Componentes do sistema de Previsão

- **TÉCNICAS QUANTITATIVAS DE PREVISÃO**
  - ***Séries Temporais***
    - **Decomposição**
    - **Box-Jenkins**
      - **Média móvel**
      - **Suavizamento exponencial**
    - **Resumo dos pontos fortes e fracos**
  - ***Causais***
- **TÉCNICAS DE QUALITATIVAS DE PREVISÃO**
  - ***Composto de Força de Vendas***
  - ***Opinião de Júri de Executivos***
- **SELEÇÃO DO MODELO**
  - ***Horizonte de previsão***
  - ***Grau de acurácia pretendido***
  - ***Dados históricos disponíveis e confiáveis***
  - ***Custo do modelo***
  - ***Complexidade do modelo***
- **MEDIDAS DE ACURÁCIA DO MODELO**
  - ***Viés***
  - ***Desvio absoluto médio (MAD)***
  - ***Erro absoluto médio percentual (MAPE)***
  - ***Tracking Signal***
- **FOCUS FORECASTING**
- **ORGANIZAÇÃO DO BANCO DE DADOS**
- **SOFTWARE**

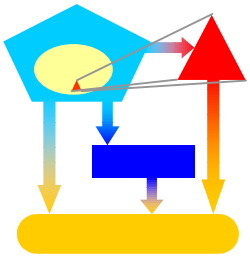

COMPONENTES DO SISTEMA DE PREVISÃO

3.1 Técnicas Quantitativas de Previsão

Existem dezenas de técnicas de previsão, mas elas podem ser divididas em qualitativas e quantitativas. As técnicas quantitativas podem ser classificadas em duas categorias: as Séries Temporais e os Modelos Causais. A principal diferença está nas premissas dos modelos: os modelos causais procuram relações do tipo "causa e efeito" para explicar o comportamento da variável. Já as Séries Temporais se baseiam na hipótese de que o futuro será uma continuação ou repetição do passado.

3.1.1 Séries Temporais

As Séries Temporais ao contrário dos modelos causais tratam a previsão como uma caixa preta não considerando fatores externos, mas somente o padrão existente nos dados históricos.

3.1.1.1 Decomposição

Os métodos de suavizamento não se preocupam em dividir os diferentes componentes dos dados, isolando cada um deles. Já os modelos de decomposição procuram aumentar a acurácia e o entendimento da demanda através da identificação e separação de cada componente da demanda. Os **três** principais componentes são: tendência, sazonalidade e ciclicidade, além da aleatoriedade.

A sazonalidade existe quando ocorrem flutuações na demanda, de acordo com um padrão relativamente constante de período para período, apresentando picos e vales de demanda sempre nos mesmos períodos. Veja a Figura 6.

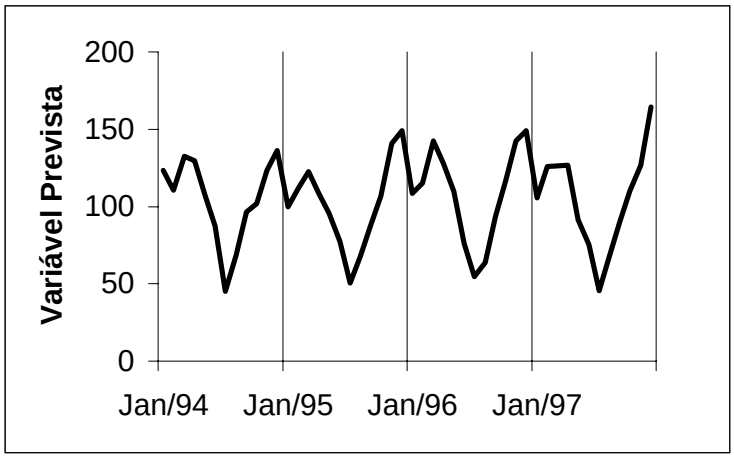

Figura 6 - Padrão de Demanda Sazonal

A diferença entre ciclicidade e sazonalidade é que esta última se repete em períodos relativamente constantes (ano, mês, semana, etc) enquanto a ciclicidade tem durações mais longas que variam de ciclo a ciclo e está em geral ligada a ciclos econômicos. Veja a Figura 7.

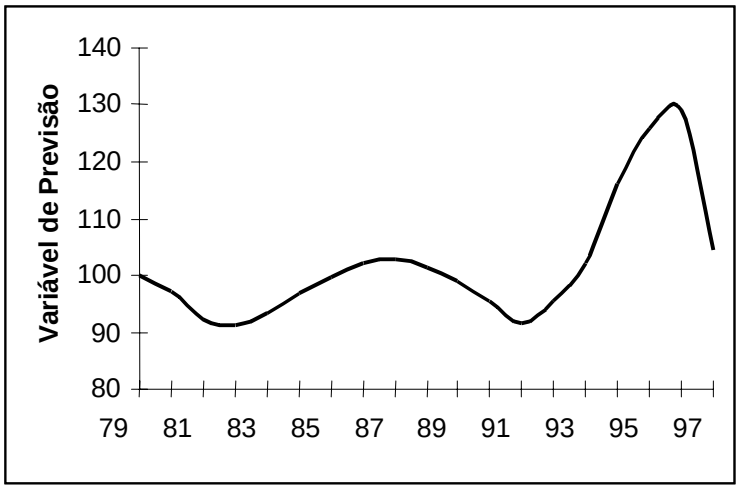

Figura 7 - Padrão de Demanda Cíclica

A tendência está presente quando existem aumentos ou decréscimos consecutivos na demanda. Isso ocorre em geral quando um mercado está em expansão, um produto é lançado, está substituindo outro ou quando uma empresa está conquistando participação de mercado e nos casos inversos. Veja a Figura 8.

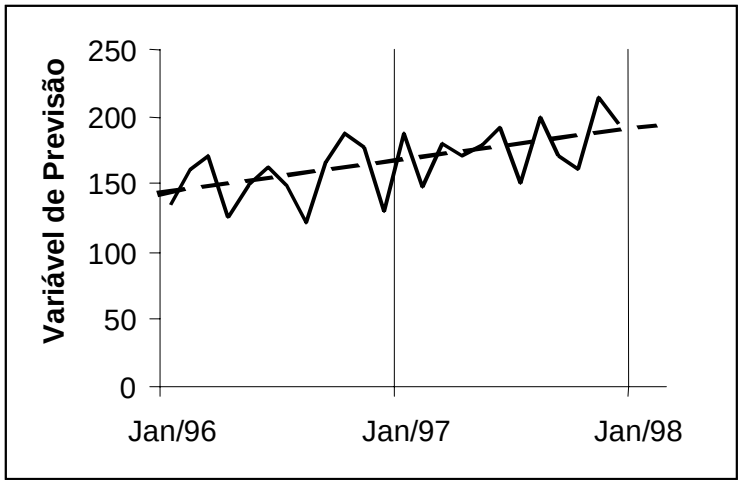

Figura 8 - Padrão de Demanda com Tendência

Existem várias abordagens para a decomposição, o conceito básico de separação dos componentes é empírico e consiste em:

- Primeiro remover a sazonalidade;
- Depois a tendência;
- E finalmente o ciclo.

Na literatura são descritas duas classes de modelos de decomposição: uma aditiva, na qual os componentes são somados e outra multiplicativa, em que eles são multiplicados. Veja a Equação (1) - Modelo de Decomposição Aditivo e a Equação (2) - Modelo de Decomposição Multiplicativo, onde:

- X_t é a demanda, no instante t;
- I_t é o componente de sazonalidade, no instante t;
- T_t é o componente de tendência, no instante t;
- C_t é o componente de ciclicidade, no instante t; e,
- E_t é o componente de aleatoriedade, no instante t.

$$X_t = I_t + T_t + C_t + E_t \quad \textbf{(1)}$$

$$X_t = I_t * T_t * C_t * E_t \quad \textbf{(2)}$$

Pontos Fortes

- A lógica de dividir os dados em tendência, ciclicidade, sazonalidade e aleatoriedade tem um grande apelo intuitivo, o que facilita sua validação e entendimento junto aos usuários.

Pontos Fracos

- O componente cíclica é de difícil determinação e previsão.

Veja a Tabela 3 para uma análise comparativa dos métodos de previsão de séries temporais abordados no trabalho.

3.1.1.2 Box-Jenkins

A abordagem de Box-Jenkins é indicada para previsões de curto prazo (diária, semanal ou mensal, até alguns meses) apresentando bons resultados de acurácia. Apesar disso ela é uma das menos usadas na prática, pois sua complexidade desencoraja os administradores e em alguns casos requer um histórico muito grande.

Box-Jenkins é na verdade é um procedimento de escolha e ajuste de séries temporais. Sua maior vantagem é a versatilidade, ele pode ser utilizado com uma ampla variedade de séries. Isso possibilita a sua utilização numa infinidade de tipos de demanda.

A seguir está a descrição feita por MAKRIDAKIS et al.(1983) desse método. Veja a Figura 9 que detalha o método.

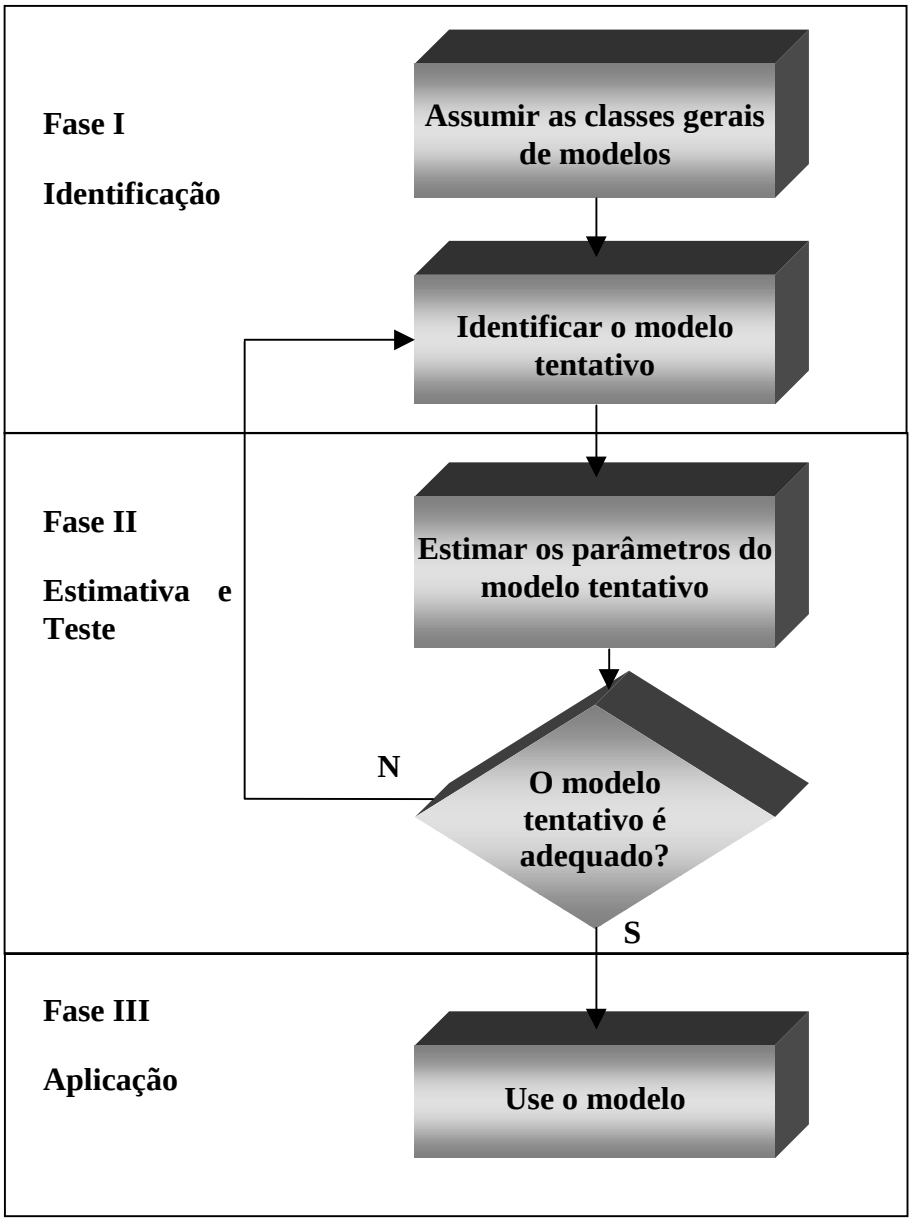

Figura 9 - Esquema da Abordagem do Modelo de Box-Jenkins, transcrita de MAKRIDAKIS et al. (1983)

FASE I - IDENTIFICAÇÃO

Antes de apresentar o método de Box-Jenkins em si, é preciso entender alguns fundamentos das séries temporais. As séries temporais importantes para o estudo do método de Box-Jenkins são as Autoregressivas (AR), as de Média Móvel[1] (MA), Integradas (I) e a combinação delas (ARIMA).

[1] "A notação Média Móvel no estudo de séries temporais não deve ser confundida com as médias móveis dos modelos de suavizamento" (MAKRIDAKIS , 1983, p.357).

As séries Autoregressivas (AR) são aquelas em que o valor da variável estudada é uma regressão dessa mesma variável em períodos passados. Veja a Equação (3) - Equação de Autorregresssão onde :

- Y_i é o valor da variável no período i;
- a, b_1, b_2, ..., b_k são os coeficientes de autoregressão para cada período; e,
- e_t é o erro.

$$Y_t = a + b_1 * Y_{t-1} + b_2 * Y_{t-2} + b_3 * Y_{t-3} + ... + b_k * Y_{t-k} + e_t \quad \textbf{(3)}$$

Veja também a Equação (4) - Exemplo de Série Autorregressiva.

$$Y_t = 3 + 2 * Y_{t-1} \quad \textbf{(4)}$$

A diferença entre a teoria de Autoregressão e Regressão é que na primeira:

1. A hipótese de independência entre as variáveis em geral não será válida; e,
2. A determinação do número de períodos a considerar é bastante complexa.

Nas séries de Média Móvel (MA) a variável será uma função dos erros passados. Veja a Equação (5) - Equação de Media Móvel e Equação (6) - Exemplo de Média Móvel, onde:

- Y_i é o valor da variável no período i;
- a, b_1, b_2, ..., b_k são os coeficientes da equação de média móvel; e,
- e_i é o erro no instante i.

$$Y_t = a + b_1 * e_{t-1} + b_2 * e_{t-2} + b_3 * e_{t-3} + ... + b_k * e_{t-k} + e_t \quad \textbf{(5)}$$

Obs.: No cálculo das previsões "o termo e_t ainda não será conhecido (…) o valor esperado dor erros aleatórios deve ser considerado zero". (MAKRIDAKIS, 1983, p.449)

$$Y_t = 2 + 0{,}8 * e_{t-1} \quad \textbf{(6)}$$

Existem também as séries mistas que são uma combinação entre as Autoregressivas e as de Média Móvel (ARMA). Veja a Equação (7).

$$Y_t = 3 + 2 * Y_{t-1} + 0{,}8 * e_{t-1} \quad \textbf{(7)}$$

Uma outra característica importante das séries para a abordagem feita por Box-Jenkins é se ela é estacionária ou não. A série pode ser não-estacionária com relação a sua média ou a sua variância. Veja a Figura 10, a série (a) mostra um comportamento estacionário no qual a média e a variância são constantes. Já a série (b) não é estacionária, mostrando uma variação em sua média. A série (c) é não estacionária tanto pela variação na média como na variância.

É preciso transformar séries não estacionárias em estacionárias. Desta forma, quando os dados apresentam qualquer tipo de variação que os tornem não – estacionários, então ela é ajustada através do processo de Integração[2] (I).

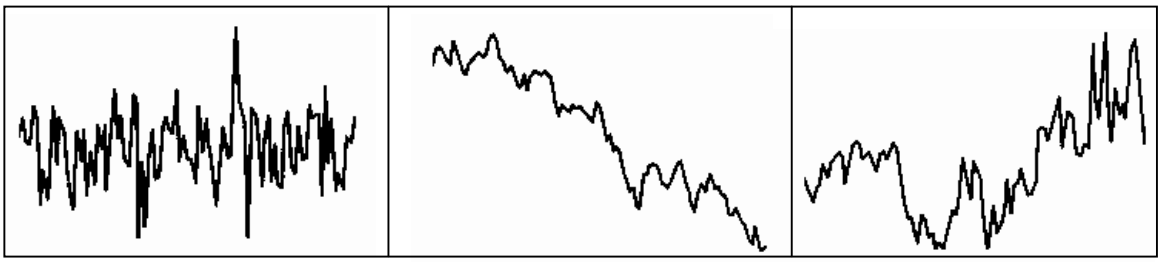

(a) Série estacionária | (b) Série não - estacionária | (c) Série não - estacionária

Figura 10–Ilustração de séries temporais, adaptada de MAKRIDAKIS et al. (1983)

A Equação (8) que inicialmente se parece com uma equação ARMA pode ser rescrita como ainda aparece na Equação (9). Com esse procedimento uma variável Y não estacionária pode dar origem a uma outra $W_t = Y_t - Y_{t-1}$ que eventualmente pode ser estacionária.

A Equação (9) representa a *primeira diferença.* O processo de integração pode ser repetido com W e assim sucessivamente até que se chegue a uma série estacionária. No caso se fizéssemos a Integração de W chegaríamos a integração de segunda ordem de Y.

$$Y_t = Y_{t-1} + e_t \quad \textbf{(8)}$$

$$Y_t - Y_{t-1} = e_t \quad \textbf{(9)}$$

Com esses três componentes são formadas as séries temporais ARIMA que são as séries autoregressivas integradas e de média móvel. Nesse ponto as classes gerais de modelos estão asumidas. Então vem a próxima etapa da FASE I, que é a Identificação do Modelo Tentativo. Isso é feito com a utilização de três ferramentas de análise de séries temporais:

1. Autocorrelação
2. Power Spectrum ou ajuste da Line Spectrum
3. Autocorrelação parcial

A forma geral dessas três ferramentas pode ser observada, genericamente, em quatro exemplos apresentados na Figura 11.

A análise das três ferramentas permite a verificação do tipo de série temporal que melhor se ajusta aos dados. Lembrando que o objetivo deste trabalho é a análise do

[2] Também chamada de Diferenciação

processo de previsão como um todo, não cabe aqui a discussão dessas ferramentas estatísticas, mas vale dizer que é com a análise delas que o modelo tentativo é identificado. Para uma revisão mais aprofundada consultar HOFF (1983).

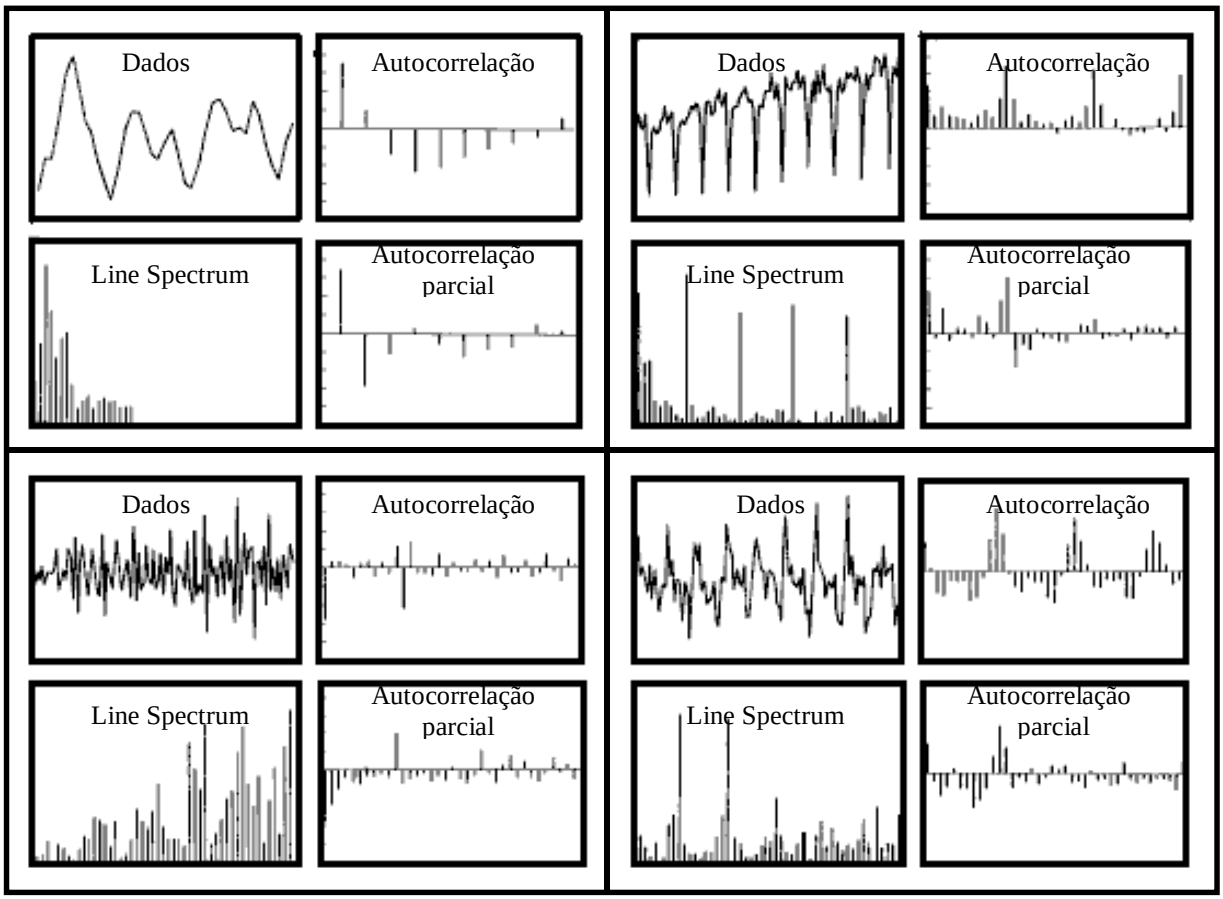

Figura 11 - Exemplos das Ferramentas de Seleção de Modelos, adaptada de MAKRIDAKIS et al. (1983)

FASE II - ESTIMATIVA E TESTE

No início da FASE II tem-se um Modelo Tentativo genérico como, por exemplo, a série representada pela Equação (10) - Modelo Tentativo Genérico.

$$Y_t = a + b_1 * Y_{t-1} + b_2 * Y_{t-2} \qquad \textbf{(10)}$$

A FASE I só vai indicar qual o tipo da série, é na FASE II que os parâmetros serão estimados. Essa estimativa pode ser feita basicamente de duas formas: por tentativa e erro ou com a utilização dos métodos de busca, em geral se prefere a segunda alternativa por ser mais eficiente e barata.

A verificação da adequação ou não do modelo tentativo é feita através da análise do erro. Essa análise é feita utilizando aquelas mesmas ferramentas usadas na FASE I para identificar o modelo tentativo (autocorrelação, a correlação parcial e o Line Spectrum). Novamente, para maior aprofundamento no tema, consultar HOFF (1983).

FASE III - APLICAÇÃO

Uma vez identificada, ajustada e aceita, a série está pronta para aplicação. A sua aplicação se dá através da simples substituição dos dados passados de demanda e erro, na série ajustada.

Pontos fortes

- Uma abordagem de séries temporais bastante flexível, permitindo a previsão de variados tipos de demanda.
- É um dos modelos mais sofisticados e completos para previsão.
- Fortemente indicado para previsões de curto prazo.

Pontos fracos

- Seu entendimento não é trivial, a sua complexidade desencoraja a utilização.
- Requer uma quantidade grande de dados, podendo em alguns caso chegar até a centenas de períodos.
- Usualmente é necessário desenvolver um modelo quando um novo dado de vendas é inserido KRESS; SNYDER (1994).

Veja a Tabela 3 para uma análise comparativa dos métodos de previsão de séries temporais abordados no trabalho.

3.1.1.2.1 Média móvel

Neste trabalho os modelos de média móvel estão classificados como um item dos modelos de Box-Jenkins, pois na verdade os modelos de média móvel são casos particulares de séries ARIMA. Essa constatação é elementar quando analisamos as equações dos modelos de média móvel e verificamos que elas sempre são funções das demandas passadas. A particularidade deste método está na definição dos parâmetros, que não serão tão flexíveis como no modelo de Box-Jenkins.

Os modelos de média móvel são úteis nas previsões de curto prazo para diversos itens devido sua simplicidade e baixo custo. É indicado para produtos com um histórico de pequenas flutuações. Como pode ser visto na Equação (11), quanto mais períodos considerados, maior será o suavizamento, ou seja, menor será o peso de cada período com isso as variações bruscas são suavizadas.

$$Y_t = \frac{Y_{t-1} + Y_{t-2} + Y_{t-3} + \ldots + Y_{t-N}}{N} \qquad \textbf{(11)}$$

O problema apontado no modelo de média móvel é quando existe uma tendência nas vendas. Isso é facilmente entendido quando visualizamos o gráfico de vendas (veja Figura 12) e notamos que a tendência para o próximo mês é de aumento e a previsão é feita com base com os dados dos meses anteriores que são mais baixos. E como se a previsão estivesse sempre “correndo atrás da demanda”.

Para resolver esse tipo de problema existem algumas variantes dos modelos de média móvel que permitem prever adequadamente séries com tendência, como por exemplo, o modelo de média móvel dupla.

Pontos fortes

- Adequado para quando existe um grande número de itens para prever.
- Adequado para itens com demanda estável.
- Suavizam variações aleatórias.
- Podem compensar alguma taxa de tendência com a utilização da média móvel dupla.

Pontos fracos

- Requerem um grande histórico
- Tem resposta lenta para variações na demanda

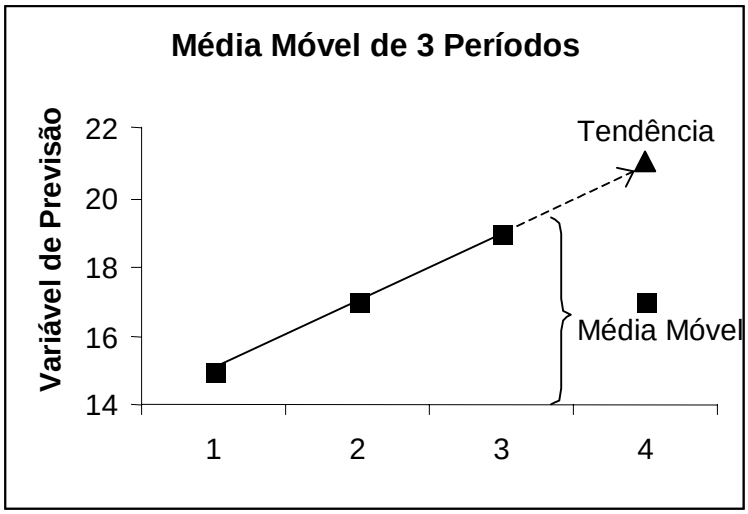

Figura 12 - Média Móvel e Tendência

Veja a Tabela 3 para uma análise comparativa dos métodos de previsão de séries temporais abordados no trabalho.

3.1.1.2.2 Suavizamento exponencial

O modelo básico de Suavizamento Exponencial é dado pela Equação (12) - Modelo Básico de Suavizamento Exponencial, onde:

S_t = Valor da BASE no instante t

α = Constante de suavizamento

Y_t = Valor da série no instante t - se o instante t for passado então o valor de Y é um valor já observado, ou seja, um valor realizado. Se o instante t for futuro então o valor de Y é uma previsão

$$S_{t+1} = \alpha * Y_t + (1-\alpha) * S_t \qquad \textbf{(12)}$$
$$Y_{t+1} = S_{t+1}$$

A constante de suavizamento (α) está limitada ao intervalo [0,1]. Observe que quanto maior a constante maior será o peso dado a demanda mais recente.

Na Equação (12) se substituirmos o valor de S_t chegaremos à Equação (13).

$$Y_{t+1} = S_{t+1} = \alpha * Y_t + \underbrace{(1-\alpha) * \alpha * Y_{t-1} + (1-\alpha)^2 * S_{t-1}}_{(1-\alpha)*S_t} \qquad \textbf{(13)}$$

Se continuarmos substituindo S_{t-1}, S_{t-2}, S_{t-3}, ... chegaremos à Equação (14) - Modelo Básico de Suavizamento Exponencial como uma Série:

$$Y_{t+1} = \alpha * Y_t + \alpha * (1-\alpha) * Y_{t-1} + \alpha * (1-\alpha)^2 * Y_{t-2} + \alpha * (1-\alpha)^3 * Y_{t-3} + \ldots + \qquad \textbf{(14)}$$
$$+ \alpha * (1-\alpha)^{N-1} * Y_{t-(N-1)} + (1-\alpha)^N * S_{t-(N-1)}$$

Os Modelos de Suavizamento Exponencial assim como os de Média Móvel são um tipo particular de uma série ARIMA. MONTGOMERY; JONHSON (1976) apresentam a dedução da Equação Básica do Suavizamento Exponencial a partir de uma série IMA(1,1).

Existem vários Modelos de Suavizamento Exponencial. O mais popular deles é o Modelo de Winter que considera variações relacionadas à tendência e a sazonalidade. Sua formulação básica está apresentada da Equação (16) até a Equação (18).

L = o número de períodos em que a sazonalidade se repete (por exemplo, L será 12 se a previsão for mensal e a sazonalidade anual)

α = Constante de suavizamento

β = Constante de suavizamento da tendência

γ = Constante de suavizamento da sazonalidade

I_t = Índice de sazonalidade do instante t

b_t = Índice da tendência no instante t

Y_t = Valor da série no instante t - se o instante t for passado então o valor de Y é um valor já observado, ou seja, um valor realizado. Se o instante t for futuro então o valor de Y é uma previsão

m = períodos de previsão - se o tamanho do período for um mês e m for 3 então está se fazendo uma previsão para daqui 3 meses

$$S_t = \alpha * \left(\frac{Y_t}{I_{t-L}} \right) + (1-\alpha) * (S_{t-1} + b_{t-1}) \quad \textbf{(15)}$$

$$b_t = \beta * (S_t - S_{t-1}) + (1-\beta) * b_{t-1} \quad \textbf{(16)}$$

$$I_t = \gamma * \left(\frac{Y_t}{S_t} \right) + (1-\gamma) * I_{t-L} \quad \textbf{(17)}$$

$$Y_{t+m} = (S_t + b_t * m) * I_{t-L+m} \quad \textbf{(18)}$$

A determinação das constantes pode ser feita utilizando métodos não-lineares de otimização.

Uma outra forma para o ajuste das constantes é fazê-lo por políticas. Se a demanda daquele item tem um comportamento estável assume-se α pequeno (entre 0,05 e 0,15), para evitar que variações aleatórias afetem as previsões. Já se sua demanda não tem um comportamento muito estável em geral aumenta-se α (entre 0,15 e 0,30), para que a previsão acompanhe as mudanças na demanda. O mesmo tipo de análise deve ser feita para determinar β e γ.

Em geral é desaconselhada a utilização de valores de α grandes (maior que 0,5), pois isso pode tornar o modelo muito reativo, ou seja, toda variação da demanda é incorporada à previsão. Isso ocorre, pois o valor de α multiplica diretamente o valor da última demanda como pode ser visto na Equação (15).

Esse problema pode ser verificado no exemplo da Figura 13. No primeiro caso com o valor de α = 0,2 a previsão varia "suavemente". Já no segundo caso com o α = 0,65 a previsão torne-se instável e "corre atrás" da demanda, aumentando os erros na previsão.

Com relação à dinâmica do método de suavizamento exponencial a Equação (14) deixa claro que a importância do valor inicial (S_0) é pequena, pois em alguns meses o coeficiente que o multiplica será algumas ordens de grandeza menor que os maiores coeficientes (lembre que (α) está limitada ao intervalo [0,1]). Isto significa que quando a utilização do modelo for iniciada o primeiro valor, S_0 pode ser definido arbitrariamente sem grandes conseqüências para o futuro.

Pontos fortes

- Fácil de entender e usar.
- Distribui a importância dos dados ao longo do tempo.
- Visa a eliminação de flutuações aleatórias e isola a média e a tendência.

- Necessita do armazenamento apenas 2 dados históricos de demanda. Isso é uma vantagem em especial quando existe a necessidade de prever uma quantidade muito grande de produtos.

- Boa relação de custo beneficio nas situações de muitos itens.

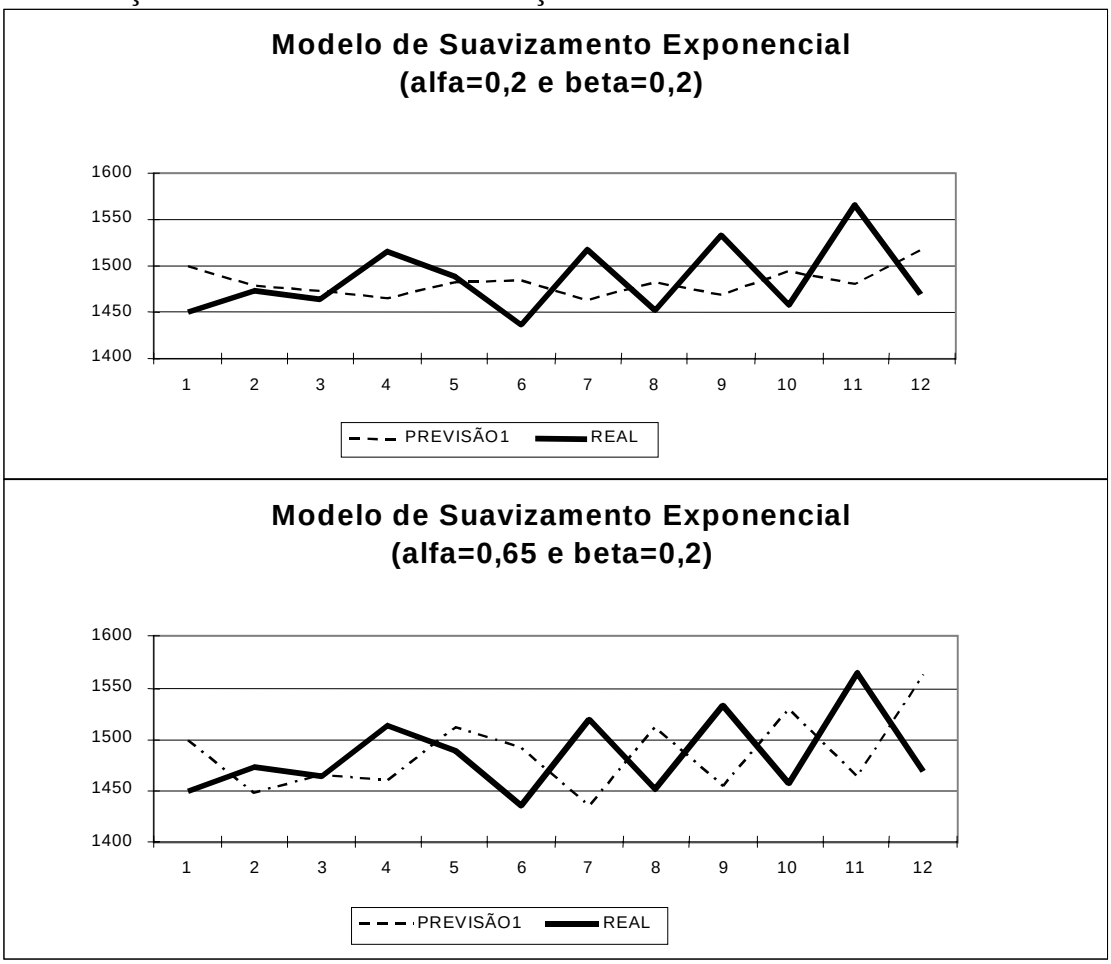

Figura 13 - Conseqüências da constante α muito grande

Pontos fracos

- Fraco resultado para previsões de médio e longo prazo.

- Previsões podem ter grandes erros devido à variações aleatórias nos dados recentes

Veja a Tabela 3 para uma análise comparativa dos métodos de previsão de séries temporais abordados no trabalho.

3.1.1.3 Resumo dos pontos fortes e fracos

Tabela 3 – Tabela Comparativa das Técnicas de Previsão de Séries Temporais

Técnica	Pontos Fortes	Pontos Fracos
Decomposição	Lógica intuitiva facilita sua validação e entendimento junto aos usuários.	O componente cíclica é de difícil determinação.
Box-Jenkins	Abordagem bastante flexível permitindo a previsão de variados tipos de demanda. É um dos modelos mais sofisticados e completos para previsão de séries temporais. Fortemente indicado para previsões de curto prazo.	Seu entendimento não é trivial, a sua complexidade desencoraja a utilização. Necessidade de grande quantidade de dados.
Média móvel	Adequado para quando existe um grande número de itens para prever. Adequado para itens com demanda estável. Amaciam variações aleatórias.	Requerem um grande histórico Tem resposta lenta para variações na demanda
Suavizamento exponencial	Fácil de entender e usar. Visa a eliminação de flutuações aleatórias e isola a média e a tendência. Necessita do armazenamento apenas 2 dados históricos de demanda. Boa relação de custo beneficio nas situações de muitos itens.	Fraco resultado para previsões de médio e longo prazo. Previsões podem ter grandes erros devido a variações aleatórias nos dados recentes

3.1.2 Causais

As técnicas de séries temporais são mais adequadas ao curto prazo, pois assumem que os fatores que influem na demanda se mantêm constantes. Já os modelos causais permitem previsões de maior prazo visto que incluem a análise daqueles fatores que se relacionam com a demanda.

Como já foi dito anteriormente, não há definição ou consenso sobre quais os limites do que é curto, médio ou longo prazo. Entretanto considerando que:

- O curtíssimo prazo é menos do que 1 mês;
- O curto prazo é de 1 a 3 meses;

- O médio prazo é de 3 meses a 2 anos; e,
- O longo prazo é maior que 2 anos.

Então os métodos de suavizamento são usualmente melhores para previsões de curto ou curtíssimo prazo. Os métodos de decomposição e ARMA são indicados para o curto e médio prazo enquanto às técnicas de regressão são adequadas ao médio e longo prazo MAKRIDAKIS et al. (1983).

Dada a sua pequena relevância para previsões de curto prazo os Modelos Causais não serão abordados nesse trabalho. Para uma revisão desses modelos consultar MAKRIDAKIS et al. (1983).

3.2 Técnicas de Qualitativas de Previsão

As técnicas quantitativas têm papel fundamental no Processo de Previsão, entretanto estas técnicas possuem várias limitações que prejudicam seu desempenho e sua validação junto aos administradores.

A utilização de técnicas apenas quantitativas falha em:

- Mudanças na taxa de progresso da economia;
- Ações políticas com influencias diretas no mercado como mudanças em taxas, impostos, bloqueios comerciais, etc.;
- Ganho ou perda significativa de clientes;
- Introdução de novos produtos (alternativos ou concorrentes); e,
- Mudança no padrão de sazonalidade.

Um exemplo disso foi o inicio do Plano Real, em 1993/4, quando a demanda por alguns itens aumentou muito causando escassez no mercado. Ou em 1997 quando ocorreu o contrário e muitas empresas amargaram altos níveis de estoques. A questão é que os modelos quantitativos por si só não são capazes de detectar tais variações, por isso os modelos qualitativos são necessários.

Isso não quer dizer que os modelos qualitativos têm por função substituir os quantitativos, mas sim complementá-los. A utilização apenas dos modelos qualitativos traz algumas características indesejáveis às previsões, como:

- O viés dos métodos de julgamento;
- O excesso de confiança no julgamento;
- Correlações ilusórias;
- Seletividade das informações causada por eventos mais recentes ou mais marcantes;

- Inconsistência no julgamento causada por influência da situação familiar, do clima, saúde, etc.;

"As previsões podem ser elaboradas por abordagens (1) estritamente intuitivas ou de julgamento, (2) estritamente quantitativas e (3) combinando os métodos quantitativos e qualitativos. (...) Abordagens que combinam os melhores elementos de ambas categorias de métodos produzem melhorias significativas nos resultados quando comparadas com aquelas abordagens que usam um ou outro tipo de método." (MAKRIDAKIS , 1983, p.845)

3.2.1 Composto de Força de Vendas

A previsão é feita agregando os dados "de baixo para cima". Cada vendedor faz sua previsão de vendas para cada período. Então as previsões vão sendo agregadas por produto e por região até somar a previsão total.

Os resultados indicam que no curto prazo (2 ou 3 meses) a previsão da força de vendas tem acurácia sensivelmente superior do que no longo prazo. Sua acurácia também é maior quando cada vendedor atende poucos clientes MAKRIDAKIS[3] (1986) apud KRESS; SNYDER (1994).

Esse método se baseia na hipótese de que as pessoas mais próximas dos consumidores são mais capacitadas para elaborar previsões.

Uma outra abordagem do composto de força de vendas é a participação apenas das gerências de vendas. Desta forma a previsão continua sendo feita por pessoas com alto contato com o mercado e com uma visão um pouco mais global do mercado.

Pontos fortes

- Entrada de dados feita pelas pessoas mais próximas ao mercado;
- Gera previsões no nível mais detalhado, por produto, região, canal, etc.; e,
- Aumenta a motivação da força de vendas se suas previsões servirem a tomada de decisão da empresa.

Pontos fracos

- As previsões podem ser subestimadas, caso o pessoal de vendas suspeite que suas quotas são definidas com base em suas previsões;
- Pode tomar muito tempo do pessoal de vendas, numa atividade secundária de sua função;
- A força de vendas pode ser mal informada ou despreparada para fazer a previsão; e,

---

[3] MAKRIDAKIS, S. The Art and Science of Forecasting. **International Jounal of Forecasting.** v.2, p.15-39, 1986.

- O pessoal de vendas é muito vulnerável a acontecimentos recentes, ou seja, pode haver pessimismo ou otimismo originado pelo passado recente.

3.2.2 Opinião de Júri de Executivos

Essa técnica é uma das mais simples e mais utilizadas. Envolve entrada de informações de diversos tomadores de decisão de várias áreas da empresa, em geral de (Vendas, Marketing, Finanças, Manufatura, Planejamento e Compras). As previsões são elaboradas em uma reunião na qual os executivos decidem qual a melhor estimativa de vendas para cada item.

Visto que as previsões da força de vendas são baseadas em aspectos mais locais e particulares, o júri de executivos se mostra apropriado àquelas situações em que a previsão já foi definida, para que então a gerência agregue suas macro perspectivas.

Pontos fortes

A principal vantagem deste método é que a previsão é elaborada por pessoas que, em tese, têm uma visão global do negócio e do cenário econômico. Além disso,

- As previsões são elaboradas com a visão de várias áreas da empresa, assim gera previsão com pontos de vista integrados;

- Os executivos em geral, têm um bom entendimento do mercado e das variáveis que influem na demanda; e,

- As previsões podem ser elaboradas rapidamente.

Pontos fracos

Além do viés das previsões por julgamento, também pode haver interferência das diferenças de poder e aquelas pessoas mais poderosas não serem contrariadas. Se forem utilizadas reuniões abertas, algumas pessoas podem dominar a elaboração da previsão. Em suma a opinião de maior peso pode não ser daquela pessoa melhor informada. Além disso,

- Pode precisar mobilizar vários executivos

- Alguns executivos podem estar desatualizados com o mercado

- Método não se adapta bem naquelas empresas que possuem muitos produtos e que não podem ser agrupados em categorias

Obs.: Uma variação dessa técnica é quando cada executivo faz suas previsões por escrito e as envia para um outro executivo que vai rever todas previsões e elaborar uma final.

3.3 Seleção do modelo

As técnicas têm sido desenvolvidas para aplicações especificas, por isso cuidado deve ser tomado na seleção das técnicas para uma aplicação particular. Quanto mais amplo for o conhecimento do responsável pela previsão sobre as técnicas, e sua aplicação, melhor será o retorno sobre o esforço despendido na previsão.

A seleção do método de previsão depende de diversos fatores: contexto da previsão, relevância e disponibilidade de dados, grau de acurácia desejado, horizonte, custo/benefício e tempo disponível para preparação da previsão, etc.

Para que se faça uma boa seleção do modelo a ser utilizado, antes se deve entender bem quais são as necessidades da empresa.

3.3.1 Horizonte de previsão

É importante saber até que ponto da cadeia de suprimentos a previsão será utilizada. O ideal é que a previsão cobrisse o maior *Lead Time* acumulado. Entretanto, quanto maior o horizonte, menor a acurácia. Essas duas informações devem ser avaliadas na determinação do horizonte de previsão.

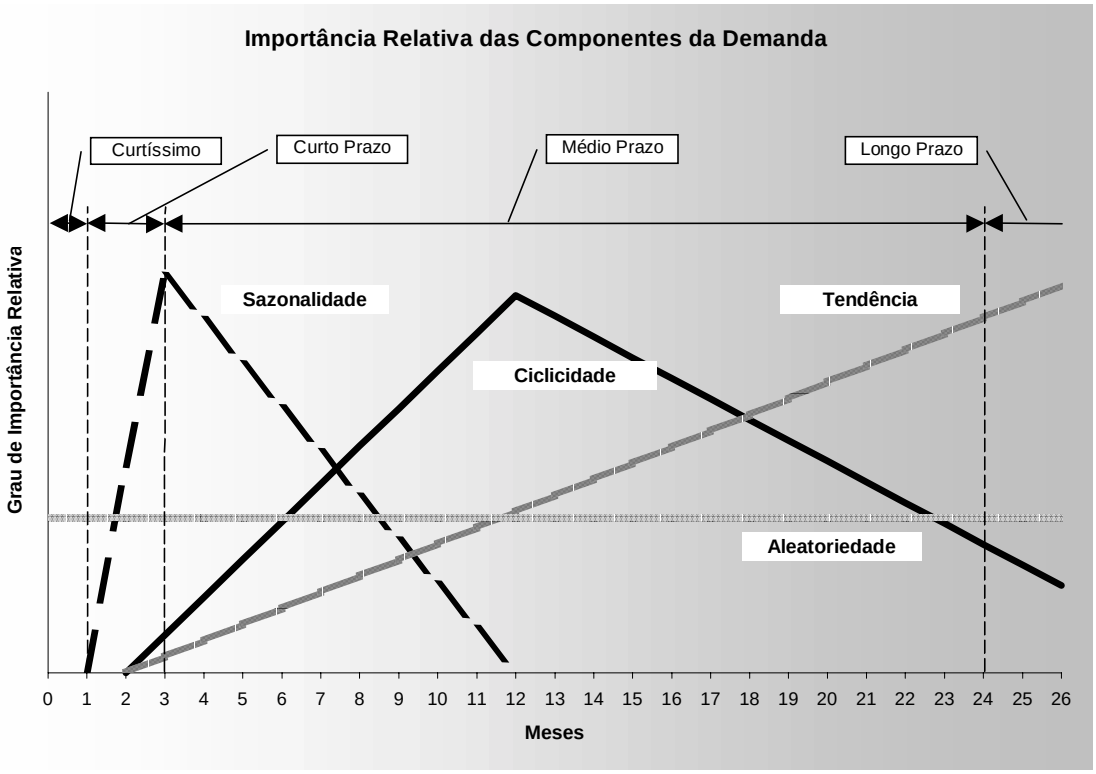

Figura 14 – Importância Relativa dos Componentes da Demanda para Diferentes Horizontes, MAKRIDAKIS et al. (1983)

Essa definição de qual deve ser o período de previsão é importante, pois a importância relativa de cada componente da demanda varia com o horizonte de previsão MAKRIDAKIS et al.(1983). Veja a Figura 14 que compara a importância relativa de cada um dos componentes da demanda com relação ao horizonte. Para as previsões de curto prazo os métodos que tratam melhor a da sazonalidade são preferíveis.

3.3.2 Grau de acurácia pretendido

O modelo deve ser capaz de no mínimo identificar e lidar com os componentes presentes no padrão dos dados (assim como tendências lineares, tendências quadráticas, sazonalidade, etc).

Existem duas abordagens para definição de qual deve ser a acurácia. A primeira é de que a acurácia de sua previsão deve ser melhor do que a da concorrência. De forma que suas decisões levem-no a uma posição de maior competitividade CORRÊA et al. (1997).

Outra abordagem é a de que não se deve medir a acurácia para avaliar o desempenho da previsão, pois a acurácia depende do grau de aleatoriedade do mercado em que se está prevendo. Desta forma duas previsões igualmente “boas” podem ter acurácias diferentes. “Boa” significa que os responsáveis por prever estão trabalhando no processo de previsão. Estão aplicando seus conhecimentos do mercado, dos consumidores e dos futuros planos de Marketing - WALLACE (1997).

Essas duas abordagens parecem complementares. Os responsáveis pela previsão devem entendê-la como um processo cujo resultado deve proporcionar vantagens competitivas para sua empresa.

Apesar dessas considerações é imprescindível que o processo de previsão produza estimativas úteis para permitir à programação da produção, planejamento de estoques, etc. Deve também existir melhoria continua com constante diminuição do erro.

3.3.3 Dados históricos disponíveis e confiáveis

Dependendo do modelo são necessários dados de até centenas de períodos. Além disso, o grau com que os dados representam a realidade é de suma importância para a consistência das previsões.

Previsões úteis só podem ser feitas se os dados forem apropriadamente lançados. O esforço despendido na "limpeza" dos dados pode ser de maior valor do que o algoritmo utilizado.

O primeiro passo para "limpar" os dados é identificar os fatores que distorcem os padrões de demanda. Isto feito, medidas corretivas devem ser tomadas para adequar os dados a previsão.

Existem vários tipos de distorção que podem estar presentes nos dados, como:

1. Distorções relacionadas à falta de produtos;

2. Evento esporádico;
3. Mudanças no produto que tornam seu histórico inadequado para previsão;
4. Realocação territorial de áreas atendidas por cada centro de distribuição;
5. Condições climáticas não comuns ou outros comportamentos " ambientais " raros;
6. Distorções relacionadas a preços.

As distorções devem ser identificadas e removidas dos dados para que esses sejam utilizados pelos programas de previsão. A tarefa de filtrar os dados exige alta capacidade analítica.

3.3.4 Custo do modelo

A coleta dos dados, desenvolvimento e operação do sistema de previsão devem ser considerados para analisar seu custo total. Outro aspecto importante é o tempo disponível para desenvolvimento e implantação do modelo bem como o tempo necessário em cada período para elaborar as previsões.

A qualidade da previsão está refletida na qualidade das decisões tomadas com base nelas. Com isso podemos definir uma medida de desempenho como a relação entre o custo para gerar a previsão e o benefício gerado por ela. Entretanto, esse tipo de custo não é fácil de ser medido nem tão pouco seus benefícios. Mesmo difíceis de mensurar, o responsável pelo desenho do processo de previsão deve saber avaliar quais as conseqüências de uma previsão de má qualidade.

Em sistemas de produção em que existem centenas de produtos o número de previsões também é elevado, requisitando um processo simples, efetivo e de baixo custo.

Na medida que os sistemas de produção podem ter até dezenas de centenas de produtos, os processos de previsão informatizados tornam-se mais necessários e importantes.

3.3.5 Complexidade do modelo

A utilização efetiva das previsões depende da confiança que o responsável por tomar decisões tem no processo de previsão. Por isso, é importante que no desenvolvimento de um processo de previsão, o usuário desta, conheça o processo, não necessariamente em detalhes, mas a sua lógica do modelo e as premissas implícitas nele. Como já foi dito anteriormente, os administradores não gostam de “caixa preta”.

Existe um ponto de discordância entre alguns autores no que diz respeito à análise custo benefício dos modelos de previsão. Alguns defendem a idéia de que os modelos mais sofisticados proporcionam resultados melhores, veja a Figura 15. “O que este gráfico nos diz é que modelos simples custam pouco, mas podem ter um custo elevado para empresa em termos dos erros nas decisões (...) modelos sofisticados e precisos custam caro, porém a contra partida é um menor custo em termos de erro decisório” (WOILER, 1996, p.107).

Na Figura 15 está implícita uma correlação entre o erro e o custo do modelo. É justamente essa correlação que é questionada por alguns autores.

"...os modelos sofisticados e caros não necessariamente são melhores. Aqueles que advogam isso devem justificar sua escolha"(VOLLMANN, 1988, p.696).

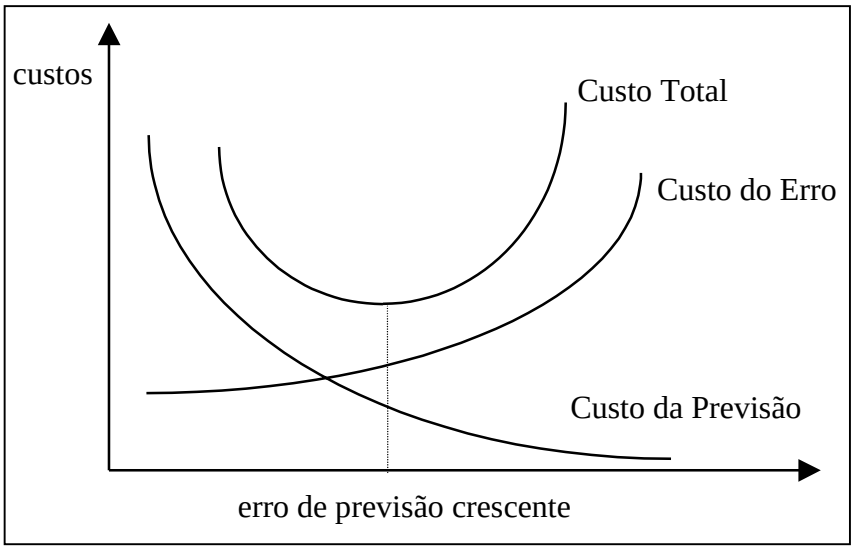

Figura 15 – Relação Custo Benefício Questionada, adaptada de WOILER; WASHINGTON (1996)

"Para previsões de prazos curto e intermediário, necessárias, por exemplo, na gestão de estoques, os métodos a ser utilizados são os métodos mais simples como suavizamento exponencial" (CHASE, 1998, p.535).

"Há 25 anos atrás, se pensava que quanto mais um modelo fosse capaz de representar uma realidade complexa, maior seria sua acurácia. Entretanto na prática os modelos mais complexos não têm apresentado resultados melhores que os mais simples." (BRANDER, 1995, p.7)

Isso não quer dizer que os modelos mais sofisticados não devem ser utilizados, mas que sua utilização deve ser justificada.

Atente para que toda essa análise de custo está restrita ao modelo e não ao processo de previsão. Um processo de previsão bem estruturado vai evidentemente custar mais caro do que um processo "descuidado".

3.4 Medidas de acurácia do modelo

As medidas de acurácia de previsão são úteis no processo de seleção de modelos e no seu monitoramento. De acordo com KRESS; SNYDER (1994) uma "boa" medida de acurácia deve atentar para:

- Facilidade de entendimento;
- Uma unidade que possibilite comparação das várias previsões, como por exemplo, os erros percentuais; e,

- Ponderação que se dá ao erro de previsão de cada período, num sentido de análise de evolução.

As diferentes medidas de acurácia têm como base o Erro, que é definido como a diferença entre a demanda real e a previsão.

A grande dificuldade para mensurar a acurácia da previsão está na escolha da medida já que não existe uma medida padronizada. A seguir exploraremos as medidas de acurácia mais comuns.

3.4.1 Viés

A medida de viés busca identificar distorções no modelo de previsão, que geram previsões sistematicamente maiores que a demanda real ou sistematicamente menores. Ou em outras palavras, a medida de viés visa identificar ocasiões em que as previsões foram sistematicamente otimistas ou pessimistas.

$$Erro_Médio = \frac{\sum_{i=1}^{n}(Demanda_Real - Previsão)}{n} \quad \textbf{(19)}$$

Uma previsão pode ser considerada como livre de viés se o resultado da Equação (19) - Equação de Medida de Viés - for próximo de zero. Não entraremos aqui no mérito do que significa próximo de zero, mas isso pode ser feito através de testes estatísticos.

O cuidado que deve ser tomado com essa medida é o de evitar que N seja muito grande, pois isso poderia causar a perda de sensibilidade do indicador.

3.4.2 Desvio absoluto médio (MAD)

A medida do viés apresentada na (20) avalia apenas se as previsões estão sendo justas, o desvio absoluto médio (MAD) vem para avaliar qual a magnitude dos erros que estão sendo cometidos. O MAD mede o quão distante a previsão está do realizado. Ao contrário da medida de viés o MAD não considera a direção do erro, mas apenas sua magnitude.

$$MAD = \frac{\sum_{i=1}^{n}\left|Demanda_Atual_i - Previsão_i\right|}{n} \quad \textbf{(20)}$$

3.4.3 Erro absoluto médio percentual (MAPE)

O MAPE representado na Equação (21) proporciona uma medida da magnitude do erro assim como o MAD. Além disso, tem a grande vantagem de ser uma medida relativa possibilitando a comparação da acurácia entre dois itens diferentes.

$$MAPE = \frac{\sum_{i=1}^{n}\left|Demanda_Atual_i - Previsão_i\right|}{\sum_{i=1}^{n} Demanda_Atual_i \Big/ n} \quad \textbf{(21)}$$

3.4.4 Tracking Signal

O viés existe quando a demanda acumulada difere da previsão acumulada. A questão é saber distinguir se essa diferença é devida a aleatoriedade da demanda ou se existe viés na previsão.

Embora existam vários tipos de Tracking Signal o mais usado deles é o representado pela Equação (22) , ARNOLD (1998).

Na Tabela 4 os erros apresentados são comparados com relação a sua facilidade de entendimento, unidade de medida e tipo de erro avaliado.

$$Traking_Signal = \frac{n * Erro_Médio}{MAD} \quad \textbf{(22)}$$

Tabela 4 – Análise comparativa das medidas de acurácia, adaptada de KRESS; SNYDER (1994)

Medida	Facilidade de entendimento	Unidade de medida	Tipo de erro
Erro médio	Fácil	Unidades	Viés
MAD	Intermediário	Unidades	Magnitude
MAPE	Intermediário	Porcentagem	Magnitude
Tracking Signal	Difícil	Adimensional	Viés e Magnitude

3.5 Focus forecasting

É um método de previsão desenvolvido empiricamente e que se baseia na seleção de diferentes regras para previsão em cada período. Foi desenvolvido por Bernard Smith com base em dois princípios:

- Melhor método de ontem pode não ser o melhor de hoje; e,
- As pessoas mais experientes no desenvolvimento de previsões utilizam modelos extremamente simples.

Seu processo começa com a simulação de previsões para os períodos passados (passado recente) de acordo com vários modelos distintos. Então o desempenho de cada modelo é revisto e o melhor é utilizado para a previsão do próximo período.

A medida de desempenho é feita com o MAPE (Erro Absoluto Médio Percentual) que é a razão entre o MAD (Desvio Absoluto Médio) e a demanda atual, para o último período. Obs.: as medidas de erro são revistas mais detalhadamente na seqüência deste trabalho.

Os modelos usados no Focus Forecasting são aqueles que têm sido usados na prática da empresa. É importante que os modelos sejam de domínio dos responsáveis pela previsão e por aqueles que a utilizarão para tomada de decisão.

Os modelos típicos são, entre outros:

1. A previsão para o próximo período é igual à demanda do mesmo período do ano anterior;

2. A previsão para o próximo período é 110% da demanda do mesmo período do ano anterior;

3. A previsão para o próximo período é igual à média da demanda dos últimos seis meses;

4. A previsão para o próximo período é a demanda do último período; e,

5. A previsão para o próximo período é da demanda do mesmo período do ano anterior com uma taxa de declínio ou crescimento, (VOLLMANN, 1988, p.696).

Esses critérios são alguns dos originalmente sugeridos durante o desenvolvimento da técnica, mas não são fixos e podem ser diferentes para cada empresa.

Obs. Essa técnica de previsão foi apresentada fora da ordem lógica do trabalho, pois sua compreensão tem como pré requisito as técnicas de medida de acurácia.

3.6 Organização do banco de dados

As previsões geralmente são baseadas em dados históricos. Dessa forma a previsão terá sua qualidade limitada pela qualidade dos dados utilizados.

Mais do que armazenar dados de demanda ou de faturamento o banco de dados deve agregar informações que expliquem comportamentos atípicos na demanda; conhecimento sobre a conjuntura econômica relacionada a cada período; informações sobre os principais clientes e sobre os concorrentes; e informações que possam influenciar ou que possam ter influenciado a demanda CORRÊA et al. (1997).

Já ARNOLD (1998) define três princípios essenciais para que os dados possam ser considerados "bons":

1. Armazenar os dados compatíveis com o tipo de previsão:

- Para previsão de demanda deve-se usar dados de demanda e não de entregas;

- O período dos dados deve coincidir com o período de previsão; e,

- A estrutura dos itens a serem previstos deve ser a mesma utilizada na produção.

2. Armazenar dados que relatem as circunstâncias: a demanda é influenciada por eventos, e esses devem ser registrados junto com a demanda; e,

3. Armazenar os dados separadamente para cada canal de distribuição: cada canal de distribuição tem particularidades que afetam a periodicidade e o tamanho dos pedidos, logo suas previsões devem ser elaboradas separadamente.

3.7 Software

O próximo componente do sistema de previsão é o software. Esse componente tem grande facilidade de moldar (influir) o processo de previsão. O software muitas vezes define como as previsões serão elaboradas.

Devido à essa característica julgou-se importante entender como os fornecedores de software vêem o processo de previsão. O próximo capítulo descreve a pesquisa que foi realizada junto aos fornecedores de software.