

Maestría en Marketing
Métodos y técnicas de análisis cuantitativo y cualitativo

Medición de relaciones entre dos variables

- Referencia: PR Caps 8, 9.G. Caps 1-5 KT Cap 18

Otoño 2003


Problema a tratar

- Queremos estudiar la relación entre dos variables, por ejemplo, cómo cambia la venta de cigarrillos cuando cambia el precio.
- Esto también nos llevará a saber:
 - Qué tan buena es nuestra estimación de esta relación?
 - Es el precio la única variable relevante?

Primera aproximación: Covarianza y Correlación

- Tenemos una muestra de tamaño n para dos variables Y_i, X_i .
- Primeramente, exploraremos la posibilidad de que ambas variables estén relacionadas linealmente.
- Lo que queremos es medir la dirección de esta relación (si es positiva o negativa) y su precisión.

Representación gráfica: diagrama de dispersión



Formas de Medición

• Covarianza:
$$Cov(Y, X) = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{n}$$

• Correlación:
$$r_{X,Y} = \frac{Cov(Y, X)}{s_X s_Y}$$

Propiedades de la Covarianza y la Correlación:

- Ambas medidas son simétricas, es decir:

$$Cov(Y, X) = Cov(X, Y)$$

$$r_{X,Y} = r_{Y,X}$$

- La Covarianza depende de la unidad de medida de ambas variables, pero la correlación no.
- La correlación está acotada entre -1 y 1, mientras que la covarianza no está acotada. Esto es:


$$-\infty \leq Cov(Y, X) \leq +\infty$$

$$-1 \leq r_{X,Y} \leq 1$$

Propiedades de la Covarianza y la Correlación:

- $r=1$ siempre que la relación entre las variables sea exacta y positiva. De forma similar, $r=-1$ cuando la relación es exacta pero negativa.
- La correlación no implica causalidad.
- Tanto la covarianza como la correlación son medidas de relaciones *lineales*.

Representación gráfica: diagrama de dispersión




El Modelo Lineal General para Dos Variables:

- Buscamos describir con más precisión la relación lineal.
- Para esto proponemos el siguiente modelo

$$Y_i = \alpha + \beta X_i + u_i$$

- En este modelo, α y β son parámetros desconocidos, que serán el objeto de nuestro estudio. u_i es un variable aleatoria no observada incluida para tomar en cuenta que la relación no es exacta.
- Para simplificar, supondremos que los residuos tienen distribución $N(0, \sigma^2)$, y también que las X no pueden tomar el mismo valor.



Estimación


- Llamemos $\hat{\alpha}$ y $\hat{\beta}$ a los valores estimados de α y β . Entonces, el valor estimado de la variable explicada será:

$$\hat{Y}_i = \hat{\alpha} + \hat{\beta}X_i$$

- Luego, es natural definir el error de predicción como:

$$e_i = Y_i - \hat{Y}_i$$

- Entonces, el objetivo es elegir $\hat{\alpha}$ y $\hat{\beta}$ de modo de hacer que e_i sea lo más pequeño posible



El método de Mínimos Cuadrados Ordinarios

- Debemos entonces dar una definición más precisa de *bueno*.
- El método de mínimos cuadrados propone una función de penalidad para los errores, de modo de elegir los parámetros tales que se minimice esta función de penalidad.
- Esta función se la denomina *suma de los cuadrados residuales*:


$$SCR = \sum_{i=1}^n e_i^2$$

- Notemos que esta función de penalidad pesa de igual manera los errores positivos y los negativos. Lo que importa es la magnitud del error.

El método de Mínimos Cuadrados Ordinarios

- Se puede mostrar que los valores estimados que minimizan esa función de penalidad son:

$$\hat{\beta} = \frac{Cov(Y, X)}{s_X^2} = r_{X,Y} \frac{s_Y}{s_X}$$
$$\hat{\alpha} = \bar{Y} - \hat{\beta} \bar{X}$$



Propiedades de los estimadores MCO:

- Notar que los estimadores son variables aleatorias, porque es una función de la muestra que es aleatoria.

- El estimador MCO es *insesgado*, esto es:

$$E(\hat{\beta}) = \beta$$

- Comparado con cualquier otro estimador lineal e insesgado, la varianza del estimador MCO es la menor

Bondad de Ajuste:

- Lo que queremos es buscar una medida que exprese qué tan bien ajusta la estimación a los datos.
- Dado que para estimar utilizamos el concepto de SRC, el criterio de bondad de ajuste que sea consistente con esto.

$$\sum_{i=1}^n Y_i^2 = \sum_{i=1}^n \hat{Y}_i^2 + \sum_{i=1}^n e_i^2$$
$$SCT = SCE + SCR$$

- Luego, la medida que utilizaremos será:

$$R^2 = \frac{SCE}{SCT}$$

Test de Hipótesis en el modelo lineal

- Queremos evaluar la significatividad de los verdaderos valores de los parámetros a través de los valores estimados.
- El test que propondremos es:

$$H_0 : \beta = 0$$

vs.

$$H_A : \beta \neq 0$$

- Luego, el estadístico que utilizaremos es:

$$Z = \frac{\hat{\beta} - 0}{\sqrt{Var(\hat{\beta})}}$$

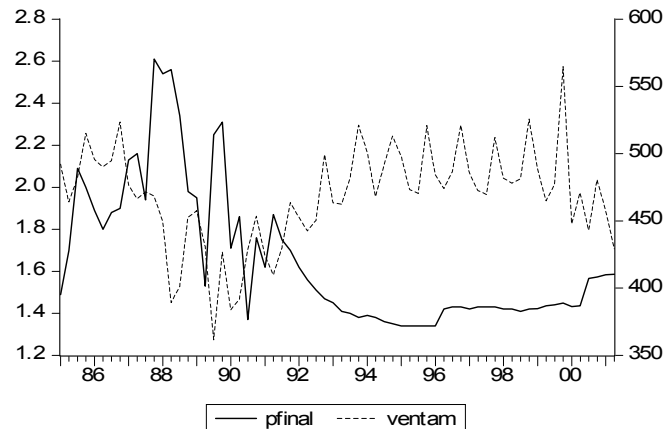
Ejemplo: Demanda de Cigarrillos

- Estadísticas descriptivas

	VENTAM	PFINAL
Mean	468.2423	1.655366
Median	471.2896	1.500000
Maximum	564.7805	2.610000
Minimum	361.5688	1.340000
Std. Dev.	37.28738	0.334876


Ejemplo: Demanda de Cigarrillos

- Evolución temporal:



Ejemplo: Demanda de Cigarrillos

- Diagrama de Dispersión:



Métodos y técnicas de análisis cuantitativo y cualitativo

20

Ejemplo: Demanda de Cigarrillos

- Salida de E-Views:


Variable	Coefficient	Std. Error	t-Statistic	Prob.
PFINAL	-48.31218	12.53999	-3.852650	0.0003
C	548.2167	21.17246	25.89291	0.0000
R-squared	0.188259	Mean dependent var	468.2423	
Adjusted R-squared	0.175576	S.D. dependent var	37.28738	
S.E. of regression	33.85613	Akaike info criterion	9.911951	
Sum squared resid	73359.19	Schwarz criterion	9.978305	
Log likelihood	-325.0944	F-statistic	14.84291	
Durbin-Watson stat	1.062075	Prob(F-statistic)	0.000273	

Métodos y técnicas de análisis cuantitativo y cualitativo

21

Ejemplo: Demanda de Cigarrillos

- Representación Gráfica:



Métodos y técnicas de análisis cuantitativo y cualitativo

22