuem para eficiência de setores distintos e dependentes dentro de uma organização, já que se tornam entrada tanto para a estratégia de negócios como para previsões dos recursos de produção.

Uma **previsão** é uma avaliação de eventos futuros utilizada para fins de planejamento. Alterações nas condições, resultantes de concorrência global,

mudança tecnológica acelerada e preocupações ambientais crescentes, exercem pressão sobre a capacidade de uma empresa gerar previsões precisas. A importância das previsões vem da necessidade de uma empresa conhecer quais recursos são essenciais para programar suas atividades ao longo do tempo (Ritzman e Krajewski, 2004). Uma boa previsão depende basicamente da decisão a ser tomada e do tempo futuro para o qual se deseja prever. Quanto mais no futuro é a previsão, mais erros o processo conterà, enquanto que quanto mais precisa for a previsão, maior será o custo de se fazê-la.

O presente trabalho tratará a previsão de demanda no curto prazo. Uma situação típica de previsão de curto prazo é a da demanda utilizada no planejamento desagregado, no programa mestre de produção e em controle de estoques.

O processo de previsão de curto prazo, parte do princípio de que o mesmo mecanismo que gerou a demanda no passado irá gerar a demanda futura – este processo é chamado de **modelo de previsão**. Portanto, sabendo o mecanismo gerador, este é usado para gerar as demandas futuras (Silver *et al.*, 1998).

Para Ritzman e Krajewski (2004), as observações repetidas da demanda de um produto ou serviço em sua ordem de ocorrência formam um padrão conhecido como séries temporais. As séries temporais podem ser representadas por dados históricos de vendas, e representam todos os produtos vendidos em cada período em questão. São de extrema importância, pois são a base de dados geradora da informação que moverá a empresa nos períodos seguintes.

3.2 Características da demanda

O desafio de prever a demanda dos clientes encontra-se na raiz da maioria das decisões empresariais. É uma tarefa difícil, porque a demanda por bens e serviços pode variar de maneira expressiva (Ritzman e Krajewski, 2004). Muitas vezes os padrões de variações da demanda são imprevisíveis e fatores incontroláveis determinam uma nova tendência de valores, como por exemplo, a ocorrência de um evento climático.

Os padrões básicos da maioria das séries temporais de demanda são:

- Horizontal: flutuação dos dados em torno de uma média constante;
- Tendência: aumento ou diminuição sistemático na média das séries ao longo dos tempos;
- Sazonal: um padrão repetido de aumentos ou reduções graduais da demanda, dependendo da hora do dia, da semana, do mês ou da estação;
- Cíclico: aumentos ou diminuições graduais da demanda menos previsíveis em períodos mais longos de tempo (anos ou décadas);
- Aleatório: uma variação da demanda que não pode ser prevista.

Os quatro primeiros padrões combinam-se em vários graus para definir o padrão de tempo fundamental para um produto ou serviço. Já o padrão aleatório resulta do acaso e, portanto, não pode ser previsto.

3.3 Etapas da Previsão de Demanda

Para realizar a previsão de demanda a empresa necessita inicialmente realizar a coleta de dados, que incluem os dados históricos de vendas realizadas e vendas perdidas e informações sobre eventos passados, que influenciaram o comportamento das vendas realizadas, e ainda coletar eventos futuros, que podem influenciar as previsões.

Os dados históricos formam uma série temporal. Desse modo, o modelo de previsão que melhor se adapta a essa série será escolhido, de acordo com alguns indicadores, que visam minimizar o erro de previsão.

Após a seleção do modelo, alguns parâmetros são definidos. A utilização de softwares de previsão auxilia esse processo, pois identificam automaticamente o modelo associado ao menor erro, a partir da série histórica inserida.

3.4 Modelos de Previsão

Os métodos ou modelos de previsão para desenvolver previsões de vendas podem ser quantitativos ou qualitativos, por natureza (Gaither e Frazier, 2004).

Os métodos qualitativos ou consenso de opiniões são baseados em opiniões e julgamentos pessoais, enquanto os métodos quantitativos são os métodos que produzem previsões com base em dados estatísticos ou técnicas estatísticas (Lustosa, 2008).

Como no presente trabalho foi aplicado um método quantitativo para realizar a previsão de demanda, somente os métodos quantitativos foram abordados. Para uma análise de métodos qualitativos sugere-se a leitura de Morettin e Tolo (1981).

3.4.1. Métodos quantitativos

Os **modelos quantitativos de previsão** são modelos matemáticos baseados em dados históricos. Esses modelos supõem que dados passados são relevantes para o futuro. Os modelos quantitativos de previsão podem ser aditivos e multiplicativos. As referências tais como Morettin e Tolo (1981) são indicadas para o estudo dos métodos multiplicativos. Neste trabalho, noções básicas dos modelos aditivos serão apresentadas. Os modelos quantitativos de previsão mais conhecidos são:

- Modelo constante;
- Modelo Linear;
- Modelo Sazonal.

3.4.1.1. Modelo constante

No modelo constante não é observada tendência de crescimento nem de decréscimo no nível da demanda, sua expressão matemática é:

$$x_t = a + \varepsilon_t ,$$

onde a é o nível da demanda e ε_t é o erro ou ruído, que apresenta por hipótese uma distribuição de probabilidade com média zero e variância σ^2 .

Para determinar o parâmetro a , a **média simples** dos valores observados da demanda pode ser usada. Por exemplo, a estimativa do parâmetro para um total

de 5 valores da demanda observados é dada por

$$\hat{a}_t = \frac{D_1 + D_2 + D_3 + D_4 + D_5}{5}.$$

E, assim, a previsão para os períodos subseqüentes $t + \tau$ (para $\tau = 1, 2, 3 \dots$) é

$$\hat{x}_{t,t+\tau} = \hat{a}_t.$$

Existem outras técnicas para estimar o parâmetro a , além da média simples. Quando a demanda média varia com o tempo, tem-se uma demanda flutuante. Desse modo, a previsão não seria boa se dados antigos fossem usados. Se no lugar da média simples a **média móvel** é usada, então o erro de previsão pode ser reduzido quando usamos os dados mais recentes. A média aritmética dos dados corresponde a um número específico de períodos de tempo mais recentes, chamado de período de recorrência, é usada para fazer a estimativa do parâmetro.

Se o período de recorrência envolver, por exemplo, três períodos de tempo, então para realizar a previsão da demanda no do período t , deve-se obter a média dos três períodos anteriores a t , ou seja, a média da demanda nos tempos $t - 1, t - 2$ e $t - 3$, ou seja,

$$\hat{a}_t = \frac{D_{t-1} + D_{t-2} + D_{t-3}}{3}.$$

A **média móvel ponderada** segue o raciocínio da técnica anterior, porém, não é usada a média aritmética e sim uma média ponderada, onde cada período recebe pesos ou ponderações que somados são igual a um.

$$\hat{a}_t = \frac{(0,7)D_{t-1} + (0,2)D_{t-2} + (0,1)D_{t-3}}{3}$$

Na técnica de determinação do parâmetro a , chamada **suavização exponencial simples**, são aplicados pesos decrescentes a partir do dado mais recente. Esta técnica leva em consideração todos os dados da série histórica, porém os pesos decrescem ao passo que os dados ficam remotos. A estimativa para a previsão \hat{a}_t é calculada a partir da última previsão realizada no período $t - 1$ adicionada de um coeficiente de ajustamento ou constante de amortecimento α (sendo $0 < \alpha < 1$, geralmente entre 0,01 e 0,3) que multiplica o

valor observado x_t e a previsão \hat{a}_{t-1} no período $t - 1$, como na expressão a seguir:

$$\hat{a}_t = \alpha x_t + (1 - \alpha)\hat{a}_{t-1}$$

Se $\alpha = 1$, a estimativa é sempre a última observação, ou seja, descarta-se todas os dados anteriores. Se $\alpha = 0$, todas as estimativas são iguais à inicial, não sendo usado nenhum dado novo. Portanto, quanto maior o α , maior é o peso que o último dado tem na previsão da estimativa.

3.4.1.2. Modelo linear

Se o mecanismo gerador da demanda apresenta um **modelo linear**, então observa-se crescimento ou decrescimento no nível da demanda. Este modelo apresenta a expressão:

$$x_t = a + bt + \varepsilon_t,$$

onde a é o nível da demanda, b é a taxa de crescimento ou decrescimento da demanda e ε_t é o erro ou ruído aleatório com média zero e variância σ^2 .

Nesse caso, pode-se usar a técnica de determinação dos parâmetros a e b chamada **suavização exponencial dupla**. São usadas duas constantes de suavização ou amortecimento, as constantes α e β , que são chamadas de constantes de Holt e Winters. α é a constante de amortecimento para o nível da demanda, tal como a técnica de suavização exponencial simples, e β é a constante de amortecimento para a tendência e varia entre 0 e 1. As estimativas dos parâmetros são expressas por:

$$\hat{a}_t = \alpha x_t + (1 - \alpha)(\hat{a}_{t-1} + \hat{b}_{t-1})$$

$$\hat{b}_t = \beta(\hat{a}_t - \hat{a}_{t-1}) + (1 - \beta)\hat{b}_{t-1}.$$

No caso do modelo linear, previsão feita no período t para o período $t + \tau$, (para $\tau = 1,2,3$) é dada por:

$$\hat{x}_{t,t+\tau} = (\hat{a} + \hat{b}t).$$

3.4.1.3. Modelo sazonal

O **modelo sazonal** representa, além de um crescimento ou de um decrescimento da demanda, variações em épocas recorrentes da serie histórica de dados sendo estudada. A expressão para o modelo sazonal é:

$$x_t = (a + bt)F_t + \varepsilon_t,$$

onde a é o nível da demanda, b é a taxa de crescimento ou decrescimento da demanda, F_t é o fator de sazonalidade no período e ε_t é o termo de erro com média zero e variância σ^2 .

O modelo sazonal pode apresentar um componente de tendência ($a + bt$) e um componente sazonal (F)_t geralmente associado a uma época do ano. Considerando P o numero anual de períodos sazonais. A técnica de Winters pode ser usada para estimar os parâmetros do modelo. As equações são:

$$\hat{a}_t = \alpha \left(\frac{x_t}{F_{t-P}} \right) + F_t + (1 - \alpha)(\hat{a}_{t-1} + \hat{b}_{t-1})$$

$$\hat{b}_t = \beta(\hat{a}_t - \hat{a}_{t-1}) + (1 - \beta)\hat{b}_{t-1}$$

$$\hat{F}_t = \gamma \left(\frac{x_t}{\hat{a}_t} \right) + (1 - \gamma)\hat{F}_{t-P},$$

onde α, β e γ são constantes de suavização entre 0 e 1.

A previsão feita no período t para o período $t + \tau$ (para $\tau = 1,2,3$) é:

$$\hat{x}_{t,t+\tau} = (\hat{a} + \hat{b}t)\hat{F}_{t+\tau-P}$$

Na técnica de Winters, as estimativas iniciais para os parâmetros a e b são calculadas através da regressão linear. É importante mencionar que a regressão linear não é adequada para realizar previsão de curto prazo.

3.4.1.4. Regressão linear

A regressão linear é obtida via o método dos mínimos quadrados para identificar a relação linear entre as variáveis dependentes e independentes presentes em um conjunto de observações históricas. Na regressão simples existe somente uma variável independente enquanto na regressão múltipla existe mais de uma variável independente. Se o conjunto de dados históricos for uma série temporal, a variável independente será o período de tempo, e a variável dependente na previsão será as vendas ou qualquer unidade que se deseja prever.

Regressão pressupõe equinormalidade, o que significa que os valores observados da variável dependente y são tidos como normalmente distribuídos nas proximidades de seu ponto médio \bar{y} e que o desvio-padrão da previsão σ é constante ao longo da linha de tendência.

O método de regressão linear ou ajustamento de retas consiste em determinar a função: $y = a + bx$, chamada de função de regressão. Nesta função y é a variável dependente e x a independente, a é o nível ou intercepto de y e b é a inclinação da linha de tendências. Seja n o número total de observações. Denote por \bar{y} o valor médio da variável dependente e por \bar{x} o valor médio da variável dependente. As estimativas de a e b são dadas por:

$$a = \bar{y} - b\bar{x},$$

$$b = \frac{\sum xy - \frac{(\sum x)(\sum y)}{n}}{\sum x^2 - \frac{(\sum x)^2}{n}}.$$

Após o cálculo dos parâmetros da regressão, deve-se verificar se existe correlação, calculando o coeficiente de correlação r , que explica a importância relativa da relação entre y e x . O sinal de r mostra a direção da variação, enquanto seu valor absoluto mostra a força da relação. Sua fórmula é:

$$r = \frac{\sum xy - \frac{(\sum x)(\sum y)}{n}}{\sqrt{\left[\sum x^2 - \frac{(\sum x)^2}{n}\right] \left[\sum y^2 - \frac{(\sum y)^2}{n}\right]}}.$$

O coeficiente de correlação r varia entre -1 e 1 , representando uma reta descendente ou ascendente, respectivamente. A correlação perfeita é com $r = 1$ e a reta passa exatamente pelos pontos.

Outra medida de correlação importante é o coeficiente de determinação que representa quanto da variação na variável dependente y é explicada pela variável x ou pela linha de tendência. Sua expressão é:

$$R^2 = \frac{b^2 \left[\sum x^2 - \frac{(\sum x)^2}{n} \right]}{\left[\sum y^2 - \frac{(\sum y)^2}{n} \right]}.$$

onde $0 \leq R^2 \leq 1$. Assim como o coeficiente de correlação, o coeficiente de determinação verifica a força entre as variáveis dependentes e independentes. Quanto mais forte essa relação, maior a probabilidade das previsões resultantes das equações de regressão serem mais precisas.

3.5 Indicadores ou erros de previsão

A precisão da previsão refere-se ao quão perto as previsões chegam dos dados reais. Os indicadores são utilizados para verificar medidas de desempenho do nível de precisão que o modelo de previsão possui. Previsões muito próximas dos dados reais significam erros de precisão baixos, logo são mais aceitas. Quando os erros de precisão são maiores é sinal que o modelo de previsão deve ser alterado ou ajustado.

Considere o erro de previsão entre o valor real X e o valor previsto \hat{X} representado por:

$$e = X - \hat{X}.$$

Para analisar e decidir o melhor modelo de previsão que se ajusta aos dados deve-se levar em conta os indicadores listados nas seções seguintes.

3.5.1. Erro percentual absoluto médio - MAPE

O erro percentual absoluto médio MAPE (*mean absolute percentage error*) representa a média percentual da divisão entre erro de previsão e o valor real.

$$MAPE = \frac{\sum_{i=1}^n \left| \frac{(X_i - \hat{X}_i)}{X_i} \right| (100)}{n}$$

Valores pequenos para o MAPE determinam precisão nos dados previstos.

3.5.2. Erro absoluto médio - MAD

O erro absoluto médio MAD (*mean absolute deviation*) é a soma dos desvios absolutos dos n períodos dividida pelo número de períodos. É representado pela fórmula:

$$MAD = \frac{\sum_{i=1}^n |X - \hat{X}_i|}{n}$$

Se MAD for pequeno, os dados reais seguem estreitamente as previsões da variável dependente e o modelo de previsão fornece previsões acuradas.

3.5.3. Erro quadrático médio – EQM

O erro quadrático médio é dado pela expressão:

$$EQM = \frac{\sum_{i=1}^n (X_i - \hat{X}_i)^2}{n}$$

De uma forma geral, quando os valores do MAD e EQM forem pequenos, os dados reais seguem estreitamente as previsões da variável dependente e o modelo de previsão fornece previsões acuradas.

Além dos indicadores mencionados, acrescentam-se o “P” e o “BIC”, representando respectivamente, o Teste de Ljung Box, que verifica se há autocorrelação, e o BIC, que compara modelos do método de Bayes. Tais indicadores podem ser melhor compreendidos em Morettin (1981).

3.6 Softwares

Os principais softwares para fazer previsões atualmente no mercado estão listados a seguir:

- | | |
|--|--|
| 1. <i>Forecast Pro</i> | 12. <i>Forecasting For Demad – FFD</i> |
| 2. <i>AFS</i> | 13. <i>Freefore</i> |
| 3. <i>tsMetrix</i> | 14. <i>Mactor, MicMac, Morphol</i> |
| 4. <i>SAS</i> | 15. <i>Mathéo Patent</i> |
| 5. <i>SPSS</i> | 16. <i>NeuroShell Predictor</i> |
| 6. <i>SAP</i> | 17. <i>PEERForecaster</i> |
| 7. <i>POM Computer Library</i> | 18. <i>Plataforma Tecnológica Cortex Competitiva</i> |
| 8. <i>Alyuda Forecaster</i> | 19. <i>Puma 3.0</i> |
| 9. <i>Crystal Ball Professional Edition.</i> | 20. <i>VantagePoin</i> |
| 10. <i>DecisionPro</i> | |
| 11. <i>Dynamic Foresight.</i> | |

Os sete primeiros softwares são sugeridos por Gaither e Frazier (2001). Os demais softwares são indicados pelo Centro e Gestão de Estudos Estratégicos (CGEE) e são ferramentas computacionais voltadas para a previsão e predição de eventos associados a tecnologia e informação.