

2 Métodos de previsão de vendas de itens de estoque

2.1 Introdução

A previsão de demanda é processo comum no planejamento das empresas e poderá ser bastante útil no controle de estoques e negociações de preços. Ao se trabalhar com um alto índice de incertezas, técnicas comuns de previsão podem requerer a participação colaborativa, como forma de reduzir prováveis resultados insatisfatórios.

Previsão de demanda e controle de estoque são dois tópicos amplamente estudados na literatura técnica, geralmente analisados em sequência (Tiacci *et al.*, 2009). De acordo com Zotteri *et al.* (2007), as contribuições no estudo da previsão de demanda provêm geralmente da estatística, e, em particular, das técnicas para melhor modelar a demanda futura. Modelos para processos de previsão de demanda são importantes no desenvolvimento de políticas de controle de inventário (Snyder *et al.*, 2002).

A previsão é uma estimativa de um evento futuro fora do controle das organizações e que provê a base para um planejamento gerencial. É ainda um componente do processo de tomada de decisão de negócios que quando acurada estima o futuro da atividade econômica associada a ações de curso específicas que podem guiar corretamente a estratégia organizacional em um ambiente incerto e quando não acurada pode guiar a empresa à falência (Smith III *et al.*, 1996).

Silver *et al.* (1998) sintetizam ações importantes que um sistema ideal de previsão de demanda por parte das corporações deve se ater:

1. Estimar a previsão de demanda esperada (em unidades em previsões de curto prazo e de forma mais agregada em previsões de longo prazo).
2. Estimar a amplitude de variação da demanda real versus a demanda esperada. Em outras palavras, estimar o erro de previsão e sua variância.
3. Prover estimativas de previsão em períodos regulares.
4. Atualizar periodicamente as previsões a fim de suportar decisões de revisão nos números de forma rápida e eficaz.
5. Balancear os custos de erros de previsão frente aos custos de se calcular as previsões.
6. Permitir a participação do julgamento humano nas previsões de demanda.
7. Ter precisão a fim de ser prover previsões acuradas, não muito sensíveis a fatores incontroláveis.

Smith III *et al.* (1996) listam também oito princípios básicos de previsão, independentemente da técnica a ser empregada:

1. Precisão das previsões: previsões estão sempre erradas em sua maior parte. As empresas utilizam-se das previsões, portanto, pelo simples motivo de que uma previsão é melhor do que nenhuma. Os erros trazidos pelas previsões podem ser tolerados e variarão de empresa para empresa, dependendo de fatores diversos que incluem tempo de reação, tamanho da empresa e o custo do erro para a mesma.
2. Horizonte de tempo da previsão: tudo o mais se mantendo igual, a precisão se reduz na medida em que o horizonte de tempo aumenta. Quanto maior o horizonte de tempo de uma previsão, maior a chance dos padrões estabelecidos e relações mudarem, conseqüentemente invalidando as previsões. Mudanças no ambiente, tecnologia, estratégica da concorrência, comportamento dos clientes e regulamentações governamentais impactam as previsões de longo prazo. Quanto mais no futuro tentamos prever, maior a chance de mudanças ambientais inesperadas.
3. Mudanças tecnológicas: quanto maior a taxa de crescimento de mudança tecnológica, maior o decréscimo da precisão da previsão.
4. Barreiras à importação: quanto menores as barreiras – alfandegárias e não alfandegárias - à entrada, mais imprecisas serão as previsões. Novos concorrentes estrangeiros podem alterar drasticamente os padrões estabelecidos.
5. Disseminação da informação: quanto mais rápida a disseminação da informação, menos útil será o valor da previsão, pois todos os agentes do mercado terão a mesma informação e poderão, conseqüentemente, atingir previsões similares.
6. Elasticidade da demanda: a previsão será menos acurada quanto maior a elasticidade da demanda, pois por razões óbvias os consumidores dão prioridade à aquisição de produtos de necessidades básicas. Em períodos de recessão, os supérfluos (de maior elasticidade) têm sua demanda reduzida.
7. Produtos de consumo versus produtos industriais: previsões de produtos de consumo são, em maior parte, mais acuradas que aquelas para produtos industriais. Isso ocorre pelo fato desses serem últimos vendidos a uma escala menor de clientes. Se um cliente é perdido, há uma significativa perda nas vendas. Os clientes industriais têm também um poder de barganha maior devido às grandes quantidades compradas.
8. Agregar versus desagregar: agregar previsões por famílias ou grupos de produtos resulta, normalmente, em previsões mais acuradas que previsões realizadas para itens de estoque individuais. Isso ocorre uma vez que o padrão dos dados agregados não muda tão rapidamente quanto o padrão dos itens individuais. Na previsão

agregada, superestimar alguns produtos pode cancelar o efeito de se subestimar outros produtos.

Além disso, as previsões devem estar ainda sujeitas a criação de equipes de especialistas, dentro das corporações, que trabalhem de forma conjunta, coletando e dispondo de dados históricos para um trabalho estatístico por parte dos administradores. Em grande parte das organizações apenas uma pessoa não deve realizar sozinha as previsões de demanda, recomendando-se o envolvimento de profissionais de diferentes áreas para as discussões das previsões.

As grandes corporações geralmente fazem uso de programas computacionais voltados para as previsões. Necessário se faz, entretanto, o envolvimento de especialistas na leitura dos resultados gerados pelos programas de forma a interpretar corretamente os dados. Os custos, para as organizações, do uso de tais procedimentos envolvem o custo de se operar o sistema e o custo gerado pelos erros de previsão. Verdade é que na prática a mensuração do custo relativo ao erro de previsão é algo bastante difícil de calcular, pois raramente as organizações registram o número de vendas não realizadas por falta de estoque, ocasionadas por erros de estimativa.

Procuraremos mostrar no estudo como corporações podem se valer de técnicas estatísticas de simples aplicação e bom grau de precisão para incrementar seu nível de serviço e controlar de forma mais eficiente seus níveis de estoque, sem demandar grandes investimentos em programas. Por meio do emprego de um programa simples, como o Excel®, é possível empregar metodologias acuradas. Nem sempre os programas mais caros resultam em melhores estimativas.

Nesse contexto, Waters (2003) classifica os métodos de previsão sob formas diferentes: quantitativos ou estatísticos, de acordo com o horizonte de tempo – curto, médio ou longo prazo – e qualitativo que inclui uma abordagem geral subjetiva, de julgamento, lidando com a opinião de especialistas das áreas de fornecimento, compras e vendas, além da opinião de clientes, publicações governamentais e estudos de mercado. Tal método, contudo, é menos confiável que o estatístico e poderá ser usado na introdução de um produto novo para a organização, quando a mesma não dispõe de dados históricos de demanda. Em alguns casos, apenas a opinião pessoal de um único especialista é considerada para a previsão e geralmente mostra-se mais suscetível a erros que a previsão elaborada por uma pessoa que nada conhece do produto e do mercado, mas que utiliza um método mais formal. Apesar disso, é um método largamente utilizado por corporações. Seu impacto não será tão grande em decisões menores, mas o nível de erro pode ter conseqüências em decisões importantes.

Algumas corporações se valem da opinião não apenas de um especialista, mas de um grupo composto por vários e que em conjunto discutem suas experiências e opiniões

de modo a se atingir um consenso. Apesar de aparentemente mais seguro que o primeiro caso, por se tratar da opinião de várias pessoas, as discussões podem não chegar a um consenso e em muitos ambientes corporativos, são raras as discussões abertas, onde todos os números podem ser abertos e discutidos com diferentes departamentos.

Quando do lançamento de um novo produto no mercado, é também bastante comum a realização de pesquisas de mercado, que podem gerar bons resultados, uma vez que coletam a opinião de grupos de consumidores potenciais de forma direta. O inconveniente desse tipo de método é não apenas o alto custo envolvido, mas também o tempo consumido no processo. Uma amostragem não representativa da população e perguntas mal elaboradas ou não respondidas honestamente podem gerar resultados pobres e não muito confiáveis.

Há ainda aquela classe de produtos que estão em fase de lançamento, mas que, possuem similares já lançados. Para esses casos, geralmente o recurso é estudar a curva do ciclo de vida do produto mais similar já existente no mercado e utilizá-la para se projetar a previsão de demanda. O cuidado que se deve ter nesse caso é escolher corretamente um produto suficientemente similar e cuidar para que se classifique corretamente o período do ciclo de vida onde o produto se encaixa.

Ainda um último método – qualitativo – merece ser aqui mencionado: método Delphi. Especialistas são chamados a participar em grupos, porém, com a diferença das perguntas serem apresentadas através de questionários respondidos anonimamente. Em reuniões posteriores, o resultado das respostas é mostrado e cada especialista é convidado a alterar sua opinião, repetindo-se o processo até se obter decisões mais próximas. É ainda um processo lento que depende do envolvimento do mesmo grupo ao longo do tempo.

Os métodos acima apresentados apoiam-se em visões subjetivas e opiniões de especialistas. Devem ser utilizados somente quando da inexistência de dados confiáveis. Por tais razões, os métodos quantitativos são aqueles que apresentam maior confiabilidade e precisão, desde que possamos contar com a disponibilidade de dados históricos. Silver *et al.* (1998), entretanto, realçam a importância de se conjugar métodos quantitativos com o julgamento dos gerentes diretamente envolvidos nos processos. Tais métodos, por sua vez, serão divididos de acordo com o horizonte de tempo, conforme discorrido abaixo:

1. Previsão de longo prazo: utilizada para se construir uma fábrica ou mais fábricas ou depósitos e centros de distribuição. Geralmente, a previsão é feita com base em anos, necessária para se planejar orçamentos e instalações. Está relacionada a decisões estratégicas.

2. Previsão de médio prazo: três meses a um ano, ou seja, o período necessário para se substituir um produto antigo por um novo ou organizar recursos. Utilizam-se

métodos de médio prazo quando se almeja planejar a produção. Em outras palavras, trata-se de decisões em nível tático.

3. Previsão de curto prazo: usualmente utilizada quando do planejamento de alguns poucos meses – ou mesmo semanas. Nesse caso, o objetivo é programar entregas e planejar estoques. Estamos falando de decisões em nível operacional. É nesse horizonte que trabalharemos com o controle de inventário/itens de estoque.

Smith III *et al.* (1996) fazem interessante comparação entre o comportamento de pequenas e grandes empresas quando o assunto é previsão de demanda. Tal comparação é bastante esclarecedora na compreensão do perfil da empresa objeto do estudo de caso. Enquanto no estágio inicial, as empresas pequenas tendem a ter seus fundadores totalmente envolvidos na produção e vendas, com a comunicação entre funcionários bastante aberta e informal, com o tempo de reação a mudanças no mercado tendendo ao imediato, empresas grandes dispõem de equipes multidisciplinares envolvidas na previsão de vendas e sistemas formais de suporte à tomada de decisões. No primeiro caso, as empresas tendem a se valer de técnicas subjetivas de previsão de demanda, baseadas tão somente no conhecimento de seus fundadores. No segundo caso, dispondo de maior estrutura e distintos centros de custos, o capital humano, composto por áreas diversas dentro da companhia, é mais capacitado e envolvido nas previsões de demanda, parecendo lógico o uso de técnicas mais avançadas, complexas e variadas de previsão.

O estudo viabilizado por Smith III *et al.* (1996) junto a centenas de empresas norte-americanas e multinacionais de pequeno, médio e grande porte traz à tona distinção de comportamento entre esses diferentes grupos de corporações. Quanto maior a empresa, maior o número de pessoas envolvidas no processo de previsão. Também quanto maior o número de filiais, plantas e escritório que uma empresa possui, maior o uso da tecnologia de informação no processo. A importância dada às técnicas quantitativas e complexas aumenta de forma proporcional ao tamanho da corporação. Do mesmo modo, pode-se dizer que a previsão nas grandes companhias encontra-se mais suscetível a influências externas, necessidade de previsão por regiões geográficas e necessidade de se prever o nível de vendas da concorrência.

Nas pequenas e médias empresas, o estudo observou que os altos executivos encontram-se mais envolvidos no processo de previsão (e não apenas o nível gerencial e equipes multidisciplinares). Empresas de pequeno e médio porte tendem também a escolher técnicas de previsão de demanda com base em sua facilidade de execução. Quanto menor a empresa, maior o uso que a mesma faz de sistemas qualitativos. Empresas de nível intermediário – médio porte – apresentaram o menor período entre previsão e resultados apurados (previsão versus vendas realizadas). Por fim, o resultado do estudo traz

ainda o comportamento de pequenas empresas que tendem a ver com menor importância a previsão da concorrência e fatores externos do ambiente econômico.

Em suma, Smith III *et al.* (1996) concluem de forma pertinente que à medida que as empresas crescem do menor para o maior porte, maior a aplicação de mão-de-obra especializada e investimento monetário em processos de previsão quantitativos. Empresas em estágio inicial de crescimento contam com um quadro enxuto de pessoal, com uma comunicação mais aberta entre os funcionários e a administração. São empresas orientadas a pessoas com processos de previsão altamente subjetivos e qualitativos, com as previsões sendo geridas por um número bem reduzido de pessoal. A combinação entre esses dois mundos – métodos quantitativos e qualitativos – poderia prover uma previsão mais acurada, baseada na tecnologia mais recente de previsão e na experiência dos executivos da empresa.

2.2 Séries temporais

Previsões quantitativas são geralmente baseadas em séries temporais, obtidas de observações tomadas em intervalos regulares. Silver *et al.* (1998) citam os cinco componentes de uma série temporal: nível, tendência, variações sazonais, movimentos cíclicos e flutuações randômicas irregulares, também conhecidas como ruído randômico.

Enquanto o nível captura a escala da série, a tendência identifica a tendência de crescimento ou declínio ao longo do tempo. As variações sazonais podem se apresentar sob duas formas: como resultado de forças naturais ou como consequência de decisões humanas. As variações cíclicas coincidem com as expansões e contrações da atividade macroeconômica.

Além dos efeitos dos quatro primeiros componentes, temos as flutuações irregulares que devem ser retiradas das séries, por serem resultados de eventos imprevistos, causados por fatores diversos tais como variação nas horas trabalhadas, velocidade de trabalho, condições climáticas, rejeições em inspeções, época do ano, influências econômicas, erros nos dados disponíveis, atraso na atualização de informações, dentre outras. É o ruído ou erro que torna a tarefa de previsão difícil. Se o ruído é relativamente pequeno, teremos uma boa previsão, próxima ao resultado do modelo selecionado. O contrário também é verdadeiro: muito ruído acaba tornando a previsão errática. O controle de erro de previsão será visto em maiores detalhes ao final deste capítulo.

Considerando que o estudo de caso apresentará a previsão de vendas para itens de estoque, nos concentraremos nos métodos de previsão de curto prazo, baseados em valores históricos de venda para a previsão futura de vendas, projetando padrões passados no futuro.

2.3 Previsão de curto prazo

A partir da aplicação de modelos relativamente simples, veremos como podemos calcular a previsão de vendas de itens de estoque individuais, de alto volume de demanda e relevantes para as organizações. A intenção é nos atermos aos modelos *constante* - onde não se observa uma tendência de crescimento ou decréscimo na demanda - e *linear* - onde há uma tendência de crescimento ou declínio da demanda. O modelo sazonal, onde além da tendência, encontram-se variações devido à época do ano, não será visto no presente estudo pelo fato de não ser aplicável às séries temporais que serão apresentadas como exemplo no estudo de caso.

A metodologia que descreveremos a seguir segue a linha do presente estudo no intuito de buscar apresentar um método passível de aplicação em qualquer corporação que trabalhe com itens de estoque e pode ser encontrado em *Silver et al. (1998)*.

2.3.1 Método de amortecimento exponencial para modelo constante

O modelo constante é representado por:

$$x_t = a + \varepsilon_t$$

onde a representa o nível e ε_t , o ruído randômico. O nível a é alterado sempre que novas demandas forem apuradas, pela seguinte equação:

$$\hat{a}_t = \alpha x_t + (1 - \alpha)\hat{a}_{t-1} \quad (2.1)$$

Sendo x_t , a observação da demanda no período t e α a constante de amortecimento, com valores que variam de 0 a 1 e que será oportunamente discutida.

Pela Equação (2.1), deduz-se que sempre que $\alpha = 1$, a estimativa é sempre o valor da última observação. Isso quer dizer que todas as demandas realizadas anteriores são descartadas, mantendo-se apenas a última. Se $\alpha = 0$, todas as estimativas ficam iguais à previsão realizada inicial, não se utilizando nenhuma nova informação.

Supondo que dispomos de t observações da demanda - x_1, x_2, \dots, x_t - e ainda que o processo de previsão foi iniciado na ocasião da observação x_t , temos a previsão ao fim do período t dada pela Equação (2.1):

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

Temos também que: $\hat{a}_{t-1} = \alpha x_{t-1} + (1 - \alpha)\hat{a}_{t-2}$.

Substituindo \hat{a}_{t-1} na Equação (2.1), teremos:

$$\hat{a}_t = \alpha x_t + (1 - \alpha)[\alpha x_{t-1} + (1 - \alpha)\hat{a}_{t-2}] = \alpha x_t + \alpha(1 - \alpha)x_{t-1} + (1 - \alpha)^2 \hat{a}_{t-2}.$$

Mas,

$$\hat{a}_{t-2} = \alpha x_{t-2} + (1 - \alpha)\hat{a}_{t-3}.$$

Substituindo \hat{a}_{t-2} na equação acima, teremos ainda:

$$\begin{aligned} \hat{a}_t &= \alpha x_t + \alpha(1 - \alpha)x_{t-1} + (1 - \alpha)^2 [\alpha x_{t-2} + (1 - \alpha)\hat{a}_{t-3}] \\ &= \alpha x_t + \alpha(1 - \alpha)x_{t-1} + \alpha(1 - \alpha)^2 x_{t-2} + (1 - \alpha)^3 \hat{a}_{t-3} \end{aligned}$$

De forma sucessiva e fazendo as substituições de \hat{a}_{t-3} , \hat{a}_{t-4} , ..., \hat{a}_1 , chegaríamos a:

$$\hat{a}_t = \alpha x_t + \alpha(1 - \alpha)x_{t-1} + \alpha(1 - \alpha)^2 x_{t-2} + \dots + \alpha(1 - \alpha)^{t-1} \hat{a}_1 + (1 - \alpha)^t \hat{a}_0$$

$$\hat{a}_t = \sum_{j=0}^{t-1} \alpha(1 - \alpha)^j x_{t-j} + (1 - \alpha)^t \hat{a}_0.$$

Em situações reais de processos previsão, usa-se quase sempre $0,01 \leq \alpha \leq 0,3$. Mesmo assim, o termo $(1 - \alpha)^t \hat{a}_0$ é aproximadamente igual a zero para valores moderados de t .

Logo, temos que:

$$\hat{a}_t = \sum_{j=0}^{t-1} \alpha(1 - \alpha)^j x_{t-j}$$

\hat{a}_t é, portanto, a média ponderada das demandas anteriores e o peso da observação x_{t-j} é $\alpha(1 - \alpha)^j$.

Tomando o valor esperado de \hat{a}_t , podemos mostrar que $E(\hat{a}_t) = E(x_t)$, o que significa que a estimativa \hat{a}_t para a demanda é sem viés, uma vez que o valor esperado da previsão utilizada (\hat{a}_t) é igual ao valor esperado da variável que está estimando (x_t).

Ao final do período t , para qualquer período futuro $t + \tau$, a previsão será:

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

Dada uma série histórica, o método se inicia através do cálculo das médias das primeiras observações para se obter a estimativa inicial de \hat{a}_0 . Para o cálculo da previsão do período seguinte, utiliza-se a Equação (2.1).

Vejamos na Tabela 2.1 um exemplo da aplicação da metodologia, onde a demanda prevista ao final do período 10 é calculada com base na média ponderada das demandas realizadas entre os períodos 1 e 10. Ao final do período 11, utili-

za-se a Equação (2.1) para a previsão do próximo período (previsão para o período 12). Assim que realizadas as demandas de cada período, o modelo é atualizado e é calculada a previsão de demanda do período subsequente. No gráfico apresentado na Figura 2.1, observa-se o comportamento da demanda prevista frente à demanda realizada.

Tabela 2.1 – Previsão da demanda com amortecimento exponencial

Período	Demanda Realizada	Demanda Prevista
1	40	
2	38	
3	36	
4	46	
5	38	
6	44	
7	50	
8	44	
9	48	
10	46	
11	44	43,00
12	48	43,05
13	36	43,30
14	38	42,93
15	48	42,69
16	44	42,95
17	48	43,00
18	42	43,25
19	46	43,19
20	50	43,33
21		43,67

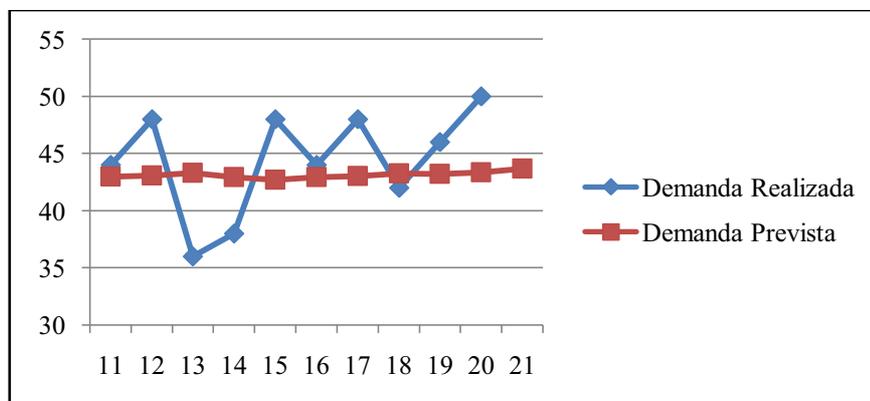


Figura 2.1 – Gráfico demanda prevista e realizada

Para a elaboração do exemplo acima, considerou-se 0,05 como valor de α , entretanto, os valores recomendados por Silver *et al.*(1998) podem variar de 0,01 a 0,3. Na prática, o valor de α será escolhido de forma a minimizar o erro quadrado médio (EQM) que representa a estimativa da variância do erro da previsão:

$$EQM = \frac{1}{n} \sum_{t=1}^n (x_t - \hat{x}_{t-1,t})^2 \quad (2.2)$$

Ou seja, a série histórica foi dividida em duas partes: com a parte inicial, escolhemos o α ótimo e com a segunda parte, simulamos as previsões.

Maiores detalhes acerca da escolha da constante de amortecimento serão tratados na seção 2.3.2. Em suma, o procedimento de previsão via amortecimento exponencial simples é um método bastante simples e efetivo de se prever a demanda por itens de estoque.

2.3.2

Método de amortecimento exponencial para modelo linear

Enquanto o modelo constante pressupõe que a demanda permanece a mesma ao longo de um período de tempo, o modelo linear apresenta uma demanda que cresce ou declina de forma sistemática. Portanto, o mais adequado no último caso seria o uso do método de amortecimento exponencial duplo. A inicialização do método de amortecimento exponencial duplo requer um procedimento pouco mais complexo que o visto anteriormente, sendo o modelo dado por

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

com a previsão expressa por $\hat{x}_t = \hat{a} + \hat{b}t$, onde \hat{a} e \hat{b} indicando as estimativas de a e b .

Sendo o erro de previsão $e_t = x_t - \hat{x}_t = x_t - (\hat{a} + \hat{b}t)$, a soma dos quadrados do erro de previsão será dada por:

$$S = \sum_{i=1}^n e_i^2 = [x_i - (\hat{a} + \hat{b}t)]^2$$

Para minimizar a soma dos quadrados dos erros de previsão, iguala-se a zero as derivadas parciais em relação a a e b .

$$\left. \frac{\partial S}{\partial a} \right|_{\hat{a}} = 0 \qquad \left. \frac{\partial S}{\partial b} \right|_{\hat{b}} = 0$$

Resolvendo as equações, chegaremos às estimativas de a e b , através de:

$$\hat{b} = \frac{\sum_{i=1}^n ix_i - \frac{(n+1)}{2} \sum_{i=1}^n x_i}{n(n^2-1)/12} \quad \text{e} \quad \hat{a} = \sum_{i=1}^n \frac{x_i}{n} - \frac{\hat{b}(n+1)}{2}$$

A inicialização via regressão linear por mínimos quadrados pode ser operacionalizada por meio do uso do Excel®, adicionando-se a linha de tendência e solicitando a exibição da equação, através da qual será possível observar os valores iniciais dos parâmetros do nível e da tendência. No gráfico da Figura (2.2), é apresentada a regressão utilizando os dez primeiros números da Tabela (2.2), onde observa-se a equação da reta $y = 2,321x + 7,602$.

A atualização das estimativas é dada pelas equações:

$$\begin{aligned} \hat{a}_t &= \alpha_{HW} x_t + (1 - \alpha_{HW})(\hat{a}_{t-1} + \hat{b}_{t-1}) \\ \hat{b}_t &= \beta_{HW} (\hat{a}_t - \hat{a}_{t-1}) + (1 - \beta_{HW}) \hat{b}_{t-1} \end{aligned} \quad (2.3)$$

sendo α_{HW} e β_{HW} constantes de amortecimento, a diferença $\hat{a}_t - \hat{a}_{t-1}$ nos traz a tendência prevista no período determinado. Entende-se por α_{HW} e β_{HW} as constantes de amortecimento segundo o modelo desenvolvido por *Holt-Winters*.

Para períodos subseqüentes, a previsão será dada por:

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

onde $\hat{x}_{t,t+\tau}$ é a previsão feita no período t da demanda no período $t + \tau$ (para $\tau = 1, 2, 3, \dots$).

O exemplo abaixo mostra a aplicação prática do amortecimento exponencial numa série com tendência linear.

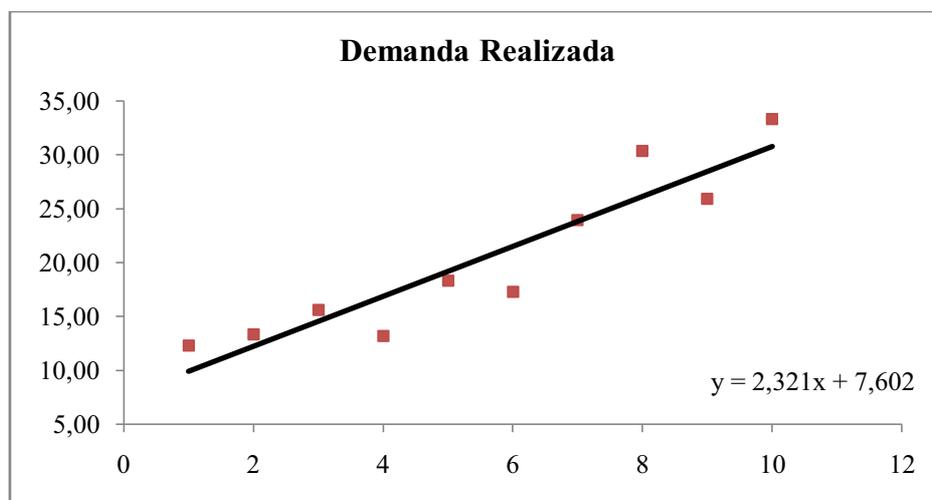


Figura 2.2 – Gráfico de demanda para uma série com tendência linear

Tabela 2.2 – Série com tendência linear de crescimento

Período t	Demanda Realizada	Período t	Demanda Realizada
1	12,30	16	42,69
2	13,32	17	55,62
3	15,60	18	48,60
4	13,20	19	54,90
5	18,33	20	60,60
6	17,31	21	65,52
7	23,97	22	65,01
8	30,36	23	66,36
9	25,95	24	69,69
10	33,36	25	66,51
11	38,40	26	77,01
12	37,02	27	72,96
13	42,36	28	76,29
14	45,60	29	81,36
15	49,02	30	84,96

Portanto, obtemos os valores iniciais \hat{a}_{10} e \hat{b}_{10} , ao final do período 10, que corresponde à inicialização do método:

$$\hat{b}_{10} = 2,321 \text{ e } \hat{a}_{10} = (2,321 \times 10 \text{ períodos}) + 7,602 = 30,812$$

Isso significa dizer que a previsão de demanda para o período seguinte corresponde ao somatório de \hat{a}_{10} e $\hat{b}_{10} = 2,321 + 30,812 = 33,133$

Tabela 2.3 – Simulação de previsão para o primeiro período após inicialização

Período t	Demanda Realizada	a_t	b_t	$a_t + b_t$	Demanda Prevista
10	33,36	30,81	2,32	33,13	
11	38,40				33,13

A partir desse momento, o método será atualizado por meio das Equações (2.3). A função *Solver* do Excel® permitirá a obtenção dos valores ótimos de α_{HW} e β_{HW} , de forma a minimizar a média dos erros quadrados da diferença entre demanda realizada e demanda prevista. Os valores de α_{HW} e β_{HW} que minimizam a média dos erros quadrados encontrados são 0,1643 e 0,0887, respectivamente. Encontramos o valor da média dos erros quadrados como sendo 12,83.

No gráfico da Figura 2.3 é apresentado o comportamento da demanda prevista versus a demanda realizada para os dados da Tabela 2.5.

Tabela 2.5 – Simulação de previsão

Período t	Demanda Realizada	a_t	b_t	$a_t + b_t$	Demanda Prevista	Erro Quadrado
1	12,30					
2	13,32					
3	15,60					
4	13,20					
5	18,33					
6	17,31					
7	23,97					
8	30,36					
9	25,95					
10	33,36	30,81	2,32	33,13		
11	38,40	34,00	2,40	36,40	33,13	27,74
12	37,02	36,50	2,41	38,91	36,40	0,39
13	42,36	39,47	2,46	41,93	38,91	11,93
14	45,60	42,53	2,51	45,04	41,93	13,47
15	49,02	45,70	2,57	48,27	45,04	15,81
16	42,69	47,35	2,49	49,84	48,27	31,09
17	55,62	50,79	2,57	53,36	49,84	33,44
18	48,60	52,58	2,50	55,08	53,36	22,65
19	54,90	55,05	2,50	57,55	55,08	0,03
20	60,60	58,05	2,54	60,59	57,55	9,31
21	65,52	61,40	2,62	64,02	60,59	24,26
22	65,01	64,18	2,63	66,81	64,02	0,98
23	66,36	66,74	2,62	69,36	66,81	0,20
24	69,69	69,42	2,63	72,04	69,36	0,11
25	66,51	71,13	2,55	73,68	72,04	30,63
26	77,01	74,23	2,60	76,83	73,68	11,07
27	72,96	76,19	2,54	78,73	76,83	14,94
28	76,29	78,33	2,50	80,83	78,73	5,96
29	81,36	80,92	2,51	83,43	80,83	0,28
30	84,96	83,68	2,53	86,22	83,43	2,33
31					86,22	

Ainda com relação às constantes de amortecimento, não seria viável estimar as constantes em empresas com milhares de itens de estoque. Silver *et al.* (1998) sugerem uma tabela de valores para tais constantes com valores razoáveis tanto para α , α_{HW} e β_{HW} , conforme Tabela 2.4:

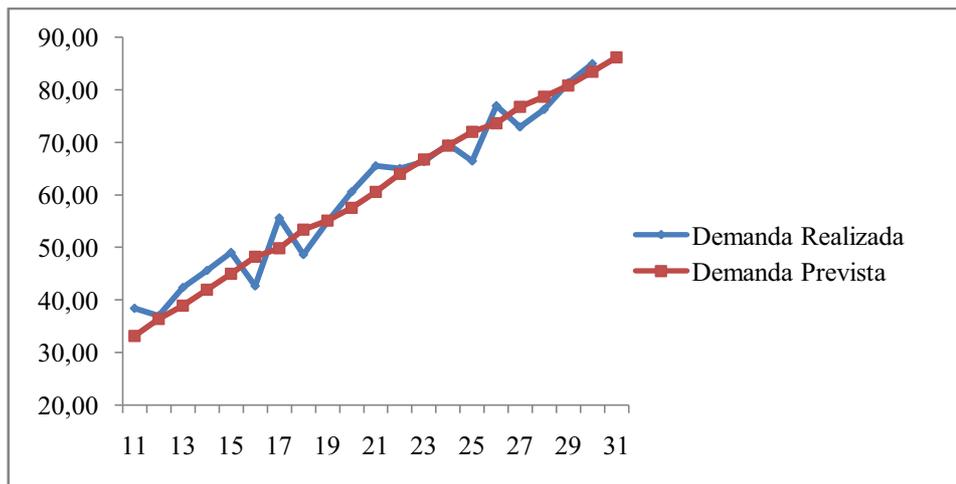


Figura 2.3 – Gráfico da demanda prevista x demanda realizada

Tabela 2.4 – Valores sugeridos por Silver *et al.* (1998) na escolha das constantes de amortecimento

	Valor de α	α_{HW}	β_{HW}
Valor máximo	0,300	0,510	0,176
Valor razoável	0,100	0,190	0,053
Valor mínimo	0,010	0,020	0,005

2.4 Medidas da variância do erro de previsão

Como mencionado ao longo do capítulo anterior, a única certeza que temos quando da aplicação de uma metodologia para a previsão de demanda é que a mesma irá gerar erros. O controle de tais erros e suas variâncias será necessário não apenas para medirmos o nível de serviço que desejamos prestar aos nossos clientes, mas também para medirmos se a aplicabilidade de determinado método é realmente a mais adequada.

O administrador de inventários e/ou de planejamentos não deve simplesmente aceitar de forma passiva determinada distribuição de erros de previsão. Se a mesma apresentar, por exemplo, um viés, medidas corretivas devem ser tomadas a fim de se evitá-lo. Por viés, entendem-se aquelas previsões que se mostram substancialmente acima ou abaixo da demanda real. Detectando-se viés, temos evidências de que o modelo é incorreto ou que seus parâmetros estão estimados inadequadamente, pois o erro de previsão – denominado e_t – deve flutuar em torno de zero.

Conhecer o papel da previsão e os impactos dos erros de previsão cria uma base para se definir uma meta realística para uma previsão mais precisa (Kerkänen *et al.*, 2009).

De forma geral, os indicadores de desempenho das previsões (medidas dos erros de previsão), servem a dois propósitos: (1) verificar se o método escolhido para previsão de demanda é preciso. No caso de se ter de forma sistemática erros positivos, observa-se uma subestimação nas previsões de demanda. O resultado disso pode ser perdas de vendas cujo custo é de difícil mensuração na prática (Silver *et al.*, 1998). (2) Administradores trabalham com os erros de previsão também de forma a planejarem um plano de contingência.

Kerkkänen *et al.* (2009) em seu artigo comentam que a literatura básica normalmente não provê abordagens para avaliação dos impactos dos erros de previsão. Usualmente, as companhias avaliam a precisão da previsão de vendas em termos do impacto no desempenho de seus negócios. Como já mencionado anteriormente, o impacto dos erros de previsão não é constante, mas varia de acordo com as características das organizações. Na vida real, os erros de previsão não são necessariamente randômicos e podem incluir características sistemáticas específicas de cada companhia. Apesar de ser quase impossível a mensuração dos impactos dos mesmos, é importante medi-los e tentar avaliá-los. Isto porque repercutirão tanto na estabilidade das programações, quanto no aproveitamento da capacidade instalada e no uso econômico da mesma, e, mais ainda, – como é o caso objeto do nosso estudo – no inventário, onde poderão refletir em excesso de estoque, maior custo para manutenção do mesmo e perdas de vendas por mau dimensionamento. Importante também é entender o ponto de vista de uma organização frente às previsões de demanda: compreender quem fará uso das informações obtidas, em que momento, como e a que propósito.

A avaliação dos impactos dos diferentes tipos de erros de previsão de vendas deve ser elaborada a fim de se definir o que se deseja com uma previsão precisa, quais os produtos verdadeiramente importantes de serem previstos e ainda alguma forma plausível de se medir o desempenho de tal previsão. A seguir, veremos algumas das mais populares medidas de erro de previsão.

2.4.1 Medidas de Variabilidade

Com o intuito de se prover um nível de serviço adequado ao cliente, calculando estoques de segurança adequados para cada item de estoque, será necessário o cálculo do desvio padrão dos erros de previsão para a demanda total de cada

item. Isso deve ser feito considerando o período necessário à reposição do estoque (*leadtime* de reposição).

Conforme já colocado anteriormente, para cada período de tempo, obtemos dois tipos de informação: a demanda real x_1, x_2, \dots, x_n e a previsão de demanda, calculada antes dos respectivos períodos $\hat{x}_{0,1}, \hat{x}_{1,2}, \dots, \hat{x}_{n-1,n}$. Uma medida de variabilidade frequentemente usada (ou minimizada) é o erro quadrado médio (EQM), diretamente ligado ao desvio padrão dos erros de previsão. De uso bastante simples, o EQM pode ser expresso por meio da seguinte fórmula:

$$EQM = \frac{1}{n} \sum_{t=1}^n (x_t - \hat{x}_{t-1,t})^2 \quad (2.4)$$

Outra medida de variabilidade é o desvio absoluto médio, representado no presente estudo pela sigla DAM. Trata-se de uma retratação da diferença absoluta entre a demanda real e a previsão elaborada ao fim do período anterior. Com o uso mais corrente de computadores, não é um dos métodos mais utilizados atualmente. Sua fórmula é dada por:

$$DAM = \frac{\sum_{t=1}^n |x_t - \hat{x}_{t-1,t}|}{n} \quad (2.5)$$

O termo $x_t - \hat{x}_{t-1,t}$ representa o erro ou o desvio da demanda para o período t e o cálculo do desvio absoluto médio será feito através de sua soma dividida pelos n períodos.

O desvio padrão dos erros de previsão é dado por:

$$\sigma_1 = \sqrt{EMQ}$$

A relação de σ_1 para o erro médio absoluto não seria de tão simples aplicação, sendo indicado um fator de 1,25 (Silver *et al.*, 1998).

Para a atualização do erro quadrado médio (EQM), poderíamos utilizar a Equação (2.4) sempre que uma nova demanda fosse disponibilizada. Podemos também utilizar uma nova fórmula, onde o EQM_t representa a estimativa do EQM ao final do período t e ω , uma constante de amortecimento, com valores que variam de 0,01 a 0,10:

$$EQM_t = \omega(x_t - \hat{x}_{t-1,t})^2 + (1 - \omega)EQM_{t-1} \quad (2.6)$$

A vantagem de se utilizar esta equação em vez da Equação (2.4) reside no fato de ser uma média ponderada dos erros quadrados anteriores, além de requerer menor espaço para armazenagem de dados.

2.4.2

Medidas do viés da previsão

Quando num sistema de previsão, há indicação de viés, estamos diante de um quadro em que as estimativas dos parâmetros da demanda são inadequadas ou mesmo que o modelo em si é incorreto, como já explicado no início do presente capítulo. O erro de previsão e_t deve variar em torno de zero. O viés não é facilmente detectável ao se observar a tabela de erros. Visualmente torna-se mais fácil verificar a existência de um viés negativo ou positivo através da construção de um simples gráfico.

2.4.3

Soma cumulativa dos erros de previsão

O gráfico da soma cumulativa dos erros de previsão é dos mais adequados para se visualizar a existência de viés. A fim de se monitorar o viés, deve-se aplicar a seguinte fórmula de modo recursivo:

$$SC_t = SC_{t-1} + e_t \quad (2.7)$$

onde SC_t representa a soma cumulativa do erro de previsão ao final do período t e $e_t (x_t - \hat{x}_{t-1})$, o erro de previsão no mesmo período t .

Em continuidade ao exemplo anteriormente estudado para o método com amortecimento exponencial duplo (Tabela 2.5) e supondo mais 10 observações da demanda realizada, geradas a partir de modelo constante, ou seja, sem tendência, teremos a representação do erro (e_t) e da soma cumulativa do mesmo (SC_t), apresentados na Tabela 2.6 e na Figura 2.4.

No gráfico da soma cumulativa do erro de previsão (Figura 2.4), observa-se uma indicação clara de viés após a demanda do período 31. Tal viés é consequência do método incorretamente empregado (amortecimento exponencial duplo) para as observações de demanda constante (modelo linear).

Tabela 2.6 – Simulação do erro de previsão e soma cumulativa do erro

Período t	Demanda Realizada	Demanda Prevista	Erro (et)	Soma cumulativa do erro (SC_t)
21	65,52	60,59	4,93	4,93
22	65,01	64,02	0,99	5,92
23	66,36	66,81	-0,45	5,46
24	69,69	69,36	0,33	5,79
25	66,51	72,04	-5,53	0,26
26	77,01	73,68	3,33	3,58
27	72,96	76,83	-3,87	-0,28
28	76,29	78,73	-2,44	-2,72
29	81,36	80,83	0,53	-2,20
30	84,96	83,43	1,53	-0,67
31	85,23	86,22	-0,99	-1,66
32	70,92	88,58	-17,66	-19,31
33	87,27	87,94	-0,67	-19,98
34	83,49	90,08	-6,59	-26,57
35	92,55	91,15	1,40	-25,17
36	97,02	93,56	3,46	-21,71
37	87,21	96,36	-9,15	-30,86
38	87,00	96,95	-9,95	-40,81
39	94,71	97,26	-2,55	-43,36
40	82,50	98,76	-16,26	-59,62

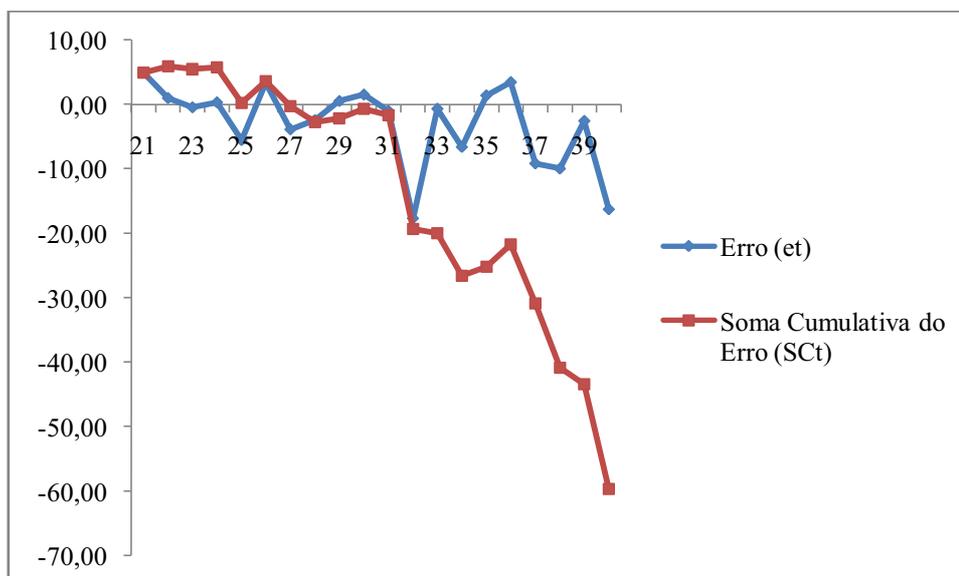


Figura 2.4 – Gráfico do erro de previsão e da soma cumulativa