

*Notas de Aula:*

*Demanda por Bens Diferenciados*

Victor Gomes

*Universidade de Brasília*

victorgomes@unb.br

7 de novembro de 2010

## 1 Modelo

Seguimos aqui o artigo de Nevo (2000).

mercado:  $t = 1, \dots, T$

consumidores por mercado:  $i = 1, \dots, I_t$

informações por mercado: (i) quantidades, (ii) preço médio ( $p_{it}$ ), (iii) características dos produtos ( $J$  produtos)

**Função de utilidade indireta** para o consumidor  $i$ , consumindo o produto  $j$  no mercado  $t$ .

$$u(x_{jt}, \epsilon_{jt}, p_{jt}, \tau_i; \theta) \quad (1)$$

tal que:

$x_{jt}$ : características observadas do produto  $j$  no mercado  $t$

$\epsilon_{jt}$ : características não-observadas pelo pesquisador/economista

$p_{jt}$ : preço médio do produto  $j$  no mercado  $t$

$\tau_i$ : características dos indivíduos

$\theta$ : parâmetros desconhecidos

### Especificação da função utilidade

$$u_{ijt} = \alpha_i(y_i - p_{jt}) + x_{jt}\beta_i + \epsilon_{jt} + \epsilon_{ijt} \quad (2)$$

- $i = 1, \dots, I_t$  (consumidores por mercado)
- $j = 1, \dots, J$  (produtos)
- $t = 1, \dots, T$  (mercados)
- $x_{jt}$  é um vetor de dimensão  $K$  de características observáveis do produto  $j$ .

- $\epsilon_{ijt}$  termo estocástico,  $E[\epsilon] = 0$ .
- $\alpha_1$  utilidade marginal do consumidor da renda.
- $\beta_i$  vetor de gostos dos indivíduos

Obs: as características variam com o tipo de produto estudado.

**Características não-observadas** podem incluir o impacto de atividade promocional, fatores não-quantificáveis (marca) ou choques sistemáticos de demanda. Ex:

$$\epsilon_{jt} = \underbrace{\epsilon_j}_{\text{dummy marca}} + \underbrace{\epsilon_t}_{\text{dummy mercado}} + \Delta\epsilon_{jt} \quad (3)$$

Três observações a respeito da função (2).

1. função utilidade
  - BLP – Cobb-Douglas
  - Nevo – quasi-linear (sem efeito-riqueza)
2. características não-observáveis são idênticas para todos os consumidores ( $\alpha_i$  varia entre indivíduos – consistente com literatura de diferenciação vertical dos produtos)
3. todos os consumidores se deparam com as mesmas características dos produtos – o mesmo preço é oferecido aos consumidores.
  - As preferências variam como função das características individuais  $\tau_i$ .
  - Duas características (tipos):
    1. Observada ( $D_i$ ): renda, idade, tamanho família, educação, etc.
    2. Não-observada ( $v_i$ ): sem informação. ex: animal estimação, religião, etc.

Formalmente:

$$\begin{pmatrix} \alpha_i \\ \beta_i \end{pmatrix} = \begin{pmatrix} \alpha \\ \beta \end{pmatrix} + \Pi D_i + \Sigma v_i \quad (4)$$

tal que

$$v_i \sim P_v^*(v)$$

$$D_i \sim \hat{P}_D^*(D)$$

são independentes.  $P(\cdot)$  é uma distribuição paramétrica ou não-paramétrica.

$\Pi : (K + 1) \times d$  : matriz dos coeficientes que varia com  $D_i$ .

$\Sigma : (K + 1) \times (K + 1)$  parâmetros : matriz dos coeficientes de  $v_i$ .

(Implicação: taste parameter varia com  $D_i$ ; + informação para análise).

**Outside good** : os consumidores podem decidir por não comprar nenhuma marca (produto).

$$u_{i0t} = \alpha_i y_i + \underbrace{\epsilon_{0t} + \pi_0 D_i + \delta_0 v_{i0}}_{\text{zero}} + \epsilon_{i0t} \quad (5)$$

$$u_{i0t} \simeq 0$$

$$\alpha_i y_i \simeq 0$$

----- X -----

Parâmetros desconhecidos  $\theta = (\theta_1, \theta_2)$ .

$\theta_1 = (\alpha, \beta)$  – parâmetros lineares

$\theta_2 = (\Pi, \Sigma)$  – parâmetros não-lineares

Combinando as equações (2) e (4) temos:

$$u_{ijt} = \alpha_i y_i - \alpha_i p_{jt} + x_{jt} \beta_i + \epsilon_{jt} + [-p_{jt}, x_{jt}] (\Pi D_i + \Sigma v_i) + \epsilon_{ijt} \quad (6)$$

$$u_{ijt} = \alpha_i y_i + \delta_{jt}(p_{jt}, x_{jt}, \epsilon_{jt}; \theta_1) + \mu_{ijt}(p_{jt}, x_{jt}, D_i, v_i; \theta_2) + \epsilon_{ijt} \quad (7)$$

tal que:

$$\delta_{jt}(p_{jt}, x_{jt}, \epsilon_{jt}; \theta_1) = -\alpha_i p_{jt} + x_{jt} \beta_i + \epsilon_{jt} \quad (8)$$

$$\mu_{ijt}(p_{jt}, x_{jt}, D_i, v_i; \theta_2) = \underbrace{[-p_{jt}, x_{jt}]}_{[1 \times (K+1)]} (\Pi D_i + \Sigma v_i) \quad (9)$$

$\delta_{jt}(\cdot)$  : utilidade média – comum a todos os consumidores.

$\mu_{ijt}(\cdot) + \epsilon_{ijt}$  : efeitos aleatórios – desvios média-zero heterocedasticos da utilidade média.

**Hipótese** consumidores compram uma unidade do bem que fornece maior utilidade.

- Como o indivíduo é definido como um vetor demográfico e choques específicos dos produtos  $(D_i, v_i, \epsilon_{i0t}, \dots, \epsilon_{ilt})$  isto implicitamente define o conjunto de atributos individuais que levam à escolha do bem  $j$ .
- Formalmente:

$$A_{jt}(x_{\cdot t}, p_{\cdot t}, \delta_{\cdot t}; \theta_2) = \{(D_i, v_i, \epsilon_{i0t}, \dots, \epsilon_{ilt}) \mid u_{ijt} \leq u_{ilt} \forall l = 0, 1, \dots, J\}, \quad (10)$$

Para todas as marcas:

- $x_{\cdot t} = (x_{1t}, \dots, x_{Jt})$  (características)
- $p_{\cdot t} = (p_{1t}, \dots, p_{Jt})$  (preços médios)
- $\delta_{\cdot t} = (\delta_{1t}, \dots, \delta_{Jt})$  (utilidade média)

## Market Share

$$s_{jt}(x_{\cdot t}, p_{\cdot t}, \delta_{\cdot t}; \theta_2) = \int_{A_{jt}} \underbrace{P^*(D, v, \epsilon)}_{\text{f. dens. pop.}} \quad (11)$$

$$= \int_{A_{jt}} \underbrace{dP^*(\epsilon \mid D, v) dP^*(v \mid D) d\hat{P}_D^*(D)}_{\text{pela regra de Bayes}} \quad (12)$$

$$\text{Dada a hipótese de independência} \quad (13)$$

$$= \int_{A_{jt}} dP^*(\epsilon) dP_v^*(v) d\hat{P}_D^*(D) \quad (14)$$

Dadas as hipóteses sobre a distribuição dos atributos individuais não-observáveis podemos computar (11). Int: analiticamente ou numericamente.

## Hipóteses Distribucionais

- Importantes para elasticidade-preço da demanda.
- se modelarmos os choques de forma aditiva e separável, então

$$\theta_2 = 0, \text{ ou } \beta_i = \beta \text{ e } \alpha_i = \alpha.$$

Neste caso estamos no modelo logit (agregado). Isto implica em

$$s_{jt} = \frac{\exp\{x_{jt}\beta - \alpha p_{jt} + \epsilon_{jt}\}}{1 + \sum_{k=1}^J \exp\{x_{kt}\beta - \alpha p_{kt} + \epsilon_{kt}\}} \quad (15)$$

- A elasticidade-preço da demanda sugerido pelos market shares em (15) são:

$$\eta_{jkt} = \frac{\partial s_{jt} p_{kt}}{\partial p_{kt} s_{jt}} = \begin{cases} -\frac{p_{jt}}{s_{jt}} \int \alpha_i s_{ijt} (1 - s_{ijt}) d\hat{P}_D^*(D) dP_v^*(v) \\ \frac{p_{kt}}{s_{jt}} \int \alpha_i s_{ijt} s_{ikt} d\hat{P}_D^*(D) dP_v^*(v) \end{cases} \quad (16)$$

tal que

$$s_{ijt} = \frac{\exp\{\delta_{jt} + \mu_{ijt}\}}{1 + \sum_{k=1}^K \exp\{\delta_{kt} + \mu_{ikt}\}}$$

é a probabilidade do indivíduo  $i$  comprar o produto  $j$ .

## 2 Estimação

### 2.1 Dados

Dados usados por Nevo.

- global: características da marca (produto)
- por mercado: market share e preço médio
- distribuição de informações demográficas ( $\hat{P}_D^*$ )

Observações:

- definir o market share em termos de bem-real.
- definir o tamanho do mercado. Importante! Definição correta do *outside good*.
- marca – dummy por marca.
  - # mercados > # marcas

### 2.2 Identificação

Algoritmo de estimação.

Estimador GMM:

$$\min_{\theta} \|s(x, p, \delta(x, p, \epsilon; \theta_1); \theta_2) - S\| \quad (17)$$

- $s(\cdot)$ : market share do modelo
- $S$ : market share observado
- Problema: os parâmetros não são lineares

**Berry's solution** Faça  $z = [z_1, \dots, z_M]$  ser um conjunto de instrumentos tal que

$$E[z_m \omega(\theta^*)] = 0, m = 1, \dots, M$$

tal que  $\omega$  é uma função dos parâmetros do modelo e um termo de erro a ser definido e  $\theta^*$  representa os valores verdadeiros de  $\theta$ .

O estimador GMM é o seguinte:

$$\hat{\theta} = \arg \min_{\theta} \{ \omega(\theta)' z \Phi^{-1} z' \omega(\theta) \} \quad (18)$$

- $\Phi$  é uma estimativa consistente de  $E[z' \omega \omega' z]$ .
- $\Phi^{-1}$  define a métrica para o quão próximo de zero estamos. / inverso da matriz Var-Cov – então damos menos peso para as eqs com maior variância.

**Modelando o termo de erro**  $\epsilon_{jt}$  é estrutural – não é a diferença entre o observado e o previsto.

Precisamos determinar o termo de erro. De (7) temos:

$$u_{ijt} = \alpha_i y_i + \underbrace{\delta_{jt}(\cdot)}_{\epsilon_{jt} \uparrow} + \mu_{ijt}(\cdot) + \epsilon_{ijt} \quad (19)$$

Aqui  $\delta_{jt}(\cdot)$  é uma função linear de  $\epsilon_{jt}$ . Podemos expressar o termo de erro como uma função linear destes parâmetros.

Para cada mercado:

$$s(\delta_{jt}; \theta_1) = S_{jt} \quad (20)$$

Solucionando

$$\begin{aligned} s_{jt} &= \frac{1}{ns} \sum_{i=1}^{ns} s_{jti} \\ &= \frac{1}{ns} \sum_{i=1}^n s_{i=1} \frac{\exp \left\{ \delta_{jt} + \sum_{k=1}^K x_{jt}^k (\sigma_k v_i^k + \Pi_{k1} D_{i1} + \dots + \Pi_{kd} D_{id}) \right\}}{1 + \sum_{m=1}^J \exp \left\{ \delta_{mt} + \sum_{k=1}^K x_{mt}^k (\sigma_k v_i^k + \Pi_{k1} D_{i1} + \dots + \Pi_{kd} D_{id}) \right\}} \end{aligned}$$

tal que

$$(v_i^1, \dots, v_i^k) \text{ amostra de } \hat{P}_v^*(v)$$

$$(D_{i1}, \dots, D_{id}) \text{ amostra de } P_D^*(D)$$

$i = 1, \dots, ns$ , e  $k = 1, \dots, K$

- $x_{jt}^k$ ,  $k = 1, \dots, K$  são variáveis com coeficientes de inclinação aleatórios.

- $P_\epsilon^*(\epsilon)$  segue uma distribuição de valor extremo.
- Usando o market share calculado podemos inverter o sistema de equações (20).

O sistema pode ser usado utilizando o ‘mapeamento’ de contração:

$$\delta_t^{h+1} = \delta_t^h + \ln S_t - \ln s(p_t, x_t, \delta_t^h, P_{ns}; \theta_2) \quad (21)$$

tal que  $t = 1, \dots, T$  e  $h = 0, \dots, H$ .

$H$  é o menor inteiro tal que

$$\|\delta_t^H - \delta_t^{H-1}\|$$

para um nível determinado de tolerância.

$\delta_t^H$  é uma aproximação de  $\delta_t$ .

Uma vez que a inversão tenha sido calculada, o termo de erro é definido como:

$$\omega_{jt} = \delta_{jt}(s_t; \theta_2) - (x_{jt}\beta + \alpha p_{jt}) \equiv \epsilon_{jt} \quad (22)$$

Comentário (intuição): para os valores dados do parâmetro não-linear  $\theta_2$ , nós solucionamos para os níveis de utilidade média  $\delta_t(\cdot)$ , que determina que os market shares previstos são iguais aos market shares observados.

O resíduo  $\epsilon_{jt}$  é a diferença entre essa valoração e a prevista pelos parâmetros lineares  $\alpha$  e  $\beta$ .

## 2.3 Instrumentos

Necessidade: um conjunto de variáveis instrumentais exógenas.

- Obs
  - variáveis que deslocam os custos mas que não são correlacionadas com a demanda.
  - cost shifter within brand?!
- BLP:
  - características observadas dos produtos
  - soma dos valores das mesmas marcas
  - $E(\epsilon | x) = 0$  características de outros produtos oferecidos pela firma.
  - soma dos valores das mesmas características produzidos por outras firmas.
- Nevo – Problemas/dúvidas sobre a validade dos instrumentos de BLP.

- as características devem (ou deveriam) ser determinadas de uma expectativa de  $\epsilon$ .
- Se as características mudam muito por que não são correlacionadas com  $\epsilon$ ? Se não mudam por que estimativa de FE?
- Estrutura de painel (Nevo). Utiliza o preço de marcas de outras cidade como VI.

$$p_{jct} = mc_{jct} + \underbrace{mup_{jct}}_{\text{mark-up}} = mc_{jct} + \Delta mc_{jct} + mup_c + mup_t + \Delta mup_{jct} \quad (23)$$

- Preços são correlacionados por meio de choques comuns ao  $mc$  ( $mc_{jt}$ ; assumo que os choques de demanda ( $\epsilon_{jct}$ ) são independentes, condicional uma vez que são controlados por marca, cidade ( $c$ ) e efeitos fixos de tempo.
- Não tão popular. Requer mais dados. Não-intuitivo. Várias razões teóricas para não funcionar. (promoção nacional / propaganda; mudança na preferência pela marca).

## 2.4 Dummy para Marca

- Berry'94 argumenta que a metodologia de estimação é primariamente construída para instrumentalizar a correlação entre preços e  $\epsilon_{jt}$ .
- Usando a dummy,  $\epsilon_{jt}$ , não é apenas as característica não-observáveis, ela se torna desvios da média não-observada específica aos vários mercados  $t$ .
- Esta variância surge quando tratamos de mais de um mercado especificamente.
- Os coeficientes de preferência  $\beta$ s podem não ser identificados.  $\beta$ s podem ser identificados usando o procedimento de distância mínima de Chamberlain'82.

$$d = (d_1, \dots, d_j)'$$

da f. utilidade (2) temos:

$$d = x\beta + \epsilon.$$

Se assumimos que  $E[\epsilon | x] = 0$  então

$$\hat{\beta} = (x'V_d^{-1}x)^{-1}x'V_d d$$



$$\hat{\epsilon} = \hat{d} - x\hat{\beta}$$

Estimação por GLS.

$\hat{d}$  vetor de coeficientes estimados.

$$V_d = \text{Var}(\hat{d})$$