

881201

2  
207

**UNIVERSIDAD ANAHUAC**

ESCUELA DE ACTUARIA

Con Estudios Incorporados a la  
UNIVERSIDAD NACIONAL AUTONOMA DE MEXICO



**UNIVERSIDAD ANAHUAC**

VINCI IN BONO MALUM

**"COMBINACION DE SERIES DE TIEMPO Y  
CORTE TRANSVERSAL"**

TESIS CON  
FALLA DE ORIGEN

**TESIS**  
que para obtener el título de  
**ACTUARIO**  
presenta

**JAVIER VARGAS DIEZ BARROSO**

Mexico, D.F.

1985



## **UNAM – Dirección General de Bibliotecas Tesis Digitales Restricciones de uso**

### **DERECHOS RESERVADOS © PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL**

Todo el material contenido en esta tesis está protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

## INDICE

<b>CAPITULO 1: INTRODUCCION.</b>	<b>4</b>
<b>CAPITULO 2: ELEMENTOS DE ALGEBRA LINEAL.</b>	
2.1 DETERMINANTES	6
2.2 LA MATRIZ INVERSA	7
2.3 PRODUCTO DE KRONECKER	8
2.4 VALORES Y VECTORES CARACTERISTICOS	8
2.5 FORMAS CUADRATICAS Y MATRICES POSITIVAS DEFINIDAS	9
<b>CAPITULO 3: MODELOS DE REGRESION LINEAL.</b>	<b>11</b>
3.1 MODELO DE REGRESION DE DOS VARIABLES.	12
3.2 MODELO DE REGRESION MULTIPLE.	18
3.3 MINIMOS CUADRADOS GENERALIZADOS.	19
<b>CAPITULO 4: MODELOS DE COEFICIENTES VARIABLES.</b>	<b>22</b>
4.1 MODELO DE COEFICIENTES CONSTANTES (COCO)	26
4.1.1 Estimacion	27
4.1.2 Pruebas de hipotesis	28
4.2 MODELOS DE PENDIENTE CONSTANTE E INTERSECCION VARIABLE SOBRE LOS INDIVIDUOS	29

4.2.1 Modelo de variables artificiales (MOVAR)	29
4.2.2 Modelo de componentes del error (MOCER)	32
4.2.3 Eleccion de supuestos	36
4.3 MODELOS DE PENDIENTE CONSTANTE E INTERSECCION VARIABLE SOBRE TIEMPO E INDIVIDUOS	37
4.3.1 Modelo de variables artificiales (MOVAR)	37
4.3.2 Modelo de componentes del error (MOCER)	39
4.3.3 Eleccion de supuestos	43
4.4 MODELOS DE PENDIENTE VARIABLE SOBRE LOS INDIVIDUOS	44
4.4.1 Modelo de "regresiones aparentemente no relacionadas" (MORAN)	44
4.4.2 Modelo Swamy de coeficientes aleatorios (MOSCA)	46
4.4.3 Eleccion de supuestos	49
4.5 MODELOS DE PENDIENTE VARIABLE SOBRE EL TIEMPO Y LOS INDIVIDUOS	49
4.5.1 Modelo Hsiao de coeficiente aleatorios (MOHCA)	50
4.6 ELECCION DE MODELO	53

## CAPITULO 5: DEMANDA DE AUTOS POR CATEGORIAS.

5.1 ESPECIFICACION DEL MODELO	55
5.2 DEFINICION DE LAS VARIABLES	56
5.3 ESTIMACIONES	61
5.3.1 El problema de la multicolinealidad	61
5.3.2 Regresiones conjunta y por categorias	62
5.3.3 Coeficientes constantes (COCO)	63
5.3.4 Modelos de interseccion variable	66
5.3.5 Modelos de pendiente variable	67
5.3.6 Estimacion individual	69

5.4 INTERPRETACION DE LOS RESULTADOS	71
<b>CAPITULO 6: CONCLUSION.</b>	74
<b>APENDICE A: TABLAS Y GRAFICAS DE LA INFORMACION.</b>	76
<b>APENDICE B: PROGRAMAS DE COMPUTACION.</b>	88
<b>BIBLIOGRAFIA.</b>	

## NOTACION

Esta tesis esta elaborada con un procesador de palabras americano que no tiene caracteres griegos. Estos caracteres son los usados comunmente en los libros de Econometria por lo que nos vimos en la necesidad de usar otros simbolos disponibles en sustitucion de aquellos caracteres griegos que mas se repiten (alfa y beta), mientras que el resto, menos frecuente, los escribimos directamente a maquina.

Por la misma razon la tesis carece de acentos, y escribimos sólo aquellos que sirven para distinguir palabras ambivalentes (por ejemplo, para distinguir el "sí" afirmativo del "si" condicional).

A continuacion presentamos una lista de los simbolos utilizados en la tesis y su equivalencia en el alfabeto griego o en notacion matematica:

### Simbolo   Equivalencia

SUM	Sumatoria
SQ	Raiz cuadrada de una expresion
a,A	Alfa (coeficiente de regresion)
b,B	Beta (coeficiente de regresion)
u	miu (en notacion matricial)
#	Producto de Kronecker

## CAPITULO 1

### INTRODUCCION.

Comenzar una tesis no es cosa facil, como no lo es tomar decisiones en la vida. Desde luego hay cosas mas importantes que una tesis, pero toda decision, toda eleccion o renuncia, es un paso importante en la vida y sólo dandoles el valor que merecen aprenderemos a decidir lo que realmente trascienda.

Emprender el camino significa tener una meta que alcanzar, unos objetivos que lograr. Y del aprecio y valoracion de esta meta dependera el esfuerzo que se ponga por alcanzarla. Muchas veces la ausencia de metas nobles, de objetivos claros y precisos, es causa del desaliento y abandono de los hombres en su afan de realizarse, cuando no de un eterno empezar que nunca llega.

Para algunos la tesis es un mero tramite para recibirse y constituye su unico sentido. Aunque este sea un objetivo, en si caso no es, ni mucho menos, el principal. Al hacer este trabajo he procurado alcanzar dos objetivos, a mi modo de ver, mas importantes.

Mi primer objetivo es conocer mejor y profundizar en algun campo de mi carrera. Si el objetivo unico fuera cumplir con un requisito, un trabajo mediocre y superficial quedaria justificado. Por el contrario, considero que el tiempo que lleva elaborar la tesis, que de cualquier manera seria una inversion grande en horas de estudio, debe ser aprovechado con verdadera avaricia para hacerlo rendir en beneficio de mi propia formacion. Por ello es importante elegir un tema adecuado, que me guste, porque ayudara a lograr un trabajo serio sin escatimar esfuerzos.

Mi segundo objetivo, como consecuencia del anterior, es realizar un trabajo serio, pero sencillo y que pueda ser de utilidad, ya sea para quien gusta de lo teorico, o para aquellos que busquen sus aplicaciones. Por tanto no es finalidad de esta tesis "aportar" algo nuevo a las teorias matematicas, sino expresar de una manera mas sencilla lo que varios autores han expuesto.

Con estos dos objetivos en mente, busque un tema adecuado dentro del campo de la Econometria, cuyo estudio me habia gustado mucho en la carrera. Despues de considerar varias posibilidades, opte por el tema "COMBINACION DE SERIES DE TIEMPO Y CORTE TRANSVERSAL", con la idea de estudiar los modelos de regresion cuyos coeficientes fueran variables.

El trabajo, de manera muy sintética, recoge los diversos modelos que existen de coeficientes variables cuya estimación toma en cuenta precisamente la combinación de series de tiempo y corte transversal. Después de estudiarlos con detenimiento, presento un ejemplo del uso de los modelos aplicándolos a un modelo económico que estima la "DEMANDA DE AUTOMOVILES POR CATEGORIAS".

En cuanto a su estructura, la tesis está dividida en seis capítulos y consta de dos apéndices. El segundo capítulo resume algunas importantes propiedades del Álgebra Lineal que serán de utilidad en el manejo posterior de los modelos. El capítulo 3 es una síntesis de los modelos de regresión, a manera de repaso general, y constituye la base sobre la cual se han de construir los modelos de coeficientes variables. En el capítulo 4 se estudian los modelos de coeficientes variables cuyas características dependen de los supuestos que se hagan. El capítulo 5 muestra la aplicación de los modelos a la demanda de automóviles por categorías, depurando las estimaciones en base a pruebas de hipótesis e interpreta los resultados obtenidos. Finalmente, en el capítulo 6 doy la conclusión del trabajo.

En el Apéndice A se encuentran las tablas y las gráficas de los datos empleados en el modelo del capítulo 5. En el apéndice B están los programas de computación utilizados en las estimaciones. Al final, se expone la Bibliografía consultada en la elaboración de la tesis.

## CAPITULO 2

### ELEMENTOS DE ALGEBRA LINEAL.

Cualquier estimacion al hacer una regresion involucra un gran numero de operaciones sencillas pero que en conjunto resultan sumamente tediosas. El algebra lineal proporciona una poderosa herramienta para manejar con sencillez la informacion, sin importar el volumen de la misma.

En este capitulo pretendemos recordar sinteticamente algunos elementos de algebra lineal que nos ayudaran al desarrollo de los capitulos siguientes. Su demostracion sale de nuestros objetivos y puede ser facilmente hallada en muchos libros de Algebra Lineal o de Econometria, algunos de los cuales se mencionan al final en la bibliografia.

#### 2.1 DETERMINANTES.

El determinante de una matriz A se define asi:

$$\text{Det } A = |A| = \sum_j (-1)^{t+j} a_{1j_1} a_{2j_2} \dots a_{nj_n}$$

donde las  $j_t$  son valores de  $j = \{1, 2, \dots, n\}$  y  $t$  es el numero de trasposiciones necesarias para reordenar las  $j_t$ 's.

MENOR  $A_{ij}$  es el determinante de la submatriz  $A_{ij}$ , obtenida al suprimir el renglon  $i$  y la columna  $j$  de la matriz A.

$$\text{COFACTOR } A_{ij} = C_{ij} = (-1)^{i+j} \text{ Menor } A_{ij}$$

#### PROPIEDADES DE LOS DETERMINANTES.

$$\begin{aligned} 2.1.1) \quad |A| &= \sum_{i=1}^n a_{ij} C_{ij} && \text{para } j = 1, 2, \dots, n \\ &= \sum_{j=1}^n a_{ij} C_{ij} && \text{para } i = 1, 2, \dots, n \end{aligned}$$

2.1.2) La suma de los elementos de un renglon por los cofactores de otro renglon es cero, es decir,

$$\sum_j a_{ij} C_{kj} = 0$$

- 2.1.3)  $|A| = |A'|$  donde  $A'$  es la traspuesta de la matriz  $A$ .
- 2.1.4) Si  $A$  tiene una fila nula, entonces  $|A| = 0$
- 2.1.5) Si  $A$  es triangular, su determinante es el producto de los elementos de la diagonal principal.
- 2.1.6)  $|AB| = |A| |B|$

## 2.2 LA MATRIZ INVERSA.

La matriz inversa de  $A$  es  $A^{-1}$ , tal que  $AA^{-1} = A^{-1}A = I$

### PROPIEDADES DE LA INVERSA.

- 2.2.1)  $A$  es invertible  $\iff |A| \neq 0$ , es decir, si es no singular
- 2.2.2)  $A^{-1} = (1 / |A|) \text{Adj } A$   
donde  $\text{Adj } A = (\text{Cof } A)'$  es la traspuesta del Cofactor de  $A$ , y  
 $\text{Cof } A = [C_{ij}]$  es la matriz de los cofactores de cada  $a_{ij}$
- 2.2.3) La inversa de la inversa es la propia matriz, esto es,  
 $(A^{-1})^{-1} = A$
- 2.2.4) El producto de dos matrices no singulares es una matriz no singular, y además  
 $(AB)^{-1} = B^{-1}A^{-1}$
- 2.2.5) La inversa de una traspuesta es la traspuesta de la inversa  
 $(A')^{-1} = (A^{-1})'$
- 2.2.6) El producto de dos matrices no singulares no puede ser una matriz nula, es decir,  
 $A \circ B$  no singular y  $AB = 0 \iff A = 0$  o  $B = 0$

### 2.3 PRODUCTO DE KRONECKER.

Sea  $A$  una matriz de orden  $(M,N)$  y  $B$  otra de orden  $(K,L)$ . Entonces el producto Kronecker de  $A$  y  $B$ , denotado  $A \otimes B$ , es una matriz de orden  $(MK, NL)$  dada por

$$A \otimes B = \begin{bmatrix} a_{11}B & a_{12}B & \dots & a_{1N}B \\ a_{21}B & a_{22}B & \dots & a_{2N}B \\ \vdots & \vdots & \ddots & \vdots \\ a_{M1}B & a_{M2}B & \dots & a_{MN}B \end{bmatrix}$$

#### PROPIEDADES DEL PRODUCTO DE KRONECKER.

- 2.3.1)  $(A \otimes B)(C \otimes D) = (AC \otimes BD)$
- 2.3.2)  $(A \otimes B)^{-1} = A^{-1} \otimes B^{-1}$
- 2.3.3)  $(A \otimes B)' = A' \otimes B'$
- 2.3.4)  $A \otimes (B + C) = (A \otimes B) + (A \otimes C)$
- 2.3.5)  $(A \otimes B)X = AX \otimes B$
- 2.3.6) Generalmente  $A \otimes B \neq B \otimes A$

### 2.4 VALORES Y VECTORES CARACTERISTICOS.

2.4.1) Sea  $A$  de orden  $(n,n)$  y  $x \neq 0$ . Las raíces características  $\lambda$  (lambda) y el vector característico  $x$  son aquellos que satisfacen

$$Ax = \lambda x \quad \text{o bien,}$$

$$(Ax - \lambda x) = 0 \quad \text{lo cual implica que}$$

$$|A - \lambda I_n| = 0$$

De esta igualdad se obtienen los  $n$  valores de  $\lambda$  y con ellos se forman los  $n$  vectores de  $x$  que satisfacen dichas condiciones.

2.4.2) **MATRIZ ORTOGONAL** es aquella cuya traspuesta es igual a su inversa, es decir,

$$X' = X^{-1} \implies X' X = I \quad \text{y} \quad x_i' x_j = \begin{cases} 1 & \text{si } i = j \\ 0 & \text{si } i \neq j \end{cases}$$

2.4.3) Si una matriz es simétrica, sus raíces características son siempre no negativas y sus vectores característicos son siempre ortogonales, es decir,

$$x_i' x_j = 0 \quad \text{para } i \neq j$$

2.4.4) Si A es una matriz simétrica y X es ortogonal, entonces

$$X' A X = \lambda I_n \quad \text{donde } \lambda \text{ es la matriz diagonal de valores característicos.}$$

X puede ser, pues, la matriz de vectores característicos de A.

## 2.5 FORMAS CUADRATICAS Y MATRICES POSITIVAS DEFINIDAS.

2.5.1) Sea A una matriz de orden (n,n) y x un vector columna de n elementos. La forma cuadrática de A está definida por:

$$x' A x = a_{11} x_1^2 + 2 a_{12} x_1 x_2 + \dots + 2 a_{1n} x_1 x_n + a_{22} x_2^2 + \dots + 2 a_{2n} x_2 x_n + \dots + a_{nn} x_n^2$$

es decir, el escalar  $x' A x$  es la suma ponderada de los productos de los elementos del vector x.

2.5.2) Si A es una matriz diagonal, su forma cuadrática es la suma de cuadrados de sus elementos,

$$x' A x = \sum_i a_{ii} x_i^2$$

- 2.5.3) Si A es POSITIVA DEFINIDA  $\rightarrow x' A x > 0$  para  $x \neq 0$   
 y de ella se puede afirmar:  
 - Que es no singular, o sea,  $|A| \neq 0$   
 - Que sus raíces características son positivas, y  $|A| > 0$   
 - Que todos sus menores principales son positivos, siendo los menores principales los determinantes de las submatrices obtenidas al eliminar todos los renglones y columnas excepto las deseadas.

- 2.5.4) Sea X la matriz que diagonaliza a la matriz simétrica positiva definida A, es decir,  $X' A X = \lambda I_n$ . Como  $\lambda_i$  son positivos, podemos definir la matriz

$$D = \begin{bmatrix} d_1 & & & \\ & d_2 & & \\ & & \ddots & \\ & & & d_n \end{bmatrix} \quad \text{donde } d_i = \frac{1}{\sqrt{\lambda_i}}$$

y multiplicarla por X, obteniendo  $Q = XD$   
 de manera que

$$Q' A Q = I_n$$

Entonces

$$A = (Q^{-1})' Q^{-1}$$

o bien,

$$A = P' P \quad \text{donde } P = Q^{-1}$$

Esta es la importante conclusión que nos recoge el siguiente teorema:

"Toda matriz simétrica positiva definida puede ser factorizada en el producto de una matriz ortogonal por su traspuesta".

## CAPITULO 3

### MODELOS DE REGRESION LINEAL

Un modelo, por definicion, es una representacion de un fenomeno, sea un sistema o un proceso. Dicho fenomeno es representado por el modelo en orden a explicarlo, a predecirlo y a controlarlo si es posible. En muchos casos los fenomenos de la vida real son muy complejos y requieren ser tratados mediante representaciones mas sencillas. Sin embargo cualquier modelo representa un compromiso entre la realidad y la facilidad de manejo; en ocasiones para lograr esto ultimo se requiere idealizar las condiciones del fenomeno, eliminando influencias extrañas y simplificando el proceso, aunque esto signifique sacrificar algo de realismo.

Un modelo econométrico representa matematicamente la relacion teorica existente entre algunas variables economicas. La econometria pretende emplear metodos estadisticos de analisis para probar hipotesis sobre estas relaciones, estimar sus magnitudes y hacer predicciones.

Dentro de los modelos econométricos estudiaremos aquellos que establecen una relacion lineal en los coeficientes de las variables, y no en las variables mismas, es decir, que establece una combinacion lineal entre la variable independiente y las otras variables del modelo, sin importar que ellas mismas puedan ser exponenciales o de otra forma. Por ejemplo, la relacion

$$Y = a + bX + cX^2$$

es una relacion lineal en sus coeficientes, a pesar de que la variable X es no lineal por estar elevada al cuadrado.

Por otra parte, cuando teoricamente se maneja una relacion no lineal en los coeficientes, muchas veces es posible hacer una transformacion que la convierta en lineal. Este es el caso donde la relacion

$$Y = aX^b$$

puede ser transformada a una relacion lineal al aplicar logaritmos:

$$\log Y = \log a + b \log X$$

A continuacion presentaremos un breve resumen de los modelos de regresion lineal estimados por los metodos de Minimos Cuadrados Ordinarios y Minimos Cuadrados Generalizados.

### 3.1 MODELO DE REGRESION DE DOS VARIABLES

Supongamos que queremos estimar la relacion lineal entre dos variables, donde la variable dependiente Y es funcion de la variable independiente X, expresada de la siguiente manera:

$$Y_t = A + B X_t + u_t \quad t = 1, 2, \dots, n \quad (3.1.1)$$

donde

$Y_t$  es la t-esima observacion de la variable dependiente

$X_t$  es la t-esima observacion de la variable independiente, y

$u_t$  es el t-esimo valor del termino de error

El conjunto de las n observaciones son tan solo una muestra del fenomeno real. Para cada observacion, Y es una variable aleatoria, X es una variable fija o no estocastica (es decir, conocida por el observador), y u es el termino aleatorio del error.

La presencia del error se debe a diversas causas. Primero, el error aparece porque el modelo es una simplificacion de la realidad; al omitir el modelo otras fuentes de variacion (sólo está en funcion de una) se incurre en error. Una segunda causa está asociada con la obtencion y medicion de los datos; la informacion de variables economicas muchas veces resulta dificil de obtener. Dadas estas razones resulta logico definir la relacion (3.1.1) como estocástica. Para cada valor de X, existe una distribucion de probabilidad de u y por lo mismo una distribucion de probabilidad de las Y's.

De acuerdo a lo anterior, el modelo de regresion lineal para dos variables queda especificado por los siguientes supuestos:

- 1) La relacion entre Y y X es lineal, como lo muestra (3.1.1)
- 2) Las variables  $X_t$ 's son no estocasticas y sus valores son fijos.
- 3) a. El termino de error tiene un valor esperado de cero y una varianza constante para todas las observaciones, es decir,  $E[u_t] = 0$  y  $E[u_t^2] = \sigma^2$   
b. Las variables aleatorias del error no estan correlacionadas, es decir, errores correspondientes a diferentes observaciones tienen correlacion igual a cero.  
c. El termino de error tiene una distribucion normal.

Si el termino de error tiene varianza constante (como asumimos en la proposicion 3a), se dice que son "homocedásticos"; en cambio si la varianza cambia con las observaciones se dice que los errores son "heterocedásticos".

Si el supuesto 3b no se cumple, es decir, cuando los errores de diferentes observaciones sí están correlacionados, se dice que el proceso está "autocorrelacionado". Si la correlación existiese y fuese positiva, el error de un periodo tenderá a asociarse a un error positivo en la siguiente observación. Si fuese negativa, un error negativo está asociado con un error positivo para el siguiente periodo.

Como consecuencia de las proposiciones 2 y 3a podemos afirmar que la variable X y el término de error u no están correlacionados. Finalmente la proposición 3c sobre la normalidad de los errores implica que la variable dependiente Y también es normal, ya que es función lineal de ellos.

Cabe hacer notar que cada término de error está descrito en términos de su varianza  $\sigma^2$  que es desconocida. Por tanto nuestro modelo de regresión tiene tres parámetros desconocidos (A, B y  $\sigma^2$ ). Hemos descrito los supuestos del modelo en términos del error pero se pueden definir también en términos de la distribución de probabilidad de la variable Y, diciendo

- La variable Y tiene valor esperado  $A + B X$  y varianza  $\sigma^2$ .
- Las variables aleatorias  $Y_i$  no están correlacionadas.

### ESTIMACION DE LOS PARAMETROS

Dado que nuestro modelo es lineal, nuestro objetivo es especificar una regla que nos permita definir la "mejor" línea recta que ajuste a los valores de las variables Y y X. Entre los varios métodos que se pueden sugerir, el de MINIMOS CUADRADOS resulta ser el más conveniente porque penaliza relativamente más los errores grandes (observaciones lejos de la recta obtenida) que los pequeños. El criterio del método de mínimos cuadrados es el siguiente: "la línea de 'mejor ajuste' es aquella que minimiza la suma de cuadrados de las desviaciones de los puntos observados respecto a la recta obtenida" (midiendo la distancia verticalmente).

De acuerdo con el método de Mínimos Cuadrados, los estimadores de los parámetros serían los siguientes:

$$b = \frac{\sum x_i y_i}{\sum x_i^2}$$

donde

b es el estimador del parámetro B

$x_i = X_i - \bar{X}$  es la desviación de X respecto a su media

$y_i = Y_i - \bar{Y}$  es la desviación de  $Y_i$  respecto a su media

y

$$a = \bar{Y} - b \bar{X}$$

donde

$a$  es el estimador del parametro  $A$

Nos queda por estimar el ultimo parametro, la varianza del error que ademas es utilizada en los anteriores estimadores. El mismo metodo nos proporciona su estimador:

$$s^2 = \frac{\text{SUM } e_i^2}{N - 2} = \frac{\text{SUM } (Y_i - a - b X_i)^2}{N - 2}$$

### PROPIEDADES DE LOS ESTIMADORES.

Tenemos ya una tecnica para estimar  $A$  y  $B$ . Cabe preguntarse si esta tecnica es buena o no. Nos interesa saber si  $a$  y  $b$  son "buenos" estimadores en el sentido de que poseen ciertas propiedades estadisticas.

En particular interesa que un estimador:

- 1) Sea INSESADO, es decir, que su media o valor esperado sea el mismo parametro. Por tanto esperamos que el valor esperado de  $a$  y  $b$  sean  $A$  y  $B$  respectivamente.
- 2) Sea EFICIENTE, es decir, que para una muestra dada, se espera que el estimador tenga una varianza menor a cualquier otro estimador insesgado. Si se diera que la varianza fuera cero, estaríamos en el caso teorico de que el estimador es el mismo parametro.
- 3) Sea CONSISTENTE lo que quiere decir que al aumentar el tamaño de la muestra el estimador se aproxima a su parametro.

Dentro del conjunto de estimadores lineales insesgados, es decir, aquellos que son lineales en la variable independiente y son insesgados, los que tienen la menor varianza se llaman los "mejores estimadores lineales insesgados" y les nombraremos BLUE (del ingles "best linear unbiased estimator").

Bajo el metodo de minimos cuadrados, los estimadores  $a$  y  $b$  resulten BLUE. Y dado que  $Y_i$  es una variable aleatoria, entonces  $a$  y  $b$  tambien lo son y su distribucion estara en funcion de sus medias y varianzas:

$$E [ b ] = B$$

$$E [ a ] = A$$

$$\text{Var} [ b ] = \frac{\sigma^2}{\text{SUM } x_i^2}$$

$$\text{Var} [ a ] = \sigma^2 \frac{\text{SUM } x_i^2}{N \text{ SUM } x_i^2}$$

$$Y \quad \text{Cov} [ a, b ] = \frac{-\bar{X} \sigma^2}{\text{SUM } x_i^2}$$

El signo negativo de la covarianza nos indica que, cuando la media de X es positiva, entonces muy probablemente una sobrestimación de a estará asociada a una subestimación de b, y viceversa.

Como a y b dependen de la variable Y en forma lineal, y esta tiene una distribución normal, podemos afirmar que a y b se distribuyen normalmente.

#### PRUEBAS DE HIPOTESIS E INTERVALOS DE CONFIANZA.

Conocer las distribuciones de los parámetros a y b nos permite hacer pruebas de hipótesis sobre los parámetros de la regresión. Los intervalos de confianza nos proporcionan un rango de valores que probablemente contiene el valor real de los parámetros de la regresión. Con cada intervalo de confianza se asocia un "nivel de significancia"; determinado este último, el intervalo de confianza es construido de manera que la probabilidad de que el intervalo contenga el parámetro real de la regresión sea 1 menos el nivel de significancia.

Tanto las pruebas de hipótesis como los intervalos de confianza están basados en las distribuciones de probabilidad por lo que conviene aquí hacer un pequeño parentesis para recordar algunas conclusiones sobre las mismas.

- 1) Distribución Chi-cuadrada ( $\chi^2$ ). La suma de cuadrados de N variables aleatorias normales independientemente distribuidas (con media 0 y varianza 1) se distribuyen como una  $\chi^2$  con N grados de libertad. Se puede demostrar que si se estima la varianza  $\sigma^2$  de una muestra con distribución normal con el estimador  $s^2$ , entonces  $(N-1)s^2/\sigma^2$  se distribuye como una Chi cuadrada con (N-1) grados de libertad.
- 2) Distribución t de student (t). Si X es una variable distribuida como una normal de media 0 y varianza 1, y Z está distribuida como una  $\chi^2$  con N grados de libertad, y ambas son independientes, entonces  $X/\sqrt{Z/N}$  tiene una distribución t con N grados de libertad.
- 3) Distribución F. Si X y Z son independientes y se distribuyen como  $\chi^2$  con N y M grados de libertad respectivamente, entonces

$(X/N)/(Z/M)$  se distribuye como una F con  $(N,M)$  grados de libertad.

Nos interesa ahora establecer las pruebas de hipótesis. La más común es la llamada "hipótesis nula" que consiste en una proposición o hipótesis que asume que cierto efecto no está presente en el modelo. Como se espera aceptar el modelo, la prueba se diseña para ser rechazada. Por ejemplo, nuestra hipótesis nula puede ser que  $B = 0$ . Debemos usar nuestro estimador  $b$  para rechazar la hipótesis nula en favor de que la pendiente de la regresión no es cero.

La prueba estadística para rechazar la hipótesis nula asociada a uno de los coeficientes de la regresión está basada en la prueba  $t$ . Para usarla primero se debe estandarizar el parámetro estimado restandole el valor hipotéticamente verdadero (la hipótesis nula en este caso sostiene que  $B = B_0$ ) y dividiendolo entre su desviación estándar estimada:

$$t = \frac{b - B_0}{s_b} = \frac{b - B_0}{s / \sqrt{\text{SUM } x_i^2}}$$

sigue una distribución  $t$  con  $(N-2)$  grados de libertad. Ahora se selecciona un "valor crítico" ( $t_c$ ) que asegura que la mitad del nivel de significancia de la distribución  $t$  cae en ambas colas, es decir,

$$\text{Prob} (-t_c < t_{N-2} < t_c) = 1 - \text{Nivel de significancia.}$$

Por tanto,

$$\text{Prob} \left( -t_c < \frac{b - B_0}{s_b} < t_c \right) = 1 - \text{Nivel de significancia.}$$

que resolviendo, obtenemos el siguiente intervalo de confianza para  $B$ :

$$b \pm t_c s_b = b \pm t_c s / \left( \sqrt{\text{SUM } x_i^2} \right)$$

De manera similar, el nivel de confianza para el parámetro  $A$  es:

$$a \pm t_c s_a = a \pm t_c s \left( \sqrt{\text{SUM } X_i^2} / \sqrt{\text{SUM } (N \text{ SUM } x_i^2)} \right)$$

### ANÁLISIS DE VARIANZA Y CORRELACION.

Hemos visto las propiedades de los estimadores de la regresión. Aunque hayan sido "buenos", queda aun la duda de si el diseño del modelo es el correcto o no; sin modelo no podemos explicar las variaciones que hay en la variable  $Y$  e interesa saber si nuestro modelo realmente "explica" las variaciones de  $Y$ , es decir, si la recta de la regresión ajusta con exactitud o no a las observaciones. El análisis de varianza y correlación nos permite conocer esto precisamente.

El analisis esta basado en las observaciones, a partir de los residuales, es decir, de las diferencias que hay entre la observacion real y la estimacion hecha por el modelo. Despues de algo de algebra, se obtiene la siguiente relacion:

$$\text{SUM } (Y_i - \bar{Y})^2 = \text{SUM } (Y_i - \hat{Y}_i)^2 + \text{SUM } (\hat{Y}_i - \bar{Y})^2$$

Variacion total de Y (o suma de cuadrados total)	Var. residual de Y (suma de cua- drados del error)	Var. explicada de Y (suma de cuadra- dos de la regresion)
TSS	ESS	RSS

Normalizando,

$$1 = \frac{\text{ESS}}{\text{TSS}} + \frac{\text{RSS}}{\text{TSS}}$$

Y de aqui,

$$R^2 = 1 - \frac{\text{ESS}}{\text{TSS}} = \frac{\text{RSS}}{\text{TSS}}$$

donde

$R^2$  ("R cuadrada") es la proporcion de la variacion de Y explicada por la regresion de Y en X. Obviamente el rango de  $R^2$  es de 0 a 1, siendo 1 cuando todos los puntos de la muestra ajustan con la linea, es decir, cuando el ajuste es perfecto. Por ello se usa mucho esta relacion para ver si el ajuste del modelo es bueno o no, esperando que este estadistico sea lo mas cercano posible a 1.

La division de la variacion de Y en sus dos componentes nos permite hacer una prueba sobre la correlacion de las variables Y y X. Bajo la hipotesis nula de que no hay correlacion entre ambas variables,

$$F_{1, N-2} = \frac{\text{varianza explicada}}{\text{varianza no explicada}} = \frac{\text{RSS}/1}{\text{ESS}/(N-2)}$$

se distribuye como una F con (1, N-2) grados de libertad. De esta manera se asocia un valor alto a la prueba si la relacion entre Y y X es fuerte, y un valor bajo a la prueba si la relacion entre dichas variables mas bien es debil.

### 3.2 MODELO DE REGRESION MULTIPLE.

Extendiendo el modelo de regresion de dos variables al caso en que la variable dependiente Y es funcion de una serie de variables independientes X1, X2, ... , XK podemos escribir

$$Y = B_1 + B_2 X_2 + \dots + B_K X_K + e \quad (3.2.1)$$

donde hemos asumido que  $X_1 = 1$  en todas las observaciones.

El estudio de este modelo es paralelo al anterior y diremos en primer lugar que los supuestos son los mismos, aunque aqui debemos incluir que no hay ninguna relacion lineal entre dos o mas de las variables independientes. Si se rompe este supuesto, es decir, si existe una relacion lineal o una alta correlacion entre las variables independientes, se dice que hay MULTICOLINEALIDAD y la interpretacion de los coeficientes estimados resulta complicada. Una manera de detectar si existe o no este problema es analizando la matriz de correlacion de los coeficientes; otro es conocer los valores caracteristicos de la matriz de informacion usando el metodo de "componentes principales"; si efectivamente hay multicolinealidad, alguno(s) de los valores sera(n) cero.

Dado que tenemos n ecuaciones del tipo (3.2.1), correspondientes a n observaciones, conviene escribir nuestro modelo en forma matricial:

$$Y = XB + e \quad (3.2.2)$$

donde

Y es un vector de orden (N,1) de la variable dependiente

X es una matriz de orden (N,K) de las variables independientes

B es el vector de orden (K,1) de los parametros a estimar

e es el vector de orden (N,1) de los errores. El supuesto 3a del modelo anterior puede expresarse ahora  $E[e e'] = \sigma^2 I_n$

Aplicando de nuevo el criterio de Minimos Cuadrados, obtenemos:

$$b = (X'X)^{-1} X'Y \quad (3.2.3)$$

La matriz  $(X'X)$  es llamada "matriz de productos cruzados" y es seguro que su inversa existe dado el supuesto de no correlacion entre las variables independientes.

El estimador b es BLU y su varianza es  $\sigma^2 (X'X)^{-1}$

La estimacion de la varianza de los errores puede obtenerse asi:

$$s^2 = \frac{\hat{e}' \hat{e}}{N - K} \quad \text{donde } \hat{e} = Y - X b$$

Las pruebas sobre los coeficientes son tambien las mismas:

$$t_{N-K} = \frac{b_i - B_i}{s / \text{SQ}(\text{Var } i)}$$

se distribuye como una t con (N-K) grados de libertad. Los intervalos de confianza se calculan de la misma manera que en el modelo anterior. Para las pruebas de correlacion, tenemos

$$Y' Y = b' X' X b + \hat{e}' \hat{e} \quad \text{que equivale a}$$

$$\text{TSS} = \text{RSS} + \text{ESS}$$

Por tanto,

$$R^2 = 1 - \frac{\text{ESS}}{\text{TSS}} = 1 - \frac{\hat{e}' \hat{e}}{Y' Y} = \frac{b' X' X b}{Y' Y} \quad (3.2.4)$$

Entonces,

$$F = \frac{R^2}{1 - R^2} \frac{N-K}{K-1} = \frac{(b - B)' X' X (b - B)}{\hat{e}' \hat{e}} \frac{N-K}{K-1}$$

se distribuye como una F con (K-1, N-K) grados de libertad.

### 3.3 MINIMOS CUADRADOS GENERALIZADOS.

Hay ocasiones en que al diseñar un modelo economico el supuesto de que la varianza del error es constante resulta poco razonable. Por ejemplo, si la observaciones se hacen en corte transversal, esto es, a traves de diversas clases, firmas, individuos, etc., se espera que la dimension de las observaciones varíe con el tamaño de la clase. Por tanto se espera que la varianza del error varíe con cada observacion, y tenemos un modelo "heterocedastico".

Cuando hay heterocedasticidad, el metodo de Minimos Cuadros Ordinarios (M.C.O.) hasta ahora visto da mayor peso a las observaciones que tienen mayor varianza en los errores que a las de menor varianza. Por su ponderacion implicita, los estimadores de M.C.O son insesgados y consistentes, pero no son eficientes, es decir, su varianza no es la minima varianza; ademas la estimacion de sus varianzas sera sesgada.

El metodo de Minimos Cuadrados Generalizados (M.C.G) nos proporciona una manera de resolver el problema de heterocedasticidad. Hasta ahora el supuesto de homocedasticidad, en notacion matricial, decia

$$E [ e e' ] = \sigma^2 I$$

donde I es la matriz identidad de orden (N,N)

El supuesto de heterocedasticidad nos hace cambiar por el supuesto

$$E [ e e' ] = \sigma^2 \Omega \tag{3.3.1}$$

donde  $\Omega$  (Omega) es una matriz conocida de orden (N,N), y se asume que es positiva definida. Como vimos en el teorema 2.5.4, el supuesto de que  $\Omega$  es una matriz positiva definida es suficiente para garantizarnos que existe una matriz P no singular de orden (N,N) tal que

$$P \Omega P' = I \tag{3.3.2}$$

de manera que

$$\Omega = P^{-1} (P')^{-1} = (P'P)^{-1}$$

de donde

$$P' P = \Omega^{-1}$$

Podemos usar entonces la matriz P para transformar el modelo original:

$$P Y = P X B + P e \tag{3.3.3}$$

o bien

$$Y^* = X^* B + e^*$$

donde

$$Y^* = P Y \quad X^* = P X \quad e^* = P e$$

El nuevo termino de error es ahora consistente con el modelo lineal clasico, dado que

$$E [ e^* e^{*'} ] = E [ P e e' P' ] = \sigma^2 P \Omega P' = \sigma^2 I \tag{3.3.4}$$

Por tanto nuestro nuevo estimador sera

$$b = (X^{*'} X^*)^{-1} X^{*'} Y^*$$

que en terminos de los datos originales sera:

$$b = (X'Q^{-1}X)^{-1} X'Q^{-1}Y \quad (3.3.5)$$

y su matriz de varianza-covarianza sera  $\sigma^2 (X'Q^{-1}X)^{-1}$

En orden a poder aplicar M.C.B. es necesario estimar la matriz  $Q$  ya que generalmente es desconocida, lo cual se puede hacer con la informacion que nos proporcionan las mismas observaciones y la especificaciones del modelo, como veremos en el capitulo siguiente.

## CAPITULO 4

### MODELOS DE COEFICIENTES VARIABLES

Los datos obtenidos a partir de la medición de variables pueden provenir de diversas fuentes y ser de diversas formas. Los datos que describen el movimiento de una variable en el tiempo son llamados "series de tiempo" y pueden ser diarios, mensuales, anuales, etc. Los datos que describen las actividades de personas individuales, empresas u otras unidades en un momento determinado son llamados "datos en corte transversal".

El estudio de modelos que combinan datos en corte transversal y series de tiempo resulta de gran interés, pues nos permite aprovechar la información que se tiene de diversos individuos a través del tiempo. Tendríamos entonces datos de este tipo:

$$\begin{array}{cccccccc}
 Y & , & X_2 & , & X_3 & , & \dots & , & X_K \\
 \text{it} & & \text{it} & & \text{it} & & & & \text{it}
 \end{array}
 \qquad
 \begin{array}{l}
 i = 1, 2, \dots, N \\
 t = 1, 2, \dots, T
 \end{array}$$

donde N denota el número de clases o individuos y T el número de observaciones en el tiempo.  $Y_{it}$  podría ser, por ejemplo, la producción de maíz en la región i durante el período t. Esta variable estará en función de las (K-1) variables independientes.

Podemos entonces expresar nuestro modelo general de la manera siguiente:

$$Y_{it} = B_1 + \sum_{k=2}^K B_k X_{k\text{it}} + e_{it} \qquad \begin{array}{l} i = 1, 2, \dots, N \\ t = 1, 2, \dots, T \end{array}$$

donde  $B_{k_{it}}$  es el k-ésimo parámetro a estimar  
 $e_{it}$  es el término de error correspondiente

De este modelo general podemos distinguir cinco casos:

$$1) \quad Y_{it} = B_1 + \sum_{k=2}^K B_k X_{k\text{it}} + e_{it}$$

$$2) \quad Y_{it} = B_1 + \sum_{k=2}^K B_k X_{k\text{it}} + e_{it}$$

$$3) \quad Y_{it} = B_1 + \sum_{k=2}^K B_k X_{k\text{it}} + e_{it}$$

$$4) \quad Y_{it} = B_1 + \sum_{k=2}^K B_k X_{k\text{it}} + e_{it}$$

$$5) \quad Y_{it} = B_1 + \sum_{k=2}^K B_k X_{k\text{it}} + e_{it}$$

es decir, respectivamente,

- 1) Todos los coeficientes son constantes.
- 2) La interseccion varia entre los individuos pero es constante en cada individuo respecto al tiempo.
- 3) La interseccion varia entre los individuos y en cada uno.
- 4) La interseccion y la pendiente varian entre los individuos, pero permanece constante en cada uno respecto al tiempo.
- 5) La interseccion y la pendiente varian entre los individuos y en cada uno de ellos respecto al tiempo.

La importancia de este estudio radica en la interpretacion que de él se haga. No cabe duda que podemos establecer una relacion entre la variable Y y las otras variables mediante una simple regresion que no tome en cuenta la proveniencia de los datos. Sin embargo tambien es verdad que existen otras variables que no estamos en posibilidad de controlar o estimar y que afectan de manera distinta a cada clase o individuo. Pensemos, por ejemplo, que las diversas regiones donde se ha plantado el maiz tienen diferente precipitacion pluvial. En estos casos la aportacion de una determinada region a la variable dependiente puede ser sobrestimada por el modelo tradicional.

Podria pensarse, como de hecho lo considera el primer caso, que las variables X tienen el mismo efecto en Y (es decir, sus coeficientes son constantes en la regresion) en las diversas clases. A pesar de ello suele ser interesante probar este supuesto en la vida real. Por ejemplo, ¿la funcion de produccion de una industria tiene los mismos coeficientes en distintas regiones, o las funciones econométricas permanecen sin cambiar a traves de los años?

Este tipo de cuestiones se encuentran detras de nuestro estudio que en particular se orienta al uso del analisis de covarianza para:

- 1) Probar diferencias en las intersecciones, con el supuesto de que la pendiente permanece constante.
- 2) Probar las diferencias en las pendientes.
- 3) Probar diferencias en la relacion absoluta entre los individuos o clases y en cada individuo, considerando la informacion como un todo.

Cabe hacer una importante observacion sobre nuestro estudio. En el modelo tradicional se establece una combinacion lineal de las variables independientes (las X's) para determinar el valor de la variable dependiente (Y). Los parametros obtenidos en la regresion son los coeficientes de la combinacion lineal, como observamos en esta ecuacion:

$$\hat{Y}_i = \hat{B}_1 + \hat{B}_2 X_{2i} + \dots + \hat{B}_K X_{Ki}$$

Se ve claramente como estos coeficientes son los mismos para toda  $i$ , y la combinación lineal nos define un espacio solución de orden  $(K-1)$ . Pensemos, por ejemplo, en el caso más sencillo donde  $Y$  solo depende de una variable, digamos  $X$ . Entonces:

$$\hat{Y} = \hat{\beta}_1 + \hat{\beta}_2 X$$

y esta es la ecuación de una recta. La regresión ajusta, pues, las observaciones a una recta donde sus parámetros están fijos.

En nuestro modelo el primer caso pretende lo mismo, es decir, establecer un plano de soluciones de orden  $(K-1)$  en el que los parámetros están fijos.

Para los siguientes casos el modelo cobra un "dinamismo" singular ya que al ir variando sus coeficientes con cada individuo y en cada tiempo, procura ir "describiendo" con mayor realismo el comportamiento de las observaciones. En el ejemplo bidimensional estaríamos buscando una recta cuya pendiente cambiaría en cada observación, siendo no ya una recta rígida, sino una "recta" que sigue los lineamientos que las observaciones le indican.

Antes de pasar al análisis de cada uno de los casos debemos percatarnos de que en la práctica al afrontar un problema de esta naturaleza surgirá de inmediato la duda fundamental de cuál modelo debemos emplear. ¿Es correcto estimar con este modelo? ¿Cuál otro debe ser el correcto?

Discutir este punto constituye el fondo del problema, porque una vez tomada la decisión, resolverlo será solo cuestión de aplicar tal o cual método.

La decisión dependerá de los supuestos que cumplan las variables en cuestión, pues cada modelo está especificado por distintos supuestos.

La tabla 4.1 que presentamos en la página siguiente nos muestra los diversos modelos de coeficientes variables como resultado de una combinación entre series de tiempo y cortes transversales y que serán objeto de nuestro análisis, comenzando por el más sencillo.

#### NOTAS:

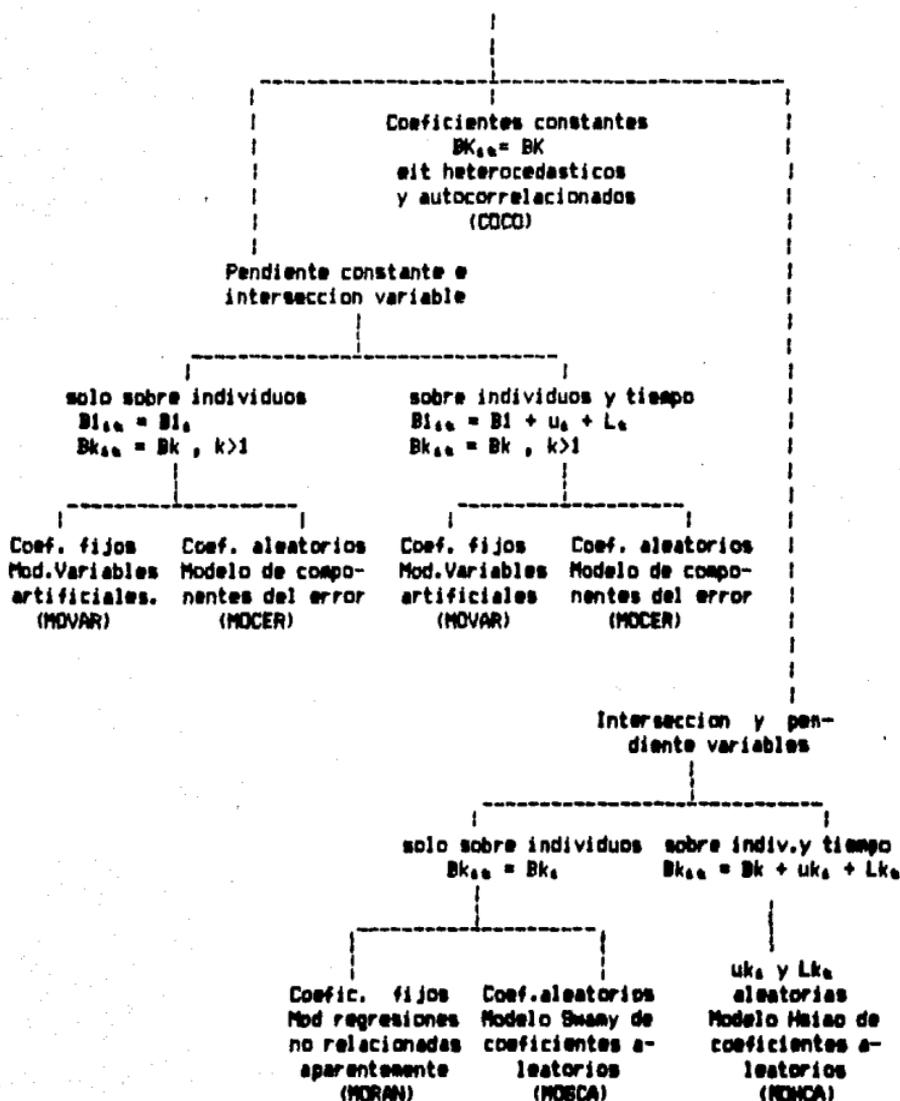
- 1) El término "series de tiempo" se refiere a observaciones estadísticas en el tiempo, no al análisis matemático que suele hacerse de una variable en el tiempo.
- 2) Al hablar de "combinación lineal" es necesario recordar que la linealidad se refiere a los parámetros  $\beta$ 's a estimar, no a las variables independientes. Estas últimas pueden ser no lineales (exponenciales, cuadráticas, etc) pero mediante una transformación conveniente (por ejemplo logarítmica) pueden ajustarse también a un comportamiento lineal.

**TABLA 4.1**

**CUADRO DE MODELOS DE COEFICIENTES VARIABLES**

El modelo lineal

$$Y_{it} = B_{1it} + \sum_{k=2}^K B_{kit} X_{kit} + e_{it}$$



#### 4.1 MODELO DE COEFICIENTES CONSTANTES (COCO)

El modelo mas sencillo que podemos aplicar a nuestros datos es:

$$Y = X B + e \quad (4.1.1)$$

que expresado en terminos de un individuo cualquiera queda

$$Y_i = X_i B + e_i \quad (4.1.2)$$

donde

$$Y_i = (Y_{i1}, Y_{i2}, \dots, Y_{iT})'$$

$X_i$  es una matriz de orden  $(T, K)$

$$B = (B_1, B_2, \dots, B_K)'$$

$e_i = (e_{i1}, e_{i2}, \dots, e_{iT})'$  es el termino del error y es tal que

$$E [e_i e_i'] = \sigma^2 I_T$$

Nuestro modelo asume que todos los coeficientes a traves de los individuos son constantes y la estimacion de los  $K$  parametros del vector  $B$  pueden ser facilmente obtenidos al aplicar Minimos Cuadrados Ordinarios al sistema (4.1.1). Llamando  $b$  al estimador que resulta de aplicar este metodo, tenemos que

$$b = (X' X)^{-1} X' Y \quad (4.1.3)$$

Alternativamente, podriamos agrupar los datos para los diversos individuos y estimar el vector  $B$  aplicando M.C.O. a cualquier individuo ya que  $B$  es constante y es independiente de los individuos, como podemos apreciar en la ecuacion (4.1.2). Por tanto la expresion (4.1.3) sera equivalente, bajo nuestros supuestos, a

$$b = (X_i' X_i)^{-1} X_i Y_i \quad \text{para cualquier } i$$

El conjunto de nuestros supuestos resulta altamente restrictiva. Por otra parte debemos recordar que generalmente las regresiones hechas sobre datos en corte transversal pueden y suelen originar problemas de heterocedasticidad, es decir, que la varianza no permanece constante entre los individuos. Esto suena logico si pensamos que la varianza en el volumen de produccion de maiz debe ser muy distinta entre las diversas regiones de un pais.

Igualmente las observaciones en el tiempo conllevan el problema de la autocorrelacion, es decir, los errores en un periodo determinan en parte el error del siguiente periodo en un individuo cualquiera.

Por todo ello se propone un cambio en la suposicion sobre el termino de error, asumiendo ahora que

$$E \begin{bmatrix} e_i \\ e_j \end{bmatrix} = \frac{\sigma_{ij}}{1 - \rho_i \rho_j} \begin{bmatrix} 1 & \rho_j & \dots & \rho_j^{T-1} \\ \rho_i & 1 & \dots & \rho_j^{T-2} \\ \vdots & \vdots & \ddots & \vdots \\ \rho_i^{T-1} & \rho_i^{T-2} & \dots & 1 \end{bmatrix} = \Omega_{ij} \quad (4.1.4)$$

De hecho esta matriz de covarianza resulta de un proceso autorregresivo de primer orden:

$$e_{it} = \rho_i e_{i,t-1} + v_{it} \quad i = 1, 2, \dots, N$$

donde

$$E[v_{it}] = 0, \quad E[v_{it} v_{it}] = \sigma_{it}, \quad E[v_{it} v_{jt}] = 0 \text{ para } i \neq j$$

El modelo asume, entonces:

- 1) Que los coeficientes son los mismos para todos los individuos, lo que equivale a decir que los datos provenientes de diversos individuos es poco significativo o no tiene relevancia, y que la variación en Y es efectivamente explicada por la variación en las variables X's.
- 2) Que el vector de error para un individuo determinado sigue un proceso autorregresivo de primer orden.
- 3) Que la varianza del error puede ser diferente para distintos individuos.
- 4) Los errores de distintos individuos están contemporáneamente correlacionados como se puede apreciar en la matriz de covarianza (4.1.4), pero dicha correlación declina en el tiempo y es distinta para distintos individuos.

Para algunos casos estos supuestos parecen ser razonables. Quizá el supuesto más restrictivo es el que afirma que los coeficientes sean constantes para todos los individuos.

#### 4.1.1 ESTIMACION.

La estimación de B puede hacerse por el método de Mínimos Cuadrados Generalizados (M.C.G.) a partir de las NT observaciones, donde la matriz de pesos está dada por la matriz de covarianza.

La matriz de covarianza (4.1.4) puede escribirse en términos del modelo completo así:

$$E[e e'] = \Omega = \begin{bmatrix} \Omega_{11} & \Omega_{12} & \dots & \Omega_{1N} \\ \Omega_{21} & \Omega_{22} & & \Omega_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ \Omega_{N1} & \Omega_{N2} & & \Omega_{NN} \end{bmatrix}$$

Si conociéramos todos los  $\rho_i$  y los  $\sigma_{it}$ , entonces B podría estimarse mediante M.C.G.

$$\hat{B} = (X' Q^{-1} X)^{-1} X' Q^{-1} Y \quad (4.1.5)$$

donde  $X$  es una matriz de orden  $(NT, K)$

que es de minima varianza en cada individuo, es insesgado y tiene matriz de covarianza  $(X' Q^{-1} X)^{-1}$ .

Sin embargo  $\rho_{it}$  y  $\sigma_{it}$  son parametros desconocidos y debemos sustituirlos por sus estimadores, obteniendo entonces el "estimador de minimos cuadrados generalizados esteado" (E.M.C.G.) que llamaremos  $B^*$ .

Para obtener los estimadores  $\hat{\rho}_{it}$  y  $\hat{\sigma}_{it}$  aplicamos Minimos Cuadrados Ordinarios (M.C.O.) separadamente a cada individuo y los estimamos de los residuales correspondientes:

$$\hat{\rho}_i = \frac{\sum_{t=2}^T \hat{e}_{i,t-1} \hat{e}_{i,t}}{\sum_{t=2}^T (\hat{e}_{i,t-1})^2} \quad i = 1, 2, \dots, N$$

donde  $\hat{e}_i = (\hat{e}_{i1}, \hat{e}_{i2}, \dots, \hat{e}_{iT})' = Y_i - X_i b_i$

o igualmente,

$$\hat{\sigma}_{ij} = \frac{\hat{e}_i' \hat{e}_j}{T} \quad \text{siendo } N(N+1) / 2 \text{ estimaciones} \quad (4.1.6)$$

#### 4.1.2 PRUEBAS DE HIPOTESIS.

Nos interesa probar, en primer termino, si la ganancia en eficiencia al estimar los parametros por medio del supuesto de autocorrelacion es significativa o no. Si no es significativo, entonces aplicar el estimador (4.1.3) sera equivalente a usar el estimador (4.1.5).

#### NOTA:

- 3) Si  $NT$  es demasiado grande, la inversion de la matriz  $Q$  puede complicarse aun cuando se cuente con poderosas computadoras. En estos casos se podria hacer una transformacion buscando una matriz  $P$  tal que  $P Q P' = S \otimes I_T$  cuya inversion sea mas facil y donde  $S$  es de esta forma:
- $$S = \begin{bmatrix} \sigma & \sigma & \dots & \sigma \\ & \sigma_{11} & \sigma_{12} & \dots & \sigma_{1N} \\ & & \sigma_{22} & \dots & \sigma_{2N} \\ & & & \dots & \sigma_{NN} \\ & & & & \sigma_{NN} \end{bmatrix}$$

Una manera de saber si es significativa sera comparar la suma de cuadrados de los residuales de ambos estimadores. Bajo la hipotesis de que no existe autocorrelacion (y por tanto la ganancia NO es significativa), proponemos un estadístico (Cfr. Pindyck, p.255):

$$F = \frac{((Y'Y - b X'Y) - (Y \cdot XB)' Q^{-1}(Y \cdot XB)) / (N+N(N+1)/2)}{(Y \cdot XB)' Q^{-1}(Y \cdot XB) / (NT-K-N-N(N+1)/2)} \quad (4.1.7)$$

y se distribuye como una F con  $(N+N(N+1)/2, NT-K-N-N(N+1)/2)$  grados de libertad (se obtienen al restar del numero de observaciones el numero de elementos a estimar, sean coeficientes o varianzas; aqui tenemos NT observaciones y debemos restar K parametros, N coeficientes de autorregresion y  $N(N+1)/2$  covarianzas).

Por otra parte resultara interesante probar la hipotesis de que los coeficientes son constantes. En la seccion 4.4 veremos un estadístico que nos permita hacerlo.

## 4.2 MODELOS DE PENDIENTE CONSTANTE E INTERSECCION VARIABLE SOBRE LOS INDIVIDUOS.

El segundo modelo es aquel que capta las diferencias entre los individuos en la interseccion mientras que asume que la pendiente permanece constante. Este modelo puede escribirse asi:

$$Y_{it} = \bar{B}_i + u_i + \sum_{k=2} B_k X_{k,it} + e_{it} \quad i = 1, 2, \dots, N \quad (4.2.1) \\ j = 1, 2, \dots, 7$$

donde

$\bar{B}_i = B_i + u_i$  es la interseccion del  $i$ -esimo individuo,  $B_i$  es la "interseccion media" y  $u_i$  la desviacion de esta media para el mismo individuo.

La estimacion de este modelo dependera de si la variable  $u_i$  es considerada fija o aleatoria. Si es fija, usaremos entonces el modelo de variables artificiales (MOVAR), mientras que si es aleatoria usaremos el modelo de componentes del error (MOCER). Ambos seran explicados a continuacion.

### 4.2.1 MODELO DE VARIABLES ARTIFICIALES.

#### (MOVAR)

Para captar el efecto de los individuos en nuestro modelo usaremos variables artificiales (dummy variables), que es un intento de justificar la ausencia de otras variables independientes explicativas

del modelo. La ecuación (4.2.1) para el  $i$ -ésimo individuo puede escribirse así:

$$Y_i = (B_1 + u_i) J_i + X_{s_i} B_s + e_i \quad (4.2.2)$$

donde

$$Y_i = (Y_{i1}, Y_{i2}, \dots, Y_{iT})'$$

$$e_i = (e_{i1}, e_{i2}, \dots, e_{iT})'$$

$$J_i = (1, 1, \dots, 1)' \quad \text{y es de orden } (T, 1)$$

$X_{s_i}$  es la matriz  $X_i$  quitando la primera columna del término de intersección,  $i$  es de orden  $(T, K-1)$

$B_s = (B_2, B_3, \dots, B_K)'$  son  $(K-1)$  parámetros fijos a estimar

$B_1 + u_i$  son los  $N$  parámetros fijos de las intersecciones.

Asumiremos que  $E[e_i] = 0$ ,  $E[e_i e_j] = \sigma^2 I$  y  $E[e_i u_j] = 0$  para  $i \neq j$

Bajo estos supuestos el estimador de M.C.D. es el mejor estimador lineal insesgado (en inglés "BLUE"). Para conocer su estructura, escribiremos (4.1.2) para las  $NT$  observaciones:

$$Y = \begin{pmatrix} I & J \\ N & T \end{pmatrix} \begin{bmatrix} B_1 \\ B_s \end{bmatrix} + E \quad (4.2.3)$$

es decir,

$$\begin{bmatrix} Y_{11} \\ \vdots \\ Y_{1T} \\ Y_{21} \\ \vdots \\ Y_{NT} \end{bmatrix} = \begin{bmatrix} 1 & & X_{21} & \dots & X_{K1} \\ \vdots & & \vdots & & \vdots \\ 1 & & X_{2T} & \dots & X_{KT} \\ \vdots & & \vdots & & \vdots \\ \vdots & & \vdots & & \vdots \\ 1 & & X_{21} & \dots & X_{K1} \\ \vdots & & \vdots & & \vdots \\ \vdots & & \vdots & & \vdots \\ 1 & & X_{2T} & \dots & X_{KT} \\ \vdots & & \vdots & & \vdots \\ \vdots & & \vdots & & \vdots \\ 1 & & X_{21} & \dots & X_{K1} \\ \vdots & & \vdots & & \vdots \\ \vdots & & \vdots & & \vdots \\ 1 & & X_{2T} & \dots & X_{KT} \end{bmatrix} \begin{bmatrix} B_1 \\ B_2 \\ \vdots \\ B_N \\ B_2 \\ B_3 \\ \vdots \\ B_K \end{bmatrix} + \begin{bmatrix} e_{11} \\ \vdots \\ e_{1T} \\ e_{21} \\ \vdots \\ e_{NT} \end{bmatrix}$$

De aquí, aplicando M.C.D., obtendremos:

$$\begin{bmatrix} B_1 \\ B_s \end{bmatrix} = \left[ \begin{pmatrix} I & J \\ N & T \end{pmatrix}' \begin{pmatrix} I & J \\ N & T \end{pmatrix} \right]^{-1} \begin{pmatrix} I & J \\ N & T \end{pmatrix}' Y \quad (4.2.4)$$

Observemos que el vector  $(B_1, B_s)'$  es de orden  $(N+K-1, 1)$  que nos indica que los primeros  $N$  valores corresponden al subvector  $(B_{11}, B_{12}, \dots, B_{1N})$  mientras que los restantes  $(K-1)$  valores son de los parámetros  $(B_2, B_3, \dots, B_K)$ .

El proceso se hace más sencillo si a la ecuación (4.2.1) la corregimos por su media respecto al tiempo, de esta manera:

$$(\bar{Y}_i - \bar{Y}) = \sum_{k=2}^K B_k (X_k - \bar{X}_k) + e_i - \bar{e}_i \quad (4.2.5)$$

donde

$$\bar{Y}_i = \sum_{t=1}^T Y_{it} / T, \quad \bar{X}_k = \sum_{t=2}^T X_{kt} / T \quad \text{y} \quad \bar{e}_i = \sum_{t=2}^T e_{it} / T$$

A partir de aquí podemos obtener  $B_s$  aplicando M.C.O. a (4.2.5), requiriendo la inversión de una matriz de orden  $(K-1)$  ya que logramos eliminar el término de la intersección que antes nos obligaba a invertir una matriz de orden  $(N+K-1)$ .

La corrección, pues, en  $X_s$  en el  $t$ -ésimo momento nos queda:

$$(\bar{X}_{2,t} - \bar{X}_{2,t}, \dots, \bar{X}_{K,t} - \bar{X}_{K,t})$$

La transformación completa de  $X_s$  para el individuo  $i$  será entonces:

$$D_T X_{s,t}$$

donde

$$D = \begin{matrix} I & -J & J' \\ \hline & T & T \end{matrix} / T = \begin{bmatrix} 1-1/T & -1/T & \dots & -1/T \\ -1/T & 1-1/T & \dots & -1/T \\ \vdots & \vdots & \ddots & \vdots \\ -1/T & -1/T & \dots & 1-1/T \end{bmatrix}$$

La transformación completa de  $X_s$  será, finalmente:

$$(I_N \otimes D_T) X_s$$

y el nuevo sistema de ecuaciones quedará así:

$$(I_N \otimes D_T) Y = (I_N \otimes D_T) X_s B_s + (I_N \otimes D_T) E \quad (4.2.6)$$

Aplicando mínimos cuadrados, obtenemos:

$$\begin{aligned} \hat{B}_s &= \left[ (I_N \otimes D_T) X_s \right]' (I_N \otimes D_T) X_s \Big]^{-1} \left[ (I_N \otimes D_T) X_s \right]' (I_N \otimes D_T) Y \\ &= \left[ X_s' (I_N \otimes D_T)' (I_N \otimes D_T) X_s \right]^{-1} X_s' (I_N \otimes D_T)' (I_N \otimes D_T) Y \\ &= \left[ X_s' (I_N \otimes D_T D_T D_T) X_s \right]^{-1} X_s' (I_N \otimes D_T D_T D_T) Y \\ &= \left[ X_s' (I_N \otimes D_T) X_s \right]^{-1} X_s' (I_N \otimes D_T) Y \end{aligned} \quad (4.2.7)$$

Desarrollando las matrices y simplificando,

$$\hat{B}_s = \left[ \sum_{i=1}^N X_{s,i}' D_T X_{s,i} \right]^{-1} \sum_{i=1}^N X_{s,i}' D_T Y_i \quad (4.2.8)$$

También en este caso se requiere invertir una matriz de orden  $(K-1)$  y la matriz de varianzas estará dada por

$$\sigma_e^2 \left( X_s' (I_N \otimes D_T) X_s \right)^{-1} \quad (4.2.9)$$

El estimador  $\hat{B}_s$  está obtenido a partir de las variaciones en el tiempo dentro de cada individuo (corrigiéndolo por su media respecto al

tiempo) y por esta razón nos referiremos a él como el "estimador interno" y lo escribiremos 'bs' por razones que más adelante se expondrán.

Heimos estimado Bs y nos falta estimar el vector de intersecciones Bi, lo que podemos hacer sencillamente por este método:

$$\hat{B}i_i = \bar{y}_i - \sum_{k=2}^K \hat{B}k Xk_i \quad (4.2.10)$$

y promediando los resultados que se obtengan,

$$u_i = \hat{B}i_i - \bar{B}i$$

Una solución alternativa a la ecuación (4.2.3) se presenta para el caso en que la computadora introduce automáticamente el término constante. En este caso una reparametrización para evitar la singularidad de la matriz X es necesaria. Podemos escribir:

$$Y = \left[ J_{N \times 1} \begin{bmatrix} 1 \\ 0 \end{bmatrix} \otimes J_V X_S \right] \begin{bmatrix} d \\ B_S \end{bmatrix} + E \quad (4.2.11)$$

donde

$$d = (d_1, d_2, \dots, d_N)'$$

$$B_i = d_1 \quad y \quad B_i = d_{i+1} + d_1 \quad i = 1, 2, \dots, N$$

Las variables artificiales, para N=3 como ejemplo, serían:

$$\left[ J_{3 \times 1} \begin{bmatrix} 1 \\ 0 \end{bmatrix} \otimes J_V X_S \right] = \begin{bmatrix} 1 & 1 & 1 & \dots & \dots & 1 & 1 \\ 1 & 1 & \dots & 1 & 1 & \dots & 1 \end{bmatrix}'$$

la estimación con las nuevas variables es exactamente la misma.

Como pruebas de hipótesis, las pruebas conocidas de M.C.O. son válidas y resulta de especial interés la prueba F sobre los residuales bajo la hipótesis de que

$$B_1 = B_2 = \dots = B_N = \bar{B}i$$

## 4.2.2 MODELO DE COMPONENTES DEL ERROR.

(MOCER)

Estudiaremos ahora el mismo modelo de la ecuación (4.2.1) pero con la suposición de que las  $u_i$  son variables aleatorias con media cero, varianza  $\sigma u^2$  y covarianza cero entre diferentes individuos. Se asume también que  $u_i$  y  $e_{it}$  no están correlacionados. Para el individuo i, tenemos:

$$Y_i = X_i B + u_i + \sum_t J_{i T} e_{it} \quad (4.2.12)$$

donde

$X_i$  incluye el termino constante y es de orden  $(T, K)$

$$B = (B_1, B_2, \dots, B_K)$$

y la matriz de covarianza de la composicion del error es:

$$\Phi_i = E \left[ \begin{matrix} (u_i J + e_i) \\ \vdots \\ (u_i J + e_i) \end{matrix} \begin{matrix} (u_i J + e_i)' \\ \vdots \\ (u_i J + e_i)' \end{matrix} \right] = \sigma_u^2 J J' + \sigma_e^2 I_T \quad (4.2.13)$$

El supuesto de que las  $u_i$  son variables aleatorias implica:

- 1) Que los  $N$  individuos del problema pueden ser considerados como una muestra de una poblacion mayor.
- 2) Que las  $u_i$  no estan correlacionadas con las  $X_i$ , pues de otro modo su media estaria en funcion de las segundas, es decir  $E[u_i] = f(X_i)$  y esto seria distinto de cero, violando el supuesto del modelo.
- 3) Que este modelo puede ser visto como uno donde todos los coeficientes son constantes y la matriz de covarianza del error es de la forma (4.2.13). Es interesante comparar esta matriz de covarianza con la vista para el modelo COCO (4.1.4). En la presente la matriz de covarianza es identica para todos los individuos; los errores en un individuo dado estan correlacionados en diferentes tiempos, pero dicha correlacion es constante y es identica para todos los individuos. En cambio en (4.1.4) vemos que la correlacion declina conforme haya mas tiempo de distancia y puede ser diferente para cada individuo.

Para la estimacion, incluyamos a todos los individuos:

$$Y = X B + u \otimes J + E \quad (4.2.14)$$

donde

$$u = (u_1, u_2, \dots, u_N)'$$

y la matriz de covarianza sera diagonal en bloques como sigue

$$\Phi = E \left[ (u \otimes J + E) (u \otimes J + E)' \right] = I_N \otimes \Phi_i \quad (4.2.15)$$

Si conocieramos  $\sigma_u^2$  y  $\sigma_e^2$ , entonces estimando con M.C.B.:

$$\hat{B} = (X' \Phi^{-1} X)^{-1} X' \Phi^{-1} Y \quad (4.2.16)$$

Haciendo una particion,  $\hat{B} = (\hat{B}_1, \hat{B}_s)'$ , es posible demostrar que el segundo componente es una matriz ponderada del "estimador interno" (4.2.8) y otro estimador conocido como "estimador externo" por tomar en cuenta las variaciones entre los individuos.

Para demostrarlo, notemos primero que

$$\Phi^{-1} = I_N \otimes \Phi_i^{-1} = I_N \otimes \left[ \frac{J J'}{T \sigma_u^2} + \frac{D}{\sigma_e^2} \right] \quad (4.2.17)$$

donde

$$\sigma_i^{-2} = T \sigma_u^{-2} + \sigma_e^{-2}$$

Hagamos tambien las particiones  $X = (J_{NT}, X_s)$  y  $X' = (J_T, X'_s)$ .  
Entonces, si las sustituimos junto con (4.2.17) en (4.2.16), obtenemos  
con algo de algebra

$$\hat{B}_s = \left[ \frac{X'_s D_1 X_s}{\sigma_1^2} + \frac{\sum_{i=1}^N X'_s D_i X_s}{\sigma_e^2} \right]^{-1} \left[ \frac{X'_s D_1 Y}{\sigma_1^2} + \frac{\sum_{i=1}^N X'_s D_i Y}{\sigma_e^2} \right]$$

donde  $D_1 = I_N - J_N J_N' / NT$  es una matriz idempotente tal que

$$D_1 X_s = \begin{bmatrix} \bar{X}_{21} - \bar{X}_{2..}, \dots, \bar{X}_{K1} - \bar{X}_{K..} \\ \bar{X}_{22} - \bar{X}_{2..}, \dots, \bar{X}_{K2} - \bar{X}_{K..} \\ \vdots \\ \bar{X}_{2N} - \bar{X}_{2..}, \dots, \bar{X}_{KN} - \bar{X}_{K..} \end{bmatrix} \cdot J_T$$

$$\bar{X}_{k..} = \frac{1}{N} \sum_{i=1}^N \sum_{t=1}^T X_{it}$$

es decir,  $D_1$  nos corrige por la media total las matrices  $Y$  y  $X$ .

El "estimador externo" sera entonces:

$$B_s^* = (X'_s D_1 X_s)^{-1} X'_s Y \quad (4.2.18)$$

que es obtenida al aplicar M.C.D. a

$$Y_i = B_1 + u_i + \sum_{k=1}^K B_k X_{ki} + \sum_{t=1}^T e_{it} \quad (4.2.19)$$

que es la ecuacion (4.2.1) promediada en el tiempo.

Podemos escribir ahora  $\hat{B}_s$  de esta manera: (4.2.20)

$$\hat{B}_s = \left[ \frac{X'_s D_1 X_s}{\sigma_1^2} + \frac{\sum_{i=1}^N X'_s D_i X_s}{\sigma_e^2} \right]^{-1} \left[ \frac{X'_s D_1 X_s}{\sigma_1^2} B_s^* + \frac{\sum_{i=1}^N X'_s D_i X_s}{\sigma_e^2} b_s \right]$$

que es una matriz ponderada de  $B_s^*$  y  $b_s$ . Por tanto el estimador de M.C.G. puede verse como una combinacion eficiente del estimador de variables artificiales que usa la variacion dentro de cada individuo y el estimador  $B_s^*$  que utiliza la variacion entre los individuos.

Para obtener el termino de interseccion, resolvemos:

$$B_1 = Y - \sum_{k=1}^K B_k X_k \quad (4.2.21)$$

Heamos visto en la ecuacion (4.2.20) la relacion entre los estimadores, pero computacionalmente puede resultar complicada su aplicacion.

Para resolver en la practica nuestro modelo, pensamos en una transformacion a partir de una matriz P, tal que  $P'P = c\Phi^{-1}$  donde c es cualquier escalar.

Buscaremos entonces una  $P_i$  y  $\Phi_i$  derivadas de la matriz ortogonal que diagonalice  $\Phi_i$ . Las raices caracteristicas de  $\Phi_i$  son  $\sigma_1^2$  y  $\sigma_e^2$  con multiplicidad 1 y (T-1) respectivamente. De acuerdo con varios autores, dicha matriz seria  $C = (1/\sqrt{D(T)} J_T, C_1)'$  donde  $C_1$  es cualquier matriz de orden (T-1, T), tal que

$$C_1 J_T = 0, \quad C_1 C_1' = I_{T-1} \quad \text{y} \quad C_1' C_1 = D_{T-1}$$

es decir,

$$C' \Phi_i C = \begin{bmatrix} \sigma_1^2 & & & \\ & \sigma_e^2 & & \\ & & \ddots & \\ & & & \sigma_e^2 \end{bmatrix}$$

Una matriz de transformacion seria  $P = I_N \otimes P_i$  donde

$$P_i = I_T - (1 - \frac{\sigma_e}{\sigma_1}) \frac{J_T J_T'}{T} \quad (4.2.22)$$

Multiplicando por P ambos lados de la ecuacion (4.2.14) resulta

$$Y_{it} - a \bar{Y}_i = (1-a) B_i + \sum_{k=2}^K B_k (X_{kit} - a X_{ki}) + v_{it} \quad (4.2.23)$$

donde

$$a = 1 - \frac{\sigma_e}{\sigma_1}$$

y  $v_{it}$  son errores homocedasticos y no correlacionados.

PREDICION DE  $u_i$

Siendo  $u_i$  una variable aleatoria, podemos establecer un predictor que nos permita conocer como varia con los individuos. El estimador BLU seria:

$$\hat{u}_i = \frac{\sigma_u^2}{\sigma_u^2 + \sigma_e^2} J_T' (Y - X B) \quad (4.2.24)$$

ESTIMACION DE LOS COMPONENTES DE VARIANZA.

Tanto el estimador B como el predictor  $u_i$  dependen de las varianzas de e y de u que generalmente son desconocidas. Existen varios metodos para estimar estos componentes de varianza, pero solo estudiaremos los que usan los residuales de  $Bs^*$  y de  $bs$ . Entonces,

$$\sigma_1^2 = \frac{e^{*'} e^*}{N-K} \quad (4.2.25)$$

donde

$$e^* = D_1 Y - D_1 X_s B_s^* \text{ son los residuales de } B^* \quad \text{y}$$

$$\sigma_e^2 = \frac{\hat{e}^* \hat{e}^*}{N(T-1)-K} \quad (4.2.26)$$

donde

$$\hat{e}^* = (I_N \otimes D_T) Y - (I_N \otimes D_T) X_s b_s \text{ son los residuales de } b_s.$$

De aquí obtenemos fácilmente

$$\sigma_u^2 = \frac{\sigma_1^2 - \sigma_e^2}{T} \quad (4.2.27)$$

que es el estimador de la varianza de  $u_i$  y que tiene la clara desventaja de que puede ser negativa. Si esto ocurre, puede ser indicación de que el efecto del tiempo ha sido equivocadamente omitido. Una solución alternativa sería considerarla cero, volviendo entonces al modelo de Mínimos Cuadrados Generalizados ya que no existe efecto diferente en los individuos ( $\sigma_u^2$ ).

### 4.2.3 ELECCION DE SUPUESTOS.

Cuando la intersección varía con los individuos, ¿cuál de los dos modelos, MIVAR o MOCER debemos usar? ¿Los efectos de la variación son fijos o son aleatorios? La elección no es sencilla.

Yair Mundlak sugiere que en ambos casos se considere  $u_i$  como aleatoria, pero que al usar MIVAR nuestra inferencia está condicionada al valor de  $u_i$  en la muestra, mientras que en MOCER la inferencia es incondicional ya que se hacen suposiciones específicas de su distribución; si además dichas suposiciones son correctas, el estimador de MOCER será más eficiente al aprovechar mayor información.

La cuestión relevante estará, pues, en saber si las  $u_i$  tienen una distribución i.i.d.  $(0, \sigma_u^2)$  o cuándo siguen algún otro proceso aleatorio. Mundlak sostiene que lo más razonable es que dicho proceso establezca una correlación entre las  $u_i$  y las  $X_i$ , en cuyo caso  $E\{u_i\} = f(X_i)$ , violando el supuesto de MOCER y dando un estimador sesgado por lo que en este caso conviene usar MIVAR.

En resumen, si las  $u_i$  pueden ser consideradas como extracciones ALEATORIAS y su distribución NO está correlacionada con  $X_i$ , entonces el estimador de MOCER será BLU. Si dicha distribución no se puede explicar o está correlacionada, entonces el estimador BLU será el de MIVAR.

Una prueba de hipótesis para ver si están correlacionadas resultará conveniente. Bajo la hipótesis nula de que MOCER será el modelo conveniente (es decir, que no hay correlación),

$$a = (b_s - B_s)' (M) (b_s - B_s)$$

se distribuye asintóticamente como una  $\chi^2 (K-1)$  donde

$M1 = \sigma_e^2 (Xs' (I \otimes D) Xs)^{-1}$  es la matriz de covarianza de  $bs$

$M0 = ( (1/\sigma_1^2) Xs' Q1 Xs + (1/\sigma_e^2) (Xs' (I \otimes D) Xs) )^{-1}$  es la de  $Bs$

Si se rechaza la hipotesis nula, M0VAR sera mas conveniente ya que  $u_i$  y  $X_i$  estan correlacionadas provocando mucha diferencias entre los estimadores de ambos modelos.

### 4.3 MODELOS DE PENDIENTE CONSTANTE E INTERSECCION VARIABLE SOBRE TIEMPO E INDIVIDUOS

El modelo estudiado en la seccion anterior puede extenderse al incluir en la interseccion un componente variable sobre el tiempo, pero constante sobre los individuos. Nuestro modelo seria

$$Y_{it} = B_i + u_i + 1_t + \sum_{k=1}^K B_k X_{kt} + e_{it} \quad i = 1, \dots, N \quad (4.3.1) \\ j = 1, \dots, T$$

donde

$B_i + u_i + 1_t$  es el termino de interseccion, siendo  $1_t$  el termino que en un periodo dado afecta de igual manera a todos los individuos.

El analisis de este modelo sera paralelo al modelo anterior, dependiendo de cuando  $u_i$  y  $1_t$  sean fijas o aleatorias.

#### 4.3.1 MODELO DE VARIABLES ARTIFICIALES

##### (M0VAR)

Cuando son consideradas fijas, podemos imponer la restriccion de que  $\sum u_i = 0$  y  $\sum 1_t = 0$  ya que una de ellas resulta redundante.

Para resolver (4.3.1) por M.C.O. necesitamos reparametrizarla incorporando las restricciones. Una reparametrizacion es definir

$$B_i = \bar{B}_i + u_i \quad i = 1, 2, \dots, N$$

$$1_t = \bar{1}_t - 1_T \quad t = 1, 2, \dots, T$$

quedando el modelo para el individuo  $i$



$$\bar{Y}_{..} = B_1 + \sum_{k=2}^K \bar{X}_{k..} B_k + \sum_{i=1}^N \sum_{t=1}^T e_{it} / NT \quad (4.3.7)$$

Restando (4.3.5) y (4.3.6) a (4.3.1) y (4.3.7), tenemos

$$Y_{it} - \bar{Y}_{i.} - \bar{Y}_{.t} + \bar{Y}_{..} = \sum_{k=2}^K (X_{k_{it}} - \bar{X}_{k_{i.}} - \bar{X}_{k_{.t}} + \bar{X}_{k_{..}}) B_k + v_{it} \quad (4.3.8)$$

donde  $v_{it}$  se define de manera obvia.

El estimador de (4.3.4) puede considerarse como el estimador de M.C.O. aplicado a (4.3.8). También puede ser visto como el estimador de M.C.G. donde  $Q \cdot Q = 0$  es la matriz de covarianza de los errores y  $Q$  es la inversa generalizada de sí misma. La matriz de covarianza de  $b_s$  es  $\sigma^2(X_s' Q X_s)^{-1}$ .

Los coeficientes restantes pueden obtenerse de:

$$\hat{u}_i = (\bar{Y}_{i.} - \bar{Y}_{..}) - \sum_{k=2}^K (\bar{X}_{k_{i.}} - \bar{X}_{k_{..}}) b_k \quad (4.3.9)$$

$$\hat{t} = (\bar{Y}_{.t} - \bar{Y}_{..}) - \sum_{k=2}^K (\bar{X}_{k_{.t}} - \bar{X}_{k_{..}}) b_k \quad (4.3.10)$$

$$\hat{b}_T = \bar{Y}_{..} - \sum_{k=2}^K \bar{X}_{k..} b_k \quad (4.3.12)$$

Para probar la hipótesis sobre la inclusión o no de variables artificiales podemos usar también la prueba  $F$  que compara las sumas de cuadrados restringidos y no restringidos.

### 4.3.2 MODELO DE COMPONENTES DEL ERROR

#### (MOCER)

En esta sección asumimos que los efectos del tiempo y de los individuos no son fijos sino aleatorios, de forma que

$$E[u_i] = 0 \quad E[u_i^2] = \sigma_u^2 \quad E[u_i u_j] = 0 \quad \text{para } i \neq j$$

$$E[t_t] = 0 \quad E[t_t^2] = \sigma_t^2 \quad E[t_t t_s] = 0 \quad \text{para } t \neq s$$

y entre ellos no están correlacionados.

Las observaciones para el i-esimo individuo quedan:

$$Y_i = X_i B + u_i J_i + I_i 1 + e_i \quad (4.3.12)$$

donde

$$1 = (1, 1, \dots, 1)'$$

La matriz de covarianza para el error compuesto es:

$$\begin{aligned} \Phi_{ii} &= E [ (u_i J_i + I_i 1 + e_i) (u_i J_i + I_i 1 + e_i)' ] \\ &= \sigma_u^2 J_i J_i' + \sigma_1^2 I_i I_i' + \sigma_e^2 I_i I_i' \end{aligned} \quad (4.3.13)$$

y la covarianza entre los vectores de dos individuos es

$$\begin{aligned} \Phi_{ij} &= E [ (u_i J_i + I_i 1 + e_i) (u_j J_j + I_j 1 + e_j)' ] \\ &= \sigma_1^2 I_i I_j' \end{aligned} \quad (4.3.14)$$

Tomando en cuenta todas las NT observaciones, el modelo queda

$$Y = X B + u \otimes J + (J \otimes I) 1 + E \quad (4.3.15)$$

donde

$$u = (u_1, u_2, \dots, u_N)'$$

y la matriz de covarianza completa es

$$\begin{aligned} \Phi &= E [ (u \otimes J + (J \otimes I) 1 + E) (u \otimes J + (J \otimes I) 1 + E)' ] \\ &= \sigma_u^2 (I \otimes J J') + \sigma_1^2 (J J' \otimes I) + \sigma_e^2 I_{NT} \end{aligned} \quad (4.3.16)$$

Aquí podemos ver que  $\Phi$  no es diagonal en bloque, y por tanto los errores en diferentes individuos están contemporáneamente correlacionados.

### ESTIMACION POR M.C.G.

Para estimar B, el estimador de M.C.G.

$$\hat{B} = (X' \Phi^{-1} X)^{-1} X' \Phi^{-1} Y \quad (4.3.17)$$

es BLUE con matriz de covarianza  $(X' \Phi^{-1} X)^{-1}$

Si B es particionada en (B1, Bs), es posible demostrar que el estimador de los coeficientes de la pendiente, Bs, es una matriz ponderada de otros tres estimadores.

La multiplicacion directa muestra que:

$$\Phi^{-1} = \frac{Q}{\sigma_e^2} + \frac{Q1}{\sigma_1^2} + \frac{Q2}{\sigma_2^2} + \frac{Q3}{\sigma_3^2} \quad (4.3.18)$$

donde

$$Q2 = (1/N) J J' \otimes I_T - (1/NT) J_{NT} J_{NT}'$$

$$Q3 = (1/NT) J_{NT} J_{NT}'$$

$$\sigma_2^2 = \sigma_e^2 + N \sigma_1^2$$

$$\sigma_3^2 = \sigma_e^2 + T \sigma_u^2 + N \sigma_1^2$$

Particionando B y usando (4.3.18) tenemos, despues de algo de algebra,

$$B_s = [(1/\sigma_1^2) X_s' D1 X_s + (1/\sigma_2^2) X_s' Q2 X_s + (1/\sigma_e^2) X_s' Q X_s]^{-1} [(1/\sigma_1^2) X_s' D1 X_s B_s^0 + (1/\sigma_2^2) X_s' Q2 X_s B_s^0 + (1/\sigma_e^2) X_s' Q X_s b_s] \quad (4.3.19)$$

$$B_1 = Y_{..} - \sum_{k=2}^K X_k \cdot B_k \quad (4.3.20)$$

donde

$B_s^0 = (X_s' D1 X_s)^{-1} X_s' D1 Y$  utiliza la variacion ENTRE los individuos

$B_s^0 = (X_s' Q2 X_s)^{-1} X_s' Q2 Y$  utiliza la variacion en el tiempo en cada individuo

$b_s$  es el estimador de var. artificiales y usa la variacion no explicada por las diferencias en individuos o periodos de tiempo

### PREDICION DE COMPONENTES ALEATORIOS.

Los predictores BLUE para los coeficientes aleatorios son:

$$\hat{u}_i = \frac{T \sigma_u^2}{\sigma_1^2} (Y_{.i} - B_1 - \sum_{k=2}^K B_k X_{k.i}) \quad (4.3.21)$$

$$\hat{t} = \frac{N \sigma_1^2}{\sigma_2^2} (Y_{.t} - B_1 - \sum_{k=2}^K B_k X_{k.t}) \quad (4.3.22)$$

El primer predictor da información sobre el futuro comportamiento de los individuos y parece más interesante que la predicción de  $l_t$  que informa sobre realizaciones pasadas.

ESTIMACION DE LOS COMPONENTES DE VARIANZA.

Los estimadores de B y los predictores de u y l dependen de las varianzas desconocidas  $\sigma_e^2$ ,  $\sigma_u^2$  y  $\sigma_l^2$ . Para reemplazarlas podemos usar los estimadores del apartado anterior adaptandolos para incluir la variación del tiempo. Entonces,

$$\hat{\sigma}_1^2 = \frac{e\# ' e\#}{N-K} \tag{4.3.23}$$

$$\hat{\sigma}_2^2 = \frac{e0 ' e0}{T-K} \tag{4.3.24}$$

$$\hat{\sigma}_e^2 = \frac{\hat{e} ' \hat{e}}{(N-1)(T-1)-(K-1)} \tag{4.3.25}$$

donde

$e\# = Q1 Y - Q1 Xs Bs^*$  son los residuales de  $Bs^*$

$e0 = Q2 Y - Q2 Xs Bs^*$  son los residuales de  $Bs^*$

$\hat{e} = Q Y - Q Xs bs$  son los residuales de bs

Para probar las hipótesis de  $u = 0$ ,  $l = 0$ , o  $u=l=0$  podemos usar el estimador de variables artificiales y la prueba F que compara las sumas de cuadrados restringidos y no restringidos.

Alternativamente una prueba asintótica para la prueba  $\text{var}(u) = \text{var}(l) = 0$  viene dada por

(4.3.26)

$$g = \frac{NT}{2} \left\{ \left[ \frac{1}{T-1} \sum_{i=1}^N \left( \sum_{t=1}^T \hat{e}_{it} \right)^2 - 1 \right]^2 + \frac{1}{N-1} \left[ \sum_{t=1}^T \left( \sum_{i=1}^N \hat{e}_{it} \right)^2 - 1 \right]^2 \right\}$$

que se distribuye asintóticamente como una  $\text{Chi}^2(2)$  donde  $\hat{e}$  son los residuales de la regresión de Y en X.

Los supuestos de este modelo son muy restrictivos, pues implican:

- 1) Que la covarianza contemporánea entre dos individuos es la misma para cualquier par de individuos.
- 2) Que la covarianza entre dos observaciones de un individuo dado es constante en el tiempo y la misma para cada individuo.

### 4.3.3 ELECCION DE SUPUESTOS.

Como mencione en la seccion 4.2.3, el uso del modelo de variables artificiales puede considerarse como una inferencia condicional en las  $u_i$  y  $l_i$  en la muestra y por tanto sin importar las suposiciones que sobre ellas se hagan.

El modelo de componentes del error (MOCER) hace un conjunto especifico de supuestos acerca de los coeficientes aleatorios y, si son correctos, el estimador de M.C.G. sera mas eficiente. Pero si las especificaciones son incorrectas, este estimador resultara sesgado.

El punto decisivo es saber cuándo las  $u_i$  y las  $l_i$  están correlacionadas con las  $X_{ik}$ . Si existe correlacion, entonces el estimador de MOVAR sera el mas apropiado. Si no existe correlacion, MOCER sera mas razonable.

Para decidir si existe o no correlacion, podemos probar la hipotesis nula de NO correlacion comparando los estimadores de MOVAR y MOCER.

Si la hipotesis nula es correcta, entonces

$$m = (b_s - \hat{B}_s)' (M_1 - M_0)^{-1} (b_s - \hat{B}_s)$$

se distribuye asintoticamente como una Chi<sup>2</sup> (K-1)

donde

$$M_1 = \sigma_e^2 (X_s' Q X_s)^{-1} \text{ es la matriz de covarianza para } b_s$$

$$M_0 = (\sigma_1^2 (X_s' D_1 X_s) + \sigma_2^2 (X_s' D_2 X_s) + \sigma_e^2 (X_s' D X_s))^{-1}$$

es la matriz de covarianza de  $B_s$ .

Las varianzas desconocidas en esta prueba pueden ser reemplazadas por sus estimadores sin cambiar la distribucion.

#### 4.4 MODELOS DE PENDIENTE VARIABLE SOBRE LOS INDIVIDUOS.

Es posible que la diferencia en el comportamiento de los individuos se manifieste no solo en el termino de interseccion, sino tambien en los coeficientes de la pendiente. Si este es el caso, nuestro modelo podria ser:

$$Y_{it} = \sum_{k=1}^K X_{k, it} B_{k, i} + e_{it} \quad \begin{matrix} i = 1, 2, \dots, N \\ j = 1, 2, \dots, T \end{matrix} \quad (4.4.1)$$

Este modelo nos hace suponer que el efecto en la variable dependiente (Y) al cambiar las variables independientes es distinto para cada individuo, pero en cada uno de ellos permanece constante en el tiempo.

Tambien aqui podremos distinguir dos modelos, correspondientes a cuando los  $B_k$ , son fijos o son aleatorios.

##### 4.4.1 MODELO DE "REGRESIONES APARENTEMENTE NO RELACIONADAS".

(MDRAN)

Si los coeficientes son tratados como parametros fijos, la ecuacion (4.4.1) puede expresarse en general:

$$Y = ZR + E \quad (4.4.2)$$

O bien,

$$\begin{bmatrix} Y_1 \\ \vdots \\ Y_i \\ \vdots \\ Y_N \end{bmatrix} = \begin{bmatrix} X_1 & & & \\ & X_2 & & \\ & & \ddots & \\ & & & X_N \end{bmatrix} \begin{bmatrix} B_1 \\ B_2 \\ \vdots \\ B_N \end{bmatrix} + \begin{bmatrix} e_1 \\ e_2 \\ \vdots \\ e_N \end{bmatrix} \quad (4.4.3)$$

Asumiremos que

$$E[e_i] = 0 \quad \text{y} \quad E[e_i e_j'] = \sigma^2 \delta_{ij}$$

De otra forma, si la covarianza fuera cero, podríamos resolver (4.4.3) por M.C.O. y el estimador sería BLUE. Tenemos entonces:

$$E [ E E' ] = \Theta = \Sigma \otimes I_T$$

donde

$$\Sigma = \begin{bmatrix} \sigma_{11} & \sigma_{12} & \dots & \sigma_{1N} \\ \sigma_{21} & \sigma_{22} & \dots & \sigma_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{N1} & \sigma_{N2} & \dots & \sigma_{NN} \end{bmatrix} \quad (4.4.4)$$

Podemos ahora estimar R por M.C.G.

$$\hat{R} = (Z' \Theta^{-1} Z)^{-1} Z' \Theta^{-1} Y = (Z' (\Sigma^{-1} \otimes I_T) Z)^{-1} Z' (\Sigma^{-1} \otimes I_T) Y \quad (4.4.5)$$

El estimador  $\hat{R}$  es, pues, BLUE y tiene por matriz de covarianza

$$E [ (\hat{R} - R) (\hat{R} - R)' ] = (Z' \Theta^{-1} Z)^{-1} = (Z' (\Sigma^{-1} \otimes I_T) Z)^{-1}$$

Si aplicáramos M.C.O. a un individuo determinado, el estimador  $b_i$  de ese individuo sería también BLUE. Sin embargo podemos pensar en una clase de estimadores más amplia, digamos la de estimadores insesgados. Dentro de esta clase, el estimador de  $B_i$ , el  $i$ -ésimo subvector del estimador de R, es mejor que  $b_i$  porque toma en cuenta la correlación entre  $e_i$  y otros vectores de error (recordemos que su covarianza es no nula) y también porque usa información de las variables explicatorias que está oculta en el sistema y que no existe para la  $i$ -ésima ecuación individual. Esta es la razón por la cual Zellner en 1962 llamó a este modelo "Regresiones aparentemente no relacionadas". Solo cuando  $\sigma_{ij} = 0$  para toda  $i \neq j$ , o cuando  $X_1 = X_2 = \dots = X_N$  los estimadores  $b_i$  y  $B_i$  serán idénticos y no se ganará en eficiencia.

Generalmente desconocemos  $\Sigma$  por lo que debemos estimarla basándonos en los residuales de M.C.O.,

$$\hat{\sigma}_{ij} = (1/T) \hat{e}_i' \hat{e}_j \quad i, j = 1, 2, \dots, N \quad (4.4.6)$$

donde

$$\hat{e}_i = Y_i - X_i b_i$$

Por tanto,

$$\hat{R} = (Z' (\hat{\Sigma}^{-1} \otimes I_T) Z)^{-1} Z' (\hat{\Sigma}^{-1} \otimes I_T) Y \quad (4.4.7)$$

es el estimador BLUE de R y se conoce como el estimador de MORAN.

PRUEBAS DE HIPOTESIS.

Como vimos en la seccion 4.1 interesa conocer si es o no significativa la informacion que nos proporciona la matriz de covarianza de los errores. La solucion alternativa sera considerar la restriccion de que los parametros son constantes para todos los individuos, incluso bajo el esquema de autocorrelacion visto en dicha seccion.

Nuevamente usaremos un estadistico que relaciona los residuales restringidos y no restringidos. Si probamos que la estimacion a partir de MORAN reduce la suma de los cuadrados de los residuales con respecto al modelo COCO, habremos probado que la informacion aportada por la matriz de covarianza es significativa, y por tanto rechazaremos la hipotesis de que los coeficientes son constantes.

Para ello nos ayudaremos del estadistico

$$F = \frac{((Y-XB)' Q^{-1} (Y-XB) - (Y-ZR)' \Theta^{-1} (Y-ZR)) / (NK-K-N)}{(Y-ZR)' \Theta^{-1} (Y-ZR) / (NT-NK-N(N+1)/2)} \quad (4.4.8)$$

que se distribuye como una F con (NK-K-N, NT-NK-N(N+1)/2) grados de libertad, cuya deduccion es igual que en la prueba (4.1.7).

**4.4.2 MODELO SWAMY DE COEFICIENTES ALEATORIOS.**

(MOSCA)

Cuando el vector de coeficientes de cada individuo  $B_i$  es considerado como un vector aleatorio extraido de una distribucion de probabilidad con media  $\bar{B}$  y matriz de covarianza CV, podemos escribir el modelo para el i-esimo individuo asi

$$Y_i = X_i B_i + e_i \quad i = 1, 2, \dots, N \quad (4.4.9)$$

donde

$$B_i = \bar{B} + u_i$$

$$E[u_i] = 0, \quad E[u_i u_i] = CV \quad \text{y} \quad E[u_i u_j] = 0 \quad \text{para } i \neq j$$

Hemos asumido en los modelos anteriores diferentes suposiciones sobre el error "e" y cualquiera de ellas puede aplicarse al presente, pero consideremos ahora las mas sencillas, esto es, que

$$E[e_i] = 0, \quad E[e_i e_i'] = \sigma^2 I \quad \text{y} \quad E[e_i e_j'] = 0 \quad \text{para } i \neq j$$

Esto implica:

1) Que los errores entre los individuos son heterocedasticos pero no correlacionados.

2) Que si los  $B_i$  fueran parametros fijos, entonces el estimador de M.C.G.  $b_i$  seria BLUE ya que no habria correlacion entre individuos, es decir, cada modelo seria independiente.

ESTIMACION POR MINIMOS CUADRADOS GENERALIZADOS.

En terminos generales podemos escribir:

$$Y = X \bar{B} + Z \underline{u} + E \tag{4.4.10}$$

donde

$$X = (X_1, X_2, \dots, X_N)'$$

$$\underline{u} = (u_1, u_2, \dots, u_N)'$$

Z esta definida como en (4.4.2)

La matriz de covarianza para el error compuesto es:

$$\Phi = E [(Z\underline{u} + E) (Z\underline{u} + E)'] \tag{4.4.11}$$

que es una matriz diagonal en bloque cuyo elemento  $i$  es

$$\Phi_{ii} = X_i CV X_i' + \sigma_{ii} I_T \tag{4.4.12}$$

El estimador de M.C.G. de  $\bar{B}$ , con sus propiedades usuales, seria

$$\begin{aligned} \hat{\bar{B}} &= (X' \Phi^{-1} X)^{-1} X' \Phi^{-1} Y \\ &= \left( \sum_{j=1}^N X_j' \Phi_{jj}^{-1} X_j \right)^{-1} \sum_{i=1}^N X_i' \Phi_{ii}^{-1} Y_i \\ &= \sum_{i=1}^N W_i b_i \end{aligned} \tag{4.4.13}$$

donde

$$W_i = \left( \sum_{j=1}^N (CV + \sigma_{jj} (X_j' X_j)^{-1})^{-1} \right)^{-1} (CV + \sigma_{ii} (X_i' X_i)^{-1})^{-1}$$

y

$$b_i = (X_i' X_i)^{-1} X_i' Y_i$$

La ecuacion (4.4.13) nos muestra como el estimador  $\hat{\bar{B}}$  es una matriz ponderada de los estimadores  $b_i$  con los pesos inversamente proporcionados a sus matrices de covarianza.

La matriz de covarianza de  $\hat{\bar{B}}$  es:

$$\begin{aligned}
 (X' \Phi^{-1} X) &= \sum_{j=1}^N X_j' \Phi_j^{-1} X_j \\
 &= \sum_{j=1}^N (CV + \sigma_j^2 (X_j' X_j)^{-1})
 \end{aligned}$$

ESTIMACION DE LAS VARIANZAS.

Como en los modelos anteriores, aqui tambien requerimos estimar las varianzas CV y  $\sigma_{jj}$  para hacer operativos los estimadores. Swamy demostro que podemos usar los residuales de M.C. para estimarlas insesgadamente:

$$\hat{\sigma}_{ii} = (1/T-K) \hat{e}_i \hat{e}_i'$$

y

$$\hat{CV} = Sb / (N-1) - (1/N) \sum_{i=1}^N \hat{\sigma}_{ii} (X_i' X_i)^{-1} \quad (4.4.14)$$

donde

$$Sb = \sum_{i=1}^N b_i b_i' - (1/N) \sum_{i=1}^N b_i \sum_{i=1}^N b_i'$$

Una dificultad con el estimador de CV es que debe ser no-negativo definido. Swamy sugiere metodos para corregirlo, pero a costa de eliminar la propiedad de insesgo. La solucion mas sencilla parece ser entonces aceptar el estimador sesgado  $\hat{CV} = Sb / (N-1)$  que es un estimador no-negativo definido y es consistente respecto a los incrementos en T.

De gran interes resulta ahora la prueba de la hipotesis nula:

$$H_0: \beta_1 = \beta_2 = \dots = \beta_N = \bar{\beta}$$

Si resulta cierta, el vector de coeficientes individuales no son aleatorios y son identicos a la media. Entonces el modelo conjunto (4.4.9) resulta ser de errores heterocedasticos, donde las varianzas son constantes dentro de los subgrupos de observaciones.

El estadistico

$$g = \frac{\sum_{i=1}^N (b_i - \bar{\beta})' X_i' X_i (b_i - \bar{\beta})}{\hat{\sigma}_{ii}} \quad (4.4.15)$$

donde

$$\bar{\beta} = \left( \sum_{i=1}^N \sigma_{ii}^{-1} X_i' X_i \right)^{-1} \sum_{i=1}^N \sigma_{ii}^{-1} X_i' X_i b_i$$

tiene una distribución asintótica  $\chi^2(K(N-1))$  bajo  $H_0$ . Puede hacerse esta misma prueba cuando las  $B_i$  son consideradas fijas y diferentes.

#### 4.4.3 ELECCION DE SUPUESTOS.

La discusión corre paralela al caso de pendiente constante e intersección variable. Cuando existe correlación entre los coeficientes y las variables explicatorias o independientes, parece más razonable usar MORAN, en tanto que si no hay correlación o no se puede especificar en el modelo, conviene usar MOSCA.

La prueba de hipótesis sobre la NO correlación ha sido estudiada por Pudney, basándose en la covarianza entre el estimador de M.C.O. de cada individuo y las medias de las variables explicatorias de cada uno de los individuos:

$$\bar{X}'_i = \frac{J' X_i}{T}$$

La covarianza muestral está dada por

$$S_{Xb} = \frac{1}{N} \left( \sum_{i=1}^N b_i \bar{X}'_i - \frac{1}{N} \sum_{i=1}^N b_i \sum_{i=1}^N \bar{X}'_i \right) \quad (4.4.16)$$

y el estadístico para la prueba es:

$$z = N \eta' V^{-1} \eta$$

donde

$\eta$  es el vector de  $(S_{Xb})$  para todas las  $i$ .

$$V = \frac{1}{N} \sum_{i=1}^N (X_i' I) (CV + \sigma^2 (X_i' X_i)^{-1}) (X_i' I)'$$

#### 4.5 MODELOS DE PENDIENTE VARIABLE SOBRE EL TIEMPO Y LOS INDIVIDUOS.

En este modelo todos los coeficientes tienen una aportación específica a cada individuo y en cada periodo de tiempo. Podemos escribirlo de la siguiente manera

$$Y_{it} = \sum_{k=1}^K (B_k + u_{k+1}) X_{k,it} + e_{it} \quad \begin{matrix} i = 1, 2, \dots, N \\ t = 1, 2, \dots, T \end{matrix} \quad (4.5.1)$$

donde 
$$B_{it} = B_k + u_i + 1_t$$

En este modelo, como en los anteriores, podemos considerar los parametros como fijos o aleatorios. Generalmente se pueden considerar aleatorios pero algun caso requiere que sean fijos. O bien podemos considerar que uno de ellos es fijo y el otro aleatorio como puede ser el caso cuando se tienen pocas observaciones respecto al tiempo.

Si en la ecuacion (4.5.1) sustituimos el efecto del tiempo con variables artificiales, tenemos exactamente el modelo anterior (MOSCA).

#### 4.5.1 MODELO Hsiao DE COEFICIENTES ALEATORIOS.

(MOHCA)

La estimacion y pruebas de hipotesis del modelo (4.5.1) lo debemos a Hsiao, que para el i-esimo individuo escribe la ecuacion asi,

$$Y_i = X_i B + X_i u_i + Z_i 1 + e_i \quad (4.5.2)$$

donde

$Y_i$  es de dimension  $(t,1)$  y  $X_i$  de  $(T,K)$

$$u_i = (u_{i1}, u_{i2}, \dots, u_{iK})'$$

$$1 = (1_1, 1_2, \dots, 1_T)'$$

$$1_t = (1_{t1}, 1_{t2}, \dots, 1_{tK})'$$

$$e_i = (e_{i1}, e_{i2}, \dots, e_{iT})'$$

$$X_{it}' = (X_{it1}, X_{it2}, \dots, X_{itK})'$$

y

$$Z_i = \begin{bmatrix} X_{i1}' & & & & \\ & X_{i2}' & & & \\ & & \cdot & & \\ & & & \cdot & \\ & & & & X_{iT}' \end{bmatrix}$$

Los supuestos que propone Hsiao son:

$$\begin{array}{lll} E[e_i] = 0, & E[e_i e_i'] = \sigma_e^2 I & E[e_i e_j'] = 0 \text{ para } i \neq j \\ E[u_i] = 0, & E[u_i u_i'] = \sigma_k I = CD & E[u_i u_j'] = 0 \text{ para } i \neq j \\ E[1_t] = 0, & E[1_t 1_t'] = \sigma_k I = A & E[1_t 1_s'] = 0 \text{ para } t \neq s \end{array}$$

y entre ellos no esta correlacionados.

Al incluir todas las observaciones, tenemos

$$Y = X \underline{B} + Z \underline{u} + \underline{Z} \underline{1} + E \quad (4.5.3)$$

con las definiciones conocidas.

Si  $\underline{u}$  y  $\underline{1}$  son considerados fijos,  $\underline{B}$ ,  $\underline{u}$  y  $\underline{1}$  pueden estimarse aplicando M.C.O. a (4.5.3), aunque habiendo reparametrizado corrigiendo por su media y tomando en cuenta que NT es suficientemente grande.

La matriz  $(X, Z, Z)$  es de orden  $(NT, (N+T+1)K)$  y de rango  $(N+T-1)K$  por lo que hay  $2K$  parametros redundantes. Para una conveniente estimacion convendria eliminar

$$\begin{matrix} (u_1, u_2, \dots, u_K, 1_1, 1_2, \dots, 1_K) \\ \begin{matrix} N & N & \dots & N & T & T & \dots & T & T & \dots & T \end{matrix} \end{matrix}$$

eliminar tambien sus columnas correspondientes en  $Z$  y  $Z$  y redefinir los otros parametros. En todo caso debemos recordar que estamos asumiendo que  $NT \gg (N+T-1)K$ .

### ESTIMACION DE VARIANZAS Y PREDICCION

Cuando  $u$  y  $1$  son aleatorias, la matriz de covarianza de los errores es

$$\begin{aligned} \Phi &= E \{ (Z \underline{u} + \underline{Z} \underline{1} + E) (Z \underline{u} + \underline{Z} \underline{1} + E)' \} \\ &= E \{ \begin{matrix} (I \otimes CD) & Z' \\ N & T \end{matrix} + \begin{matrix} (I \otimes A) & Z' \\ T & T \end{matrix} + \sigma_e^2 I_{NT} \} \end{aligned} \quad (4.5.4)$$

y el estimador

$$\hat{B} = (X' \Phi^{-1} X)^{-1} X' \Phi^{-1} Y \quad (4.5.5)$$

es BLUE para estimar  $B$  con matriz de covarianza  $(X' \Phi^{-1} X)^{-1}$

Siendo  $\Phi$  de orden  $(NT, NT)$  su inversion puede complicarse. Sin embargo, Hsiao muestra que  $\Phi^{-1}$  puede escribirse asi

$$\begin{aligned} \Phi^{-1} &= I - ZGZ' - ZCZ'(I - ZGZ') \\ &\quad + (I + ZCZ') Z (Z'ZCZ'Z - G^{-1})^{-1} Z'ZCZ'(I - ZGZ') \end{aligned} \quad (4.5.6)$$

donde

$$C = (Z'Z + (I \otimes A^{-1}))^{-1}$$

$$G = (Z'Z + (I \otimes CD^{-1}))^{-1}$$

En esta expresion la inversion de mayor orden se reduce al MAX (NK,TK) pero esto puede ser aun algo grande.

Para predecir los componentes aleatorios para cada individuo, podemos usar el predictor BLUE

$$\hat{u} = (I + CD) Z' \phi^{-1} (Y - XB) \quad (4.5.7)$$

ESTIMACION DE VARIANZAS.

Tanto  $\hat{B}$  como  $u$ , dependen de CD, A y  $\sigma e^2$  que son desconocidas. Para estimarlas podemos escribir la ecuacion (4.5.1) de esta manera

$$Y_{it} = \sum_{k=1}^K B_{k,i} X_{k,it} + v_{it}$$

donde

$$B_{k,i} = \bar{B}_{k,i} + u_{k,i}$$

y

$$v_{it} = \sum_{k=1}^K l_{k,t} X_{k,it} + e_{it} \quad (4.5.8)$$

con varianza

$$VR_{it} = E[v_{it}^2] = \sum_{k=1}^K X_{k,it}^2 \alpha_k + \sigma e^2$$

que en forma vectorial podemos escribir

$$VR_{-i} = X X_i a_i$$

donde

$X X_i$  es  $X_i$  con cada uno de sus elementos al cuadrado

$$a_i = (\alpha_1 + e_i^2, \alpha_2, \alpha_3, \dots, \alpha_K)'$$

Sea  $e_i = Y_i - X_i b_i$  el vector de residuales del estimador de M.C.O.

y

$e_i X_i$  el vector de los cuadrados de dichos residuales. Entonces,

$$E[e_i X_i] = M X_i VR_i = F_i a_i$$

donde

$$M X_i \text{ contiene los cuadrados de los elementos de } M = I - X_i (X_i' X_i)^{-1} X_i'$$

y

$$F_i = M X_i X_i$$

Repetiendo el proceso para todos los cortes transversales, tenemos

$$E [ EX ] = F\alpha \quad (4.5.9)$$

donde

$$EX = (e\%_1', e\%_2', \dots, e\%_N')$$

$$Y = (F_1', F_2', \dots, F_N')$$

Aplicando M.C.O. a (4.5.9), obtenemos el estimador

$$\hat{\alpha} = (F' F)^{-1} F' EX$$

Siguiendo el mismo procedimiento respecto a cada  $t$ , obtendremos el estimador insesgado  $\hat{\delta}$  para  $\delta = (\delta_1 + e^2, \delta_2, \delta_3, \dots, \delta_K)'$

Un estimador consistente para  $\sigma_e^2$  esta dado por

$$\hat{\sigma}_e^2 = \frac{N}{\text{SUM}_{i=1}^N} \frac{T}{\text{SUM}_{t=1}^T} \frac{e\%_{it} e^*_{it}}{N T} \quad (4.5.10)$$

donde

$e^*$  son los residuales obtenidos al aplicar M.C.O. separadamente a cada periodo de tiempo

De  $\hat{\alpha}$ ,  $\hat{\delta}$  y  $\hat{\sigma}_e^2$  se pueden derivar una estimacion para  $\alpha$  y  $\delta$ .

En la practica, el modelo Hsiao es poco aceptado en parte por la complicacion de sus calculos y en parte tambien porque sus supuestos parecen poco realistas. La principal objecion es considerar  $A$  y  $VD$  como diagonales, pero su eliminacion supone mayores complicaciones en el manejo computacional. Incluso, si existiesen el suficiente numero de observaciones en el tiempo, convendria considerar el efecto del tiempo como un problema de autocorrelacion en los errores.

#### 4.6 ELECCION DE MODELO.

Cuando afrontamos un problema en la practica, nos encontramos con la dificultad de elegir el modelo mas adecuado. En otras palabras, debemos decidir cual es el conjunto de suposiciones mas factibles para nuestro problema. Esto obviamente no es sencillo pues no existe una evaluacion exacta para hacerlo, aunque si puede ayudarnos una guia:

1) ¿Los coeficientes de la pendiente parecen variar sobre los individuos, o es razonable captar la diferencia entre los individuos a traves de la interseccion o de un modelo apropiado del termino de error?

2) Si los coeficientes o la intersección varían sobre los individuos, ¿las diferencias parecen depender de las variables independientes de los individuos? Si es así, MOVAR o MORAN parecen ser preferibles. Si no, entonces MOCER o MOSCA parecen ser los correctos.

3) Para modelar cambios sobre el tiempo es necesario ver qué método es el mejor:

- a) Usar la estructura de correlación constante del MOCER
- b) Asumir que los errores siguen un proceso autorregresivo o de promedios móviles (COCO)
- c) Usar variables artificiales y usar inferencia condicional para los cambios en la muestra (MOVAR)

4) ¿Cuántas observaciones hay? En modelos donde se asume que los parámetros son aleatorios, los tamaños relativos de N y T tendrán un importante influjo en la confiabilidad de la estimación de varianzas para muestras finitas. Si, por ejemplo, N es pequeña, no parece que  $\sigma^2$  para el MOCER, o la estimación de CD para el MOSCA sean muy confiables. Consecuentemente, tampoco serán confiables las estimaciones hechas a partir de ahí y para su estimación será más conveniente considerarlos como parámetros fijos, aun cuando parezca razonable el supuesto de aleatoriedad.

## CAPITULO 5

### DEMANDA DE AUTOS POR CATEGORIAS.

A manera de ejemplo, trabajaremos con un modelo que estime la demanda de automoviles en Mexico, donde el corte transversal se hara sobre tres categorias de autos (compactos, medianos y de lujo) y las observaciones en el tiempo corresponden a 60 meses, de enero de 1980 a diciembre de 1984.

La estimacion de un modelo encierra bastantes complicaciones, primero en cuanto a determinar las variables que expliquen la variacion real de la variable independiente, luego en recopilar la informacion de cada variable y, finalmente, en procesar toda esta informacion mediante transformaciones para que se ajusten lo mas posible a la realidad.

En este capitulo presentaremos la especificacion del modelo, la definicion de cada una de las variables y, por ultimo, los resultados obtenidos al aplicar algunos modelos de los estudiados en el capitulo 4.

#### 5.1 ESPECIFICACION DEL MODELO.

Todo modelo economico de demanda debe incluir entre sus variables explicatorias el precio del bien en estudio, el ingreso y el precio de los bienes sustitutos. Nosotros decidimos usar como bienes sustitutos el precio del transporte y la tasa de interes bancaria. Ademas de las variables anteriores, incluimos en nuestro modelo una medida del consumo de gasolina.

Muchas otras variables podrian incluirse en nuestro modelo y seguramente el lector pensara algunas de ellas. Pero recordemos que un modelo debe simplificar la realidad, y el efecto de toda aquella informacion no incluida en el mismo sera absorbida por el termino de error.

Asi, pues, podemos escribir para la categoria  $i$ :

$$Y_i = f(X_2, X_3, X_4, X_5, X_6, X_7) \quad (5.1.1)$$

donde

$Y_i$  = demanda de automoviles de la categoria  $i$

$X_2$  = precio de los automoviles de la categoria  $i$

$X_3$  = medida del consumo de gasolina de los autos de la categoria  $i$

$X_4$  = ingreso real (es igual para las tres categorias)

- X<sub>5</sub> = precio del transporte (es igual para las tres categorías)
- X<sub>6</sub> = tasa de interes activa (es igual para las tres categorías)
- X<sub>7</sub> = precio de los automoviles sustitutos

Una especificacion mas concreta del modelo la podremos hacer despues de analizar la definicion de cada una de las variables y las transformaciones que deben hacerse.

## 5.2 DEFINICION DE LAS VARIABLES.

### 5.2.1 DEMANDA DE AUTOMOVILES (Y).

¿Hasta donde es posible medir la demanda real de automoviles? La informacion disponible consiste, por un lado, en el volumen de produccion de automoviles por cilindrada (es decir, una medida de la oferta), segun la Direccion General de Estadistica de la Secretaria de Programacion y Presupuesto (S.P.P.), y por otro lado en las ventas mensuales de automoviles por marcas, proporcionada por la Asociacion Mexicana de la Industria Automotriz (A.M.I.A.).

¿Podemos identificar las ventas con la demanda real? El hecho de que en el mercado mexicano la oferta de automoviles es mayor que la demanda (la produccion es mayor que el consumo en el pais), hace admisible identificar las ventas de autos con la demanda.

Aqui conviene anotar que nuestra idea inicial era hacer el corte transversal no por categorías sino por cilindrada, de manera que tendríamos tambien tres tipos de autos: de 4, de 6 y de 8 cilindros. Sin embargo el mercado de autos en Mexico ha venido sufriendo modificaciones en su estructura en los ultimos años. Asi, los modelos Chrysler que antes eran de 6 u 8 cilindros, pasaron a ser de 4 cilindros con la nueva serie de modelos "K" a partir de enero de 1983. De manera similar, el mercado de autos de 8 cilindros desaparece a partir de noviembre de 1984, incrementando la variedad de automoviles de 4 y 6 cilindros. De acuerdo a estos hechos, un modelo que estimara la demanda de automoviles por cilindrada estaria fuera de nuestros objetivos ya que no nos permitiria un estudio confiable en el corte transversal.

Elegimos entonces hacer el corte transversal sobre la categoría de los automoviles (compactos, medianos y de lujo) porque esta clasificacion es semejante al de cilindrada antes del cambio de estructura del mercado, y porque despues del cambio se conservaban las categorías, en cuanto que los coches de lujo seguian siendo de lujo a pesar de tener ahora 4 o 6 cilindros en lugar de 8 que tenian.

Una vez establecidas las categorías, definimos: (5.2.1)

Y<sub>it</sub> = demanda de automoviles del tipo i en el mes t

donde

$Y_{it}$  esta en unidades vendidas  
 $i = 1, 2, 3$  ( $1 =$  compactos,  $2 =$  medianos,  $3 =$  de lujo)  
 $t = 1, 2, \dots, 60$

## 5.2.2 PRECIO DE LOS AUTOMOVILES (X2).

Definir el precio de los automoviles constituyo uno de los problemas mas serios al especificar nuestro modelo, porque no contamos con la informacion requerida.

La informacion que disponiamos era el volumen de produccion y el costo total de la produccion segun la S.P.P., y tambien con el indice de precios al consumidor para los automoviles en general proporcionado por el Banco de Mexico.

Por otra parte la necesidad de involucrar los bienes sustitutos hacia necesario incluir no solo el precio de los automoviles en cuestion (el precio de los automoviles tipo  $i$  explicando la venta de automoviles del mismo tipo), sino tambien el precio de los otros autos (en (5.1.1) la variable  $X7$ ).

Varias soluciones fueron estudiadas:

### 1) Costos unitarios.

Podriamos utilizar la variable "costo unitario" (costo unitario = costo total / volumen de produccion) como una aproximacion del precio real, bajo la hipotesis de que la diferencia entre ambos seria una constante.

El modelo involucraria tres variables correspondientes al costo unitario de cada categoria, y se incluirian las tres para cumplir con el requisito de los bienes sustitutos. Sin embargo, al tener la misma tendencia, podria ocasionar multicolinealidad.

### 2) Indice de precios por categoria.

Teniamos el indice de precios de automoviles en general, pero no para cada categoria. Por otro lado teniamos el costo unitario de cada categoria. Mediante un metodo estadistico conocido por el "Metodo de Ginsburgh"<sup>4</sup>, pudimos "desagregar" el indice de precios general en un indice de precios para cada categoria, asociando sus comportamientos al de las variables de costo unitario.

Nota 4) Sobre el Metodo de Ginsburgh puede consultarse "A further note on the derivation of quarterly figures consistent with annual data", Ginsburgh V.A., 1973 (J.R.S.B., 368-378)

Este metodo tenia el grave inconveniente de que, al ser indice de precios, las tres variables de indices generadas para cada categoria, aunque distintas, eran muy semejantes y no reflejaban las diferencias de precios entre las categorias. Por tanto no seria util para comparar precios, y usar las tres para incluir bienes sustitutos crearia un problema grande de multicolinealidad por tener la misma tendencia.

### 3) Proporción de precios.

Teniendo el costo unitario de cada categoria, podemos establecer una variable que mida la proporción del costo de cada categoria. De acuerdo a la hipótesis mencionada de que la diferencia entre el costo y el precio es una constante, entonces la proporción en costos sera igual a la proporción en precio.

Así, pues, decimos:

$$\text{Proporción de precio tipo } i = \frac{\text{costo unitario tipo } i}{\text{SUM costo unitario tipo } j} \times 100.0$$

Esta sola variable representa el peso que tiene el precio de los autos del tipo  $i$  con respecto al precio de otros autos, por lo que en esta opción no necesitamos involucrar las otras variables (en concreto ya no se necesita la variable  $X_7$ ) como bienes sustitutos, evitando así el problema de multicolinealidad ocasionado por los otros metodos, y especialmente por el segundo.

Optamos, por fin, por el tercer metodo, y definimos: (5.2.2)

$X_{2,t}$  = proporción de precio de los automoviles tipo  $i$  en el mes  $t$

donde

$X_{2,t}$  esta en porcentaje

$i = 1, 2, 3$  (como definimos en 5.2.1)

$t = 1, 2, \dots, 60$

### 5.2.3 CONSUMO DE GASOLINA (X3).

Con el precio de la gasolina en terminos nominales obtenidos de PEMEX y el consumo promedio de gasolina de cada categoria, segun fuentes de las compañías Chrysler y Ford, obtuvimos una medida del consumo nominal en pesos:

$$\text{Consumo nominal categoria } i = \frac{\text{Precio de la gasolina}}{\text{Rendimiento en kas./litro cat. } i}$$

donde el rendimiento de cada categoria en promedio es:

Autos compactos ----> 9 kms/litro  
 Autos medianos ----> 7 kms/litro  
 Autos de lujo ----> 5 kms/litro

Falta ponerlo ahora en terminos reales, lo que hacemos dividiendo entre el deflactor:

$$\text{Consumo real categoria } i = \frac{\text{Precio de la gasolina} \times 100.0}{\text{Rendimiento cat. } i \times \text{Deflactor}}$$

Por tanto, definimos nuestra tercera variable de esta manera: (5.2.3)

$X_{3,t}$  = consumo real de gasolina para los autos tipo  $i$  en el mes  $t$

donde

$X_{3,t}$  esta en pesos

$i = 1, 2, 3$  (como definimos en 5.2.1)

$t = 1, 2, \dots, 60$

#### 5.2.4 INGRESO (X4).

Como una medida del ingreso real, decidimos usar el Producto Interno Bruto Real (PIBR). Sin embargo aqui tambien contabamos con la informacion anual del PIBR proporcionada por el Banco de Mexico y fue necesario "desagregarla" mensualmente por el ya mencionado Metodo de Ginsburgh, asociandola al comportamiento del indice de volumen del sector industrial que el Banco de Mexico si publica mensualmente.

Ademas el PIBR estaba en base 1978, por lo que fue necesaria una sencilla transformacion para ponerla en base 1980 y lograr asi la uniformidad de bases con las otras variables. La transformacion consistio en dividir cada termino del PIBR entre el promedio del PIBR de 1978, es decir,

$$\text{PIBR base 1980} = \frac{\text{PIBR base 1978}}{43,358.8917} \times 100.0$$

Finalmente, definimos:

(5.2.4)

$X_{4,t}$  = ingreso real en el mes  $t$ , igual para toda  $i$

donde

$X_{4,t}$  esta en miles de millones de pesos

$i = 1, 2, 3$

$t = 1, 2, \dots, 60$

5.2.5 PRECIO DEL TRANSPORTE (X5).

El precio del transporte, como bien sustituto, fue obtenido a partir del índice de precios al consumidor, base 1960, de acuerdo al Banco de México. Como podemos observar, las variables hasta ahora definidas (ventas, precio, consumo e ingreso) están en términos reales, por lo que nos interesa trabajar con la variación de los índices del transporte para conocer también el impacto real de los precios del transporte, por lo que redefinimos nuestra variable sacando sus diferencias, es decir,

$$\text{Variación} = \frac{\text{Índice del transporte en el mes } t}{\text{Índice del transporte en el mes } t-1}$$

Por tanto, la quinta variable se define así: (5.2.5)

$X5_{it}$  = variación en el índice de precios al consumidor del transporte en México

donde

$i = 1, 2, 3$  y es igual para toda  $i$   
 $t = 1, 2, \dots, 60$

5.2.6 TASA DE INTERÉS ACTIVA (X6).

Considerando el dinero como un bien sustituto, tomamos como el costo del mismo la tasa de interés, y utilizamos la conocida como el "Costo Porcentual Promedio" (C.P.P.) que es la tasa activa que publica mensualmente el Banco de México.

Al encontrar esta variable en términos nominales, fue necesario ponerla en términos reales, transformándola esta vez por la siguiente fórmula:

$$\text{C.P.P. Real } (t) = \frac{\frac{\text{C.P.P. Nominal } (t)}{12} - \text{Inflación } (t)}{1.0 + \text{Inflación } (t)}$$

Definimos, entonces, nuestra última variable de esta manera: (5.2.6)

$X6_{it}$  = C.P.P. Real para el auto tipo  $i$  en el mes  $t$

donde

$i = 1, 2, 3$  y es igual para toda  $i$   
 $t = 1, 2, \dots, 60$

Finalmente, podemos escribir, de una manera mas explicita, nuestro modelo:

$$Y_{it} = B_0 + B_1 X_{1it} + B_2 X_{2it} + B_3 X_{3it} + B_4 X_{4it} + B_5 X_{5it} + B_6 X_{6it} + e_{it}$$

donde

$$i = 1, 2, 3$$

$$t = 1, 2, \dots, 60$$

$e_{it}$  es el termino de error para la categoria  $i$  y el mes  $t$

### 5.3 ESTIMACIONES.

Todas las estimaciones realizadas en este capitulo fueron hechas con el paquete computacional de metodos econométricos conocido como "SHAZAM" (Cfr. Bibliografía), utilizando una computadora VAX/1100 que generosamente presto el centro de "Estudios Economicos BANAMEX". En el apendice B aparecen los programas utilizados con este paquete, así como los programas en FORTRAN que generaron las tablas de información y los programas tambien en FORTRAN que generan las matrices de transformación definidas en las secciones 4.2.2 y 4.3.2 .

#### 5.3.1 EL PROBLEMA DE LA MULTICOLINEALIDAD.

Al comenzar las estimaciones de nuestro modelo es logico pensar en la presencia de autocorrelación y heterocedasticidad por las razones ya conocidas. Pero cabe preguntarnos tambien si existe el problema de multicolinealidad, es decir, si existe una alta correlación entre nuestras variables independientes. Lo primero que haremos sera discutir este asunto.

Para detectar multicolinealidad (y de hecho tambien para corregirla) existe el metodo de "Componentes Principales"<sup>5</sup> que consiste en reducir la matriz de correlación (la matriz formada por la correlación entre las  $K-1$  variables independientes) a una matriz de rango menor a través de un proceso que elimina tantas variables cuantas estén en dependencia de las otras.

NOTA 5) Para una explicación mas detallada sobre el metodo de "Componentes Principales" puede consultarse como referencia el texto de J. Johnston, "Econometric Methods", pp. 321-331.

Dentro del proceso se involucran las raices caracteristicas de la matriz de correlacion. Como vimos en el capitulo 2, si hay dependencia lineal cuando menos un valor caracteristico sera cero, mientras que si hay independencia perfecta las raices caracteristicas seran todas iguales a uno (recordar que la matriz de correlacion es una matriz positiva definida), de manera que analizando dichos valores podremos saber si existe o no multicolinealidad. La cuestion esta en determinar que tan cercanos a cero deben ser las raices caracteristicas para aceptar la multicolinealidad, pero aqui la experiencia determina el criterio.

Asi, pues, aplicamos el metodo de Componentes Principales a las matrices de correlacion correspondientes a las tres categorias de automoviles, y obtuvimos los siguientes resultados:

1) Autos compactos:

Raices caracteristicas	1.9003	1.5881	0.95738	0.35636	0.19783
Porcentaje acumulado	0.38007	0.69769	0.88916	0.96043	1.00000

2) Autos medianos:

Raices caracteristicas	2.0267	1.6623	0.71151	0.40018	0.19937
Porcentaje acumulado	0.4053	0.73779	0.88009	0.96013	1.00000

3) Autos de lujo:

Raices caracteristicas	1.6620	1.2049	0.99766	0.78589	0.34948
Porcentaje acumulado	0.33241	0.57339	0.77293	0.93010	1.00000

De acuerdo a estos resultados, se admite la existencia de una cierta dependencia en las variables explicatorias de nuestro modelo.

### 5.3.2 REGRESIONES CONJUNTA Y POR CATEGORIAS.

Pasando ya a las regresiones del modelo, la primera que debemos hacer sera la regresion del modelo conjunto, es decir, aquella que supone los coeficientes constantes y la NO existencia de autocorrelacion y heterocedasticidad. Segun (4.1.3), obtendriamos por M.C.O.

$$b = (X' X)^{-1} X' Y$$

donde X es la matriz que resulta de considerar la informacion de las tres categorias como una sola matriz de informacion.

Los resultados de esta primera regresion son los siguientes:

REGRESION CONJUNTA:

- 1) R-cuadrada = 0.6626
- 2) Prueba F = 67.95 con (5,173) grados de libertad
- 3) Analisis de varianzas:

VARIABLE	COEFICIENTE ESTIMADO	DESVIACION ESTANDAR	PRUEBA t
PORC. PRECIO	-259.48	30.397	-8.5362
CONSUMO	-7933.80	1067.300	-7.4333
TRANSPORTE	936.88	2098.200	0.4465
INGRESO	92.66	39.215	2.3628
C.P.P.REAL	-1879.00	897.690	-2.0931
INTERSECCION	9910.80	4668.400	2.1229

- 4) Suma de los cuadrados de los residuales = 0.13490 E+10
- 5) Durbin-Watson = 0.6658 lo cual deja ver claramente la existencia de autocorrelacion.

El siguiente paso fue correr la regresion para cada una de las tres categorias por separado, usando el mismo estimador. Los resultados son los siguientes:

REGRESION INDIVIDUAL PARA AUTOS COMPACTOS:

- 1) R-cuadrada = 0.4762
- 2) Prueba F = 9.637 con (5,53) grados de libertad
- 3) Analisis de varianzas:

VARIABLE	COEFICIENTE ESTIMADO	DESVIACION ESTANDAR	PRUEBA t
PORC. PRECIO	-173.88	127.730	-1.3614
CONSUMO	-11474.00	2497.300	-4.5944
TRANSPORTE	-772.22	9252.600	-0.0833
INGRESO	135.31	59.603	2.2702
C.P.P.REAL	-5131.10	1529.700	-3.3543
INTERSECCION	8362.40	12503.000	0.6688

- 4) Suma de los cuadrados de los residuales = 0.25993 E+9
- 5) Durbin-Watson = 2.0244

REGRESION INDIVIDUAL PARA AUTOS MEDIANOS:

- 1) R-cuadrada = 0.7111  
 2) Prueba F = 29.549 con (5,53) grados de libertad  
 3) Analisis de varianzas:

<u>VARIABLE</u>	<u>COEFICIENTE ESTIMADO</u>	<u>DESVIACION ESTANDAR</u>	<u>PRUEBA t</u>
PORC. PRECIO	-16.15	53.839	-0.2841
CONSUMO	-11325.00	1268.500	-8.9280
TRANSPORTE	-2079.90	5881.500	-0.3536
INGRESO	110.43	39.018	2.8302
C.P.P.REAL	-1522.80	994.240	-1.5317
INTERSECCION	3676.70	7790.100	0.4720

- 4) Suma de los cuadrados de los residuales = 0.11112 E+9  
 5) Durbin-Watson = 1.3815

REGRESION INDIVIDUAL PARA AUTOS DE LUJO:

- 1) R-cuadrada = 0.2632  
 2) Prueba F = 5.572 con (5,53) grados de libertad  
 3) Analisis de varianzas:

<u>VARIABLE</u>	<u>COEFICIENTE ESTIMADO</u>	<u>DESVIACION ESTANDAR</u>	<u>PRUEBA t</u>
PORC. PRECIO	16.69	25.373	0.6577
CONSUMO	-1847.90	375.120	-4.9262
TRANSPORTE	1051.00	3712.100	0.2831
INGRESO	-9395.20	4709.800	-1.9948
C.P.P.REAL	540.03	638.850	0.1094
INTERSECCION	2738.60	3794.500	0.7217

- 4) Suma de los cuadrados de los residuales = 0.50961 E+8  
 5) Durbin-Watson = 1.6084

### 5.3.3 COEFICIENTES CONSTANTES (COCO).

En los resultados anteriores, podemos ver claramente la presencia de autocorrelación tanto en el modelo conjunto como en las estimaciones individuales para las categorías de autos medianos y de lujo. Por tanto se antoja lógico proceder a analizar el modelo conjunto (que sostiene que los coeficientes son constantes) bajo el supuesto de autocorrelación en los errores, que es justamente el modelo COCO que estudiamos en la sección 4.1 Utilizando el estimador (4.1.5), obtuvimos:

1) R-cuadrada = 0.8293 , que es una notable mejoría.

2) Los coeficientes de autocorrelación de las tres categorías son:

$$P_1 = 0.06 \qquad P_2 = 0.98 \qquad P_3 = 0.66$$

3) Sus pruebas t de significancia correspondientes son:

$$t_1 = 0.4577 \qquad t_2 = 37.82 \qquad t_3 = 6.74802$$

4) Analisis de varianzas:

<u>VARIABLE</u>	<u>COEFICIENTE</u> <u>ESTIMADO</u>	<u>DESVIACION</u> <u>ESTANDAR</u>	<u>PRUEBA</u> <u>t</u>
PORC. PRECIO	-32.65	40.831	-0.7996
CONSUMO	-5379.00	1505.700	-3.5723
TRANSPORTE	517.23	1246.500	0.4149
INGRESO	142.58	37.853	3.7670
C.P.P.REAL	-1441.20	784.870	-1.8363
INTERSECCION	-4418.80	4375.000	-1.0100

5) Suma de los cuadrados de los residuales = 0.66350 E+9

Estos resultados nos muestran la presencia real de autocorrelación para los autos medianos y los de lujo, pero no en los compactos. También se reduce mucho la suma de cuadrados de los residuales lo cual favorece la siguiente prueba.

#### PRUEBA DE HIPOTESIS.

De acuerdo con el estadístico (4.1.7), podemos probar que esta estimación del modelo COCO es mejor que la del modelo conjunto inicial. Bajo la hipótesis nula de que el modelo conjunto inicial es el indicado, estimamos:

$$F = \frac{(0.13490 E+10 - 0.66350 E+9) / (3 + 3(4)/2)}{0.66350 E+9 / (180 - 6 - 3 - 3(4)/2)} = 18.94$$

y el valor critico de F con (9,165) grados de libertad es 2.56 .

Como resulta altamente significativa, rechazamos la hipotesis nula y aceptamos la alternativa que nos indica que el modelo COCO resulta mas adecuado.

Es importante hacer notar algunas diferencias sobre los dos modelos aqui comparados. En primer lugar la  $R^2$  en el modelo COCO es mayor lo que nos dice que explica en mayor proporcion la varianza de la variable dependiente. En segundo lugar notamos el cambio en los coeficientes, pero sobre todo en la significancia de los mismos (de acuerdo con la prueba t); asi la variable "porcentaje del precio" deja de ser significativa y la "tasa de interes" es ahora apenas significativa; el termino de interseccion cambia de signo y deja de ser significativo. Sin embargo el resto de las variables conserva su significancia y sus signos son los esperados, aunque de ello hablaremos mas tarde, en las conclusiones.

#### 5.3.4 MODELOS DE INTERSECCION VARIABLE.

Nos debemos preguntar ahora si los modelos de interseccion variable estudiados en las secciones 4.2 y 4.3 pueden ser los adecuados, es decir, si pueden aun mejorar la estimacion del modelo COCO.

Observando los resultados de las regresiones individuales, vemos que efectivamente los terminos de interseccion varian, pero tambien lo hacen los coeficientes de las variables independientes. Mas aun, si nos fijamos bien, el coeficiente del ingreso (y por tanto su prueba t) es positivo para los autos compactos y medianos, pero casualmente es negativo para los autos de lujo.

Por otra parte debemos reconocer, independientemente de lo anterior, que las pruebas t para los terminos de interseccion en las tres categorias es sumamente baja (<0.73) por lo que en ningun caso resulta significativo, a diferencia del primer modelo conjunto ya estudiado.

Todo ello nos lleva a pensar que la diferencia entre las categorias no se puede explicar sencillamente por la variacion en sus intersecciones, sino mas bien en el cambio de sus pendientes. Por tanto no resultaran convenientes las estimaciones de este tipo de modelos (MOCER y MOVAR respecto a las categorias y/o respecto al tiempo).

Estudiaremos, entonces, la estimacion de los modelos que explican la diferencia entre los individuos (en este caso entre las categorias) en la variacion de sus pendientes.

### 5.3.5 MODELOS DE PENDIENTE VARIABLE.

De acuerdo a la seccion 4.4, un primer modelo de pendiente variable es MORAN (SUR en los textos de habla inglesa) que establece una estructura de correlacion de los errores entre los distintos individuos y su estimacion por el metodo de Minimos Cuadrados Generalizados, donde la matriz de covarianza (S) es calculada a partir de los vectores de error resultantes al aplicar M.C.O. a cada individuo por categoria.

El programa de computacion "SHAZAM" posee un comando que ejecuta precisamente este modelo, y la matriz de covarianza la calcula iterativamente con el mismo modelo. La instruccion clave que nos permite esta estimacion es "SYSTEM i" donde i es el numero de individuos; en nuestro caso  $i=3$  categorias.

Al ejecutar este programa, obtuvimos los siguientes resultados:

1)  $R^2$  del sistema = 0.8354

2) Analisis de varianzas:

<u>VARIABLE</u>	<u>COEFICIENTE ESTIMADO</u>	<u>DESVIACION ESTANDAR</u>	<u>PRUEBA t</u>
PORC.PR.COMP.	-165.59	120.340	-1.3761
CONSUMO COMP.	-11519.00	2363.000	-4.8745
TRANSPORTE	-606.76	8765.800	-0.0692
INGRESO	135.72	56.342	2.4088
C.P.P.REAL	-5112.80	1449.500	-3.5274
INTERSECCION	7960.30	11827.000	0.6730
PORC.PR.MEDIAN.	-25.73	53.006	-0.4854
CONSUMO MEDIAN.	-11394.00	1176.800	-9.6822
TRANSPORTE	-1971.00	5568.400	-0.3539
INGRESO	111.53	35.664	3.1273
C.P.P.REAL	-1559.20	941.360	-1.6563
INTERSECCION	3783.20	7278.700	0.5197
PORC.PR.DE LUJO	17.20	25.374	0.6777
CONSUMO DE LUJO	-1845.80	374.940	-4.9229
TRANSPORTE	1012.20	3711.200	0.2727
INGRESO	-88.57	43.338	-2.0438
C.P.P.REAL	560.63	639.230	0.8770
INTERSECCION	2755.20	3793.900	0.7262

- 3) Numero de iteraciones necesarias = 5 en el calculo de S.  
 4) La matriz de covarianza entre los errores es la siguiente:

$$S = \begin{array}{ccc} 4,406\ 000 & & \\ 331\ 480 & 1,188\ 440 & \\ 180\ 140 & 430\ 000 & 863\ 600 \end{array}$$

$$\text{Det } S = 0.62509 \text{ E+19}$$

- 5) Suma de cuadrados de los residuales = 0.402092 E+9

Si comparamos estos resultados con los obtenidos en las regresiones individuales para cada categoria vemos que casi no hay mucha diferencia y podemos pensar, a priori, que el considerar la existencia de correlacion entre los errores no aporta significativamente mejores resultados. Sin embargo esto deberemos probarlo.

Por otra parte tambien deberemos probar si el presente modelo es mejor que el modelo COCO, es decir, si aceptamos la hipotesis de que los coeficientes de la pendiente varian con los individuos en lugar de ser constantes.

Ambas cosas haremos a continuacion.

### PRUEBAS DE HIPOTESIS.

Primero probaremos la hipotesis nula de que los coeficientes son constantes (es decir, que el modelo COCO es el adecuado) contra la hipotesis alternativa de que son variables (y por tanto MORAN sera mejor). Para comparar ambos modelos, usaremos el estadistico 4.4.B:

$$F = \frac{(0.6635 \text{ E+9} - 0.402092 \text{ E+9}) / (18 - 6 - 3)}{(0.402092 \text{ E+9}) / (180 - 18 - 6)} = 11.26$$

que igualmente resulta muy significativa para una F con (9,156) grados de libertad, lo que nos lleva a optar por la hipotesis alternativa de que los coeficientes varian en las categorias.

Para probar si la aportacion del modelo MORAN es significativa con respecto a las estimaciones individuales iniciales, usaremos el estadistico equivalente, donde ahora los residuales restringidos seran la suma de los residuales individuales y sus grados de libertad seran (NT-NK) por tener NT observaciones y NK parametros a estimar. Por tanto los grados de libertad del numerador seran la resta de estos grados de libertad y los del MORAN, resultando  $(N(N+1)/2)$  grados de libertad. Asi pues,

$$F = \frac{(0.42201 E+9 - 0.402092 E+9) / (3(4)/2)}{(0.402092 E+9) / (180 - 18 - 6)} = 1.28$$

El valor crítico para  $F(6,156)$  con 5 % de nivel de significancia es, aproximadamente, 2.18 por lo que nuestro estadístico es muy bajo y se acepta la hipótesis de que el modelo de estimaciones individuales es el adecuado.

Las pruebas anteriores nos indican que se trata, efectivamente, de un modelo donde los coeficientes de la pendiente varían con las categorías, pero que la correlación existente entre los errores de diversas categorías no aporta eficiencia significativamente.

Como dijimos en la sección 4.4.1, la estimación por MORAN generalmente es mejor que otros estimadores, excepto cuando no existe correlación alguna entre los individuos, o cuando la matriz de información ( $X_i$ ) es la misma para todos los individuos; en ambos casos la estimación por MORAN será exactamente igual a la estimación por M.C.O. de cada individuo por separado.

En nuestro caso podemos ver en la matriz de covarianza (S) que la covarianza entre los errores sí es distinta de cero. Sin embargo las matrices de información de cada categoría son casi iguales, ya que tienen en común tres variables (precio del transporte, ingreso y tasa de interés), y solo difieren en las dos primeras variables (porcentaje de los precios y consumo de gasolina); además estas dos variables tienen una misma tendencia entre las diferentes categorías.

Todo esto nos hace pensar que nuestro modelo es un ejemplo del segundo caso que Zellner menciona, es decir, de regresiones efectivamente no relacionadas.

Podemos concluir que la mejor estimación para nuestro modelo es la estimación individual de cada categoría. Pero cabe hacer un último análisis para saber cuál de las estimaciones individuales posibles es la mejor.

### 5.3.6 ESTIMACION INDIVIDUAL.

De acuerdo con los resultados obtenidos en la sección 5.3.2 de regresiones por categorías, y como lo expresamos ya al analizar el modelo COCO, la existencia de autocorrelación en los errores para los autos medianos y de lujo es manifiesta, pero no en los compactos (la prueba de Durbin-Watson = 2.0244 lo comprueba).

Vimos conveniente por ello analizar el modelo con la estructura de autocorrelación en los errores pero sujeto a la restricción de que los coeficientes son constantes. Sabiendo ahora que esta restricción no es la conveniente, es necesario ver si logramos una mejor estimación

individual bajo el supuesto de autocorrelacion pero ahora de manera independiente entre las categorias.

Con el fin de presentar los resultados juntos y de forma clara, repetimos los resultados de los autos compactos obtenidos por M.C.O. y despues presentamos las estimaciones bajo autocorrelacion para los autos medianos y de lujo.

REGRESION POR M.C.O. PARA AUTOS COMPACTOS

- 1) R-cuadrada = 0.4762
- 2) Prueba F = 9.637 con (5,53) grados de libertad
- 3) Analisis de varianzas:

VARIABLE	COEFICIENTE ESTIMADO	DESVIACION ESTANDAR	PRUEBA t
PORC. PRECIO	-173.88	127.730	-1.3614
CONSUMO	-11474.00	2497.300	-4.5944
TRANSPORTE	-772.22	9252.600	-0.0835
INGRESO	135.31	59.603	2.2702
C.P.P.REAL	-5131.10	1529.700	-3.3543
INTERSECCION	8362.40	12503.000	0.6688

- 4) Suma de los cuadrados de los residuales = 0.25993 E+9
- 5) Durbin-Watson = 2.0244

AUTOS MEDIANOS BAJO AUTOCORRELACION

- 1) R-cuadrada = 0.7977
- 2) Coeficiente de autocorrelacion = 0.98
- 3) Prueba t de significancia = 37.83
- 4) Analisis de varianzas:

VARIABLE	COEFICIENTE ESTIMADO	DESVIACION ESTANDAR	PRUEBA t
PORC. PRECIO	56.711	49.999	1.1342
CONSUMO	-15648.00	3624.300	-4.3175
TRANSPORTE	-322.63	2003.400	-0.1610
INGRESO	36545.00	4819.100	7.5835
C.P.P.REAL	-2374.20	896.950	-2.6470
INTERSECCION	150410.00	23042.000	-6.5275

- 5) Suma de los cuadrados de los residuales = 0.77792 E+8

AUTOS DE LUJO BAJO AUTOCORRELACION

- 1) R-cuadrada = 0.5367
- 2) Coeficiente de autocorrelacion = 0.66
- 3) Prueba t de significancia = 6.748
- 4) Analisis de varianza:

<u>VARIABLE</u>	<u>COEFICIENTE ESTIMADO</u>	<u>DESVIACION ESTANDAR</u>	<u>PRUEBA t</u>
PORC. PRECID	24.75	23.397	1.0577
CONSUMO	-1409.80	656.900	-2.1462
TRANSPORTE	-2528.90	2567.300	-0.9850
INGRESO	15.56	32.350	0.4810
C.P.P.REAL	114.74	613.320	0.1871
INTERSECCION	5752.20	2618.600	2.1967

- 5) Suma de los cuadrados de los residuales = 0.31761 E+8

La suma de cuadrados de los residuales de todo el modelo es la suma de los residuales individuales, es decir, 0.369483 E+9, y con ellos haremos la ultima prueba bajo la hipotesis nula de que las regresiones por M.C.D. individuales son las indicadas, contra la alternativa de nuestras ultimas estimaciones. El estadistico es el mismo de antes:

$$F = \frac{(0.42201 - 0.369483) / 3}{(0.369483) / 169} = 8.01$$

que es de nuevo altamente significativo para una F (3,169). Por tanto nuestras ultimas estimaciones son las mas convenientes.

#### 5.4 INTERPRETACION DE LOS RESULTADOS

Mediante las pruebas de hipotesis estudiadas, hemos concluido que el modelo de demanda de automoviles, definido como lo hemos hecho al presente, es de coeficientes variables y su mejor estimacion es la individual, considerando cada categoria como independiente y por tanto aceptando para los autos medianos y de lujo la existencia de autocorrelacion en sus errores.

Pasemos ahora a interpretar los resultados de los coeficientes de cada una de las variables para completar el estudio.

### 1) PORCENTAJE DE PRECIOS.

El signo negativo en los autos compactos revela que mientras mas suban de precio esos autos (cuando se nos respecto al precio de los otros automoviles), menor sera la demanda; el signo positivo en las otras categorias nos puede hacer pensar lo contrario o que no importa mucho a los consumidores de autos medianos y de lujo si el precio de estos autos es mayor o menor en proporcion a otros.

De cualquier manera, en las tres categorias observamos que el porcentaje de precios no es significativa (la prueba t mas alta de las tres es -1.3614). Por tanto no importara tanto la interpretacion que se de a los signos.

Al especificar el modelo, pensabamos que el precio si seria significativo (al comprar un coche es determinante su precio) y el hecho de que haya resultado no significativo puede deberse a una mala definicion de la variable, o al metodo con el cual aproximamos el precio o, en ultimo caso a que en el mercado de verdad no son determinantes los precios. Esta ultima razon puede ser perfectamente valida en un mercado como el nuestro afectado por la crisis economica, como mencionaremos mas adelante en las conclusiones.

### 2) CONSUMO DE GASOLINA.

Por el contrario, encontramos que los coeficientes de consumo de gasolina en las tres categorias son negativas y altamente significativas. Esto quiere decir, como lo esperabamos, que los compradores de autos se fijan en el consumo de gasolina del coche, sobre todo porque el precio de la misma ha subido considerablemente en los ultimos años (vease en la grafica del precio de la gasolina, en el apendice A, el aumento fuerte de su precio en estos años).

### 3) PRECIO DEL TRANSPORTE.

Al especificar el modelo, pensabamos que un comprador de autos en Mexico definitivamente no toma en cuenta el precio del transporte ya que en nuestro pais este esta altamente subsidiado (a la fecha el costo del pasaje en el Metro sigue siendo de un peso) por el gobierno, y quien considera la posibilidad de comprar un coche esta en una situacion economica muy arriba de quien solo puede recurrir al transporte publico.

Los resultados nos confirmaron lo anterior, ya que los coeficientes en los tres casos es negativo pero nada significativos (la t más grande es de -0.9850).

#### 4) INGRESO.

En todo modelo de demanda se espera que el ingreso (el dinero del que se dispone) sea positivo y significativo, es decir, que mientras mas dinero haya mas autos se pueden comprar. Esto se confirmaba en las categorias de compactos y medianos a lo largo de las diversas estimaciones, pero en el caso de los autos de lujo muchas veces el signo era negativo.

Sin embargo en la estimacion definitiva, aquella que considera la estructura de autocorrelacion en los errores para los autos medianos y de lujo, el signo del ingreso para los autos de lujo fue positivo, aunque no significativo, y positivo y significativo para los compactos y medianos.

Esto tiene una logica. A los consumidores de autos de lujo no les afecta si el ingreso nacional aumenta o disminuye (recordar que nuestro ingreso se refiere al ingreso nacional, no al ingreso individual) ya que ellos podran seguir comprando este tipo de autos cualquiera que sea la situacion economica nacional. De hecho todos podemos constatar que este tipo de personas siguen comprando autos de lujo a pesar de que el ingreso nacional disminuya. Esto no sucede con los consumidores de autos compactos y medianos, cuyo ingreso individual es un reflejo claro del ingreso nacional, y las crisis les afecta directamente.

#### 5) TASA DE INTERES.

Como en la variable anterior, aqui tambien podemos observar una diferencia entre las estimaciones para autos compactos y medianos y los de lujo. Para los primeros sus coeficientes son negativos y significativos lo que es coherente con la realidad, ya que un aumento en el C.P.P. (en el costo del dinero) les afecta, y no podran comprar facilmente un automovil (mientras mas les cueste un prestamo bancario, menos podran comprar un auto). En cambio, para los autos de lujo, el signo es positivo pero no significativo ( $t = 0.1871$ ) y se puede justificar de la misma manera como lo hicimos para el ingreso.

## CAPITULO 6

### CONCLUSION.

Como vimos en los resultados, el modelo que aplicamos es un caso en el que la información combinada de series de tiempo y corte transversal no aporta mucha eficiencia a la estimación de cada individuo por separado. También dijimos que ello se debía a la similitud de las matrices de información de cada categoría de automóviles.

Alguno podría decir que se trata de un mal ejemplo ya que no se obtuvo mayor eficiencia al combinar la información, pero no somos de esta opinión, ya que fue precisamente la aplicación de los diversos modelos de estimación lo que nos condujo a estas conclusiones; luego los modelos estudiados funcionan y el nuestro en concreto ha servido de ejemplo para demostrarlo.

Ciertamente serían deseables mejores resultados: no tener multicolinealidad, unas  $R^2$  más altas, coeficientes más significativos en variables que esperábamos lo fueran (como en el caso del precio), una mejor eficiencia al combinar la información de las diversas categorías, etc.

Esto no lo discutimos en lo absoluto, y pensamos que si los resultados no fueron mejores se debe a varias razones, entre las cuales destacamos las siguientes:

- 1) En primer lugar la estructura del mercado de automóviles en México afronta cambios continuos, como vimos cuando definimos las variables del modelo, comprometiendo la estabilidad de cualquier modelo que se quiera hacer.
- 2) El mercado de automóviles en México es sumamente irregular, con altas y bajas extremas, unas veces como consecuencia de las irregularidades en el comportamiento económico del país, pero otras sin razón alguna.
- 3) La situación política y económica apremiante que vive el país induce a la gente al consumo de bienes, sin importar mucho otros factores que en circunstancias normales afectan de manera decisiva toda relación de demanda, y así vemos que en algunos círculos de la sociedad se siguen comprando coches de gran valor a pesar de la crisis económica. Esto hace también difícil poder explicar y modelar la demanda de autos en función de unas variables.

- 4) La información fue obtenida con dificultad, teniendo que recurrir en ocasiones a métodos estadísticos que nos "aproximaban" a la realidad, pero no con una certeza absoluta (recordar el Método de Ginsburgh).
- 5) Igualmente, y de forma principal, la carencia de datos reales en los precios de los automóviles quizá sea una de las causas más importantes de su no significancia en el modelo.

Indudablemente, podemos entonces decir, nuestro modelo es susceptible de ser mejorado, y no solo lo aceptamos sino que se propone como un trabajo de investigación posterior donde se pueden alcanzar diversos objetivos:

- 1) Eliminar la presencia de multicolinealidad.
- 2) Mejorar las  $R^2$  de las estimaciones.
- 3) Obtener una información más precisa y conveniente.
- 4) Lograr una información que sí aumente la eficiencia al combinar el corte transversal y las series de tiempo, quizá cambiando la estructura del corte transversal.
- 5) Establecer comparaciones con otros modelos.
- 6) Probar la resistencia de los estimadores.

etcetera.

Finalmente, en lo personal pienso que el mayor beneficio de esta tesis es la satisfacción de haber abordado, con la profundidad que me fue posible, un tema que me gusta y que considero apenas comienzo a conocer.

Como dije en la introducción, mi primer objetivo, afianzarme en un campo de mi carrera, se ha logrado con creces, y al terminar satisfecho este trabajo puedo decir con Sócrates que mientras más he conocido, "lo único que he sabido es que no sé nada".

## APENDICE A

### TABLAS Y GRAFICAS DE LA INFORMACION

En este apendice presentamos las tablas y las graficas de los datos procesados en nuestro modelo. Para un mayor conocimiento de estos datos debe consultarse la seccion 5.2 donde definimos cada una de las variables del modelo.

La primera tabla, titulada "TABLA DE INFORMACION" presenta los datos definitivos de las variables del modelo que fueron procesados en las estimaciones.

La segunda tabla, titulada "TABLA PREVIA DE INFORMACION", muestra las variables auxiliares que sirvieron para generar las variables definitivas; esas variables son: costo unitario de los automoviles, ingreso (PIB Real) base 1978, costo porcentual promedio nominal, precio de la gasolina, deflactor y la inflacion.

En el apendice B se pueden encontrar los programas en FORTRAN que generaron ambas tablas mediante la lectura y transformacion de unos archivos fuente.

En la bibliografia se pueden consultar las fuentes precisas de donde obtuvimos todos los datos anteriores.

En cuanto a las graficas, ayudaran a visualizar el comportamiento de las variables del modelo en las diversas categorias. Estan construidas con las Tablas de informacion, usando el programa de computacion "S.A.I." del Centro de Estudios Economicos de Banamex.

Las graficas que presentamos son las siguientes:

- 1) Ventas de automoviles, por categorias.
- 2) Proporcion de precios, por categorias.
- 3) Consumo de gasolina, por categorias.
- 4) Indice de precios del transporte.
- 5) Ingreso (PIB)
- 6) Costo Porcentual Promedio
- 7) Ingreso contra ventas de automoviles, por categorias.
- 8) Costo unitario contra venta de autos, por categorias.
- 9) Consumo de gasolina contra venta de autos, por categorias.

T A B L A D E I N F O R M A C I O N .											
Y	V	V	I	N	I	C	C	C	E	I	C.P.P.
VENTAS	VENTAS	VENTAS	CO	CO	CO	CON	CON	CON	INDICE	INGRESO	REAL
COMPACTOS	MEDIAN	LUJO	STO	STO	STO	SUMOS	SUMOS	SUMOS	TRASP.	BASE 80	
			DE	DE	DE	COMPACTOS	MEDIANOS	DE			
			LUJO	LUJO	LUJO			LUJO			
1	126.27	776.88	289.3	34.31	121.14	0.0	0.0	0.0	85.00	95.72	-0.58877
2	139.19	817.25	307.3	35.44	129.25	0.0	0.0	0.0	92.19	99.19	-0.28110
3	139.19	817.25	307.3	35.44	129.25	0.0	0.0	0.0	92.19	99.19	-0.28110
4	139.19	817.25	307.3	35.44	129.25	0.0	0.0	0.0	92.19	99.19	-0.28110
5	139.19	817.25	307.3	35.44	129.25	0.0	0.0	0.0	92.19	99.19	-0.28110
6	139.19	817.25	307.3	35.44	129.25	0.0	0.0	0.0	92.19	99.19	-0.28110
7	139.19	817.25	307.3	35.44	129.25	0.0	0.0	0.0	92.19	99.19	-0.28110
8	139.19	817.25	307.3	35.44	129.25	0.0	0.0	0.0	92.19	99.19	-0.28110
9	139.19	817.25	307.3	35.44	129.25	0.0	0.0	0.0	92.19	99.19	-0.28110
10	139.19	817.25	307.3	35.44	129.25	0.0	0.0	0.0	92.19	99.19	-0.28110
11	139.19	817.25	307.3	35.44	129.25	0.0	0.0	0.0	92.19	99.19	-0.28110
12	139.19	817.25	307.3	35.44	129.25	0.0	0.0	0.0	92.19	99.19	-0.28110
13	139.19	817.25	307.3	35.44	129.25	0.0	0.0	0.0	92.19	99.19	-0.28110
14	139.19	817.25	307.3	35.44	129.25	0.0	0.0	0.0	92.19	99.19	-0.28110
15	139.19	817.25	307.3	35.44	129.25	0.0	0.0	0.0	92.19	99.19	-0.28110
16	139.19	817.25	307.3	35.44	129.25	0.0	0.0	0.0	92.19	99.19	-0.28110
17	139.19	817.25	307.3	35.44	129.25	0.0	0.0	0.0	92.19	99.19	-0.28110
18	139.19	817.25	307.3	35.44	129.25	0.0	0.0	0.0	92.19	99.19	-0.28110
19	139.19	817.25	307.3	35.44	129.25	0.0	0.0	0.0	92.19	99.19	-0.28110
20	139.19	817.25	307.3	35.44	129.25	0.0	0.0	0.0	92.19	99.19	-0.28110
21	139.19	817.25	307.3	35.44	129.25	0.0	0.0	0.0	92.19	99.19	-0.28110
22	139.19	817.25	307.3	35.44	129.25	0.0	0.0	0.0	92.19	99.19	-0.28110
23	139.19	817.25	307.3	35.44	129.25	0.0	0.0	0.0	92.19	99.19	-0.28110
24	139.19	817.25	307.3	35.44	129.25	0.0	0.0	0.0	92.19	99.19	-0.28110
25	139.19	817.25	307.3	35.44	129.25	0.0	0.0	0.0	92.19	99.19	-0.28110
26	139.19	817.25	307.3	35.44	129.25	0.0	0.0	0.0	92.19	99.19	-0.28110
27	139.19	817.25	307.3	35.44	129.25	0.0	0.0	0.0	92.19	99.19	-0.28110
28	139.19	817.25	307.3	35.44	129.25	0.0	0.0	0.0	92.19	99.19	-0.28110
29	139.19	817.25	307.3	35.44	129.25	0.0	0.0	0.0	92.19	99.19	-0.28110
30	139.19	817.25	307.3	35.44	129.25	0.0	0.0	0.0	92.19	99.19	-0.28110
31	139.19	817.25	307.3	35.44	129.25	0.0	0.0	0.0	92.19	99.19	-0.28110
32	139.19	817.25	307.3	35.44	129.25	0.0	0.0	0.0	92.19	99.19	-0.28110
33	139.19	817.25	307.3	35.44	129.25	0.0	0.0	0.0	92.19	99.19	-0.28110
34	139.19	817.25	307.3	35.44	129.25	0.0	0.0	0.0	92.19	99.19	-0.28110
35	139.19	817.25	307.3	35.44	129.25	0.0	0.0	0.0	92.19	99.19	-0.28110
36	139.19	817.25	307.3	35.44	129.25	0.0	0.0	0.0	92.19	99.19	-0.28110
37	139.19	817.25	307.3	35.44	129.25	0.0	0.0	0.0	92.19	99.19	-0.28110
38	139.19	817.25	307.3	35.44	129.25	0.0	0.0	0.0	92.19	99.19	-0.28110
39	139.19	817.25	307.3	35.44	129.25	0.0	0.0	0.0	92.19	99.19	-0.28110
40	139.19	817.25	307.3	35.44	129.25	0.0	0.0	0.0	92.19	99.19	-0.28110

NOTAS: VENTAS EN UNIDADES.  
 CONSUMO EN PESOS/AN.  
 INGRESO EN MILES DE MILLONES DE PESOS.

FUENTES: BANCO DE MEXICO  
 BARRERA  
 S.A.-A.  
 PENA

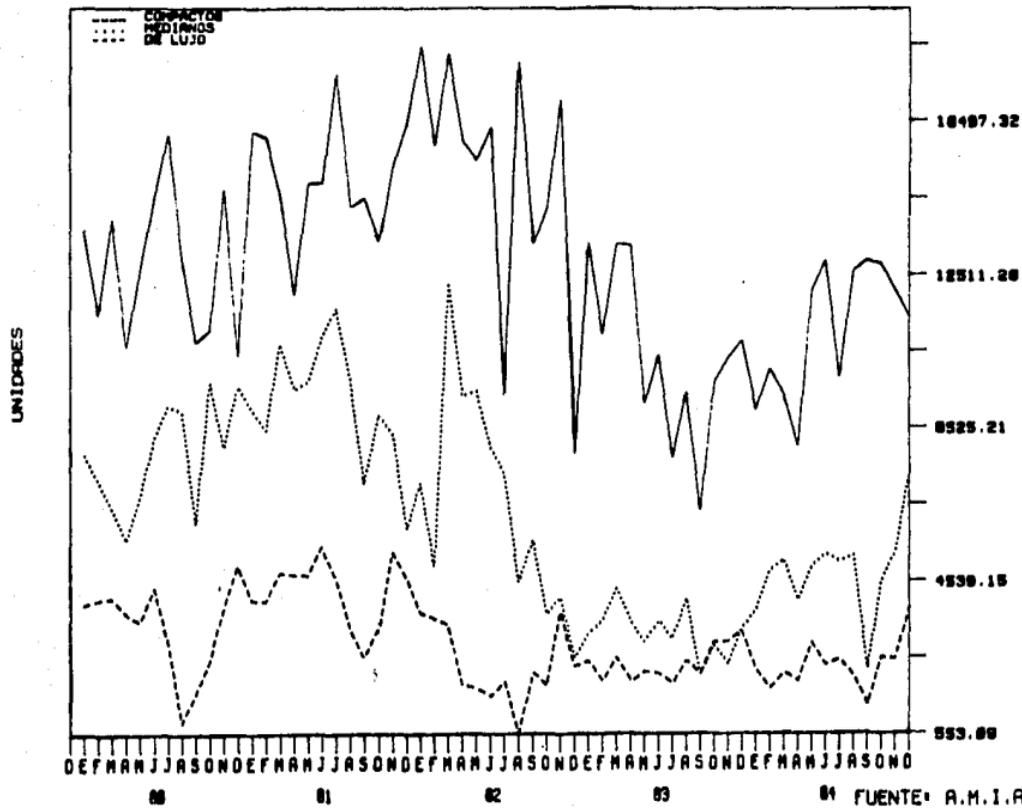
TABLA PREVIA DE INFORMACION

7	COSTO UN. CONTRACTO	COSTO UN. MEDIANOS	COSTO UN. DE LUJO	INGRESO BASE 70	C. P. P. NOMINAL	GASO- LINA	DEFLAC- ION	INFLA- CION
1	116.6271	155.0859	208.0700	43418.70	17.90	2.80	131.60	5.0152
2	117.9970	150.0227	217.4300	43619.80	18.39	2.80	132.50	5.0156
3	118.0059	154.7282	217.7900	43248.20	19.20	2.80	141.70	2.2583
4	118.0059	153.0055	218.1100	43970.80	19.81	2.80	143.90	1.7946
5	118.0059	153.0055	218.1100	43080.30	20.39	2.80	145.90	1.6846
6	118.0059	153.0055	218.1100	43970.80	20.47	2.80	150.00	2.0000
7	118.0059	153.0055	218.1100	43607.10	20.82	2.80	153.00	2.6797
8	118.0059	153.0055	218.1100	43970.80	21.20	2.80	153.00	2.0369
9	118.0059	153.0055	218.1100	43970.80	21.51	2.80	150.00	0.0000
10	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
11	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
12	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
13	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
14	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
15	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
16	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
17	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
18	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
19	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
20	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
21	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
22	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
23	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
24	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
25	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
26	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
27	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
28	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
29	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
30	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
31	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
32	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
33	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
34	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
35	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
36	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
37	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
38	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
39	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
40	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
41	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
42	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
43	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
44	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
45	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
46	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
47	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
48	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
49	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
50	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
51	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
52	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
53	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
54	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
55	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
56	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
57	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
58	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
59	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997
60	118.0059	153.0055	218.1100	43970.80	21.51	2.80	161.80	1.1997

NOTA: COSTO UNITARIO EN MILES DE PESOS  
 INGRESO EN MILES DE MILLONES DE PESOS  
 GASOLINA EN PESOS.

# VENTAS DE AUTOMOVILES

S.A.I.  
BONAMEX



- 79 -

FUENTE: A.M.I.A.

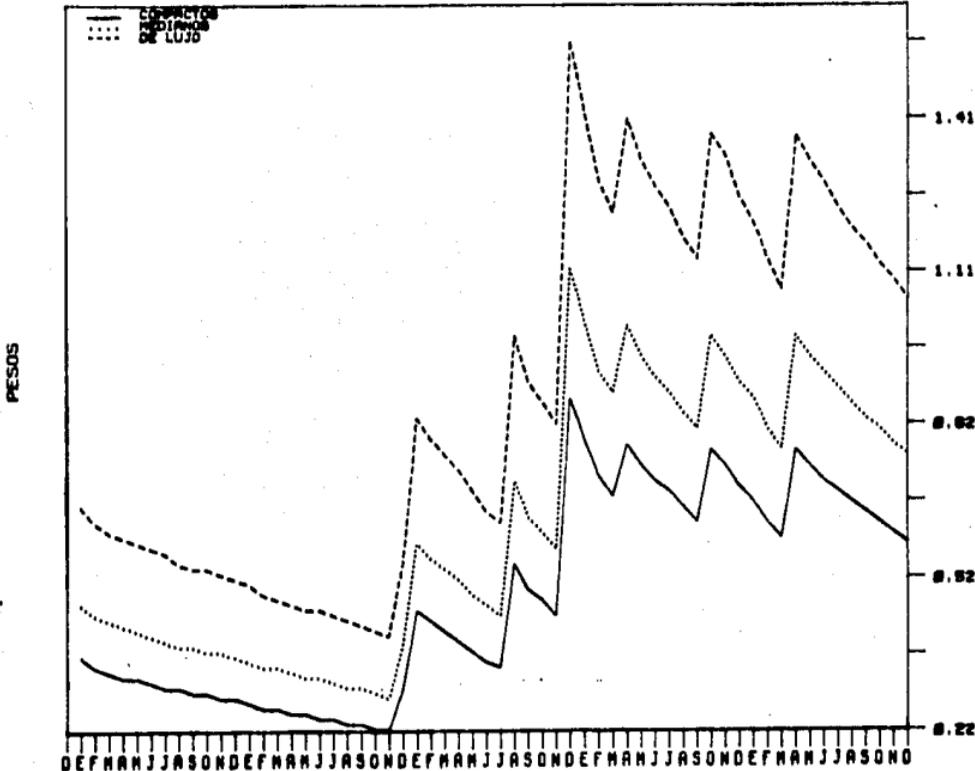
COPIA DE LA COLUMBIANA  
 1984  
 17 JULIO 1984



# CONSUMO DE GASOLINA PESOS/KM.

S.A.I.

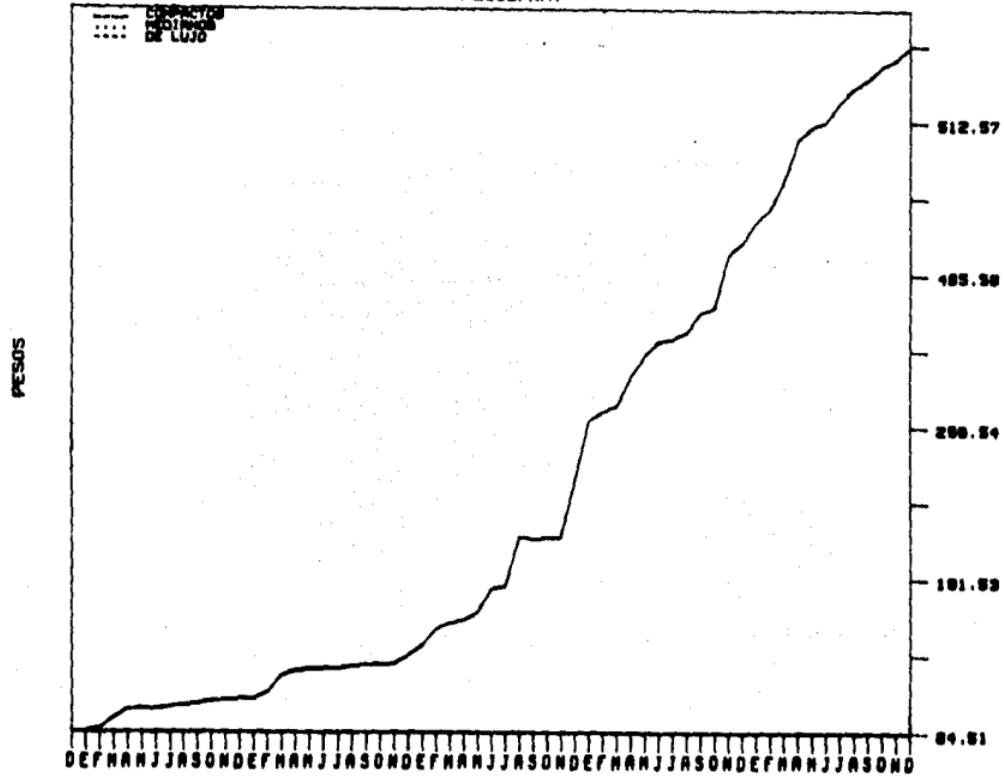
BRANEX



FUENTE: PEMEX

# INDICE DE PRECIOS DEL TRANSPORTE PESOS/KM.

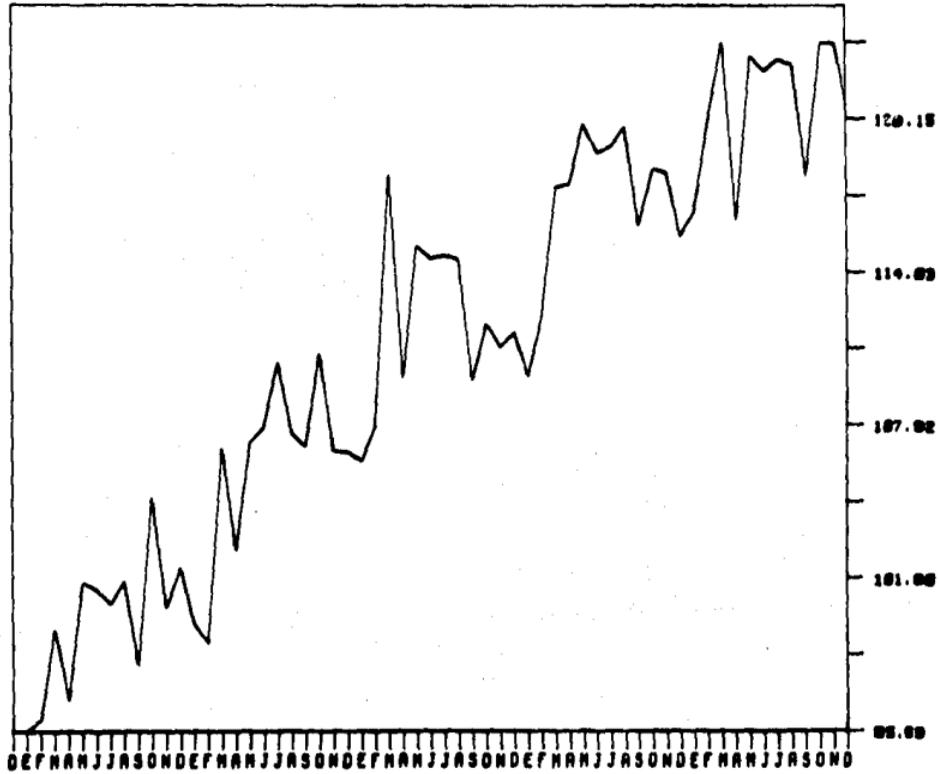
S.A.I.  
BANAMEX



# INGRESO (PIB) BASE 1960

S.A.I.  
SERIE INDEX

MILES DE MILL.

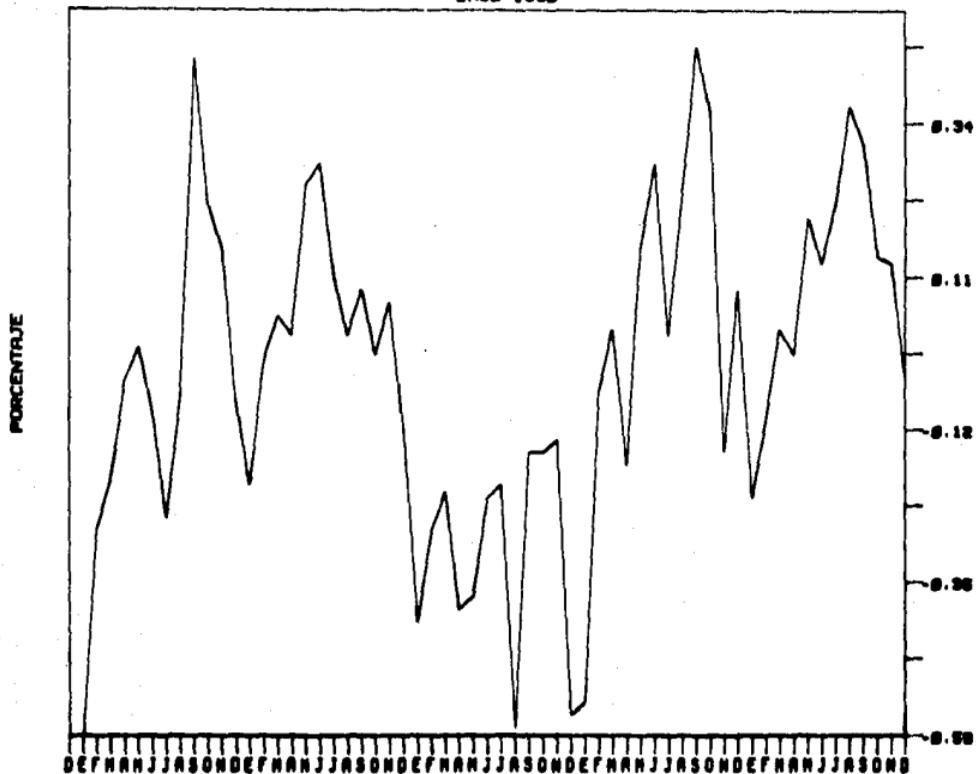


- 83 -

FUENTE: BANCO DE MEXICO

# COSTO PORCENTUAL PROMEDIO BASE 1980

S. A. I.  
BANAMEX

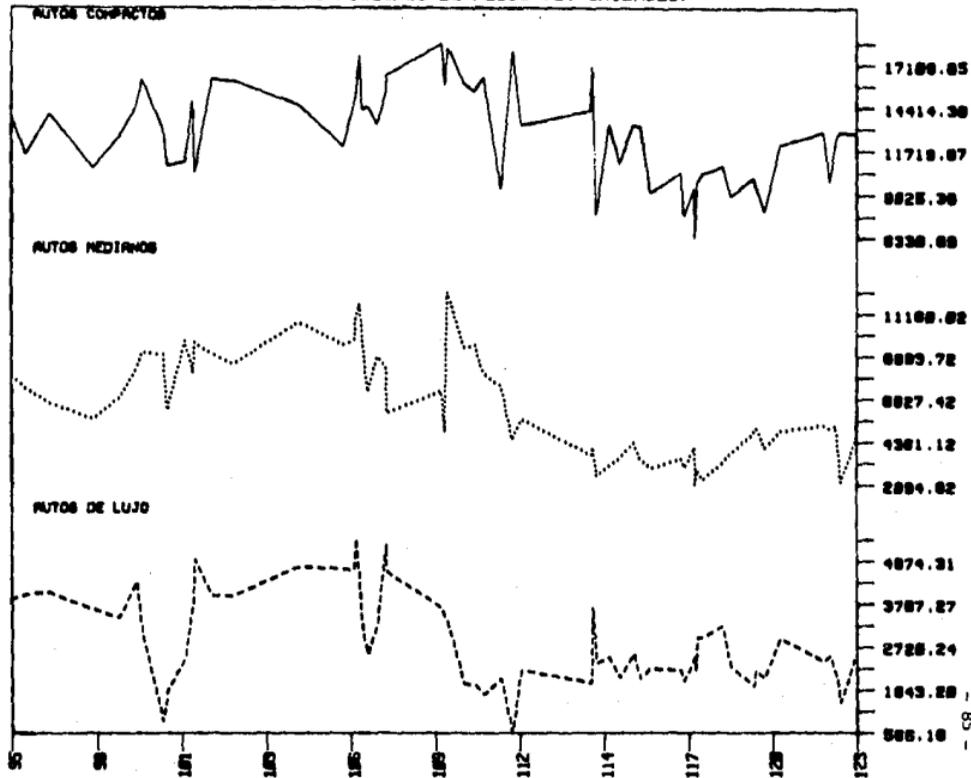


FUENTE: BANCO DE MEXICO

# INGRESO VS. VENTAS DE AUTOMOVILES

(MILES DE MILLONES DE PESOS VS. UNIDADES)

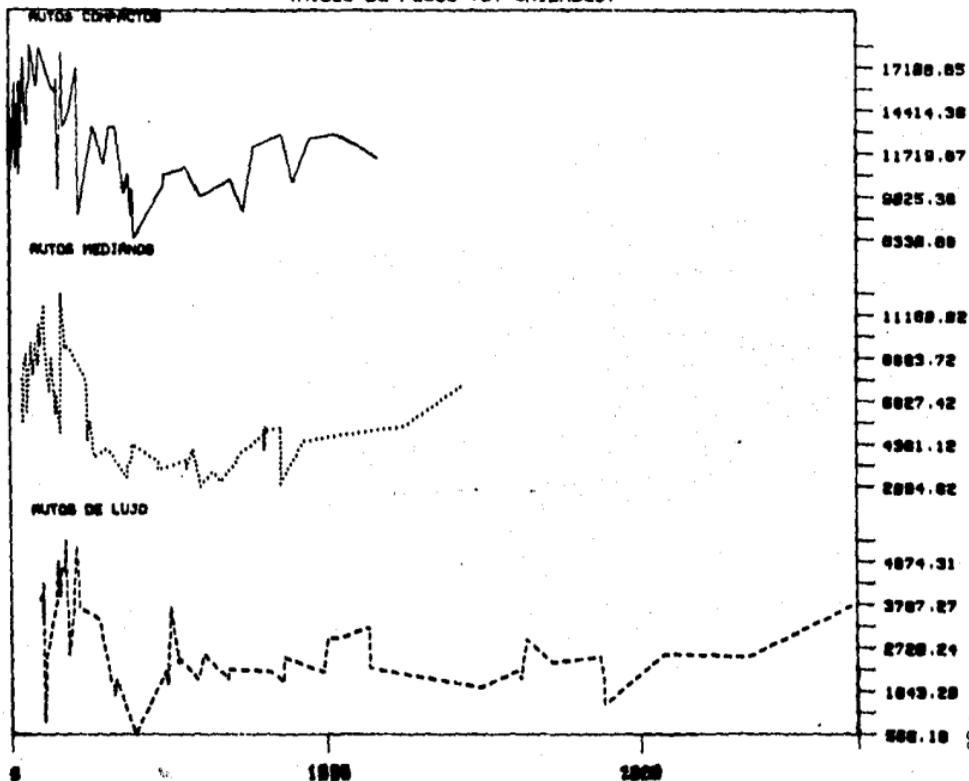
S.A.I.  
BANKEX



FUENTE: A.M.I.A. Y BANCO DE MEXICO

# COSTO VS. VENTAS DE AUTOMOVILES (MILES DE PESOS VS. UNIDADES)

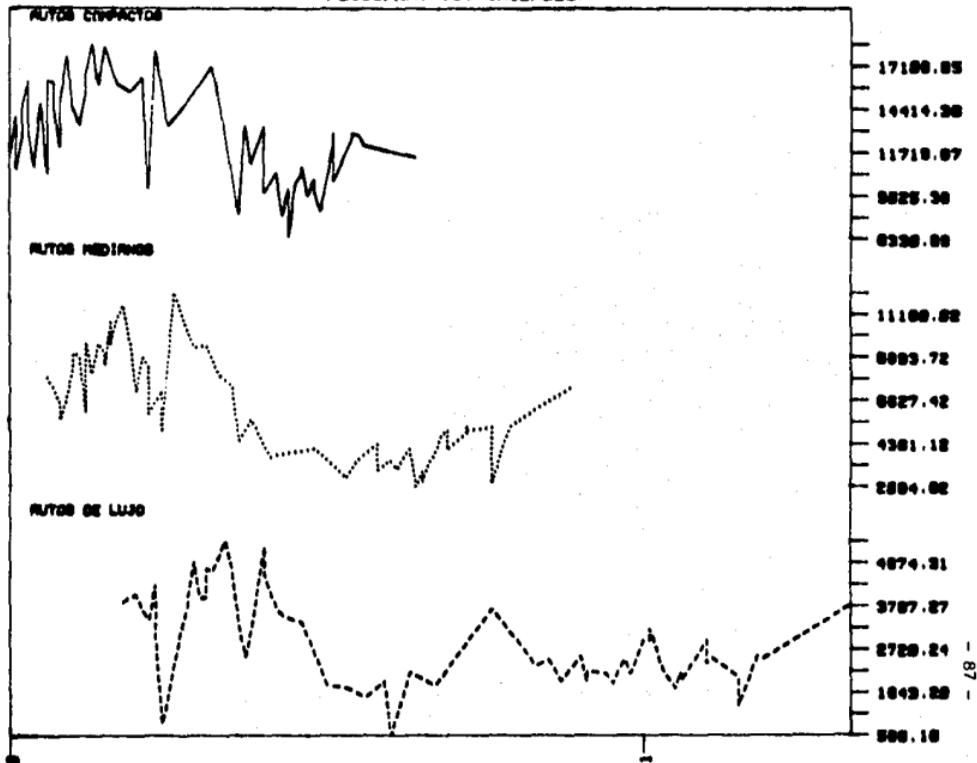
S.A.I.  
BANAMEX



FUENTE: A.M.I.A.

# CONSUMO DE GASOLINA VS. VENTAS DE AUTOS (PESOS/KH. VS. UNIDADES)

S.A.I.  
BROWNE



FUENTE: A.M.I.A. Y PEMEX

## APENDICE B

### PROGRAMAS DE COMPUTACION

En este apendice presentamos los programas de computacion que utilizamos en la elaboracion de esta tesis, tanto para la generacion de las tablas de informacion como para las estimaciones del modelo. Tambien presentamos un programa que genera las matrices de transformacion (corrigen por las medias) usadas para los modelos **NOVAR** del capitulo 4.

Todos los programas, incluyendo los de estimacion del Paquete **SHAZAM**, estan en **FORTRAN**. En los programas de **SHAZAM** simplificamos el listado poniendo "[Tabla de informacion]" en lugar de listar los datos completos, entendiendo que en ese lugar deben insertarse los datos de la tabla mencionada.

Los programas que presentamos son los siguientes:

- 1) Generacion de las tablas de informacion
- 2) Estimacion conjunta
- 3) Estimacion individual y **MORAN**
- 4) Estimacion con autocorrelacion
- 5) Matrices de transformacion
- 6) Ejemplo de matrices de transformacion ( $N=2$ ,  $T=5$ ).

### PROGRAMA 1

#### TABLAS DE INFORMACION

OBJETIVO: Lee datos de archivos fuente y genera tablas de informacion.

EJECUCION: FORTRAN.

PROGRAMA:

```
REAL*4 INF(60)
DIMENSION VENTC(60), VENTM(60), VENTL(60), TRAN(60), CPP(60), CPPR(60)
DIMENSION PORCC(60), PORCM(60), PORCL(60), SUMA(60), PIB(60), PIBR(60)
DIMENSION CONSC(60), CONSM(60), CONSL(60), BASO(60), DEF(60), DEFL(60)
DIMENSION COSTC(60), COSTM(60), COSTL(60)
OPEN (UNIT=1, FILE='COMPACTOS.', STATUS='OLD')
OPEN (UNIT=2, FILE='MEDIANOS.', STATUS='OLD')
OPEN (UNIT=3, FILE='LUJD.', STATUS='OLD')
OPEN (UNIT=4, FILE='COSTUNIT.COM', STATUS='OLD')
OPEN (UNIT=5, FILE='COSTUNIT.MED', STATUS='OLD')
OPEN (UNIT=6, FILE='COSTUNIT.LUJ', STATUS='OLD')
OPEN (UNIT=7, FILE='DEFLACION', STATUS='OLD')
OPEN (UNIT=8, FILE='PIBR.MEN', STATUS='OLD')
OPEN (UNIT=9, FILE='NOVA.', STATUS='OLD')
OPEN (UNIT=10, FILE='CPP.', STATUS='OLD')
OPEN (UNIT=11, FILE='TRANSP.', STATUS='OLD')
OPEN (UNIT=12, FILE='DEFLA.DAT', STATUS='OLD')
OPEN (UNIT=13, FILE='TABLA.INFORMACION', STATUS='NEW')
OPEN (UNIT=14, FILE='TABLA.ANEXA', STATUS='NEW')
DO I=1,60
  READ(1,8,END=25)VENTAC(I)
  READ(2,8)VENTAM(I)
  READ(3,8)VENTAL(I)
  READ(4,8)COSTOC(I) 81000.0
  READ(5,8)COSTOM(I) 81000.0
  READ(6,8)COSTOL(I) 81000.0
  READ(7,8)DEFL(I)
  READ(8,8)PIB(I)
  READ(9,8)BASO(I)
  READ(10,8)CPP(I)
  READ(11,8)TRAN(I)
  READ(12,8)INF(I)
ENDDO
25 DO I = 1,60
  SUMA(I) = COSTC(I) + COSTOM(I) + COSTOL(I)
```

```
PORCC(I) = COSTC(I)*100 / SUMA(I)
PORCM(I) = COSTM(I)*100 / SUMA(I)
PORCL(I) = COSTL(I)*100 / SUMA(I)
DEFLAC(I) = DEFL(I)*100.0 / 154.60833
PIBR(I) = PIB(I)*100.0 / 45358.8917
CPPR(I) = ((CPP(I)/12.0)-INF(I)) / (1.0 + INF(I))
CONSC(I) = GASO(I)*100.0 / (9.0*DEFLAC(I))
CONSM(I) = GASO(I)*100.0 / (9.0*DEFLAC(I))
CONSL(I) = GASO(I)*100.0 / (9.0*DEFLAC(I))
WRITE(13,18)I,VENTC(I),VENTM(I),VENTAL(I),PORCC(I),PORCM(I),
1PORCL(I),CONSC(I),CONSM(I),CONSL(I),TRAN(I),PIBR(I),CPPR(I)
WRITE(14,20) PIB(I),CPP(I),GASO(I),DEFL(I),INF(I)
ENDDO
PRINT 0, 'YA TERMINE'
18 FORMAT(1X,F3.0,3F8.1,6F10.5/9X,2F9.2,F10.5)
20 FORMAT(1X,4F9.2,F11.4)
STOP
END
```

**PROGRAMA 2**  
**ESTIMACION CONJUNTA**

**OBJETIVO:** Estimacion conjunta del modelo.

**EJECUCION:** SHAZAM

**PROGRAMA:**

SIZE 40  
SOLOMON 6 180 DEMANDA DE AUTOS POR CATEGORIAS.  
IO LS DS  
SMPL 2 180  
NAME VENTAS PORCENTAJE CONSUMO TRANSPOR INGRESO CPPR  
GENR TRANSPOR = TRANSPOR / LAG(TRANSPOR)  
DATA  
...

[ TABLA DE INFORMACION CONJUNTA ] (vease nota)

...

PC 2 3 4 5 6 / CR NC=4  
OLS 1 2 3 4 5 6 / MAX  
AUTO 1 2 3 4 5 6 / DN GS  
MERCURY

**NOTA:** La "tabla de informacion conjunta" se refiere a la matriz formada al unir las matrices de informacion de cada categoria, de forma que su dimension es de (180,5).

PROGRAMA 3

ESTIMACION INDIVIDUAL Y MORAN

OBJETIVO: Componentes principales, estimacion individual y por el MORAN.

EJECUCION: SHAZAM

PROGRAMA:

SIZE 40  
SOLOMON 13 60 DEMANDA DE AUTOS POR CATEGORIAS.  
ID LB DS  
SMPL 2 60  
NAME TIEMPO VENTAC VENTAM VENTAL PORCC PORCM PORCL  
CONSC CONSM CONSL TRANSPOR INGRESO CPPR  
GENR TRANSPOR = TRANSPOR / LAG(TRANSPOR)  
DATA (1X,F3.0,3FB.1,6F10.5/9X,2F9,2,F10.5)  
...

[ TABLA DE INFORMACION ]

...

PC PORCC CONSC TRANSPOR INGRESO CPPR / CR NC=4  
PC PORCM CONSM TRANSPOR INGRESO CPPR / CR NC=4  
PC PORCL CONSL TRANSPOR INGRESO CPPR / CR NC=4  
OLS VENTAC PORCC CONSC TRANSPOR INGRESO CPPR / MAX  
OLS VENTAM PORCM CONSM TRANSPOR INGRESO CPPR / MAX  
OLS VENTAL PORCL CONSL TRANSPOR INGRESO CPPR / MAX  
SYSTEM 3  
OLS VENTAC PORCC CONSC TRANSPOR INGRESO CPPR  
OLS VENTAM PORCM CONSM TRANSPOR INGRESO CPPR  
OLS VENTAL PORCL CONSL TRANSPOR INGRESO CPPR  
OPTIONS DN  
MERCURY

**PROGRAMA 4**  
**ESTIMACION CON AUTOCORRELACION**

**OBJETIVO:** Estimacion del modelo con estructura de autocorrelacion.

**EJECUCION:** SHAZAM

**PROGRAMA:**

SIZE 40  
SOLOMON 13 60 DEMANDA DE AUTOS POR CATEGORIAS.  
IO LB DS  
SMPL 2 60  
NAME TIEMPO VENTAC VENTAM VENTAL PORCC PORCM PORCL  
CONSC CONSM CONSL TRANSPOR INGRESO CPPR  
GENR TRANSPOR = TRANSPOR / LAG (TRANSPOR)  
DATA (1X,F3.0,3FB.1,6F10.5/9X,2F9,2,F10.5)  
...

[ TABLA DE INFORMACION ]

...

AUTO VENTAC PORCC CONSC TRANSPOR INGRESO CPPR / MAX  
AUTO VENTAM PORCM CONSM TRANSPOR INGRESO CPPR / MAX  
AUTO VENTAL PORCL CONSL TRANSPOR INGRESO CPPR / MAX  
MERCURY

### PROGRAMA 5

#### MATRICES DE TRANSFORMACION

OBJETIVO: Genera las matrices de transformacion para MOVAN.  
El programa es un ejemplo para cuando N=2 y T=5

EJECUCION: FORTRAN

PROGRAMA:

```
DIMENSION A(10,10),B(10,10),Q(10,10),Q1(10,10),Q2(10,10),Q3(10,10),  
INTEGER T
```

```
! Para otros casos, cambiar las siguientes dimensiones!
```

```
N = 2
```

```
T = 5
```

```
NT = N*T
```

```
LN = 1.0/N
```

```
UT = 1.0/T
```

```
LNT = 1.0/NT
```

```
DO I=1, NT
```

```
  DO J=1, NT
```

```
    Q1(I,J) = -LNT
```

```
    Q2(I,J) = -LNT
```

```
    Q3(I,J) = LNT
```

```
    IF (I.EQ.J) THEN
```

```
      A(I,J) = 1.0
```

```
      B(I,J) = 1.0
```

```
    ENDIF
```

```
  ENDDO
```

```
ENDDO
```

```
DO L=1, N
```

```
  DO I=(L-1)*T+1, L*T
```

```
    K = I-(L-1)*T
```

```
    DO J=(L-1)*T+1, L*T
```

```
      A(I,J) = A(I,J) - UT
```

```
      Q1(I,J) = UT - LNT
```

```
    ENDDO
```

```
  ENDDO
```

```
ENDDO
```

```
DO I=1,NT
```

```
  DO J=1,NT
```

```
    Q(I,J) = B(I,J) - Q1(I,J)
```

```
  ENDDO
```

```
ENDDO
```

```
PRINT *, 'LA MATRIZ A ES:'
```

```
PRINT 10,A
PRINT 8, 'LA MATRIZ B ES:'
PRINT 10,B
PRINT 8, 'LA MATRIZ Q ES:'
PRINT 10,Q
PRINT 8, 'LA MATRIZ Q1 ES:'
PRINT 10,Q1
PRINT 8, 'LA MATRIZ Q2 ES:'
PRINT 10,Q2
PRINT 8, 'LA MATRIZ Q3 ES:'
PRINT 10,Q3
10 FORMAT (NT(1X,F5.2)//)
STOP
END
```

## EJEMPLO DEL PROGRAMA 5

## MATRICES DE TRANSFORMACION (N=2, T=5)

OBJETIVO: Presentar los resultados obtenidos al ejecutar el programa 5.

RESULTADOS:

LA MATRIZ A ES:

0.8	-0.2	-0.2	-0.2	-0.2	0.0	0.0	0.0	0.0	0.0
-0.2	0.8	-0.2	-0.2	-0.2	0.0	0.0	0.0	0.0	0.0
-0.2	-0.2	0.8	-0.2	-0.2	0.0	0.0	0.0	0.0	0.0
-0.2	-0.2	-0.2	0.8	-0.2	0.0	0.0	0.0	0.0	0.0
-0.2	-0.2	-0.2	-0.2	0.8	0.0	0.0	0.0	0.0	0.0
0.0	0.0	0.0	0.0	0.0	0.8	-0.2	-0.2	-0.2	-0.2
0.0	0.0	0.0	0.0	0.0	-0.2	0.8	-0.2	-0.2	-0.2
0.0	0.0	0.0	0.0	0.0	0.0	-0.2	0.8	-0.2	-0.2
0.0	0.0	0.0	0.0	0.0	-0.2	-0.2	-0.2	0.8	-0.2
0.0	0.0	0.0	0.0	0.0	-0.2	-0.2	-0.2	-0.2	0.8

LA MATRIZ B ES:

0.5	0.0	0.0	0.0	0.0	0.0	-0.5	0.0	0.0	0.0
0.0	0.5	0.0	0.0	0.0	0.0	0.0	-0.5	0.0	0.0
0.0	0.0	0.5	0.0	0.0	0.0	0.0	0.0	-0.5	0.0
0.0	0.0	0.0	0.5	0.0	0.0	0.0	0.0	0.0	-0.5
0.0	0.0	0.0	0.0	0.5	0.0	0.0	0.0	0.0	0.0
-0.5	0.0	0.0	0.0	0.0	0.5	0.0	0.0	0.0	0.0
0.0	-0.5	0.0	0.0	0.0	0.0	0.5	0.0	0.0	0.0
0.0	0.0	-0.5	0.0	0.0	0.0	0.0	0.5	0.0	0.0
0.0	0.0	0.0	-0.5	0.0	0.0	0.0	0.0	0.5	0.0
0.0	0.0	0.0	0.0	-0.5	0.0	0.0	0.0	0.0	0.5

LA MATRIZ Q ES:

0.7	-0.1	-0.1	-0.1	-0.1	-0.4	0.1	0.1	0.1	0.1
-0.1	0.7	-0.1	-0.1	-0.1	0.1	-0.4	0.1	0.1	0.1
-0.1	-0.1	0.7	-0.1	-0.1	0.1	0.1	-0.4	0.1	0.1
-0.1	-0.1	-0.1	0.7	-0.1	0.1	0.1	0.1	-0.4	0.1
-0.1	-0.1	-0.1	-0.1	0.7	0.1	0.1	0.1	0.1	-0.4
-0.4	0.1	0.1	0.1	0.1	0.7	-0.1	-0.1	-0.1	-0.1
0.1	-0.4	0.1	0.1	0.1	-0.1	0.7	-0.1	-0.1	-0.1
0.1	0.1	-0.4	0.1	0.1	-0.1	-0.1	0.7	-0.1	-0.1
0.1	0.1	0.1	-0.4	0.1	-0.1	-0.1	-0.1	0.7	-0.1
0.1	0.1	0.1	0.1	-0.4	-0.1	-0.1	-0.1	-0.1	0.7



## BIBLIOGRAFIA

- DIELMAN, Terry E.  
"Pooled Cross-Sectional and Time Series Data: a survey of current statistical methodology"  
The American Statistician, Vol 37, No. 2, May, 1983,
- GRAYBILL  
"Introduction to Matrices with Applications in Statistics"  
Wadsworth Publishing Co., Inc. ,1969,
- GUENTHER, WILLIAM C.  
"Introduccion a la Inferencia Estadistica"  
Mc Graw Hill, 1968, Madrid
- HADLEY, G.  
"Linear Algebra"  
Addison Wesley ,1961,
- INTRILIGATOR, Michael D.  
"Econometric Models, Techniques & Applications"  
Prentice Hall ,1978, Englewood Cliffs, New Jersey
- JOHNSTON, J.  
"Econometric Methods", 2nd. Edition  
Mc Graw Hill ,1972, New York
- JUDGE George G., GRIFFITHS William, HILL Carter & LEE Tsoung-Chao  
"The theory and practice of Econometrics"  
John Wiley & Sons ,1980
- KMENTA, Jan  
"Elements of Econometrics"  
Macmillan, 1971, New York
- MUNDLAK, Yair  
"On the pooling of time series and cross section data"  
Econometrica, Vol. 46, No.1, January, 1978
- PINDYCK, Robert S and RUBINFELD Daniel L.  
"Econometric Models and Economic Forecasts"  
Mc Graw Hill ,1981, Singapore
- SNEDECOR, George and COCHRAN, William  
"Statistical Methods"  
Iowa State

- SOUZA, Rita  
"Algebra Lineal"  
Universidad Anahuac ,1980, Mexico D.F.
- THEIL, Henry  
"Principles of Econometrics"  
John Wiley & Sons, Inc. ,1971, New York
- WHITE, KENNETH J.  
"SHAZAM, an econometric computer program", Version 4.1  
University of British Columbia, Mayo, 1982 Vancouver, Canada

OTRAS FUENTES:

- ASOCIACION MEXICANA DE LA INDUSTRIA AUTOMOTRIZ  
"Venta mensual-anual de automoviles por categorias y marcas  
1975-1984"  
Estadisticas A.M.I.A., 1985
- BANCO DE MEXICO  
"Indice de precios al consumidor"  
Ediciones de enero de 1980 a diciembre de 1984
- BANCO NACIONAL DE MEXICO  
"Producto Interno Bruto desagregado mensualmente"  
Centro de Estudios Economicos, 1985
- BANCO NACIONAL DE MEXICO  
"Costo Porcentual Promedio"  
Centro de Estudios Economicos, 1985
- PETROLEOS MEXICANOS  
Precios al consumidor  
Enero de 1980 a diciembre de 1984
- SECRETARIA DE PROGRAMACION Y PRESUPUESTO  
"Encuesta Industrial Mensual: Volumen de la produccion de los  
principales productos manufacturados"  
Direccion General de Estadistica, Instituto Nacional de  
Estadistica, Geografia e Informatica, 1981-1985
- SECRETARIA DE PROGRAMACION Y PRESUPUESTO  
"Encuesta Industrial Mensual: Valor de la produccion de los  
principales articulos manufacturados"  
Direccion General de Estadistica, Instituto Nacional de  
Estadistica, Geografia e Informatica, 1981-1985