

# Modelos de participación de mercado

## IN58B Ingeniería de Marketing

Nicolás Fritis  
Manuel Reyes  
Mauricio Ramírez

# Introducción

- ¿Por qué modelos de **Participación de Mercado** (PM)?

Se busca modelos en que puedan introducirse factores competitivos de las marcas presentes en el mercado y puedan aislarse los efectos externos (por ejemplo, ciclos económicos).

# Modelos de participación de mercado

## Modelos estocásticos agregados

# Modelos estocásticos

- Estos modelos están muy asociados a lo que vimos como modelos estocásticos de compra del consumidor.
- Buscamos modelos que describan adecuadamente el comportamiento agregado de los consumidores.
- Vimos un modelo respecto a los instantes de compra de los consumidores (Modelo de incidencia de compra). Ahora el foco corresponde al estudio de las participaciones de mercado.

# Definiciones preliminares<sub>(1)</sub>

- Datos de Panel:**  
 Seguimiento de las marcas compradas por una muestra identificable de consumidores.
  
- Matrices de intercambio de marcas (Brand Switch):** Registros derivado de datos de panel que indican como los consumidores cambian de marcas de un periodo a otro.

Datos Panel	T1	T2	T3	T4	T5
C001	A	A	A	B	A
C002	A	C	B	A	B
C003	A	B	B	B	A

Compras	T+1						
	A	B	C	Total			
T	Conjunta	T+1			Total		
		A	B	C			
To	T	Condicional	T+1			Total	
			A	B	C		
To	T	Condicional	A	0.675	0.232	0.094	1.000
			B	0.177	0.772	0.052	1.000
			C	0.282	0.128	0.590	1.000

## Definiciones preliminares<sub>(2)</sub>

- Se definen:

$$\left. \begin{aligned}
 P(i | j) &= \text{P}(\text{comprar } i \text{ en } t+1 \mid \text{compra } j \text{ en } t) \\
 P(i, j) &= \text{P}(\text{comprar } j \text{ en } t \text{ y comprar } i \text{ en } t+1) \\
 P(j) &= \text{P}(\text{comprar } j \text{ en } t+1)
 \end{aligned} \right\} P(i | j) = \frac{P(i, j)}{P(j)}$$

- Notar que:

$$\sum_i P(i | j) = 1 \quad (\text{ley probabilidad})$$

$$\sum_j P(i, j) = P(i) = m_i \quad (\text{market share})$$

## Modelo Ehremberg (Orden 0)

- Basado en observaciones empíricas, Ehremberg postuló que:

$$P(i, j) = k \cdot m_i \cdot m_j$$

- Con esto:

$$P(i, i) = m_i - k \cdot m_i (1 - m_i)$$

La lealtad depende sólo de la participación de mercado

$$P(i | j) = \begin{cases} k \cdot m_i & i \neq j \\ 1 - k(1 - m_i) & i = j \end{cases}$$

La compra actual no depende de la compra anterior

# Calibración

- Para la calibración del modelo requerimos:
  - Participaciones de mercado del último periodo ( $m_i$ )
  - Probabilidad de compra repetitiva para cada marca ( $P(i,i)$ ).

$$k = \frac{1 - \sum_i P(i,i)}{1 - \sum_i m_i^2}$$

- El valor de  $k$  indica algunas características del mercado:
  - Mercado maduro  $k \approx 0.5$
  - Mercado de lealtad  $k \ll 1$

## Uso de gestión

- La capacidad predictiva es bastante baja (un modelo de orden cero asume implícitamente cierta estabilidad en el mercado).
- La aplicación más directa corresponde a la validación de los supuestos por medio de la comparación de las matrices de Brand Switch reales y teóricas:
  - Los consumidores compran como en un modelo de atracción.
  - Los consumidores son de orden 0 (no importa que compraron en el pasado).

## Ejemplo<sub>(1)</sub>

Compras		T+1				
		A	B	C	Total	mi
T	A	137	47	19	203	0.396
	B	41	179	12	232	0.452
	C	22	10	46	78	0.152
Total		200	236	77	513	1.000

Conjunta (real)		T+1			
		A	B	C	Total
T	A	0.267	0.092	0.037	0.396
	B	0.080	0.349	0.023	0.452
	C	0.043	0.019	0.090	0.152
Total		0.390	0.460	0.150	1.000

$$\begin{aligned}
 k &= \frac{1 - (0.267 + 0.349 + 0.090)}{1 - (0.396^2 + 0.452^2 + 0.152^2)} \\
 &= 0.478
 \end{aligned}$$

## Ejemplo<sub>(2)</sub>

Conjunta (real)		T+1			
		A	B	C	Total
T	A	0.267	0.092	0.037	0.396
	B	0.080	0.349	0.023	0.452
	C	0.043	0.019	0.090	0.152
Total		0.390	0.460	0.150	1.000

Conjunta (teórica)		T+1			
		A	B	C	Total
T	A	0.281	0.086	0.029	0.396
	B	0.086	0.334	0.033	0.452
	C	0.029	0.033	0.090	0.152
Total		0.396	0.452	0.152	1.000

$$\left\{ \begin{array}{l} P(i, j) = k \cdot m_i \cdot m_j \\ P(i, i) = m_i - k \cdot m_i (1 - m_i) \end{array} \right.$$

## Ejemplo<sub>(3)</sub>

Condicional (real)		T+1			
		A	B	C	Total
T	A	0.675	0.232	0.094	1.000
	B	0.177	0.772	0.052	1.000
	C	0.282	0.128	0.590	1.000

Condicional (teórica)		T+1			
		A	B	C	Total
T	A	0.711	0.216	0.073	1.000
	B	0.189	0.738	0.073	1.000
	C	0.189	0.216	0.595	1.000

$$\leftarrow \left\{ P(i | j) = \begin{cases} k \cdot m_i & i \neq j \\ 1 - k(1 - m_i) & i = j \end{cases} \right.$$

## Modelo Markoviano<sub>(1)</sub>

- **Supuesto:** La probabilidad de comprar una determinada marca depende sólo de la marca comprada en el periodo anterior.
- Sea  $Y_t$  la marca elegida en el periodo  $t$ . Luego los supuestos se reducen a:

$$\mathbf{P}\{Y_t = k \mid Y_{t-1}, Y_{t-2}, \dots, Y_0\} = \mathbf{P}\{Y_t = k \mid Y_{t-1}\} \quad \text{Propiedad markoviana}$$

$$\mathbf{P}\{Y_t = k \mid Y_{t-1}\} = \mathbf{P}\{Y_{t+n} = k \mid Y_{t+n-1}\} \quad \text{Incrementos estacionarios}$$

## Modelo Markoviano<sub>(2)</sub>

- Sea una matriz de probabilidad  $P = \{p_{ij}\}_{ij}$ , donde  $p_{ij}$  es la probabilidad que un consumidor compre  $j$  dado que en el periodo actual compró  $i$ .

$$0 \leq p_{ij} \leq 1$$

$$\sum_i p_{ij} = 1$$

## Modelo Markoviano<sub>(3)</sub>

- Sea  $m_{it}$  la probabilidad de comprar la marca  $i$  en el periodo  $t$ . Entonces:

$$m_{it} = \sum_{j=1}^n p_{ji} m_{jt-1} \quad i = 1 \dots n$$

$$m_{i\infty} : \quad m_{\infty} = m_{\infty} \cdot P \quad \sum_i m_{i\infty} = 1$$

## Modelo Markoviano<sub>(4)</sub>

- Ejemplo:

- Con  $m_{A,t-1} = m_{B,t-1} = 0.5$

		t	
		A	B
t-1	A	0.7	0.3
	B	0.5	0.5

$$m_{A,t} = m_{A,t-1} * p_{AA} + m_{B,t-1} * p_{BA}$$

$$m_{A,t} = (0.5)(0.7) + (0.5)(0.5) = 0.6$$

$$m_{B,t} = 1 - m_{A,t} = 1 - 0.6 = 0.4$$

$$m_{A,t+1} = m_{A,t} * p_{AA} + m_{B,t} * p_{BA} = (0.6)(0.7) + (0.4)(0.5) = 0.62$$

$$m_{A,\text{infinito}} = 0.625$$

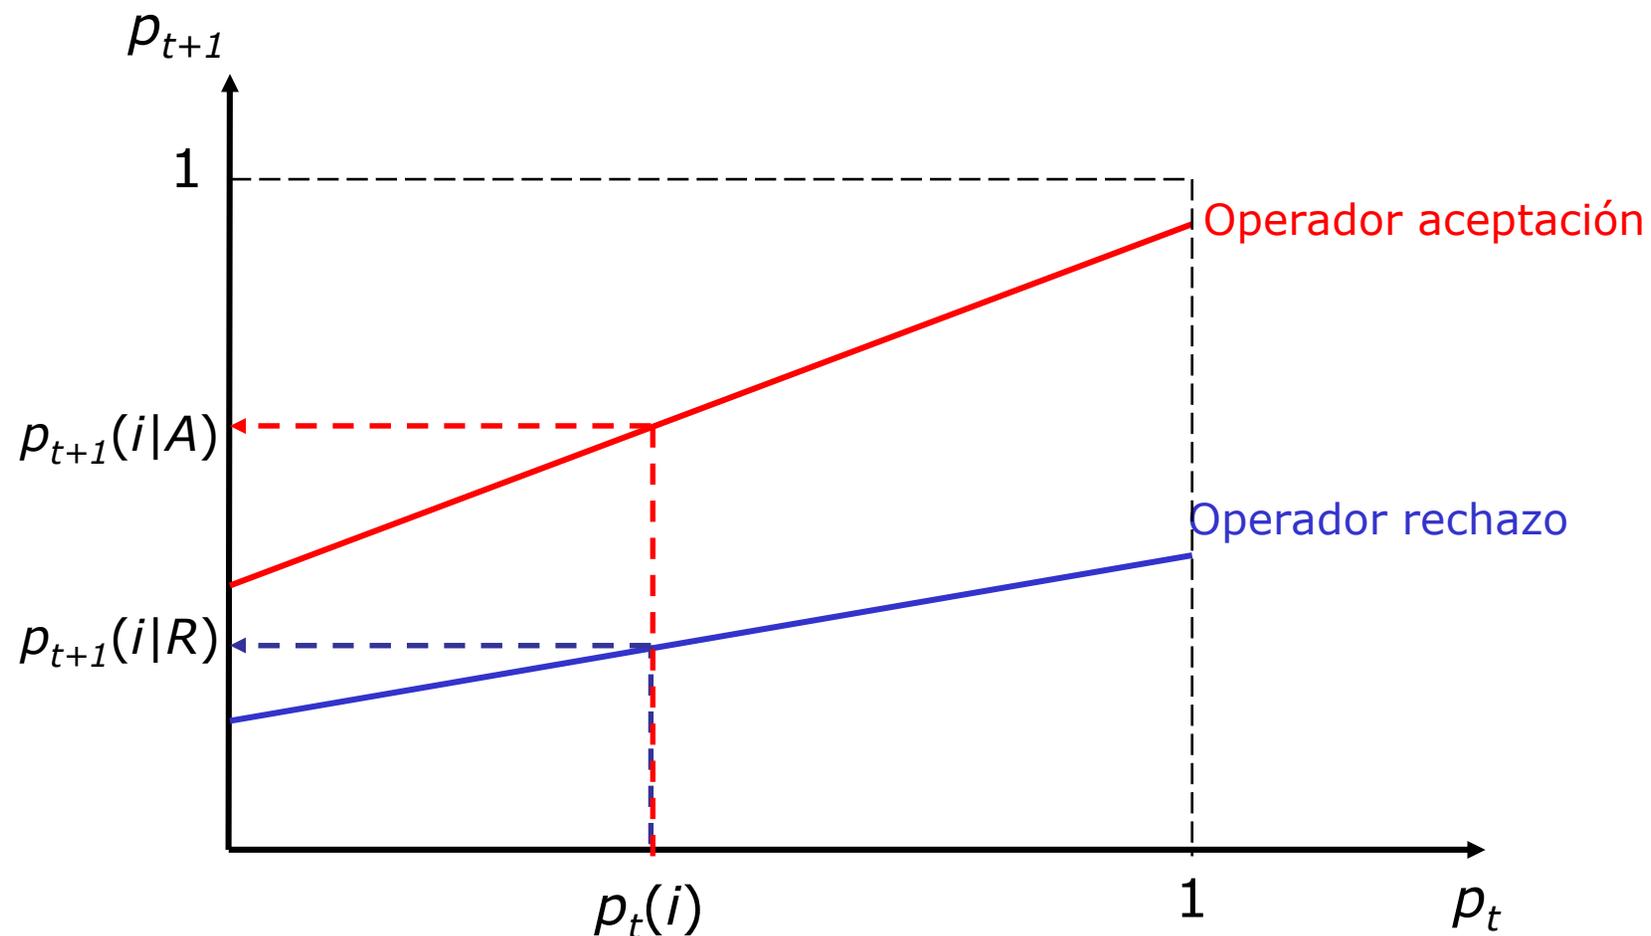
## Modelo de aprendizaje

- **Supuesto:** La compra de la marca aumenta la probabilidad de repetirla mientras que la no compra la disminuye.
- Modelo básico con 2 marcas. Sea  $p_t$  la probabilidad de comprar la marca de interés en el periodo  $t$ . El modelo:

$$p_t = \begin{cases} \alpha_1 + \lambda_1 p_{t-1} & \text{si se elije marca en } t \\ \alpha_2 + \lambda_2 p_{t-1} & \sim \end{cases}$$

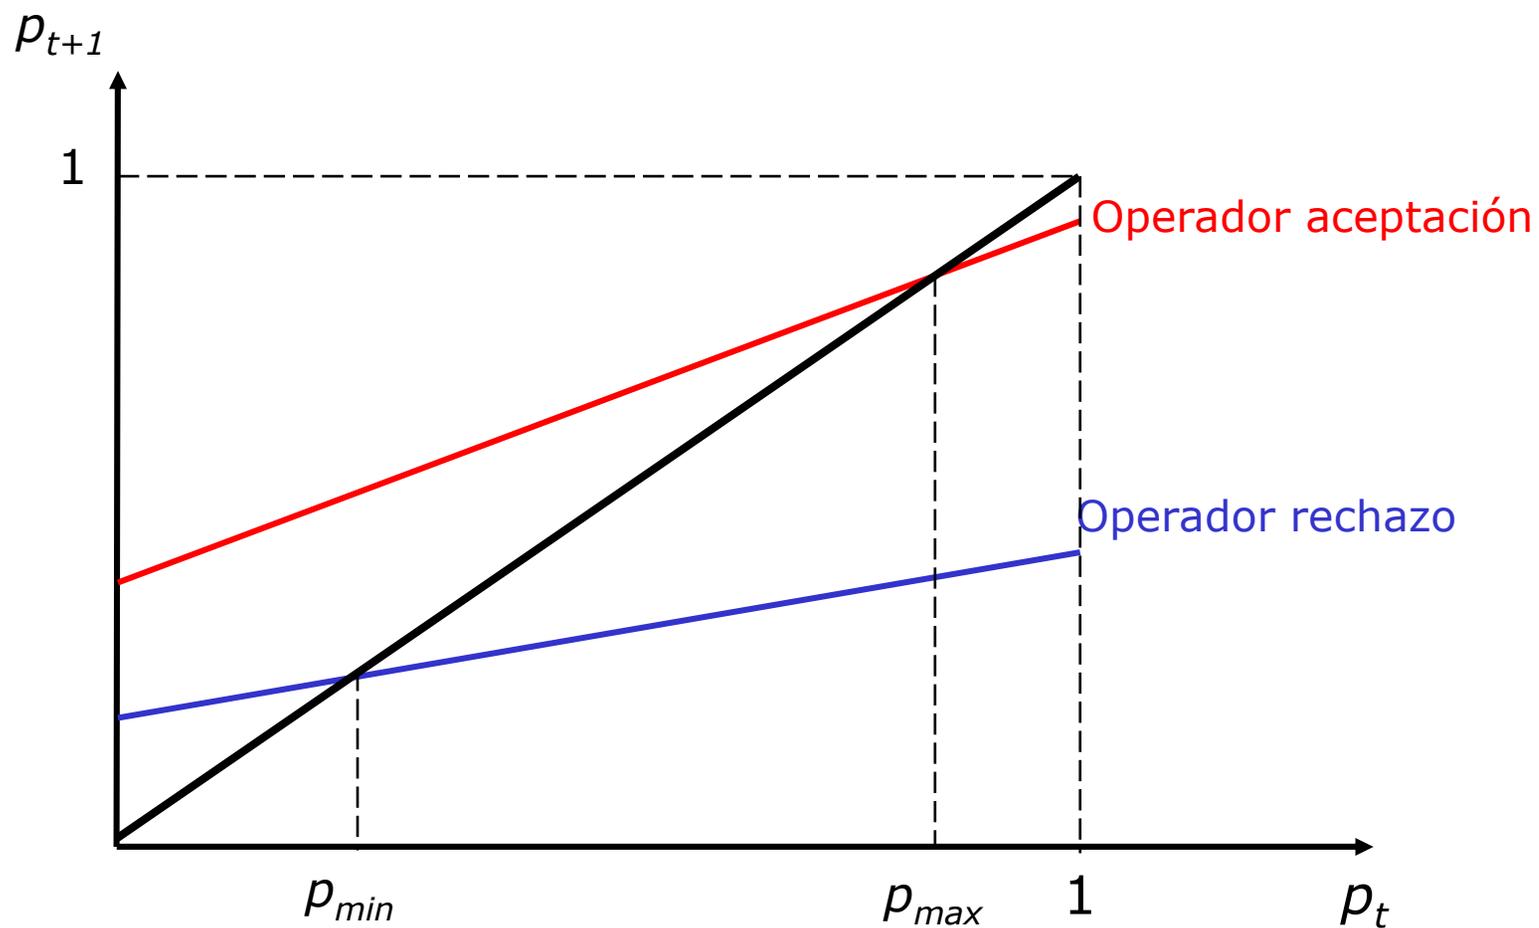
Operador  
 aceptación  
  
 Operador  
 rechazo

## Gráficamente<sub>(1)</sub>



¿Qué ocurre si no compra nunca el producto?  
 ¿Qué ocurre si compra siempre el producto?

## Gráficamente<sub>(2)</sub>



¿Cómo interpretar los parámetros del modelo?

# Modelos de participación de mercado

Modelos basados en la competencia

## Definiciones básicas

- La definición del mercado y del conjunto de marcas a considerar dependerán del contexto:
  - Ej: mercados de las zapatillas o de las zapatillas para deporte o de las zapatillas para jugar fútbol o...
- Consideremos.
  - Participación de mercado (market share) de la marca  $i$  ( $s_i$ ).
  - Ventas del producto  $i$ , típicamente medidas en unidades ( $Q_i$ ).
  - Ventas totales de los productos del mercado ( $Q$ ).
  - Número de marcas en el mercado ( $m$ ).

$$s_i = \frac{Q_i}{Q} = \frac{Q_i}{\sum_{j=1}^m Q_j}$$

## Enfoque de esfuerzos de marketing<sub>(1)</sub>

- **Premisa básica:** la participación de mercado de una marca  $i$  es proporcional a su esfuerzo de marketing  $M_i$  (Kotler, 1984):

$$s_i = k \cdot M_i \quad \sum_i s_i = 1 \Rightarrow k = \frac{1}{\sum_i M_i}$$

- **Teorema fundamental de la participación de mercado:** “La participación de mercado de cada marca es proporcional a su porción total del esfuerzo de marketing”.

$$s_i = \frac{M_i}{\sum_i M_i}$$

## Enfoque de esfuerzos de marketing<sub>(2)</sub>

- Los esfuerzos son independientes de los resultados. Podemos introducir un coeficiente de efectividad por marca  $\alpha_i$ :

$$s_i = \frac{\alpha_i M_i}{\sum_j \alpha_j M_j}$$

- Hasta ahora no hemos dicho mucho: necesitamos explicitar que queremos decir con *esfuerzo de marketing*. Según Kotler, es función del marketing mix actual y previo.

$$M_i = f(\text{precio}_i, \text{publicidad}_i, \text{distribucion}_i, \dots)$$

## Esfuerzos de marketing

- Se han propuesto varias formas funcionales. Consideremos:
  - Precio del producto de la marca  $i$ ,  $P_i$ .
  - Gasto en publicidad de la marca  $i$ ,  $A_i$ .
  - Esfuerzo en distribución de la marca  $i$  (por ejemplo, número de tiendas),  $D_i$ .

$$M_i = \exp(pP_i + aA_i + dD_i + \dots)$$

$$M_i = P_i^p A_i^a D_i^d \dots$$

- La primera forma corresponde a la versión más simple del **MNL** (multinomial logit), mientras que la segunda corresponde a **MCI** (multiplicative, competitive-interaction).

# Esfuerzos de marketing (Ejp)

$$M_i = P_i^p A_i^a D_i^d \dots$$

Ejemplo numérico del Teorema Fundamental de Kotler

Empresa	Coef Efect	Precio	Publicidad	Distribución	Esf Mktg	Esf Mktg pond	Market Share
1	0,9	\$ 10,5	\$ 80.000	\$ 54.000	\$ 77.558	\$ 69.802	28,7%
2	1,2	\$ 11,3	\$ 90.000	\$ 48.000	\$ 66.374	\$ 79.649	32,7%
3	1	\$ 9,8	\$ 70.000	\$ 65.000	\$ 94.012	\$ 94.012	38,6%
		-1,8	0,6	0,8	\$ 237.944	\$ 243.463	100,0%
<i>parametros</i>							

Aumento del Market Share en la empresa 2

Ejemplo Numérico - El efecto de bajar el precio

Empresa	Coef Efect	Precio	Publicidad	Distribución	Esf Mktg	Esf Mktg pond	Market Share
1	0,9	\$ 10,5	\$ 80.000	\$ 54.000	\$ 77.558	\$ 69.802	26,5%
2	1,2	\$ 10,0	\$ 90.000	\$ 48.000	\$ 82.706	\$ 99.248	37,7%
3	1	\$ 9,8	\$ 70.000	\$ 65.000	\$ 94.012	\$ 94.012	35,7%
		-1,8	0,6	0,8	\$ 254.276	\$ 263.062	100,00%
<i>parametros</i>							

## Enfoque de atracción de marcas

- **Premisa básica:** El único determinante al momento de realizar la compra es la atracción que ejerce la marca sobre los consumidores (Bell, Kenney y Little 1975):
- La atracción que ejerce una marca  $i$  ( $A_i$ ) debe cumplir con una serie de axiomas:

$$\text{Ax1: } A_i \geq 0 \forall i \wedge \sum_i A_i > 0$$

$$\text{Ax2: } A_i = 0 \Rightarrow s_i = 0$$

$$\text{Ax3: } A_i = A_j \Rightarrow s_i = s_j$$

Ax4: Si la atracción de una marca cambia, el market share de cualquier marca se ve afectado, independiente de cual sea esa marca.

$$s_i = \frac{A_i}{\sum_i A_i}$$

## Modelos de participación de mercado<sub>(1)</sub>

- Consideremos:
  - Valor de la variable explicativa  $k$  de la marca  $i$  ( $x_{ki}$ ).
  - Parámetro de influencia constante de la marca  $i$  ( $\alpha_i$ ).
  - Parámetro a ser estimado ( $\beta_k$ ).
  - Error ( $\varepsilon_i$ )

$$\left. \begin{array}{l}
 \text{MCI: } A_i = \exp(\alpha_i) \prod_k x_{ki}^{\beta_k} \varepsilon_i \\
 \text{MNL: } A_i = \exp\left(\alpha_i + \sum_k \beta_k x_{ki} + \varepsilon_i\right)
 \end{array} \right\} s_i = \frac{A_i}{\sum_i A_i}$$

## Modelos de participación de mercado<sub>(2)</sub>

- Existen otros modelos de participación de mercado en que no importan los competidores:

$$s_i = \alpha_i + \sum_k \beta_k x_{ki} + \varepsilon_i \quad \text{lineal}$$

$$s_i = \exp(\alpha_i) \prod_k x_{ki}^{\beta_k} \varepsilon_i \quad \text{multiplicativo}$$

$$s_i = \exp\left(\alpha_i + \sum_k \beta_k x_{ki} + \varepsilon_i\right) \quad \text{exponencial}$$

- Naert & Bultez (1973), plantean 2 requerimientos de consistencia lógica que estos modelos no cumplen:
  - $s_i \geq 0$ .
  - $\sum_i s_i = 1$ .

## Calibración de parámetros

- La calibración de parámetros se puede hacer usando regresiones lineales para lo cual se deben linealizar (log-centering) las expresiones.

$$\text{MCI: } \ln\left(\frac{S_i}{\bar{S}}\right) = \alpha_i^* + \sum_{k=1}^K \beta_k \ln\left(\frac{x_{ki}}{\bar{x}}\right) + \varepsilon_i^* \quad \text{con} \quad \alpha_i^* = (\alpha_i - \bar{\alpha})$$

$$\varepsilon_i^* = \ln\left(\frac{\varepsilon_i}{\bar{\varepsilon}}\right)$$

$$\text{MNL: } \ln\left(\frac{S_i}{\bar{S}}\right) = \alpha_i^* + \sum_{k=1}^K \beta_k (x_{ki} - \bar{x}) + \varepsilon_i^* \quad \text{con} \quad \alpha_i^* = (\alpha_i - \bar{\alpha})$$

$$\varepsilon_i^* = (\varepsilon_i - \bar{\varepsilon})$$

## Elasticidades de $MS_{(1)}$

- **Definición:** Corresponde al cambio relativo en la participación de mercado ante la variación en una variable del marketing mix.

$$e_{s_i} = \frac{\Delta s_i / s_i}{\Delta x_{ki} / x_{ki}} = \frac{\Delta s_i}{\Delta x_{ki}} \frac{x_{ki}}{s_i}$$

- En la práctica es muy difícil aislar los efectos para una medición empírica. Para encontrar una elasticidad debemos asumir un modelo, calibrarlo y calcular las elasticidades punto:

$$e_{s_i} = \frac{\partial s_i}{\partial x_{ki}} \frac{x_{ki}}{s_i}$$

## Elasticidades de $MS_{(2)}$

- Siguiendo este esquema podemos calcular elasticidades para cada uno de los modelos propuestos:

$$e_{s_i} = (\beta_k x_{ki}) / s_i \quad \text{lineal}$$

$$e_{s_i} = \beta_k \quad \text{multiplicativo}$$

$$e_{s_i} = \beta_k x_{ki} \quad \text{exponencial}$$

$$e_{s_i} = \beta_k (1 - s_i) \quad \text{MCI}$$

$$e_{s_i} = \beta_k (1 - s_i) x_{ki} \quad \text{MNL}$$

# Propiedades elasticidad

- ¿Qué propiedades debiera cumplir una elasticidad de participación de mercado?

$$1. e_{Q_i x_j} = e_{Q x_j} + e_{s_i x_j}$$

$$2. \text{Si } s_i \text{ creciente en } x_j \Rightarrow \lim_{s_i \rightarrow 1} e_{s_i x_j} = 0 \quad \text{Se satura el mercado}$$

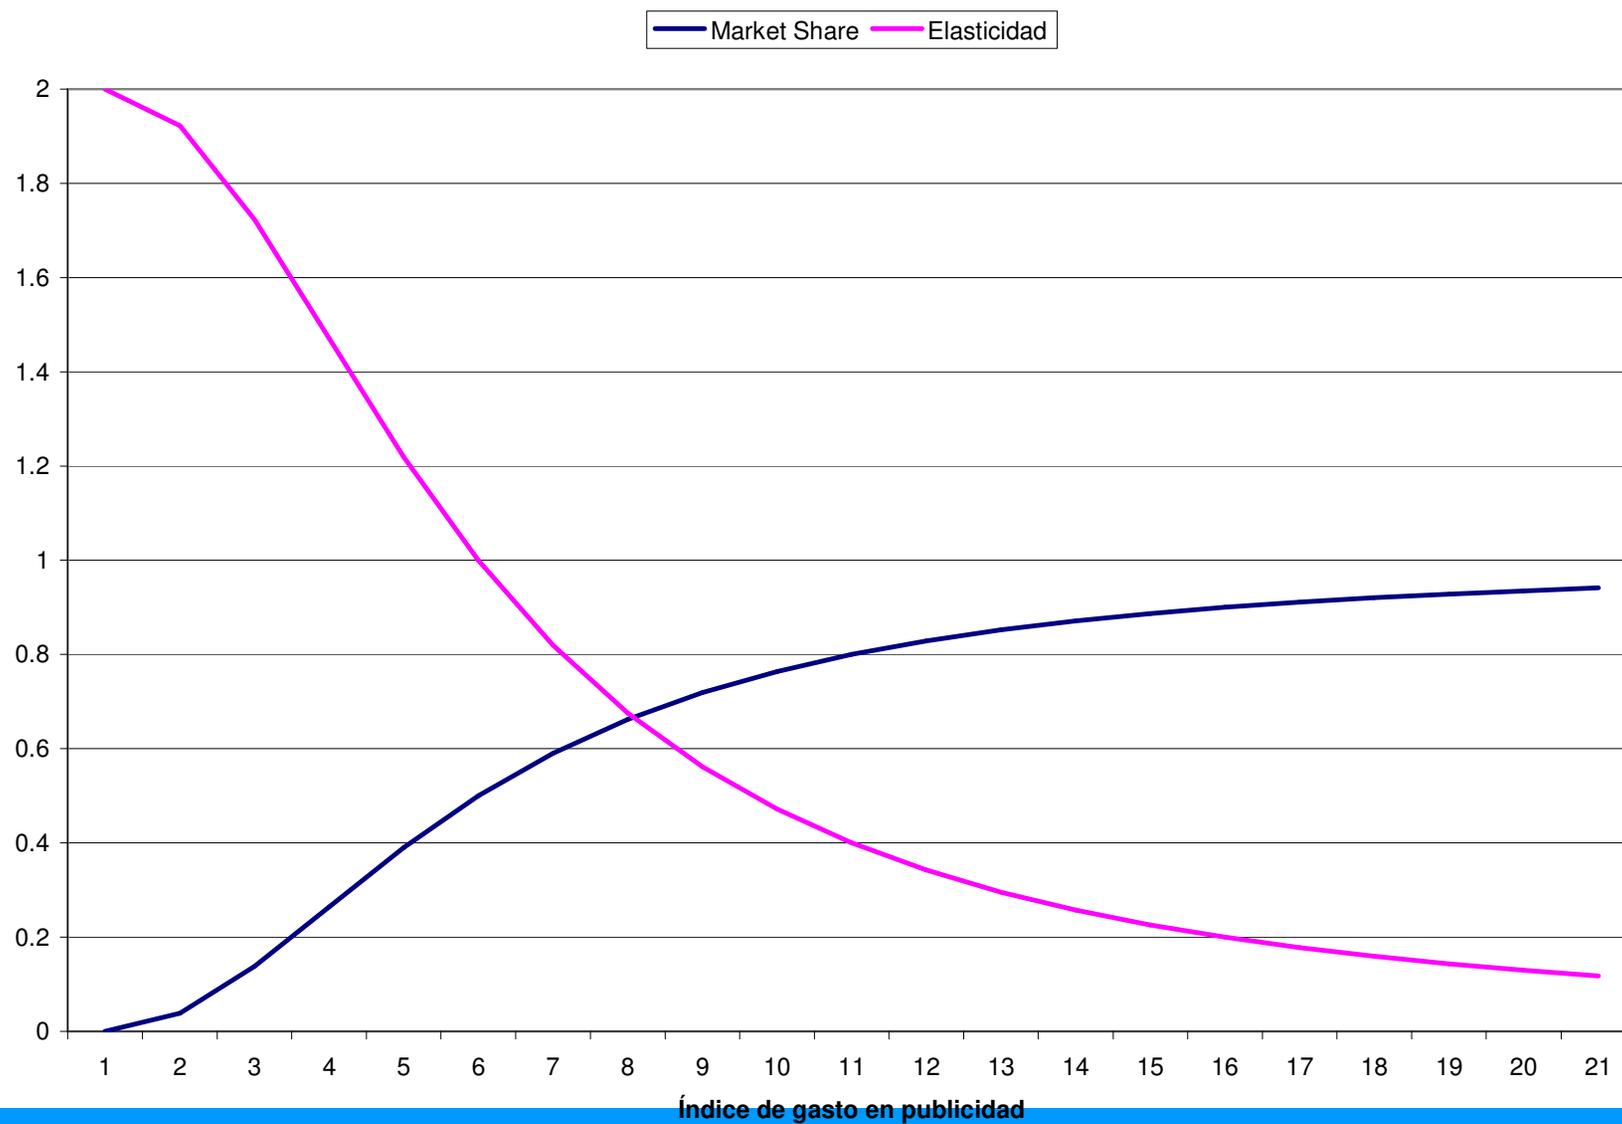
$$3. \text{Si } s_i \text{ creciente en } x_j \Rightarrow \lim_{x \rightarrow \infty} e_{s_i x_j} = 0 \quad \text{Se satura el recurso}$$

- Se puede demostrar que todos los modelos cumplen con propiedad 1, pero modelos lineal, multiplicativo y exponencial no satisfacen 2 y 3.

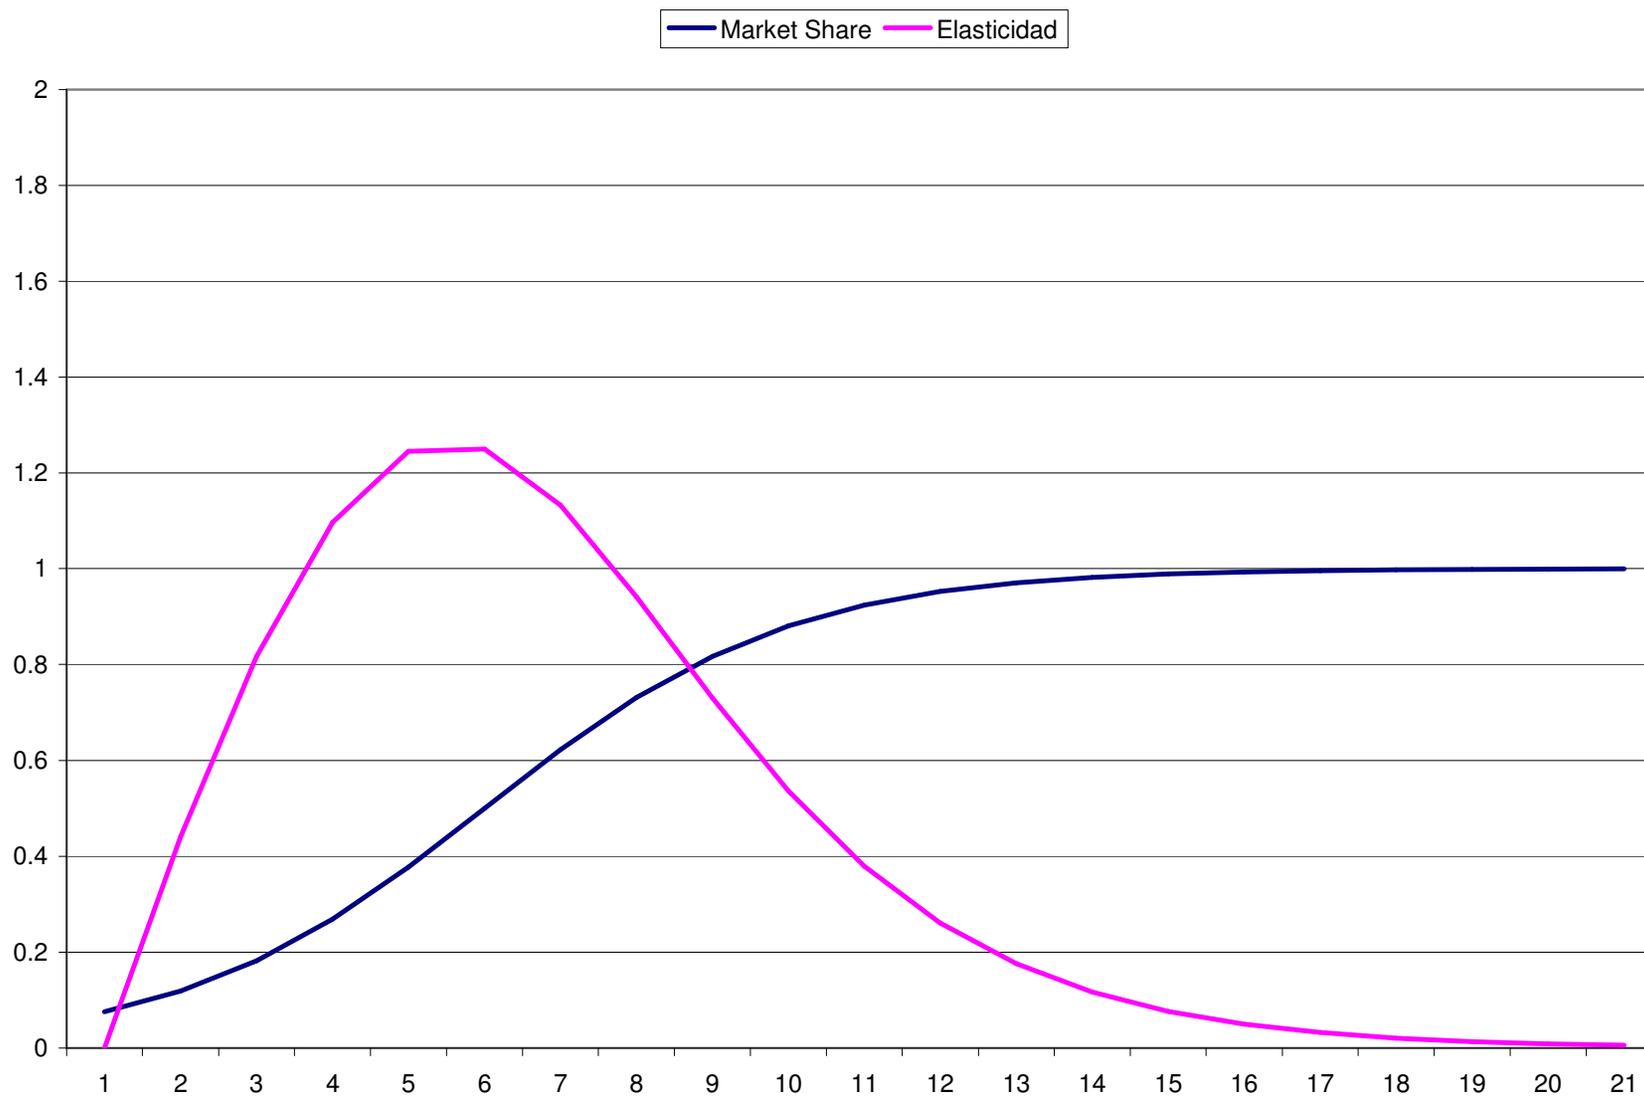
## MCI vs. MNL

- Hemos visto razones por las cuales preferir MNL o MCI frente a modelos lineales, multiplicativo o exponenciales. Pero, ¿Cuándo usar MCI y cuándo usar MNL?
- A pesar de ser conceptualmente muy distintos, si miramos numéricamente los resultados de las participaciones de mercado, los comportamientos son muy similares. Las diferencias aparecen al observar las elasticidades:
  - ¿Cómo debiera ser el comportamiento para valores bajos de la variable explicativa?
  - ¿depende del mercado o del atributo?

# MCI



# MNL



## Modelo general de atracción

- Podemos formular un modelo en que algunos efectos sean del tipo MCI y otros del tipo MNL.

$$\text{MGA: } A_i = \exp(\alpha_i + \varepsilon_i) \prod_{k=1}^K f_k(x_{ki})^{\beta_k}$$

$$f_k(x) = \begin{cases} x & \text{MCI} \\ \exp(x) & \text{MNL} \end{cases}$$

## Extensiones<sub>(1)</sub>

- El parámetro de efectividad  $\alpha_i$  es propio de cada marca, pero independiente de las acciones específicas que tome.
- Una marca podría ser más efectiva en algunas variables del marketing mix.
- Podemos hacer que el parámetros  $\beta$  dependa de la marca.

$$\text{MGA: } A_i = \exp(\alpha_i + \varepsilon_i) \prod_{k=1}^K f_k(x_{ki})^{\beta_{ki}}$$

## Extensiones<sub>(2)</sub>

- Elasticidades cruzadas:

$$e_{s_i \cdot j} = \frac{\partial s_i / s_i}{\partial x_{kj} / x_{kj}} = \frac{\partial s_i}{\partial x_{ki}} \frac{x_{ki}}{s_i}$$

$$e_{s_i \cdot j} = -\beta_{kj} s_j$$

MCI

$$e_{s_i \cdot j} = -\beta_{kj} x_k s_j$$

MNL

Problema IIA!  
(Revisar Axioma 4)

- Definimos un parámetro de competitividad cruzada de la variable  $x_{kj}$  sobre la marca  $i$  ( $\beta_{kij}$ ).

$$\text{MGA: } A_i = \exp(\alpha_i + \varepsilon_i) \prod_{k=1}^K f_k(x_{ki})^{\beta_{kij}}$$

# Modelos de participación de mercado

## IN58B Ingeniería de Marketing

Nicolás Fritis  
Manuel Reyes  
Mauricio Ramírez