

2

Fundamentos Teóricos

2.1

Previsões de Demanda

Nos últimos anos o papel da previsão de demanda tem se tornado importante devido às pressões de um mercado cada vez mais competitivo. Este fato pode ser evidenciado pelo uso desta técnica nas diversas áreas de gestão organizacional, como por exemplo, a área financeira, de recursos humanos e de vendas. Tais previsões são também essenciais na operacionalização de diversos aspectos do gerenciamento da produção, como a identificação de oportunidade de novos mercados, antecipação de demandas futuras, programação da produção mais eficiente e gestão de estoques (Sanders, et al 2003).

Existem na literatura diversas definições de previsão de demanda, tais como:

...”Previsão de Demanda é um processo metodológico para a determinação de dados futuros baseado em modelos estatísticos, matemáticos ou econométricos, ou ainda em modelos subjetivos apoiados em uma metodologia de trabalho clara e previamente definida” (Martins & Laugeni, 2005).

...”Previsão de Demanda é uma estimativa da demanda futura. Pode ser determinada por modelos matemáticos, usando dados históricos, pode ser criada subjetivamente usando estimativas de fontes internas ou podem representar uma combinação de ambas as técnicas” (Cox & Blackstone, 2004).

...”Previsão de demanda é um processo racional de busca de informações acerca do valor das vendas futuras devendo fornecer também, quando possível, informações sobre a qualidade a ser exigida no futuro” (Moreira, 1996).

..”Previsões são projeções de valores ou quantidades que provavelmente serão produzidas, vendidas e expedidas” (Bowersox & Closs, 2007).

... “a arte de estimar a demanda futura através da antecipação do que compradores provavelmente farão em determinado conjunto de condições” (Mudie, 1997).

A importância da Previsão de demanda é citada intensivamente na literatura técnica. Alguns autores enfatizam que o uso das previsões ajuda a estruturar as organizações visando dimensionar a quantidade de bens ou serviços que irão produzir de modo que possam prever e atender à demanda proveniente do mercado consumidor (Werner & Ribeiro, 2006). Então, pode se dizer que a atividade de previsão de demanda é parte integrante do processo decisório da gestão empresarial e que ela é importante porque auxilia na determinação dos recursos necessários para a empresa, ou seja, é a base para o planejamento estratégico da produção, vendas e finanças (Makridakis et al. 1998; Tubino, 2007). Arnold (1999), por exemplo, cita em seu trabalho que a maioria das empresas não pode esperar que os pedidos sejam realmente recebidos antes de começarem a planejar o que produzir.

Apesar da reconhecida relevância da previsão de demanda, o seu uso deve ser feito com prudência, pois exerce forte influência nos outros setores da empresa, ou seja: a gestão de estoques de produto acabado e de matéria-prima, assim como o fluxo financeiro, gestão de pessoas, entre outros.

2.1.1

Modelos de Previsão de Demanda

De acordo com Bowersox & Closs (2007) existem três tipos de técnicas de previsão: a qualitativa, a causal e a série temporal.

A técnica qualitativa considera a opinião e/ou julgamento dos especialistas nos produtos ou nos mercados onde atuam estes produtos para prever o futuro. Quando aplicável ou disponível, os dados do passado também podem ser considerados. Segundo o autor, esta técnica é ideal para as situações onde há

pouca disponibilidade de dados históricos e que deve ser explorada a capacidade de julgamento gerencial (Bowersox & Closs, 2007).

No caso da técnica causal, é necessário associar os dados históricos do produto com uma, ou mais, variáveis que tenham alguma relação com a demanda do produto. Utiliza uma classificação própria para as variáveis – *explicativas* ou *independentes* – que descreve uma relação entre um evento importante e suas principais causas, podendo esta relação ser usada para realizar previsões. O autor considera esta técnica mais apropriada para previsões em longo prazo (Bowersox & Closs, 2007).

Por último, a técnica baseada em série temporal que modela matematicamente a demanda futura, através do uso de métodos estatísticos, relacionando os dados históricos do próprio produto com o tempo. De acordo com o autor, esta técnica assume que o futuro é similar ao passado, e por esta razão considera a premissa que os padrões de demanda existentes continuarão no futuro. Sendo assim, o seu uso é mais aconselhável para o planejamento de curto prazo, e dentre as três é a que tem maior aplicabilidade na previsão de demanda (Bowersox & Closs, 2007).

Para Tubino (2007), uma série temporal pode conter os seguintes componentes: Tendência, Sazonalidade, Variações Irregulares e Randômicas. Segundo o autor, a Tendência consiste em um movimento gradual dos dados em longo prazo, podendo ser crescente ou decrescente. A Sazonalidade refere-se a variações cíclicas de curto prazo, relacionadas com o fator tempo. As Variações Irregulares são alterações nas demandas passadas resultantes de fatos excepcionais, as quais não devem ser incluídas no modelo, sendo recomendada à substituição pela média da série histórica. As Variações Randômicas ou Normais (outros autores a chamam de Níveis) são tratadas pela média. De acordo com Chopra & Meindl (2003) é a demanda atual dessazonalizada.

Os modelos de previsão de demanda podem ser estáticos ou adaptáveis. Para Chopra & Meindl (2003) um modelo estático pressupõe que as estimativas de Nível, Tendência e Sazonalidade não variam quando uma nova demanda é observada. Deste modo, a determinação de cada um desses componentes, quando possível, é feita a partir dos dados históricos e se tornam constantes nas previsões de demandas futuras. Já no caso da previsão de demanda adaptável, as estimativas

para os mesmos componentes são atualizadas logo após cada observação da demanda.

Segundo Wanke *et al.* (2006), existem mais de 60 modelos de técnicas quantitativas baseadas em séries temporais com variados graus de sofisticação. No entanto, esse elevado estado de sofisticação não garante, na maioria dos casos, resultados expressivamente melhores do que os alcançados com os modelos mais simples.

Com ênfase somente na técnica baseada em séries temporais com previsão adaptável, os modelos clássicos mais divulgados na literatura são: média móvel, média móvel dupla, suavização exponencial simples, suavização exponencial dupla, suavização exponencial com tendência, suavização exponencial com tendência e sazonalidade e os modelos de Box-Jenkins.

(a) Média Móvel: A utilização do modelo de média móvel ocorre quando a demanda não apresenta tendência ou sazonalidade. Neste modelo, a previsão é feita estimando o nível no período t pela média da demanda ocorrida durante os n períodos mais recentes. A cada previsão se substitui o valor mais antigo pelo mais novo da demanda. A média móvel pode então ser obtida através do uso da Equação 1:

$$P_{t+1} = N_t = (D_t + D_{t-1} + \dots + D_{t-n+1})/n \quad \text{eq. (1)}$$

Onde: P_{t+1} : estimativa da previsão de demanda para o período $t+1$; N_t : estimativa do nível para o período t ; D_t : demanda ocorrida no período t e n : número de períodos.

O número de períodos estabelecidos determina o grau de sensibilidade deste modelo em relação aos dados mais recentes.

(b) Média Móvel Dupla: O modelo da média móvel dupla pode ser usado nas séries temporais com tendência. Primeiro calcula-se a média móvel, conforme o modelo da média móvel simples e em seguida calcula-se a média móvel baseado na média das médias móveis. Então se determina os coeficientes de ajuste para o nível e a tendência, para finalmente calcular a previsão (Equações 2-5).

$$N_t = (D_t + D_{t-1} + \dots + D_{t-n+1})/n \quad \text{eq. (2)}$$

$$N'_t = (N_t + N_{t-1} + \dots + N_{t-n+1})/n \quad \text{eq. (3)}$$

$$a_t = 2N_t - N'_t \quad \text{eq. (4)}$$

$$b_t = 2(N_t - N'_t)/(n - 1) \quad \text{eq. (5)}$$

$$P_{t+1} = a_t + b_t \quad \text{eq. (6)}$$

Onde: N_t : estimativa do nível para o período t ; N'_t : média das estimativas do nível para o período t ; D_t : demanda ocorrida no período t ; a_t : coeficiente de ajuste para o nível no período t ; b_t : coeficiente de ajuste para a tendência no período t e n : número de períodos

Assim como no modelo da média móvel, o número de períodos influencia o grau de sensibilidade em relação aos dados mais recentes.

(c) Suavização Exponencial Simples: Como na média móvel, o modelo de suavização exponencial simples é adequado para séries temporais que não apresentam tendência e/ou sazonalidade. Por este motivo, a primeira estimativa é baseada na média de todos os dados históricos de uma série temporal (nível). Para cada nova previsão é feito um ajuste entre a previsão e a demanda real anterior através de um coeficiente de suavização. A Equação 7 descreve este modelo.

$$P_{t+1} = P_t + \alpha (D_t - P_t) \quad \text{eq. (7)}$$

Onde: P_{t+1} : estimativa para a previsão de demanda para o período $t+1$; P_t : estimativa para a previsão de demanda para o período t ; α : coeficiente de suavização da média e D_t : demanda ocorrida no período t .

O valor do coeficiente de suavização da média varia dentro de uma faixa de 0 a 1. Quanto maior este coeficiente mais reativo será o modelo em função da demanda, portanto, para valores altos de α a previsão sofre maior influência das variações aleatórias da demanda.

(d) Suavização Exponencial Duplo (Modelo de Brown): O modelo de suavização exponencial duplo pode ser usado em previsões de séries temporais com tendência, onde é importante atribuir pesos diferentes aos valores históricos.

A metodologia utilizada nos cálculos deste modelo é semelhante ao da média móvel dupla. Primeiro calculam-se as suavizações S_0 e \hat{S}_0 (Equações 8 e 9).

$$S_0 = a_0 - ((1 - \alpha) / \alpha) b_0 \quad \text{eq. (8)}$$

$$\hat{S}_0 = a_0 - 2 ((1 - \alpha) / \alpha) b_0 \quad \text{eq. (9)}$$

Onde: S_0 : primeira suavização no período 0; \hat{S}_0 : segunda suavização também para o período 0; a_0 : coeficiente linear da regressão dos valores da série pelos números dos períodos; b_0 : coeficiente angular da regressão dos valores da série pelos números dos períodos e α : coeficiente de suavização da média.

Depois se calculam as suavizações S_t e \hat{S}_t para o período t (Equações 10 e 11).

$$S_t = \alpha D_t + (1 - \alpha) S_{t-1} \quad \text{eq. (10)}$$

$$\hat{S}_t = \alpha S_t + (1 - \alpha) \hat{S}_{t-1} \quad \text{eq. (11)}$$

Onde: D_t : demanda ocorrida no período t

A seguir, as diferenças entre as duas suavizações são determinadas e se calcula o fator de ajuste adicional, similar a um coeficiente angular (Equações 12 e 13).

$$a_t = 2S_t - \hat{S}_t \quad \text{eq. (12)}$$

$$b_t = (\alpha / (1 - \alpha)) (S_t - \hat{S}_t) \quad \text{eq. (13)}$$

Finalmente, a previsão de demanda para os próximos p períodos é então determinada pela Equação 14.

$$P_{t+p} = a_t + b_t p \quad \text{eq. (14)}$$

(e) Suavização Exponencial com Tendência (Modelo de Holt): O modelo de suavização exponencial com tendência é adequado para séries temporais que apresentam tendência, mas não apresentam sazonalidade. Para estimar a primeira previsão é preciso calcular a média e a tendência relativa dos dados da série temporal. Por possuir uma tendência gradual e em longo prazo, é

possível supor que o comportamento entre a demanda e o tempo seja linear. Assim, através da utilização de uma regressão linear pode-se calcular o coeficiente linear (a) que será a estimativa inicial da média (nível) e o coeficiente angular (b) que será a estimativa inicial da tendência. Este comportamento pode ser descrito através da Equação 15.

$$D_t = a + b_t \quad \text{eq. (15)}$$

Onde: D_t : demanda ocorrida no período t ; a : coeficiente linear que mede a estimativa da demanda no período $t=0$ e é uma estimativa da média (nível) inicial; b_t : coeficiente angular que mede a taxa de inclinação da demanda em função do período t e é uma estimativa inicial para a tendência.

A estimativa da previsão de demanda para o próximo período é dada pela soma dos componentes média (nível) e tendências relativas ao período anterior com os devidos ajustes exponenciais. As Equações 16 -18 apresentam estas relações:

$$P_{t+1} = N_t + T_t \quad \text{eq. (16)}$$

$$N_t = P_t + \alpha (D_t - P_t) \quad \text{eq. (17)}$$

$$T_t = T_{t-1} + \beta ((P_t - P_{t-1}) - T_{t-1}) \quad \text{eq. (18)}$$

Onde: P_{t+1} : estimativa para a previsão de demanda para o período $t+1$; P_t : estimativa para a previsão de demanda para o período t ; P_{t-1} : estimativa para a previsão de demanda para o período $t-1$; N_t : estimativa do nível para o período t ; T_t : estimativa da tendência exponencial para o período t ; T_{t-1} : estimativa da tendência exponencial para o período $t-1$; D_t : demanda ocorrida no período t ; α : coeficiente de suavização da média; β : coeficiente de suavização da tendência.

Os coeficientes de variação variam entre 0 e 1. Conforme visto no modelo anterior, quanto mais próximos de 1 mais reativo será o modelo. Por outro lado, valores baixos para os coeficientes de variação tornam o modelo menos sensível aos fatores aleatórios da demanda.

(f) Suavização Exponencial com Tendência e Sazonalidade (Modelo de Winter): Este modelo é adequado quando a série temporal apresenta os

componentes de nível, de tendência e de sazonalidade. Inicialmente é necessário retirar a sazonalidade da série, em seguida, calcular o nível e a tendência da mesma forma que no modelo de suavização exponencial com tendência. Por fim, obtém-se os fatores de sazonalidade baseados na demanda depois de extraída a sazonalidade. Nas observações futuras devem ser revisadas as estimativas de nível, de tendência e dos fatores de sazonalidade. A estimativa de previsão pode ser modelada conforme Equações 19 - 22 para o modelo misto e 23 - 26 para o modelo aditivo.

- **Modelo Misto**

$$N_t = \alpha(D_t/S_t) + (1 - \alpha)(N_{t-1} + T_{t-1}) \quad \text{eq. (19)}$$

$$T_t = \beta(N_t - N_{t-1}) + (1 - \beta)T_{t-1} \quad \text{eq. (20)}$$

$$S_t = \gamma(D_t/N_t) + (1 - \gamma)S_{t-1} \quad \text{eq. (21)}$$

$$P_{t+1} = (N_t + T_t)S_t \quad \text{eq. (22)}$$

Modelo aditivo

$$N_t = \alpha(D_t - S_t) + (1 - \alpha)(N_{t-1} + T_{t-1}) \quad \text{eq. (23)}$$

$$T_t = \beta(N_t - N_{t-1}) + (1 - \beta)T_{t-1} \quad \text{eq. (24)}$$

$$S_t = \gamma(D_t - N_t) + (1 - \gamma)S_{t-1} \quad \text{eq. (25)}$$

$$P_{t+1} = N_t + T_t + S_t \quad \text{eq. (26)}$$

Onde: N_t : estimativa do nível para o período t ; N_{t-1} : estimativa do nível para o período $t-1$; D_t : demanda ocorrida no período t ; T_t : estimativa da tendência exponencial para o período t ; T_{t-1} : estimativa da tendência exponencial para o período $t-1$; S_t : estimativa da sazonalidade para o período t ; S_{t-1} : estimativa da sazonalidade para o período $t-1$; α : coeficiente de suavização da média; β : coeficiente de suavização da tendência; γ : coeficiente de suavização da sazonalidade; P_{t+1} : estimativa para a previsão de demanda para o período $t+1$.

(g) Modelos de Box-Jenkins: Os modelos de Box-Jenkins, conhecidos também como *ARIMA (Autoregressive Integrated Moving Average)* foram propostos na década de 70 por George Box e Gwilym Jenkins. A construção dos modelos tem a finalidade de encontrar uma função que descreva uma série

temporal e que permita fazer previsões sendo que a estrutura desse modelo é baseada em ciclos iterativos utilizando os próprios dados. Os modelos ARIMA podem ser formados por três componentes: o auto-regressivo (AR), o de integração (I) e o de média móvel (MA), sendo que a série pode ser modelada para cada um dos componentes ou por combinações entre eles, resultando em vários modelos encontrados na literatura.

- **Modelo auto-regressivo:** Neste modelo a série temporal Y_t é descrita por seus valores passados e um ruído aleatório u_t definido pela Equação 27.

$$\hat{Y}_t = \phi_1 \hat{Y}_{t-1} + \phi_2 \hat{Y}_{t-2} + \dots + \phi_p \hat{Y}_{t-p} + u_t \quad \text{eq. (27)}$$

$$\text{Sendo que:} \quad \hat{Y}_t = Y_t - \mu \quad \text{eq. (28)}$$

Onde: ϕ_i : parâmetro auto-regressivo que descreve como \hat{Y}_t se relaciona com \hat{Y}_{t-i} para $i = 1, 2, \dots, p$; Y_t : observação ocorrida no tempo t ; μ : média da série temporal; \hat{Y}_t : desvio da observação Y_t em relação a média μ e u_t : ruído aleatório.

De acordo com Pellegrini, (2000) uma série possui ruído aleatório, quando a diferença entre as observações e a média é estatisticamente independente, seguindo alguma distribuição de probabilidade, ou seja, a ordem na qual as observações ocorrem não informa nada a respeito da série.

O modelo auto-regressivo de ordem p (AR(p)) pode ser reescrito utilizando-se o operador de defasagem L , conforme as Equações 29 e 30.

$$\phi(L) \hat{Y}_t = u_t \quad \text{eq. (29)}$$

$$\phi(L) = 1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p \quad \text{eq. (30)}$$

- **Modelo de Média Móvel:** Em um modelo de média móvel, \hat{Y}_t resulta da combinação dos ruídos aleatórios de um determinado período com aqueles ocorridos em períodos anteriores. Desta forma o modelo é descrito pela Equação 31.

$$\hat{Y}_t = u_t - \theta u_{t-1} - \theta_2 u_{t-2} - \dots - \theta_q u_{t-q} \quad \text{eq. (31)}$$

Onde: θ_i : parâmetro de média móvel que descreve como \hat{Y}_t se relaciona com u_{t-i} para $i = 1, 2, \dots, q$.

O modelo de média móvel de ordem q (MA(q)) pode ser reescrito utilizando-se o operador de defasagem L , conforme as Equações 32 e 33.

$$\hat{Y}_t = \theta(L) u_t \quad \text{eq. (32)}$$

$$\theta(L) = 1 - \theta_1 L - \theta_2 L^2 - \dots - \theta_q L^q \quad \text{eq. (33)}$$

- **Modelo Auto-regressivo de Média Móvel:** Em alguns casos pode ser vantajoso modelar uma série temporal usando-se os modelos auto-regressivos AR(p) e média móvel MA(q) juntos, formando-se assim o modelo ARMA(p, q) que pode ser descrito pela Equação 34.

$$\begin{aligned} \hat{Y}_t = & \phi_1 \hat{Y}_{t-1} + \phi_2 \hat{Y}_{t-2} + \dots + \phi_p \hat{Y}_{t-p} + u_t - \\ & - \theta_1 u_{t-1} - \theta_2 u_{t-2} - \dots - \theta_q u_{t-q} \end{aligned} \quad \text{eq. (34)}$$

O modelo auto-regressivo de ordem p (AR(p)) e média móvel de ordem q (MA(q)) – ARMA(p, q) – pode ser reescrito utilizando-se o operador de defasagem L , conforme a Equação 35.

$$\phi(L) \hat{Y}_t = \theta(L) u_t \quad \text{eq. (35)}$$

Uma condição necessária para a aplicação desses modelos é que a série temporal seja estacionária, ou seja, que sua média e variância sejam constantes no tempo.

Séries estacionárias e não estacionárias são demonstradas graficamente na Figura 1.




Figura 1: Séries temporais (Pellegrini, 2000)

Os gráficos (a) e (b) na Figura 1 representam séries temporais estacionárias. Já o gráfico (c) representa uma série temporal não estacionária.

Para que os modelos auto-regressivos sejam estacionários é necessário que o operador auto-regressivo (Equação 30) seja igual à zero, com todas as suas raízes maiores que 1.

Nos modelos de média móvel, nenhuma restrição é necessária sobre os parâmetros para assegurar a estacionariedade.

Muitas séries temporais não possuem suas médias e variâncias constantes ao longo do tempo, portanto não são estacionárias. Neste caso será necessário transformá-las em séries estacionárias. A transformação mais comum na literatura (Morretin & Toloi, 2006, B. N., 2005; Mandall, 2006; Macciota, et al, 2000) consiste em determinar diferenças sucessivas da série original com ordem d de diferenciações até obter uma série estacionária, conforme as Equações 36 e 37

$$\Delta Y_t = Y_t - Y_{t-1} \quad \text{eq. (36)}$$

$$\Delta^2 Y_t = Y_t - 2Y_{t-1} - Y_{t-2} \quad \text{eq. (37)}$$

O número d de diferenciações para tornar a série estacionária é chamado de ordem de integração. Na prática d pode variar de 0 até 2. A inclusão deste

processo, permite a utilização do modelo auto-regressivo integrado a média móvel (ARIMA(p,d,q)) descrito pela Equação 38.

$$W_t = \phi_1 W_{t-1} + \dots + \phi_p W_{t-p} + u_t - \theta_1 u_{t-1} - \dots - \theta_q u_{t-q} \quad \text{eq. (38)}$$

Sendo que: $W_t = \Delta^d Y_t$

O modelo ARIMA(p,d,q) pode também ser reescrito utilizando-se o operador de defasagem L , conforme as Equação 39 e 40.

$$\phi(L) W_t Y_t = \theta(L) u_t \quad \text{eq. (39)}$$

$$\text{Sendo que: } W_t = (1 - L)^d Y_t \quad \text{eq. (40)}$$

Outra condição encontrada nestes modelos é a de reversibilidade. Esta condição é independente da série temporal ser estacionária ou não e é necessário que o operador de média móvel (Equação 33) seja igual a zero, com todas as suas raízes maiores que 1.

De acordo com os autores Box e Jenkins, são necessários três processos para se obter um modelo adequado (Figura 2):

- **Identificação:** Esta fase consiste em determinar qual dos modelos de Box e Jenkins é o mais adequado. Duas ferramentas são usadas para medir a correlação entre as observações dentro de uma série temporal. Estas ferramentas são as funções de autocorrelação (ACF) e autocorrelação parcial (PACF). A função de autocorrelação (ACF) descreve a correlação entre duas observações adjacentes da mesma série temporal, ocorridos em diferentes períodos. A função de autocorrelação parcial (PACF) mede o grau de associação entre as observações de uma série temporal quando o efeito de defasagem é retirado. A identificação do modelo a ser estimado ocorre pelo comportamento destas funções.

- **Estimação:** Consiste em estimar os parâmetros auto-regressivo (ϕ) e média móvel (θ). Alguns autores recomendam o método da máxima verossimilhança, que é uma técnica bastante utilizada em inferências estatísticas.
- **Verificação:** Recomenda-se avaliar a consistência dos modelos através da análise dos resíduos. As análises das funções de autocorrelação (ACF) e autocorrelação parcial (PACF) dos resíduos devem apresentar um comportamento aleatório, sendo suas autocorrelações consideradas não significativas.

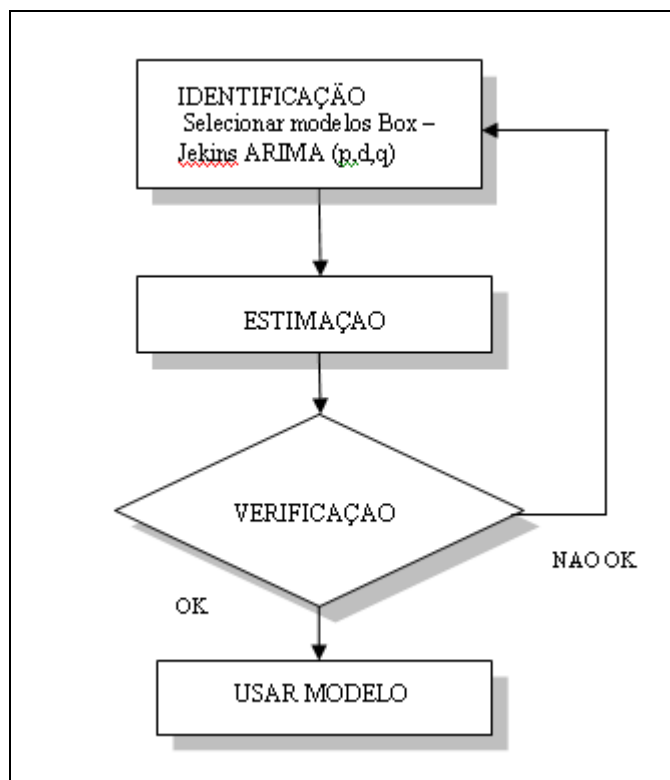


Figura 2: Método iterativo apresentado por Box-Jenkins para determinar um modelo ARIMA

Vários modelos podem ser usados para previsão. A escolha do modelo mais adequado se dará pela análise dos erros de previsão da demanda. Enquanto não for atingido o modelo adequado, o ciclo é repetido, voltando-se ao processo de identificação. Uma vez escolhido o modelo mais adequado passa-se para o objetivo principal, que é realizar as previsões.

Uma análise dos trabalhos de pesquisa dos últimos 25 anos na área de previsão de demanda com o uso de séries temporais foi realizada pelos autores Gooijer & Hyndman (2006) que, além dos modelos já descritos anteriormente, citam outros tipos, tais como: FARMA/ARFIMA, Não Lineares, ARCH/GARCH, entre outros. Os autores mencionam que enormes progressos foram feitos em muitos domínios, mas que acreditam que um grande número de temas ainda necessita de maior desenvolvimento.

2.1.2

Métodos de Cálculo dos Erros de Previsão de Demanda

De acordo com Wanke *et al.* (2006), existem diversos métodos de cálculo para a acurácia da previsão, dentre eles, destacam-se:

(a) **Método *Mean Absolute Deviation (MAD)***: permite avaliar o erro da previsão sem a influência dos sinais, desta forma um erro negativo não anula um erro positivo (Tabela 1, Equação 41).

(b) **Método *Mean Percentual Error (MPE)***: verifica se o modelo de previsão possui alguma tendência, ou seja, se os valores estimados da previsão estão sistematicamente acima ou abaixo das demandas (Tabela 1, Equação 42).

(c) **Método *Mean Absolute Percentual Error (MAPE)***: tem o objetivo de avaliar a grandeza do erro em relação à série temporal. O cálculo é feito em percentual (Tabela 1, Equação 43).

(d) **Método *Mean Squared Error (MSE)***: permite estimar a variação do erro de uma previsão, elevando-se ao quadrado a média dos erros e dividindo o resultado pelo número de períodos. Um dos problemas deste método é que os valores que apresentam uma significativa discrepância em relação à média receberão grande significância, quando deveriam ser desconsiderados (Tabela 1, Equação 44).

Tabela 1: Cálculo da Acurácia da Previsão (Wanke et al., 2006)

Método	Modelo Matemático
<i>Mean Absolute Deviation</i> (MAD)	$MAD = 1/n \sum_{t=1}^n D_t - P_t \quad \text{eq. (41)}$
<i>Mean Percentual Error</i> (MPE)	$MPE = 1/n \sum_{t=1}^n (D_t - P_t)/D_t \quad \text{eq. (42)}$
<i>Mean Absolute Percentual Error</i> (MAPE)	$MAPE = 1/n \sum_{t=1}^n D_t - P_t /D_t \quad \text{eq. (43)}$
<i>Mean Squared Error</i> (MSE)	$MSE = 1/n \sum_{t=1}^n (D_t - P_t)^2 \quad \text{eq. (44)}$

Sendo que: D_t = demanda ocorrida no período t ; P_t = estimativa para a previsão de demanda para o período t e n = número de períodos.

2.1.3

Software de Previsão de Demanda

Os autores Kusters *et al.* (2006) fazem uma retrospectiva dos 25 anos dos softwares de previsão, concentrando especificamente na integração entre hardware e software. Os softwares destinados à previsão de demanda, neste trabalho, foram classificados em duas áreas de aplicação (a) aplicativos desenvolvido para análise de pequeno número de series; e (b) aplicativos destinados a ambientes freqüentemente integrados que operam com um grande número de séries. Ao final do artigo, os autores citam que poucos softwares possuem funcionalidade e que existe uma defasagem de tempo na atualização. Algumas sugestões de melhorias em relação aos softwares de previsões são também citadas

O uso de software de previsão de demanda pode ser necessário dependendo da complexidade e da operacionalização dos dados das séries temporais. Existe um grande número destes softwares no mercado. Para Pellegrini

(2000), os softwares podem ser classificados segundo o tipo de usuário em: Genéricos e Específicos.

(a) **Genéricos:** São softwares estatísticos que possuem, entre outros, um módulo de previsão de demanda. Exemplos: NCSS, Statgraphics, SPSS.

(b) **Específicos:** São softwares que contém apenas as ferramentas estatísticas necessárias para a análise de séries temporais e geração de previsões. Exemplos: Forecast Pro e o Autobox.

2.1.4

Aplicação da Previsão de Demanda

A literatura técnica apresenta diversos casos de utilização da previsão de demanda onde os autores mostram as experiências por eles vividas.

Kesten & Armstrong (2007) estudaram o uso de analogias no processo de previsão de demanda, ou seja, compararam situações do passado que podem ajudar em situações semelhantes no presente. Neste trabalho, os autores concluíram que é difícil prever as tomadas de decisões em caso de conflito e que tiveram maior sucesso de acerto quando a analogia foi feita de forma estruturada e por um especialista no negócio.

Hibon & Evgeniou (2005) avaliaram o uso dos métodos de previsão de demanda de forma individual e por combinação e comprovaram que a combinação dos métodos leva a uma redução do erro da previsão em relação aos métodos de previsão individuais. No entanto, os autores citam que o desafio é encontrar qual a melhor combinação entre os diversos métodos disponíveis na literatura.

Tema similar também foi abordado por Werner & Ribeiro (2006). Neste trabalho, o desenvolvimento da modelagem contemplou a utilização de duas formas de integração de previsões – combinação de previsões e ajuste baseado no julgamento – e teve como base de informação os dados históricos, econômicos e análises de especialistas. A combinação das metodologias de previsões consistiu em empregar procedimento matemático e subjetivo de forma a reunir as informações provenientes de várias previsões, em uma única. Já o ajuste baseado no julgamento se refere às correções que devem ser realizadas pelas pessoas que

possuem o domínio de conhecimento na área do negócio em que a previsão está sendo realizada, com o intuito de aperfeiçoá-la. Os resultados mostraram que o modelo composto ajustado apresentou maior acurácia que o modelo combinado ou as previsões individuais (estatística econométrica e de especialistas).

Em outro trabalho, apresentado por Sanders & Manrodt (2003), a existência de uma diferença entre a teoria e a prática no processo de previsão foi mencionada. Enquanto sofisticadas técnicas de previsão estão sendo desenvolvidas e aperfeiçoadas, alguns negócios continuam usando na prática o julgamento. Os autores buscaram identificar as diferenças existentes entre as empresas que usam os métodos de previsão por julgamento e quantitativo. A conclusão do trabalho mostra que o método de previsão por julgamento tem a sua importância para ambientes de grande incerteza, mesmo assim os autores aconselham a adoção do método quantitativo.

O interesse no uso do Julgamento para a previsão de demanda tem sido constantemente objeto de estudo por pesquisadores. Antes visto como um inimigo da acurácia, atualmente, o julgamento é apresentado como benéfico, entretanto ele ainda está sujeito a incertezas devido a fatores subjetivos (Lawrence et al., 2006).

2.2

Simulação Computacional

A utilização da simulação computacional como apoio a tomada de decisão tem permitido analisar de forma sistêmica as unidades de negócio. Law & Kelton (2000) afirmam que a simulação tem como benefício obter uma visão sistêmica do efeito que alterações locais podem produzir sobre o desempenho global de todo o sistema de produção. Modelos de simulação são construídos para dar suporte a decisões sobre investimentos em novas tecnologias, expansão da capacidade de produção, gerenciamento de materiais, recursos humanos e integração com os fornecedores, ou seja, através da simulação é possível estabelecer metas estratégicas de manufatura (McLean & Leong, 2001).

A análise dos efeitos causados pela variação da demanda, mudança do layout, ampliação dos processos produtivos, distribuição da mão-de-obra direta, entre outros pode ser feita pela simulação computacional, tendo como resultado um melhor aproveitamento dos recursos, redução de estoques em processo, prazos

menores e mais confiáveis, menores custos operacionais e possibilidade de uma melhor compreensão do sistema produtivo.

Diversas definições sobre simulação computacional são encontradas na literatura, dentre elas, podem ser citadas:

“a simulação computacional é uma técnica de pesquisa operacional que envolve a criação de um programa computacional, que representa alguma parte do mundo real de forma que experimentos no modelo original predizem o que acontecerá na realidade (Hollocks, 1992).

“a simulação computacional de sistemas consiste na utilização de um conjunto de métodos e técnicas matemáticas, com o objetivo de imitar o comportamento de sistemas reais, geralmente utilizando-se computadores e softwares adequados” (Kelton et al., 2004).

“simulação envolve, para um dado sistema, a criação de um histórico artificial e sua observação a fim de extrair inferências sobre as características operacionais do sistema real que é por ele representado. A simulação é uma metodologia indispensável para solucionar muitos problemas reais. Ela é utilizada para descrever e analisar o comportamento de um sistema, perguntando questões do tipo “O que...se...” e auxiliando o projeto sobre o sistema real. Ambos sistemas conceitual e existente podem ser modelados com a simulação “ (Banks, 1998).

“simulação computacional é a representação de um sistema real através de um modelo utilizando o computador “(Pereira, 2000).

2.2.1

Alternativas de abordagem

De acordo com Law & Kelton (2000), um sistema é um conjunto de entidades compostas por pessoas ou máquinas que interagem a fim de atingir um objetivo. Estes autores citam um modelo para estudar um sistema, conforme descrito na Figura 3.

Segundo esses autores, um sistema pode ser analisado basicamente de duas formas: experimentação com o sistema real e experimentação com modelos do sistema. A experimentação com o sistema real é provavelmente a alternativa mais confiável, pois as mudanças realizadas são analisadas no próprio sistema. Entretanto, esta alternativa pode apresentar altos riscos, custos elevados, comprometimento do funcionamento do sistema e ainda pode estar sujeita as restrições físicas e temporais.

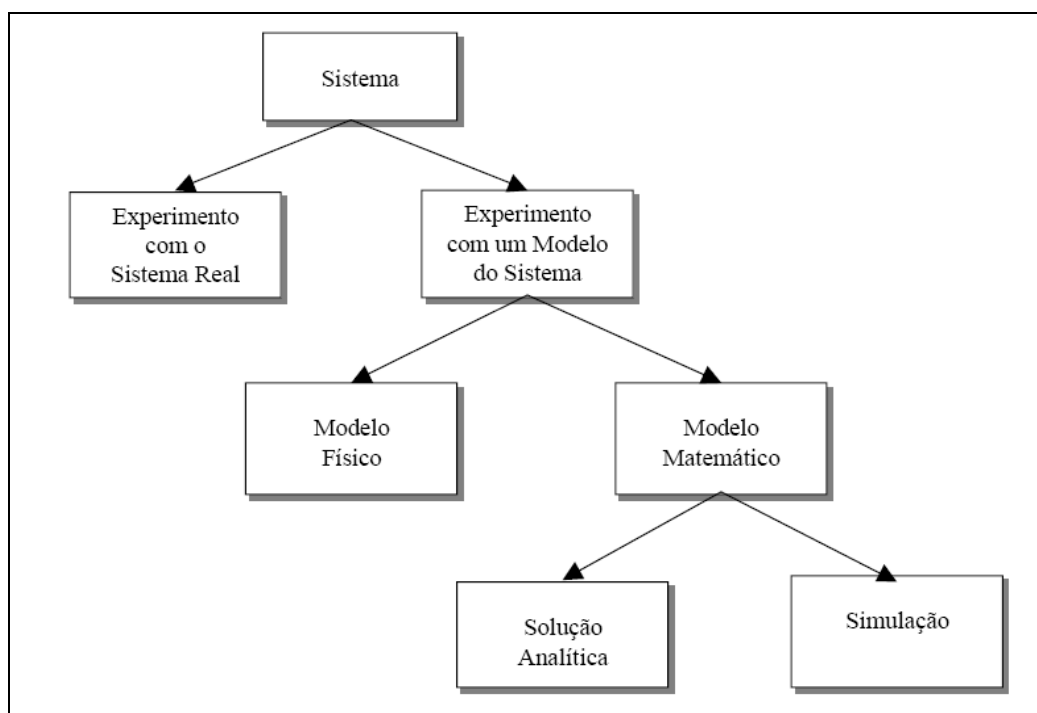


Figura 3: Modelo apresentado por Law e Kelton (2000) para avaliação de um Sistema

A experimentação com modelos é recomendada para os sistemas que não permitam experimentos reais. Devem representar uma simplificação do sistema real, identificando e destacando os elementos mais importantes para auxiliar a tomada de decisão. Estes experimentos apresentam baixo custo, maior rapidez e segurança, quando comparados aos experimentos realizados com o sistema real. Recomenda-se que a modelagem seja suficientemente detalhada de modo que as conclusões sejam válidas com relação ao sistema real (Law & Kelton, 2000).

Ainda segundo Law & Kelton (2000), os modelos podem ser classificados em matemáticos ou físicos. Os modelos físicos são representações do sistema real, construídos com componentes reais. Os modelos matemáticos representam o

sistema real através de notações simbólicas e equações, que podem ser alteradas quando necessário.

Os modelos matemáticos possuem duas abordagens: solução analítica e simulação. Na abordagem analítica busca-se um resultado ótimo para o modelo. Esta técnica pode apresentar algumas restrições em relação ao uso, devido à dificuldade em se obter um modelo matemático que descreva um sistema. Muitos sistemas reais são complexos, dificultando o uso da abordagem analítica. Neste caso, recomenda-se o uso da simulação, já que ela permite realizar experimentos com o modelo tendo como finalidade a possibilidade de observar e compreender como ele se comporta. Para Pidd (1997) a base conceitual da simulação computacional esta representada na Figura 4.

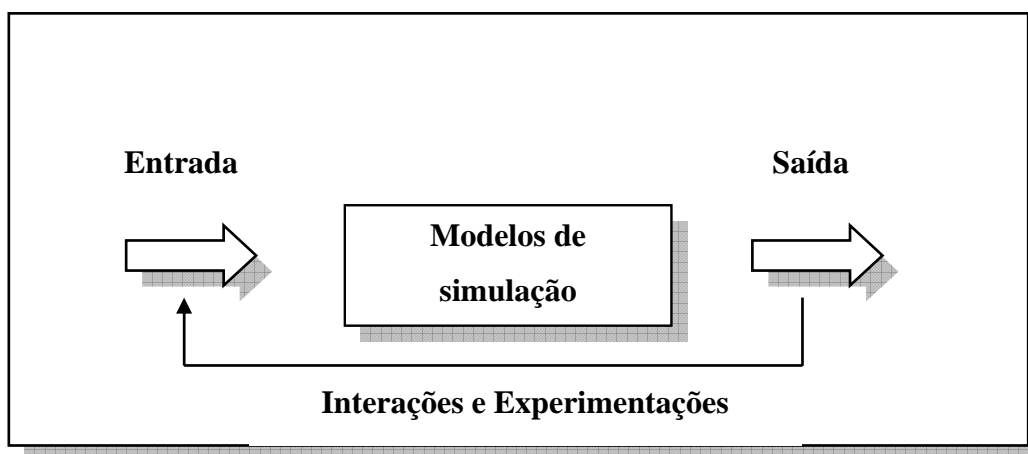


Figura 4: Base conceitual da simulação apresentado por Pidd (1997)

2.2.2

Software de Simulação Computacional

Um significativo desenvolvimento de softwares de simulação que facilitem a modelagem rápida de um dado ambiente vem crescendo ultimamente devido ao grande interesse por este assunto. Este fato pode ser evidenciado pela facilidade do uso dos softwares disponíveis no mercado, onde as Telas de entrada de dados são orientadas por menus, reduzindo significativamente o esforço e o tempo necessário ao processo de construção de um modelo. Além disso, observa-se que esses novos ambientes são mais amigáveis, consistentes em termos estatísticos e possuem interfaces gráficas que permitem visualizações das

simulações. Habilidades em programação de computadores, embora benéficas, não são mais imprescindíveis. Outra vantagem na utilização destas ferramentas é que elas apresentam animação gráfica e as saídas de informações estatísticas que facilitam a crítica de modelos (Barboza, 2006). A autora menciona em seu trabalho que os aplicativos podem ser classificados em três categorias:

(a) Linguagem de programação de propósito geral, como Fortran, C, C⁺⁺, Visual Basic entre outras;

(b) Linguagem de programação para simulação específica, tais como GPSS, GPSS/H, SIMSCRIPT 11.5, MODSIM II, SIMAN V® e SLAMSYSTEM;

(c) Pacotes de simulação. Esta categoria inclui muitos produtos que se diferenciam de acordo com suas aplicações, mas que possuem características comuns.

A escolha de um programa de simulação, entre os softwares de linguagem de programação de propósito geral, linguagem de programação para simulação específica ou pacotes de simulação, está diretamente relacionada com a interligação entre a flexibilidade e a especialização do usuário. A Figura 5 apresenta um esquema que correlaciona esta dependência (Rodrigues, 1994).

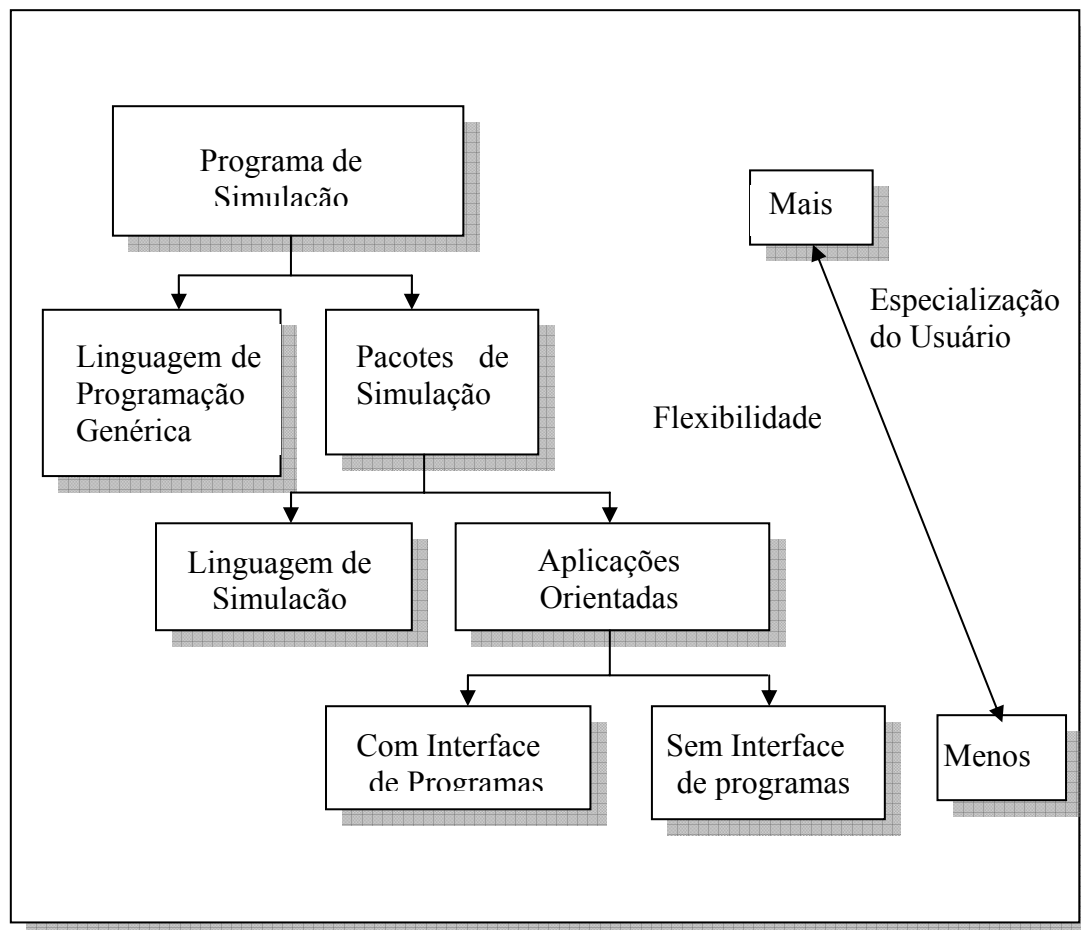


Figura 5: Interligação da Flexibilidade e Especialização do Usuário em Simuladores (Rodrigues, 1994)

Os softwares mais conhecidos na área de modelagem e simulação computacional são: Witness, Arena, Automod, Micro Saint, Extend, QUEST e Promodel.

2.2.3

Aplicação da Simulação

A simulação computacional pode ser empregada nos diversos setores da indústria de manufatura. McLean & Leong (2001) citam, entre outros, os seguintes exemplos de uso desta metodologia: (a) avaliação da capacidade de manufatura de novos projetos de produtos; (b) suporte para o desenvolvimento e validação de novos produtos; (c) auxiliar a engenharia de novos sistemas de produção e processos e avaliar o impacto deste sobre o desempenho global; (d)

definir a alocação dos recursos e alternativas de programação; (e) analisar layout e fluxos de materiais dentro das áreas de produção, linhas e estações de trabalho; e (f) desenvolver metas que estimulem a melhoria contínua dos processos de fabricação.

Os autores Pierreval *et al.*, (2007) estudaram o uso da simulação em uma empresa automotiva francesa visando identificar os pontos fracos, a flexibilidade e o tempo de resposta a alterações da demanda, através da análise dinâmica do comportamento da cadeia de suprimento. Os resultados do estudo identificaram um ponto fraco no setor de produção de motores que sinalizou resultados indesejados podendo ser obtidos em função dos volumes de estoque e pedidos. Os autores citam que esta metodologia apresenta benefícios concretos e indicam direções de melhorias. Enfatizam ainda a possibilidade de estudar os efeitos das variações de demanda na cadeia de suprimento.

Molina & Medina (2003) apresentaram uma metodologia, baseada nas ferramentas de modelagem e simulação, para selecionar e avaliar as práticas de manufatura de forma a se obter as melhorias na empresa e dar suporte aos gestores na tomada de decisões. Com esta metodologia foi possível avaliar os benefícios e os impactos causados pelas práticas de manufatura através dos indicadores de desempenho.

A simulação do comportamento futuro de uma unidade de fabricação, em fase de implantação, de um componente de cabine de caminhões para montadoras foi proposta por Mendonça (2008) com o objetivo de analisar, entre outros: se o projeto seria capaz de operar conforme o esperado; verificar se o projeto seria capaz de atender a demanda de 150 produtos/dia/turno; identificar gargalos e balanceamento da linha. A técnica utilizada neste estudo parte do princípio que a simulação é uma metodologia de pesquisa que adotou os passos descritos na Figura 6 e o software de simulação o ProModel. Os resultados do estudo mostraram que o projeto não teria capacidade de atender a demanda em algumas células operando em um turno, conseguindo apenas produzir pouco mais que a metade requerida. Identificaram que a causa do insucesso era o balanceamento da linha.

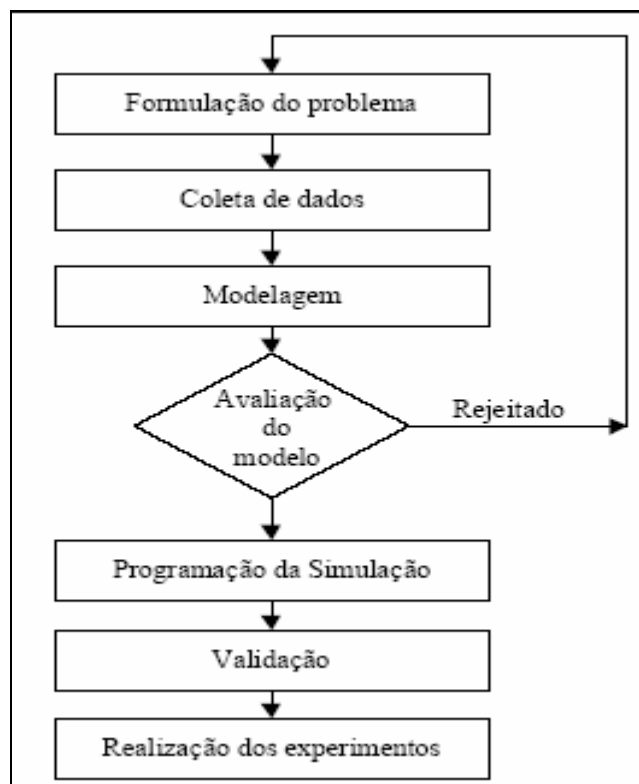


Figura 6: Fluxograma da Metodologia de Simulação (Mendonça, 2008)

O dimensionamento de uma célula de manufatura de cruzetas foi estudado por Cassel *et al.* (2004) através do uso de simulação computacional, com o objetivo de demonstrar a utilização do Mecanismo Função Produção (MFP), empregando como ferramenta o software Micro Saint. A modelagem foi dividida em: a) **Construção do Modelo Conceitual:** consiste na transcrição das diversas atividades do fluxo de materiais e pessoas em um modelo simplificado representativo das características determinantes do sistema estudado; b) **Construção do Modelo Computacional:** tratou-se de codificar o modelo conceitual em um conjunto de instruções lógicas que emulassem o comportamento do sistema. Essas instruções possuem um formato específico, de acordo com a ferramenta computacional utilizada. A conclusão do trabalho foi que o mapeamento das funções Operação e Processo, de acordo com a lógica do MFP, contribuem para a etapa de modelagem conceitual e coleta de dados do sistema.

Porque utilizar a Simulação computacional? Os trabalhos divulgados na literatura técnica constataam os diversos benefícios obtidos com o uso da Simulação Computacional. Dentre eles, destacam-se: (a) através dos modelos de

simulação é possível estimar o que precisa ser melhorado e quando esta melhoria se faz necessária, facilitando, portanto, a tomada de decisões; (b) grandes idéias e melhorias podem ser obtidas através do uso da simulação computacional, já que a animação do processo facilita o entendimento dos gestores; (c) a simulação permite a possibilidade de validar se a decisão tomada é a melhor ou não; (d) a simulação reduz os gastos, o tempo e evita as interrupções inerentes a tradicional técnica de tentativa e erro (McClellan, 2004; Harrel et al., 2000).

Entretanto, o maior benefício do uso da simulação no ambiente industrial, mencionado por Law & Kelton (2000), é que a simulação permite ao gestor obter uma visão ampla do sistema, identificando alterações locais e prevendo o impacto que essas possam produzir no sistema geral.

Apesar dos benefícios anteriormente citados, alguns autores mostram um lado cauteloso de abordar os resultados obtidos com a simulação. Shannon (1975) relata que a circunstância da simulação pode ser imprecisa e que é difícil avaliar o grau de imprecisão, o que se torna uma desvantagem. Os modelos de simulação são incapazes de gerar uma solução própria, sendo apenas uma ferramenta de análise do gestor sobre o comportamento do sistema. O excesso de confiança nos resultados pode ser outra desvantagem da técnica, já que as ferramentas utilizadas – computadores e layout animado – podem conduzir os gestores a uma exacerbada credibilidade nos resultados (Robinson, 2004).

A simulação pode na fase inicial apresentar custo elevado, especialmente durante a fase de projeto. Entretanto, o custo geral do projeto pode ser menor do que o custo da implementação e operação quando a simulação não é empregada, através da provável redução dos erros. A Figura 7 ilustra a diferença de custo em função do uso da simulação (Harrell et al., 2000; Siebers, 2004).




Figura 7: Custo acumulado do sistema com e sem simulação (Sierbers, 2004)

O capítulo seguinte apresenta a Empresa que foi utilizada para a aplicação da teoria aqui apresentada.