O modelo custo-volume-lucro e a teoria bayesiana

Luiz João Corrar
Professor Doutor do Departamento de Contabilidade e Atuária da Faculdade de Economia, Administração e Contabilidade da Universidade de São Paulo

Resumo

A análise tradicional das relações custo-volume-lucro (CVL) tem sido bastante útil como instrumento gerencial, auxiliando a administração da empresa na tomada de decisões. Entretanto, essa análise considera serem as variáveis do modelo conhecidas com certeza, ignorando os fatores risco e incerteza. Para a construção de modelos mais adaptáveis à realidade é necessário, porém, considerar que as variáveis componentes podem assumir comportamento aleatório. Uma das formas de aperfeiçoar o modelo CVL é a utilização da Teoria Bayesiana. Neste artigo apresentamos um caso de decisão em condições de **incerteza**, no qual é aplicada a **Teoria Bayesiana** ao **modelo Custo-Volume-Lucro** considerando serem independentes as variáveis envolvidas.

Palavras-chave:

- tomada de decisão
- modelo custo-volume-lucro tradicional
- teoria Bayesiana

INTRODUÇÃO

O método aqui proposto tem por base a hipótese de não se dispor de perfeito conhecimento das conseqüências relacionadas a uma determinada decisão, ou seja, não serem conhecidas precisamente as probabilidades de ocorrência de cada uma delas.

Tais probabilidades não são exatamente conhecidas porque o centro de decisão não dispõe de distribuição estabelecida com base nas freqüências relativas observadas depois de ter passado por decisão similar. O agente decisório dispõe, entretanto, de conhecimento *a priori* sobre as conseqüências das decisões e pode traduzir esse julgamento, ou essa experiência, elaborando uma distribuição subjetiva de probabilidades.

As decisões administrativas em condições de incerteza situam-se nessa perspectiva e procuram, em primeira abordagem, uma formalização tão precisa quanto possível do estado de ignorância parcial, sobre o qual poder-se-á agir. Tentar resolver um problema de decisão complexo dentro de contexto de ignorância parcial constitui, em si, fato não-negligenciável, visto permitir pelo menos melhorar a decisão, fornecendo um primeiro conjunto de conseqüências possíveis ligadas à decisão.

Neste artigo apresenta-se um caso de decisão em condições de incerteza, no qual se aplica a Teoria Bayesiana ao modelo Custo-Volume-Lucro considerando serem as variáveis envolvidas independentes.

FUNDAMENTOS DA TEORIA BAYESIANA

A Teoria da Decisão relaciona-se, primordialmente, com a tomada de decisões em condições de risco e incerteza. A condição de risco está presente quando não há disponibilidade de informação perfeita, mas existe a possibilidade de estimar as probabilidades de ocorrência de determinados eventos. Assim, para a resolução de problemas sob condições de risco utiliza-se a teoria das probabilidades. Por outro lado, um estado de incerteza refere-se a uma condição em que não são conhecidas as probabilidades de ocorrência de determinado evento em dada situação de decisão.

Em uma situação de incerteza o agente decisório conhece os diversos cursos de ação alternativos, em função dos diferentes eventos ou estados da natureza, da mesma forma em que numa decisão sob condições de risco. No entanto, não dispõe da informação necessária para associar probabilidades de ocorrência aos diversos eventos ou estados da natureza (Lee, Moore & Taylor, 1981).

O termo **estado da natureza** "procura enquadrar o fato de, em geral, o agente decisório se defrontar com a natureza que, de fato, se encontra em um certo estado, mas do qual ele não tem conhecimento exato" (Bekman & Costa Neto, 1980).

Quando o agente decisório necessita selecionar uma decisão alternativa, baseando-se em informações limitadas, pode estabelecer *a priori* estimativas subjetivas de probabilidade sobre os diversos estados da natureza ou eventos possíveis. Entretanto, com o intuito de chegar à melhor decisão, o **tomador de decisões** pode obter informações adicionais acerca das probabilidades de ocorrência dos vários eventos. É possível, então, utilizar essas novas informações para revisar as probabilidades *a priori* e, assim, melhorar a qualidade da decisão final. Este procedimento sintetizado é denominado de Estatística **Bayesiana**, em homenagem a Bayes, estatístico do século passado, pela interpretação dada ao teorema que leva seu nome (Markland, 1983).

PRESSUPOSTOS BÁSICOS DESTE ESTUDO

Assume-se a independência entre as variáveis do modelo. Supõe-se, ainda, depender o resultado operacional apenas de uma variável aleatória, ou seja, as quantidades produzidas e vendidas. Assim, a equação geral do lucro é:

$$\tilde{L} = (p - v)\,\tilde{Q} - F \qquad \textbf{(1)}$$

e o lucro esperado **E(L)** é dado por:

$$E(L) = (p - v)\,.\,E(Q) - F \qquad \textbf{(2)}$$

onde:

p = preço unitário de venda;
v = custo variável por unidade;
(E)Q = volume de vendas esperado;
F = custo fixo total.

Será estudada a hipótese de as quantidades vendidas comportarem-se conforme uma distribuição de probabilidades discreta.

APRESENTAÇÃO DO PROBLEMA

Suponha que determinada empresa apresente as seguintes informações para determinado produto:

P = preço unitário de venda = \$ 150
V = custo unitário variável = \$ 100
F = custo fixo total = \$ 22.000
ej = estados da natureza ou eventos possíveis, com **j** = 1, 2, 3,..., n
$\tilde{\mathbf{Q}}$ = volumes de vendas para cada estado da natureza:

- **e1** = vendas fracas, $\tilde{Q}$ = 300 unidades
- **e2** = vendas médias, $\tilde{Q}$ = 600 unidades
- **e3** = vendas fortes, $\tilde{Q}$ = 1000 unidades

Po = probabilidades *a priori* para cada estado da natureza:
- **Po(e1)** = 0,3
- **Po(e2)** = 0,5
- **Po(e3)** = 0,2

d_i = decisões possíveis:
- **d1** = fabricar o produto
- **d2** = não fabricar o produto

Considere que se o produto não for fabricado as vendas serão nulas. Qual decisão a ser tomada proporcionaria o melhor resultado?

QUADRO DE GANHOS E DE CUSTOS DE OPORTUNIDADE CONDICIONAIS

Considerando-se a hipótese de o produto ser fabricado, poderíamos nos defrontar com os três estados da natureza mencionados.

Os ganhos referentes a cada estado da natureza poderiam ser obtidos utilizando-se a expressão **1**. Para cada um dos estados da natureza poderíamos ter um nível de ganho, que variaria com o número de unidades vendidas. Esse ganho chamaremos de **condicional**, pelo fato de estar relacionado com a ocorrência de um dos estados da natureza, e o notaremos por L_{ij}, sendo $i = 1, 2$; e $j = 1, 2, 3$.

Aplicando-se a expressão **1** para cada evento e_j, têm-se:
- **e1** = $\tilde{L}_{11}$ = −7.000
- **e2** = $\tilde{L}_{12}$ = 8.000
- **e3** = $\tilde{L}_{13}$ = 28.000

É possível construir, assim, o painel de ganhos condicionais, conforme pode ser observado no quadro 1.

Quadro 1

Ganhos Condicionais

Decisão	Estados da Natureza		
	e_1	e_2	e_3
$d_1 = L_{1j}$	−7.000	8.000	28.000
$d_2 = L_{2j}$	0	0	0
Ganhos Máximos = $\max L_{ij}$	0	8.000	28.000

A última linha do quadro 1 mostra os ganhos máximos que poderiam ser obtidos com a ocorrência de cada um dos estados da natureza. Verifica-se, por exemplo, quando ocorre e_1, que se o produto fosse fabricado a empresa teria prejuízo de \$ 7.000 e se ele não o fosse (d_2) obter-se-ia o ganho máximo **zero**.

Por outro lado, verifica-se que no caso do evento e_2 a melhor decisão, ou seja, a que proporciona maior ganho (\$ 8.000), é a d_1. Se fosse tomada a decisão d_2 em lugar da d_1 a empresa deixaria de ganhar \$ 8.000. Este valor representa o denominado **custo de oportunidade condicional** e será notado por C_{ij}.

O quadro de custos de oportunidade condicionais é construído com base na relação:

$$C_{ij} = \max_i L_{ij} - L_{ij} \qquad \textbf{(3)}$$

Por exemplo, para o evento e_2 do quadro 1, o ganho máximo é $\max L_{i2} = \$ \ 8.000$. Assim, os custos de oportunidade para o evento e_2 são dados por:

- $C_{12} = 8.000 - 8.000 = 0$ e
- $C_{22} = 8.000 - 0 = 8.000$

Com base nesse raciocínio foi construído o quadro 2, no qual constam os custos de oportunidade condicionais.

Quadro 2

Custos de Oportunidades Condicionais

Decisão	e_1	e_2	e_3
$d_1 = C_{1j}$	7.000	0	0
$d_2 = C_{2j}$	0	8.000	28.000

DECISÃO ÓTIMA *A PRIORI*

A escolha da melhor decisão é feita com base no ganho máximo, que pode ser obtido pela expressão:

$$\max_i E(d_i) = \max_i \sum_j L_{ij} \, Po(e_j) \qquad \textbf{(4)}$$

Para simplificar os cálculos pode-se utilizar uma representação matricial. Assim, $[L_{ij}]$ representará a matriz de ganhos e $[Po(e_j)]$ o vetor coluna de probabilidades, como segue:

$$\begin{bmatrix} -7.000 & 8.000 & 28.000 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} 0,3 \\ 0,5 \\ 0,2 \end{bmatrix} = \begin{bmatrix} E(d1) = 7.500 \\ E(d2) = \ \ 0 \end{bmatrix}$$

Então:

- decisão ótima = $\max E(d_i)$ = 7.500

Portanto, a decisão ótima *a priori* é fabricar o produto (**d_1**), pois proporciona o maior ganho, \$ 7.500.

Árvore de decisão

Outra forma de resolver o problema é através do uso de árvores de decisão. Assim, os dados originais podem ser convenientemente apresentados por meio da árvore mostrada na figura 1.

Adotaremos a convenção de que os **nós** envolvendo decisão são representados por um **quadradinho** e os de probabilidade por uma **bolinha**.

Percorrendo a árvore de decisão de trás para frente, a cada nó de probabilidade associamos o correspondente valor esperado e, a cada nó de decisão, aquela que maximiza o valor esperado. Se a decisão for **d_1**, o valor esperado será \$ 7.500. Analogamente, se a decisão for **d_2**, teremos um valor esperado nulo. A decisão ótima será, portanto, **d_1**, correspondendo ao valor esperado de \$ 7.500. Representamos tal fato na árvore diferenciando a linha correspondente à ação **d_1**.

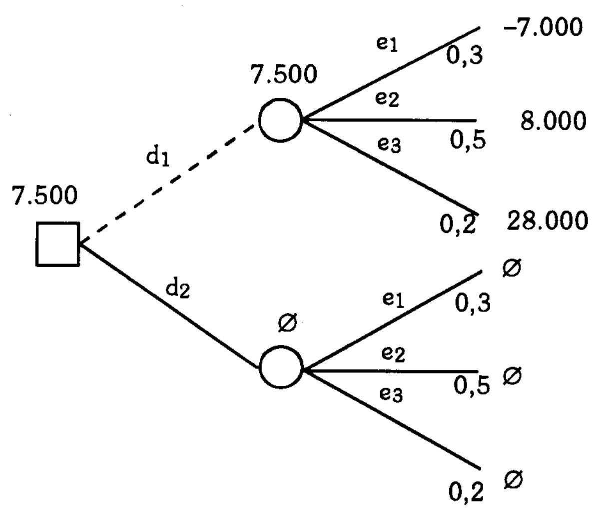

Figura 1: Árvore de Decisão

CUSTO DA INCERTEZA

A lógica da análise bayesiana está baseada no fato de o centro de decisão poder melhorar seu grau de conhecimento relativo, com referência aos eventos possíveis, através de pesquisas para obter informações suplementares que envolvem custos adicionais. Convém, portanto, comparar a vantagem que se pode esperar com relação ao custo gerado por essa coleta de informações suplementares. O caminho a ser seguido consiste, primeiramente, em calcular o custo da incerteza.

Logicamente, o valor das decisões que podem ser tomadas é inferior ao valor das decisões que poderiam ser tomadas se houvesse informação perfeita sobre os eventos possíveis. A diferença entre essas duas grandezas corresponde ao custo da incerteza ou, então, ao valor da informação perfeita.

Apresentaremos duas formas de determinar o custo da incerteza.

Cálculo com base no valor esperado da informação perfeita

O custo da incerteza (**CI**), ou o valor esperado da informação perfeita (**VEIP**), é dado pela expressão:

$$CI = VEIP = \sum_j \max_i L_{ij} \cdot Po(e_j) - \max_i \sum_j L_{ij}\, Po(e_j) \quad \textbf{(5)}$$

Assim:

$$CI = VEIP = (0\ \ 8.000\ \ 28.000)\begin{bmatrix}0,3\\0,5\\0,2\end{bmatrix} - 7.500 =$$

$$CI = VEIP = 2.100$$

Portanto, o custo da incerteza é de \$ 2.100. Esse é o valor máximo que pode ser gasto para obter informações suplementares.

Árvore de decisão com informação perfeita

A árvore de decisão resultante, sabendo-se dispor de informação perfeita, é apresentada na figura 2. Pode-se observar que o valor esperado com informação perfeita (**VEIP**) é de \$ 9.600.

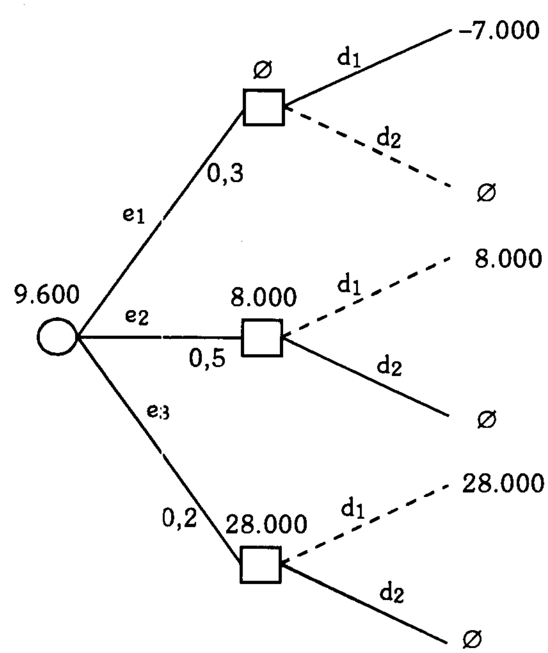

Figura 2: Árvore de Decisão com Informação Perfeita

Como o valor esperado sem informação perfeita era de \$ 7.500, conforme calculado anteriormente, o custo da incerteza será dado pela diferença, ou seja, \$ 2.100 (\$ 9.600 – \$ 7.500).

Cálculo com base no custo de oportunidade esperado

O custo da incerteza é obtido, neste caso, através da expressão:

$$CI = \min_i \sum_j C_{ij}\ Po(e_j) \qquad \textbf{(6)}$$

$$CI = \begin{bmatrix} 7.000 & 0 & 0 \\ 0 & 8.000 & 28.000 \end{bmatrix} \begin{bmatrix} 0{,}3 \\ 0{,}5 \\ 0{,}2 \end{bmatrix} =$$

$$CI = \begin{bmatrix} E(C_1) = 2.100 \\ E(C_2) = 9.600 \end{bmatrix}$$

$$CI = \min_i E(C_i) = 2.100$$

Os dois métodos — cálculo com base no valor esperado da informação perfeita e cálculo com base no custo de oportunidade esperado — proporcionam o mesmo resultado, ou seja, o custo da incerteza no valor de \$ 2.100. Assim, conclui-se ser $\mathbf{d_1}$ a decisão ótima *a priori*, a qual proporciona menor custo da incerteza.

APLICAÇÃO DO TEOREMA DE BAYES E REVISÃO DAS PREVISÕES INICIAIS

Suponha que a administração obtenha de um especialista determinada informação suplementar (**x**) sobre os eventos possíveis. Considere apresentar essa informação nível de confiança de 80%.

Segundo o especialista ocorrerá o evento $\mathbf{e_3}$ e, portanto, essa opinião pode ser notada como $\mathbf{x_3}$. As probabilidades condicionais $\mathbf{P(x_3/e_j)}$ podem ser assim anotadas:

- $\mathbf{P(x_3/e_3)} = 0{,}80$
- $\mathbf{P(x_3/e_1)} = 0{,}10$
- $\mathbf{P(x_3/e_2)} = 0{,}10$

O Teorema de Bayes possibilita calcular as probabilidades revisadas $\mathbf{P(e_j/x_3)}$, a partir das probabilidades *a priori* $\mathbf{P(e_j)}$ e das condicionais $\mathbf{P(x_3/e_j)}$, como segue:

$$P(e_1/x_3) = P(e_1)\ .\ P(x_3/e_1)\ /\ [P(e_1)\ P(x_3/e_1) + P(e_2)\ P(x_3/e_2) + P(e_3)\ .\ P(x_3/e_3)] =$$

$$P(e_1/x_3) = 0{,}13$$

$$P(e_2/x_3) = P(e_2)\ .\ P(x_3/e_2)\ /\ [P(e_1)\ P(x_3/e_1) + P(e_2)\ P(x_3/e_2) + P(e_3)\ .\ P(x_3/e_3)] =$$

$$P(e_2/x_3) = 0{,}21$$

$$P(e_3/x_3) = P(e_3)\ .\ P(x_3/e_3)\ /\ [P(e_1)\ P(x_3/e_1) + P(e_2)\ P(x_3/e_2) + P(e_3)\ .\ P(x_3/e_3)] =$$

$$P(e_3/x_3) = 0{,}67$$

A administração pode, agora, selecionar a melhor decisão *a posteriori*, levando em conta a informação suplementar. A expressão a ser utilizada é a seguinte:

$$\max_i E(d_i/x_3) = \max_i \sum_j L_{ij}\ P(e_j/x_3) \qquad \textbf{(7)}$$

$$\begin{bmatrix} -7.000 & 8.000 & 28.000 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} 0{,}13 \\ 0{,}21 \\ 0{,}67 \end{bmatrix} =$$

$$= \begin{bmatrix} E(d_1/x_3) = 19.458 \\ E(d_2/x_3) = 0 \end{bmatrix}$$

A decisão ótima é, portanto, a $\mathbf{d_1}$ e o ganho esperado é de \$ 19.458.

Árvore de decisão com revisão das previsões iniciais (caso 1)

Na figura 3 apresenta-se a árvore de decisão resultante da aplicação do Teorema de Bayes e da revisão das previsões iniciais com base na opinião do especialista, para quem o evento **3** realizar-se-á.

A análise pode ser efetuada percorrendo-se a árvore em sentido retro ativo, calculando o valor esperado correspondente a cada nó de probabilidade e adotando a decisão maximizante relativa ao nó de decisão. A decisão ótima é a $\mathbf{d_1}$ e o ganho esperado é de \$ 19.458.

Cabe ressaltar que os valores das probabilidades revisadas foram arredondados utilizando-se duas casas decimais. Conseqüentemente, o leitor que efetuar os cálculos usando tais valores chegará a resultados esperados apenas aproximados.

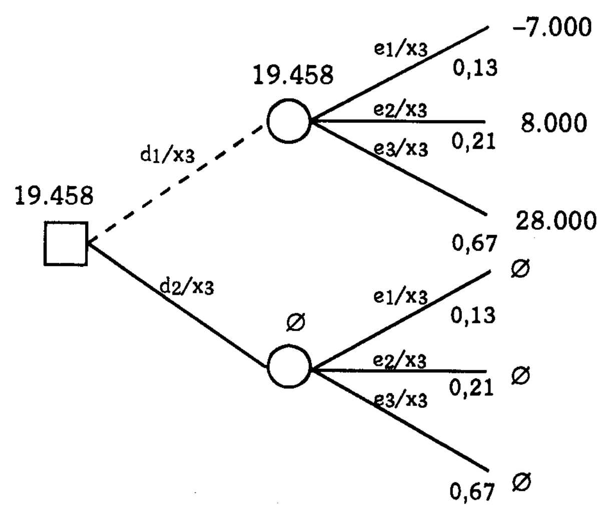

Figura 3: Árvore de Decisão com Revisão das Previsões Iniciais (Caso 1)

VALOR ESPERADO DA INFORMAÇÃO SUPLEMENTAR

Método dos ganhos condicionais

Mesmo que a administração da empresa não consulte um especialista, ela pode obter uma matriz de probabilidades condicionais. Para tanto, deve supor a possibilidade de ocorrência de qualquer um dos eventos. Suponha ser de 80% o nível de confiança de cada escolha. Assim, a matriz de probabilidades condicionais $\mathbf{P(x_i/e_j)}$ seria:

	e_1	e_2	e_3
x_1	0,80	0,10	0,10
x_2	0,10	0,80	0,10
x_3	0,10	0,10	0,80

Em função dos três resultados possíveis — $\mathbf{x_1}$, $\mathbf{x_2}$ e $\mathbf{x_3}$ —, a administração pode revisar as probabilidades iniciais, usando o Teorema de Bayes.

Serão utilizadas as seguintes notações:

- $\mathbf{P(e_j)}$ = probabilidade *a priori*
- $\mathbf{P(x_i/e_j)}$ = probabilidades condicionais
- $\mathbf{P(x_i\ e\ e_j)}$ = $P(e_j).P(x_i/e_j)$ = probabilidades conjuntas
- $\mathbf{P(e_j/x_i)}$ = probabilidades revisadas
- $\mathbf{P(x_i)}$ = $\sum_j P(e_j).P(x_i/e_j)$ = probabilidades marginais

A matriz de probabilidades encontra-se no quadro 3.

Portanto, pode-se revisar as probabilidades *a priori* mesmo antes de consultar um especialista, a partir do momento em que se conheça o coeficiente de confiança da informação suplementar. Para facilitar os cálculos posteriores é necessário achar a **matriz transposta** da matriz de probabilidades revisadas.

Considerando $\mathbf{[P(e_j/x_i)]^t}$ como a notação da matriz transposta, esta é dada por:

(e_j)	$P(e_j/x_1)$	$P(e_j/x_2)$	$P(e_j/x_3)$
e_1	0,77	0,07	0,13
e_2	0,16	0,89	0,21
e_3	0,06	0,04	0,67

Uma vez determinada a matriz de probabilidades revisadas, pode ser calculado o valor esperado da informação suplementar através da expressão:

$$\sum_x \max_i \sum_j (L_{ij} - k)\, P(x/e_j)\, Po(e_j) - \max_i \sum_j L_{ij}\, Po(e_j) \quad \mathbf{(8)}$$

onde:

k = custo da informação suplementar. No caso, suponha representar este custo uma porcentagem de 21,74% do valor esperado da informação suplementar.

Em termos práticos, os cálculos seguem as etapas:

- Multiplicação da matriz de ganhos pela matriz de probabilidades revisadas transposta — $\mathbf{[L_{ij}]\ [P(e_j/x_i)]^t}$. Este produto dá origem à matriz de ganhos revisados — $\mathbf{[E\ (d_i/x_i)]}$.

$$\begin{bmatrix} -7.000 & 8.000 & 28.000 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} 0,77 & 0,07 & 0,13 \\ 0,16 & 0,89 & 0,21 \\ 0,06 & 0,04 & 0,67 \end{bmatrix} =$$

$$[E(d_i/x_i)] = \begin{bmatrix} -2.323 & 7.889 & 19.458 \\ 0 & 0 & 0 \end{bmatrix}$$

- Seleção dos valores máximos por coluna, ou seja, $\mathbf{[\max_i E(d_i/x_i)]}$.

$$[\max_i E(d_i/x_i)] = [0 \quad 7.889 \quad 19.458]$$

- Multiplicação do vetor $\mathbf{[\max_i E(d_i/x_i)]}$ pelo vetor coluna $\mathbf{[P(x_i)]}$.

$$[\,0 \quad 7.889 \quad 19.458\,] = \begin{bmatrix} 0,31 \\ 0,45 \\ 0,24 \end{bmatrix} = 8.220$$

O valor assim obtido, $ 8.220, corresponde ao valor condicional da informação suplementar.

Quadro 3

Matriz de Probabilidades

x_i	P(j)	$P(x_i/e_j)$			$P(x_i \text{ e } e_j)$			$P(x_i)$	$P(e_j/x_i)$		
		e_1	e_2	e_3	e_1	e_2	e_3		e_1	e_2	e_3
x_1	0,3	0,8	0,1	0,1	0,24	0,05	0,02	0,31	0,77	0,16	0,06
x_2	0,5	0,1	0,8	0,1	0,03	0,40	0,02	0,45	0,07	0,89	0,04
x_3	0,2	0,1	0,1	0,8	0,03	0,05	0,16	0,24	0,13	0,21	0,67
					0,30	0,50	0,20				

- Para obter-se o valor esperado da informação suplementar, deve-se subtrair o valor da decisão ótima *a priori*: **8.220 - 7.500 = 720**. Assim, o valor bruto esperado da informação suplementar é de $ 720.

- Subtrai-se, então, o custo da informação suplementar: **720 - (0,2174 x 720) = 564**. Desta forma, $ 564 corresponde ao valor líquido esperado da informação suplementar.

Árvore de decisão com revisão das previsões iniciais (caso 2)

Supondo agora poder ocorrer qualquer um dos eventos e ser de 80% o nível de confiança de cada escolha, montou-se a árvore da figura 4.

A análise, como sempre, consiste em percorrer a árvore em sentido retro ativo, calculando o valor esperado correspondente a cada nó de probabilidade e adotando a ação maximizante relativa a cada nó de decisão. Isto leva ao valor condicional da informação suplementar de $ 8.220. Subtraindo-se deste o valor da decisão ótima a *priori* ($ 7.500), chega-se ao valor esperado da informação suplementar, ou seja, $ 720 (**$ 8.220 - $ 7.500**). Conseqüentemente, o valor líquido da informação suplementar é de $ 564 [**720 - (0,2174 x 720)**].

Método dos custos de oportunidade condicionais

A expressão a utilizar é a seguinte:

$$\min_i \sum_j C_{ij} \; Po(e_j) - \sum_x \min_i \sum_j C_{ij} \, . \, P(e_j/x) \; Px \quad \textbf{(9)}$$

- Inicialmente, deve-se multiplicar a matriz de custos de oportunidade **[Cij]** pela matriz de probabilidades revisada transposta, obtendo-se a matriz de custos de oportunidade revisada — **$[E(C_i/x_i)]$**.

$$\begin{bmatrix} 7.000 & 0 & 0 \\ 0 & 8.000 & 28.000 \end{bmatrix} \begin{bmatrix} 0,77 & 0,07 & 0,12 \\ 0,16 & 0,89 & 0,21 \\ 0,06 & 0,04 & 0,67 \end{bmatrix} =$$

$$[E(C_i/x_i)] = \begin{bmatrix} 5.419 & 467 & 875 \\ 3.097 & 8.356 & 20.333 \end{bmatrix}$$

- Selecionando-se os menores valores por coluna, têm-se **$[\min_i E(C_i/x_i)]$ = (3.097 467 875)**.

- Multiplicando-se o vetor **$[\min_i \Sigma\, E(C_i/x_i)]$** pelo vetor coluna **$[P(x_i)]$**, vem:

$$[\ 3.097 \quad 467 \quad 875\ ] \ . \begin{bmatrix} 0,31 \\ 0,45 \\ 0,24 \end{bmatrix} = 1.380$$

- Sabe-se que **$[\min_i E(C_i)]$** corresponde ao valor mínimo do custo de oportunidade esperado *a priori*, calculado anteriormente, ou seja $ 2.100. Conseqüentemente, **2.100 - 1.380 = 720**. Assim, $ 720 é o valor bruto esperado da informação suplementar.

- Subtraindo-se o custo da informação suplementar, que representa 21,74% do valor bruto da informação suplementar, obtém-se: **720 - (0,2174 x 720) = 564**. Concluindo, $ 564 representa o valor líquido esperado da informação suplementar.

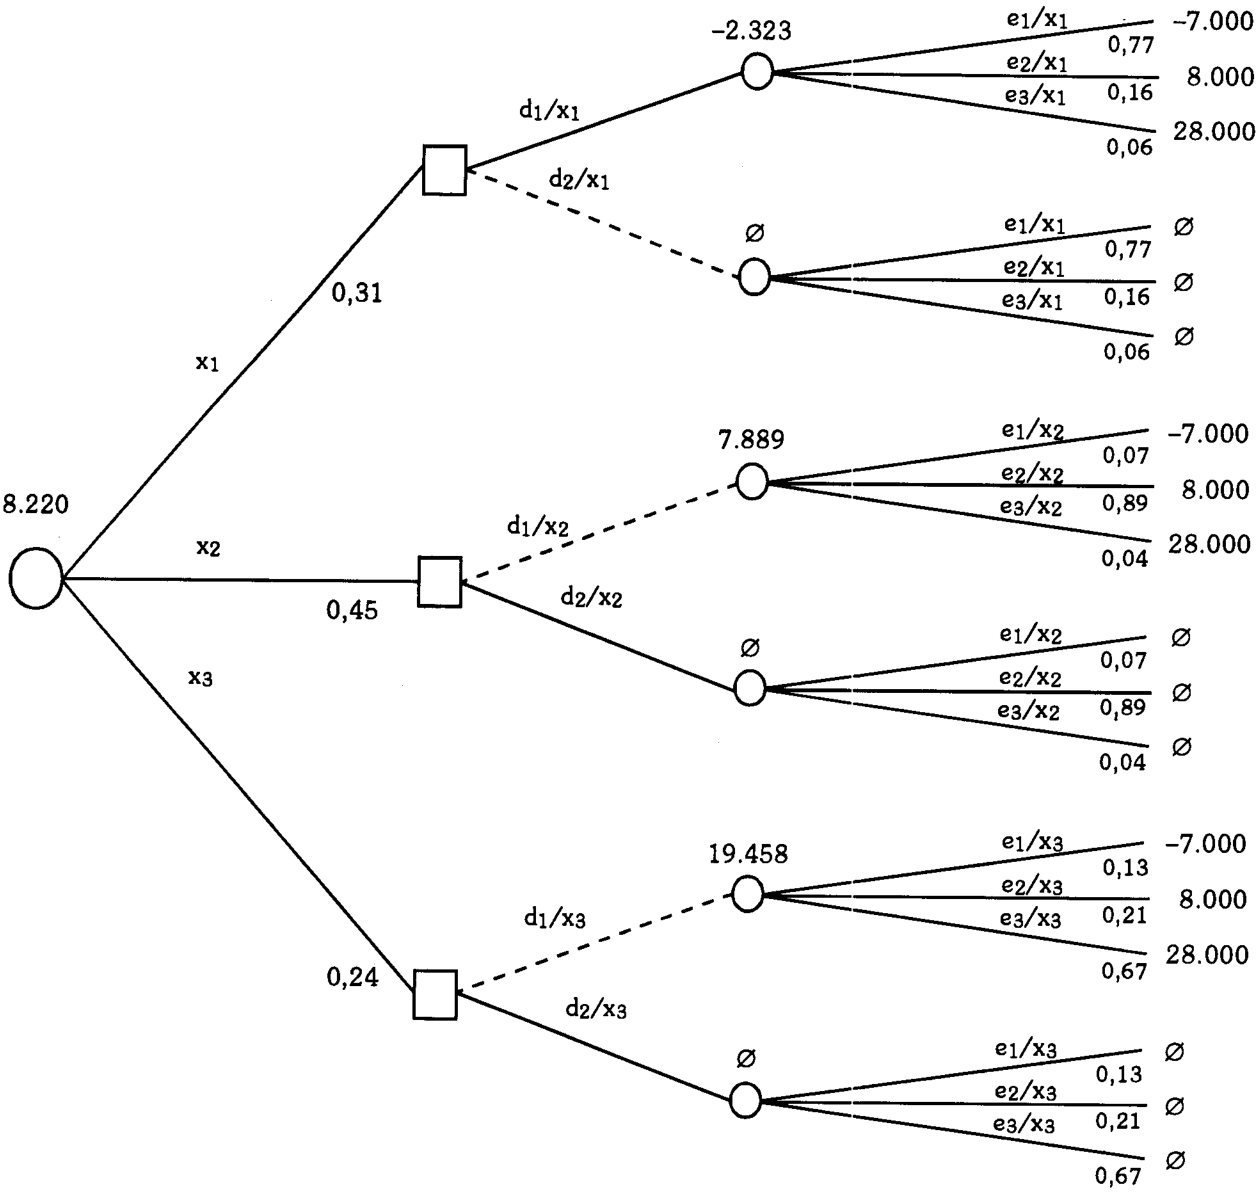

Figura 4: Árvore de Decisão com Revisão das Previsões Iniciais (Caso 2)

CONCLUSÕES

A análise tradicional das relações Custo-Volume-Lucro tem sido bastante útil como instrumento gerencial, ajudando a administração da empresa na tomada de decisões. Entretanto, a análise CVL tradicional considera que as variáveis do modelo são conhecidas com certeza, ignorando os fatores risco e incerteza.

Contudo, para a construção de modelos mais adaptáveis à realidade torna-se necessário considerar que as variáveis componentes podem assumir comportamento aleatório. Uma das maneiras de aperfeiçoar o modelo CVL é o uso da Teoria Bayesiana.

A lógica da análise Bayesiana baseia-se no fato de a administração poder melhorar seu grau de conhecimento relativo com relação aos estados da natureza, através de pesquisas para a obtenção de informações suplementares. Fazendo uso dessa metodologia é possível determinar o custo da incerteza com base nas informações *a priori*. Se o custo da incerteza de determinado produto é muito elevado, pode-se reduzí-lo através de pesquisa de mercado ou de outras vias de obtenção de informações suplementares sobre a distribuição de probabilidades relativa à demanda prevista. O teorema de Bayes possibilita calcular a distribuição de probabilidades *a posteriori* e, assim, revisar as previsões iniciais de todos os parâmetros de decisão, gerando instrumento mais adequado ao agente decisório.

Abstract

The traditional cost-volume-profit (CVP) analysis has been very useful as a management tool, helping the firm's administration decision taking. However, the traditional CVP analysis assumes that the model variables are known with certainty, ignoring, this way, the risk and uncertainty. To develop more adaptable models to the real life however it's necessary to consider that the component variables may assume random behaviour. One way to improve the CVP model is the utilization of the Bayesian Theory. In this paper we shall present a decision case in **uncertainty** conditions in which the **Bayesian Theory** is applied to the **Cost-Volume-Profit model** considering being independent the component variables.

Uniterms:

- decision taking
- traditional cost-volume-profit model
- Bayesian theory

Referências Bibliográficas

BEKMAN, O.R. & COSTA NETO, P.L. *Análise estatística da decisão*. São Paulo, Edgard Blücher, 1980.

CORRAR, L.J. *Análise das relações custo-volume-lucro para multiprodutos em condições de incerteza*. São Paulo, 1990. Tese (Doutoramento) — Faculdade de Economia, Administração e Contabilidade da Universidade de São Paulo.

LEE, S.M.; MOORE, L.J.; TAYLOR III, B.W. *Management science*. 2 ed. Boston, Allyn Bacon, 1981.

MARKLAND, R.E. *Topics in management science*. New York, John Wiley & Sons, 1983.

RAIFFA, H. *Decision analysis*. New York, Newbery Award Records, 1968.

TELLER, R. *Contrôle de gestion en avenir incertain*. Paris, Dunod Entreprise, 1974.

Recebido em dezembro/92
2ª versão em agosto/93