

UNIVERSIDAD DE PANAMA

VICERRECTORIA DE INVESTIGACIONES Y POSTGRADO

PROGRAMA DE MAESTRIA EN MATEMATICA

ESTUDIO DE LA AUTOCORRELACION DE LAS PERTURBACIONES

EN LOS MODELOS LINEALES

POR:

SAMUEL IBARRA MURILLO

Tesis presentada como uno de los requisitos para optar por el grado de
Maestro en Ciencias con Especialización en Estadística Matemática.

FM

UNIVERSIDAD DE PANAMA



VICERRECTORIA DE INVESTIGACION Y POSTGRADO

Aprobado por:

Director de Tesis

DIMAS QUIEL, M.Sc.

Miembro del Jurado

JORGE POLTRONIERI, Ph.D.

Miembro del Jurado

PLUTARCO E. RAMOS, M.Sc.

Fecha

20 de Octubre de 1986

12 ENE. 1987

Obsequio del autor

21078

"Año 1986, Centenario del Natalicio del Dr. Harmodio Arias"

CIUDAD UNIVERSITARIA OCTAVIO MENDEZ PEREIRA

ESTAFETA UNIVERSITARIA

PANAMA, R. DE P.

DEDICATORIA

Dedico este humilde trabajo a todas aquellas personas que fueron el motor y el soporte que me impulsaron a continuar por el camino del estudio hasta obtener este logro, pues, sin ellos esto no hubiese sido posible. Por esto lo dedico:

A la mujer que me brindó sus embelesos, me envolvió en sus besos y me meció en la cuna; a mi madre LOLA, que es dulzura vertida en mi amargura y en éste momento de mi vida, estrella; porque sin ella no hubiese sido posible mi existencia.

A mis amados y preciosos hijos SAMUEL, SAMUEL IVAN, SHAYANNI y a quien en estos momentos viene en camino como una nueva estrella para iluminar mas el firmamento de mi vida; a todos ellos que se constituyen en el motor que impulsa mis deseos y mis esfuerzos de superación.

Con mucho amor a mi querida y adorada esposa MAYRA, quien supo soportar con valentía y estoicismo todos los malos momentos que le ocasionó éste esfuerzo y que supo comprenderme y alentarme en todo momento.

A mis queridos compañeros de estudios AURORA, GLADYS, JOSE, RAFAEL, ARGELIA, DILCIA y CEFERINO; quienes confiaron siempre en mi y me brindaron su ayuda en los estudios.

A mis amigos y colegas JULIO ALBERTO, JOSE RAFAEL, FERNANDO, RICARDO, MANUEL y a todos aquellos que escapan de mi mente y que de alguna manera me brindaron su colaboración de manera desinteresada para que este momento se hiciera una realidad.

Y muy especialmente lo dedico a mi DIOS TODO PODEROSO, pues sin su participación y anuencia nada es posible.

AGRADECIMIENTO

A todas las personas que hicieron posible el que yo haya podido culminar ésta etapa de mi vida, deseo expresarles mi más profundo y sincero agradecimiento. Por ello quiero expresarles mi agradecimiento :

A mi profesor DIMAS QUIEL, por sus sabias enseñanzas, por su gran paciencia y sus oportunos y certeros consejos.

A mi profesor JORGE POLTRONIERI, quien no solo me brindó sus grandes conocimientos a través de sus sabias enseñanzas, sino que, también supo soportarme con infinita paciencia y quien además, se constituyó en el espejo en el cual debíamos de mirarnos.

Al Coordinador del Programa de Maestría, EGBERTO AGARD por su insistencia y preocupación en que culmináramos nuestros estudios.

Al Decano de la Facultad de Ciencias Naturales y Exactas, JUSTO MEDRANO, por todas las facilidades que nos brindó en todos los momentos de nuestros estudios, para poder estudiar con comodidad.

Al Rector de nuestra más alta casa de estudios, DR. CEFERINO SANCHEZ por todas las facilidades que nos brindó y por su confianza depositada en el programa y sus estudiantes.

A mis hermanos JULIO, VILMA, MARITZA, DAVID, FLORIDA y muy especialmente a LUCIANO quien siempre me brindó su apoyo sincero y desinteresado.

INDICE

Introducción	i
Modelo Lineal General	1
I - El Modelo Lineal General	2
II - Algunos Estimadores y sus Propiedades	3
A - Los Estimadores Mínimos Cuadráticos de β	3
1 . Propiedades del Estimador $\hat{\beta}$	3
B - Estimador de Máxima Verosimilitud de β	4
C - Estimador de la Varianza de la Perturbación	4
III - Autocorrelación de Errores	5
A - Mínimos Cuadrados Generalizados	5
B - Estimador de Máxima Verosimilitud	9
C - Implicaciones de los Estimadores Mínimos Cuadráticos Generalizados	9
D - Prueba de Hipótesis para la Autocorrelación de las Perturbaciones Seriales	12
Algunos Criterios para la Prueba de la Autocorrelación de las Perturbaciones	14
I - Criterio de Durbin - Watson	15
A - Introducción al Tratamiento Teórico	15
B - Distribución de r	33
1 - Regresión sobre Variables Aleatorias	33
2 - Regresión sobre Variables Fijas	34
C - Momentos de r	36
D - Función Característica de u y v ,	42

E - Selección del Criterio de la Prueba	46
F - Algunos Resultados Especiales	50
II Otros Criterios para Probar la Autocorrelación de los Errores.	54
A - Aproximación a una Beta	54
B - La Aproximación $d^* = a + bd_u$	55
Potencia de la Prueba de Durbin - Watson	58
Método 1	62
Método 2	68
Conclusiones	73
Bibliografía	

INTRODUCCION

El trabajo que estamos presentando como uno de los requisitos para optar por el grado de Maestro en Ciencias con Especialización en Estadística Matemática, está inspirado en uno de los problemas fundamentales que se presentan en el estudio de los Modelos Lineales Generales.

A través del tiempo, el hombre a tratado de crear modelos matemáticos que le ayuden a interpretar la realidad que lo rodea con la intención de poder predecir, inferir o probar hipótesis de sucesos en estudio. Uno de los modelos matemáticos que ha tenido mayor utilidad y aplicabilidad ha sido el Modelo Lineal, ya que, este modelo permite que el análisis de muchos de los problemas concretos que nos presenta la vida y la naturaleza sea más sencillo, además, por el hecho de que muchos de los otros tipos de modelos matemáticos se pueden transformar en modelos del tipo lineal mediante ciertas transformaciones. Sin embargo, sabemos que las observaciones de hechos reales no siempre se ajustan exactamente a un modelo lineal ya que, no siempre la relación entre las variables observadas es lineal o pudiera ser que las observaciones no se ajusten al modelo lineal debido a, errores cometidos en la medición, por errores humanos o, de otra índole.

Existen diversos métodos para ajustar una serie de datos reales a un Modelo Lineal; uno de los métodos de mayor uso para efectuar dicho ajuste es el llamado " Método de los Mínimos Cuadrados ". Para poder aplicar este método, es necesario suponer básicamente que los términos de los

errores o perturbaciones de los datos a ajustar en el modelo de regresión, son estadísticamente serialmente independientes.

En nuestro trabajo estudiaremos el Modelo Lineal General, en el cual supondremos que se cumplen algunas hipótesis con la intención de que las estimaciones obtenidas sean las mejores. Las hipótesis básicas que supondremos cumple nuestro modelo son las siguientes:

- i .) Las variables X_i son no relacionadas entre sí.
- ii .) Las Perturbaciones tienen Varianza constante.
- iii .) Las variables X_i no son valores previos de las Y_i .
- iv .) Las Perturbaciones u_i son serialmente independientes.

De las hipótesis supuestas anteriormente, el no cumplimiento de la última de ellas y se conoce como el problema de la Autocorrelación de las Perturbaciones, es lo que nos ha inspirado a efectuar este trabajo.

En el Problema de la Autocorrelación de las Perturbaciones, nuestro estudio central se ha encaminado a analizar uno de los principales criterios que se usan para probar la hipótesis de Independencia entre los Errores llamado "Criterio de Durbin-Watson", el cual fué propuesto por Durbin y Watson ([3]), ([4]) y ([5]).

Para efectuar el estudio objeto de nuestra atención hemos desarrollado el presente trabajo en tres capítulos, así:

En el Capítulo I se efectúa un estudio resumido del Modelo Lineal

General k Variante. Dentro del mismo se analizan los Estimadores de Mínimos Cuadrados y los de Máxima Verosimilitud de los parámetros desconocidos del modelo y sus principales propiedades, también se estudia el Estimador de la Varianza de las Perturbaciones, además, se presenta el concepto de lo que se conoce como Autocorrelación de los Errores y las pruebas que se pueden hacer al respecto de la misma.

En el Capítulo II se analiza en detalle el Criterio de Durbin-Watson para probar la Autocorrelación de las Perturbaciones. En el análisis se justifica la existencia del criterio, se estudia su distribución, se calculan los momentos de su numerador y denominador y además, se determina la Función Característica Conjunta del numerador y denominador del criterio. Por último, se hace un análisis de selección del criterio de la prueba para obtener una prueba que sea Uniformemente la más Potente entre las pruebas. También se revisan otros criterios para probar la Autocorrelación de los Errores en el supuesto de que el de Durbin-Watson nos conduzcan a inconclusiones.

En el Capítulo III analizamos dos métodos para la obtención de los límites de las Raíces Características de la Matriz Γ asociada a los errores, y que nos proporcionaran la Potencia de la Prueba del Estadístico de Durbin-Watson.

Por último, advertimos a los interesados en el tema que, el mismo exige del conocimiento general del Algebra Lineal, la Inferencia Estadística y los Modelos Lineales, los cuales se podrían obtener de los estudios

de Franklin A. Graybill ([15]), Wonnacott ([16]), Bowman, O'Connell
y Dicky ([17]) y de Courant and Hilbert ([18]).

MODELO LINEAL GENERAL

I EL MODELO LINEAL GENERAL

Sea $Y = X\beta + U$ (1)

nuestro Modelo Lineal General k variante, donde,

$$Y = \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} \quad X = \begin{bmatrix} X_{11} & X_{21} & \cdots & X_{k1} \\ X_{12} & X_{22} & \cdots & X_{k2} \\ \vdots & \vdots & \ddots & \vdots \\ X_{1n} & X_{2n} & \cdots & X_{kn} \end{bmatrix} \quad (2)$$

$$\beta = \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_k \end{bmatrix} \quad U = \begin{bmatrix} U_1 \\ U_2 \\ \vdots \\ U_n \end{bmatrix}$$

y donde supondremos que,

- a.) $E[U] = 0$
- b.) $E[UU'] = \sigma^2 I_n$ (3)
- c.) X es una matriz de rango completo $k \leq n$, cuyas columnas son las variables explicativas.
- d.) β es el vector de parametros desconocidos.
- e.) U vector de errores de componentes U_t , $t = 1, \dots, n$.

Como $E[U] = 0 \implies E[U_t] = 0$; $\forall t: 1 \leq t \leq n$

ademas, como

$$E[UU'] = \sigma^2 I \implies \begin{cases} E[U_t^2] = \sigma^2; \forall t: 1 \leq t \leq n \\ E[U_t U_{t+s}] = 0; \forall s \neq 0 \end{cases}$$

esto nos indica que las perturbaciones U_t son no correlacionadas a pares. La hipótesis (3c) nos indica que la única fuente de variación de Y es el vector U y que nuestro modelo está condicionado a X.

II ALGUNOS ESTIMADORES Y SUS PROPIEDADES

A-LOS ESTIMADORES MINIMOS CUADRATICOS DE β

Sea $\hat{\beta}' = (\hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_k)$ el vector de las estimaciones de β , así tenemos que,

$$Y = X\hat{\beta} + \epsilon \quad (4)$$

donde ϵ es el vector de las estimaciones de los n residuos

$$\epsilon = Y - X\hat{\beta}$$

$$\Rightarrow \epsilon'\epsilon = Y'Y - 2(X\hat{\beta})'Y + (X\hat{\beta})'(X\hat{\beta}) \quad (5)$$

Si derivamos (5) con respecto a $\hat{\beta}$ e igualamos a cero el resultado, obtendremos que,

$$\hat{\beta} = (X'X)^{-1}X'Y \quad (6)$$

el cual es el Estimador de Mínimos Cuadrados de β .

A 1. PROPIEDADES DEL ESTIMADOR $\hat{\beta}$.

1.) $\hat{\beta}$ es Función Lineal de las perturbaciones U , o sea que,

$$\hat{\beta} = \beta + (X'X)^{-1}X'U \quad (7)$$

2.) $\hat{\beta}$ es un Estimador Insesgado de β o sea que.

$$E[\hat{\beta}] = \beta \quad (8)$$

3.) $\hat{\beta}$ es de Varianza Mínima, esto significa que si B es otro Estimador Insesgado de β , tal que $B = AY$ donde A es una matriz de rxn ; si hacemos $AX = C$, entonces tendremos que $\text{var}(B) = \sigma^2AA'$. (9)

Para minimizar la varianza de nuestros estimadores debemos escoger los elementos de A tales que, $\text{tr}(A'A)$ sea mínima. Como la $\text{var}(\hat{\beta}) = \sigma^2(X'X)^{-1}$ y $\text{var}(B) = \sigma^2C(X'X)^{-1}C'$ son mínimas, se tiene que si hacemos $C = I$ resultará que $\hat{\beta}$ es de varianza mínima y es el óptimo.

B-ESTIMADOR DE MAXIMA VEROSIMILITUD DE β :

Si en el modelo lineal (1), además de las hipótesis (3), suponemos que,

$$U \sim N(0, \sigma^2 \mathbf{I}) \quad (10)$$

Se prueba a través de la Función de Verosimilitud de U que el Estimador de Máxima Verosimilitud de β está dado por,

$$\tilde{\beta} = (X'X)^{-1}X'Y \quad (11)$$

el cual, por ser igual al Estimador de Mínimos Cuadrados de β , es el Mejor Estimador Lineal Insesgado y además que,

$$\tilde{\beta} \sim N(\beta, \sigma^2(X'X)^{-1}) \quad (12)$$

C-ESTIMADOR DE LA VARIANZA DE LA PERTURBACION.

De (4) se tiene que,

$$\varepsilon = Y - X\hat{\beta} \quad (13)$$

y luego, de (1) y (6) tenemos que,

$$\varepsilon = [\mathbf{I} - X(X'X)^{-1}X']U \quad (14)$$

donde $[\mathbf{I} - X(X'X)^{-1}X'] = A$, es una matriz semidefinida positiva, simétrica e idempotente, o sea que,

$$A = A' \quad \wedge \quad A.A = A \quad (15)$$

La suma de los cuadrados de los residuos es,

$$\varepsilon'\varepsilon = U'[\mathbf{I} - X(X'X)^{-1}X']U \quad (16)$$

$$\begin{aligned} \implies E[\varepsilon'\varepsilon] &= E[U'(\mathbf{I} - X(X'X)^{-1}X')U] \\ &= \sigma_u^2(n - k) \end{aligned} \quad (17)$$

Así, si designamos por $S^2 = \frac{\epsilon' \epsilon}{n - k}$ al estimador de la varianza de las perturbaciones, tendremos que S^2 es un estimador insesgado, tal que,

$$S^2 = \frac{Y'Y - Y'X(X'X)^{-1}X'Y}{n - k} \quad (18)$$

III AUTOCORRELACION DE ERRORES:

A. MINIMOS CUADRADOS GENERALIZADOS.

$$\text{Sea} \quad Y = X\beta + U \quad (19)$$

con Y , X , β y U como en (2), donde además, se supone que,

$$E[U] = 0 \quad E[UU'] = V \quad (20)$$

Con V Matriz de Varianza-Covarianza del término de perturbación U , donde V es una matriz no singular de orden $n \times n$.

Supongamos que U sigue un proceso estacionario de Markov de Primer Orden, o sea que,

$$U_t = \rho U_{t-1} + \epsilon_t \quad (21)$$

en que $|\rho| < 1$ y donde ϵ_t satisface,

$$\begin{aligned} \text{a.) } E[\epsilon_t] &= 0 \\ \text{b.) } E[\epsilon_t \epsilon_{t+s}] &= \begin{cases} \sigma^2 & \text{si } s = 0 ; \forall t \\ 0 & \text{si } s \neq 0 ; \forall t \end{cases} \end{aligned} \quad (22)$$

Las ecuaciones (21) y (22) definen la forma más simple de un esquema autorregresivo a fin de considerar la dependencia serial que pudiera haber en las perturbaciones.

De (21) se tiene que,

$$U_t = \rho^\infty U_{t-\infty} + \sum_{i=0}^{\infty} \rho^i \epsilon_{t-i} \quad (23)$$

Si hacemos $\rho^\infty = 0$ en (23), resulta que,

$$U_t = \sum_{i=0}^{\infty} \rho^i \epsilon_{t-i} \quad (24)$$

Como $\forall t$ se tiene que $E[\epsilon_t] = 0$, entonces, $E[U_t] = 0$.

Por otro lado,

$$\begin{aligned} E[U_t^2] &= E\left[\left(\sum_{i=0}^{\infty} \rho^i \epsilon_{t-i}\right)^2\right] \\ &= [1 + \rho^2 + \rho^4 + \dots] \sigma_\epsilon^2 \end{aligned} \quad (25)$$

Como $1 + \rho^2 + \rho^4 + \dots$ es la suma de los términos de una Progresión Geométrica Infinita Decreciente con primer término $a = 1$ y razón $r = \rho^2$, entonces, se tiene que,

$$1 + \rho^2 + \rho^4 + \dots = \frac{1}{1 - \rho^2} \quad (26)$$

$$E[U_t^2] = \frac{\sigma_\epsilon^2}{1 - \rho^2} \quad \forall t \quad (27)$$

Como $E[U_t^2] = E[(U_t - E[U_t])^2] = \sigma_u^2$; $\forall t$

$$\implies \sigma_u^2 = \frac{\sigma_\epsilon^2}{1 - \rho^2} \quad \forall t \quad (28)$$

Por otro lado tenemos que,

$$\begin{aligned} \text{Cov}(U_t, U_{t-1}) &= E[U_t U_{t-1}] \\ &= E[(\epsilon_t + \rho\epsilon_{t-1} + \rho^2\epsilon_{t-2} + \dots)(\epsilon_{t-1} + \rho\epsilon_{t-2} + \dots)] \\ &= E[\{\epsilon_t + \rho(\epsilon_{t-1} + \rho\epsilon_{t-2} + \dots)\}(\epsilon_{t-1} + \rho\epsilon_{t-2} + \dots)] \\ &= E[\epsilon_t(\epsilon_{t-1} + \rho\epsilon_{t-2} + \dots) + \rho(\epsilon_{t-1} + \rho\epsilon_{t-2} + \dots)^2] \\ &= E[\epsilon_t(\epsilon_{t-1} + \rho\epsilon_{t-2} + \dots)] + \rho E[(\epsilon_{t-1} + \rho\epsilon_{t-2} + \dots)^2] \end{aligned}$$

Luego, por (22b) se tiene que,

$$E[\epsilon_t(\epsilon_{t-1} + \rho\epsilon_{t-2} + \dots)] = 0$$

$$\begin{aligned}
\implies \text{Cov}(U_t, U_{t-1}) &= \rho E[(\varepsilon_{t-1} + \rho\varepsilon_{t-2} + \rho^2\varepsilon_{t-3} + \dots)] \\
&= E[U_{t-1}^2] \rho \\
&= \rho \sigma_u^2
\end{aligned} \tag{29}$$

Si efectuamos el mismo procedimiento a U_t y U_{t-2} , se tiene que,

$$\text{Cov}(U_t, U_{t-2}) = E[U_t U_{t-2}] = \rho^2 \sigma_u^2$$

Luego, generalizando este resultado $\forall s \neq 0$, se tiene que,

$$\text{Cov}(U_t, U_{t-s}) = \rho^s \sigma_u^2 \quad \forall s \neq 0 \tag{30}$$

Por lo tanto, (19) no satisface la hipótesis de independencia serial entre las perturbaciones.

Sea

$$V = \begin{bmatrix} 1 & \rho & \rho^2 & \dots & \rho^{n-1} \\ \rho & 1 & \rho & \dots & \rho^{n-2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \rho^{n-1} & \rho^{n-2} & \rho^{n-3} & \dots & 1 \end{bmatrix} \sigma_u^2 \tag{31}$$

$$y \quad \beta^* = AY \tag{32}$$

donde A es una matriz de $k \times n$ y β^* es un estimador lineal de β (lineal en los valores de Y).

Si hacemos $AX = \mathbb{I}$, tendremos que:

1.) β^* es un Estimador Insesgado de β , o sea que,

$$E[\beta^*] = E[AY] = \beta \tag{33}$$

2.) $\text{Var}[\beta^*] = E[(\beta^* - \beta) \cdot (\beta^* - \beta)] = AVA' \tag{34}$

Para determinar un estimador de β con mínima varianza, debemos encontrar una matriz A tal que $\text{tra}(A'AV)$ sea mínima y cumpla

con (33). Para ello introducimos k^2 multiplicadores de Lagrange ϕ_{ij} tal que:

$$\Psi = \text{tra}(A'AV) - \text{tra}[\Phi'(AX - I)] \quad (35)$$

donde

$$\Phi = \begin{bmatrix} \phi_{11} & \phi_{12} & \dots & \phi_{1k} \\ \phi_{21} & \phi_{22} & \dots & \phi_{2k} \\ \vdots & \vdots & \ddots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ \phi_{k1} & \phi_{k2} & \dots & \phi_{kk} \end{bmatrix} \quad (36)$$

Luego, derivando (35) parcialmente con respecto a A e igualando a cero tendremos que,

$$2AV = \Phi X' \quad (37)$$

Multiplicando (37) por $V^{-1}X$ y despejando se tiene que,

$$\Phi = 2(X'V^{-1}X)^{-1} \quad (38)$$

De (37) y (38) se tiene por sustitución que,

$$A = (X'V^{-1}X)^{-1}X'V^{-1} \quad (39)$$

Para demostrar que A , dada en (39) proporciona una varianza mínima, definimos un estimador lineal insesgado arbitrario de β de la siguiente forma,

$$B = (A + R)Y \quad (40)$$

donde R es una matriz de $k \times n$ no nula y donde, si se hace $RX = 0$ se tendrá que,

$$\text{Var}[B] = \text{Var}[\beta^*] + E[RUU'R'] \quad (41)$$

Como para cualquier matriz real R , la matriz dada por $RUU'R'$ es definida positiva si $\text{rang}(R) = k$ y es semidefinida positiva

si $\text{rang}(R) < k$, entonces A proporciona una varianza mínima, con A definida por (39) y β^* definido por (32).

β^* es un estimador lineal insesgado de varianza mínima.
(BLUE)

B. ESTIMADOR DE MAXIMA VEROSIMILITUD.

Si en el modelo (19), además de la hipótesis (20) se supone que,

$$U \sim N(0, V) \quad (43)$$

entonces, su Función de Verosimilitud estará dada por,

$$L = (2\pi)^{-\frac{1}{2}n} |V|^{-\frac{1}{2}} \text{Exp}\{-\frac{1}{2}(Y - X\beta)'V^{-1}(Y - X\beta)\} \quad (44)$$

Si elegimos como estimador de β aquel que minimiza la forma cuadrática,

$$(Y - X\beta)'V^{-1}(Y - X\beta) \quad (45)$$

llegaremos a obtener (39) y además, tendremos que,

$$1.) \quad \beta^* = AY = \beta + (X'V^{-1}X)^{-1}X'V^{-1}U \quad (46)$$

$$2.) \quad E[(\beta^* - \beta)(\beta^* - \beta)'] = (X'V^{-1}X)^{-1} \quad (47)$$

$$3.) \quad \beta^* \text{ es de Varianza Mínima}$$

Así, β^* es un Estimador Lineal Insesgado de Varianza Mínima, tal que,

$$\beta^* \sim N(\beta, (X'V^{-1}X)^{-1}) \quad (48)$$

C. IMPLICACIONES DE LOS ESTIMADORES MINIMOS CUADRATICOS GENERALIZADOS. CASO SIMPLE DE PERTURBACIONES AUTOCORRELACIONADAS.

Supongamos que se tiene un esquema de la forma,

$$Y_t = \alpha + \beta X_t + U_t \quad (49)$$

en donde U_t sigue un proceso autorregresivo como el descrito en (21)

y Y_t es tal que cumple con la descripción de Y en (19). Entonces, tendremos que:

$$E[UU'] = V = \frac{\sigma_\varepsilon^2}{1 - \rho^2} \begin{bmatrix} 1 & \rho & \rho^2 & \dots & \rho^{n-1} \\ \rho & 1 & \rho & \dots & \rho^{n-2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \rho^{n-1} & \rho^{n-2} & \rho^{n-3} & \dots & 1 \end{bmatrix} \quad (50)$$

$$\Rightarrow V^{-1} = \frac{1}{\sigma_\varepsilon^2} \begin{bmatrix} 1 & -\rho & 0 & \dots & 0 & 0 \\ -\rho & 1+\rho^2 & -\rho & \dots & 0 & 0 \\ 0 & -\rho & 1+\rho^2 & \dots & 0 & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & 0 & \dots & -\rho & 1 \end{bmatrix} \quad (51)$$

Se demuestra que el Estimador de Mínimos Cuadrados Generalizado es equivalente al estimador que se obtiene de un proceso de mínimos cuadrados en dos etapas, de la siguiente forma:

- 1.) Transformando las variables originales de acuerdo con la estructura autorregresiva del término de perturbación.

En efecto, sea $Y = X\beta + U$ y T una matriz de transformación tal que,

$$TY = TX\beta + TU \quad (52)$$

- 2.) Aplicando Mínimos Cuadrados Ordinarios a las variables transformadas en (52).

El estimador de mínimos cuadrados ordinarios de β será:

$$\begin{aligned} \beta^* &= [(TX)'(TX)]^{-1}(TX)'(TY) \\ &= (X'T'TX)^{-1}X'T'TY \end{aligned} \quad (53)$$

Si hacemos $T'T = V^{-1}$ como en (51), resulta que,

$$\beta^* = (X'V^{-1}X)^{-1}X'V^{-1}Y \quad (54)$$

de donde, por (39) se tiene que, $\beta^* = AY$.

Si por razones de simplicidad hacemos $\sigma_{\epsilon}^2 = 1$, entonces, una matriz T de $(n-1) \times n$ que satisface casi completamente a (54) es,

$$T = \begin{bmatrix} -\rho & 1 & 0 & \dots & 0 & 0 \\ 0 & -\rho & 1 & \dots & 0 & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & 0 & \dots & -\rho & 1 \end{bmatrix}_{(n-1) \times n} \quad (55)$$

puesto que,

$$T'T = \begin{bmatrix} \rho^2 & -\rho & 0 & \dots & 0 \\ -\rho & 1+\rho^2 & -\rho & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \dots & 1 \end{bmatrix}_{n \times n} \quad (56)$$

De (51) y (56) se observa que la única diferencia entre V^{-1} y $T'T$ es el primer elemento de la primera fila y primera columna.

Luego, las variables transformadas indicadas por T son:

$$\begin{bmatrix} Y_2 - \rho Y_1 \\ Y_3 - \rho Y_2 \\ \vdots \\ Y_n - \rho Y_{n-1} \end{bmatrix} \quad \hat{=} \quad \begin{bmatrix} X_2 - \rho X_1 \\ X_3 - \rho X_2 \\ \vdots \\ X_n - \rho X_{n-1} \end{bmatrix} \quad (57)$$

Con lo cual se tiene que:

$$E[(TU)(TU)'] = TVT' = \sigma_{\epsilon}^2 \begin{bmatrix} 1 & 0 & 0 & \dots & 0 \\ 0 & 1 & 0 & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \dots & 1 \end{bmatrix} \quad (58)$$

D. PRUEBAS DE HIPOTESIS PARA LA AUTOCORRELACION DE LAS PERTURBACIONES SERIALES.

Dado un Modelo Lineal General $Y = X\beta + U$, como el descrito en la sección III-A, se quiere probar la siguiente hipótesis:

$$H_0 : \rho > 0$$

$$H_1 : \rho = 0$$

Esto equivale a querer probar que:

H_0 : Los errores están autocorrelacionados positivamente.

H_1 : Los errores no están autocorrelacionados.

Para probar ésta hipótesis, existen varios métodos, algunos de los cuales presentan muy pocas diferencias pero, casi todos están basados en el estudio de los residuos.

En el siguiente capítulo estudiaremos algunos de los criterios utilizados para probar estas hipótesis, entre los cuales podemos mencionar el Criterio del Cociente d , de Durbin - Watson. Este método lo estudiaremos con bastante profundidad debido a que es uno de los más utilizados y que tiene mayor aplicabilidad. Este método se basa en el criterio del cociente de verosimilitud de los errores, pues supone que los errores se distribuyen como variables aleatorias normales.

Si suponemos que, $\epsilon \sim N(0, \sigma^2 \mathbf{I})$

donde $\epsilon = (\epsilon_1, \epsilon_2, \dots, \epsilon_n)'$, con ϵ_t definido como en (22), $\forall t$; $1 \leq t \leq n$, entonces, se tiene que,

$$\sum_{t=1}^n \epsilon_t^2 = \epsilon' \epsilon = U' [I - X(X'X)^{-1}X'] U \quad (59)$$

donde $I - X(X'X)^{-1}X' = P$ es una matriz simétrica e idempotente y de rango n , por lo tanto se tiene que,

$$\epsilon' \epsilon \sim \chi^2_{\nu} \quad \text{con } \nu = n \text{ g.d.l} \quad (60)$$

Por otro lado tenemos que,

$$\sum_{t=2}^n (\epsilon_t - \epsilon_{t-1})^2 = \epsilon' A \epsilon \quad (61)$$

donde $A = T'T$ con $T'T$ definida como en (56), de aquí se deduce que

$$\sum_{t=2}^n (\epsilon_t - \epsilon_{t-1})^2 = U' [A - AX(X'X)^{-1}X'] U \quad (62)$$

donde, $A - AX(X'X)^{-1}X' = Q$ no es una matriz idempotente ya que A no lo es. Por lo tanto $\epsilon' A \epsilon$ no se distribuye como una Chi-cuadrado; además, como

$$P \cdot Q = [I - X(X'X)^{-1}X'] \cdot [A - AX(X'X)^{-1}X'] \neq 0 \quad (63)$$

entonces, se tiene que $\epsilon' \epsilon$ y $\epsilon' A \epsilon$ no se distribuyen en forma independiente, con lo cual el cociente formado por (62) y (59):

$$d = \frac{\sum_{t=2}^n (\epsilon_t - \epsilon_{t-1})^2}{\sum_{t=0}^n \epsilon_t^2} = \frac{\epsilon' A \epsilon}{\epsilon' \epsilon} \quad (64)$$

no se distribuye bajo ninguna de las formas comunes conocidas.

ALGUNOS CRITERIOS
PARA LA PRUEBA DE
LA AUTOCORRELACION
DE LAS PERTURBACIONES

I CRITERIO DE DURBIN-WATSON.

A- INTRODUCCION AL TRATAMIENTO TEORICO.

Sabemos que una simple ecuación de un Modelo de Regresión puede ser escrita de la forma

$$Y = \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \epsilon \quad (1)$$

donde Y es la variable dependiente, X_i es la i-ésima variable independiente, β_i es el i-ésimo parámetro, el cual es desconocido y ϵ es un término de error, también desconocido. Para una muestra de n observaciones, nuestro modelo toma la forma,

$$\begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} = \begin{bmatrix} X_{11} & X_{21} & \dots & X_{k1} \\ X_{12} & X_{22} & \dots & X_{k2} \\ \vdots & \vdots & \ddots & \vdots \\ X_{1n} & X_{2n} & \dots & X_{kn} \end{bmatrix} \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_k \end{bmatrix} + \begin{bmatrix} \epsilon_1 \\ \epsilon_2 \\ \vdots \\ \epsilon_n \end{bmatrix} \quad (2)$$

o sea que

$$Y = X\beta + \epsilon \quad (3)$$

de donde se tiene que $\hat{\beta}$ es el Estimador de Mínimos Cuadrados de β , el cual está dado por,

$$\hat{\beta} = (X'X)^{-1}X'Y \quad (4)$$

además, $Z = Y - X\hat{\beta}$ es el Vector de Residuos de la Regresión, donde

$$Z = \{I_n - X(X'X)^{-1}X'\}Y = \{I_n - X(X'X)^{-1}X'\}\epsilon = M\epsilon \quad (5)$$

donde M es una matriz simétrica semidefinida positiva e idempotente, o sea que,

$$M = (m_{ij}) = M' = (m_{ji}) = M^2 \quad (6)$$

con estos elementos definimos el estadístico:

$$r = \frac{Z'AZ}{Z'Z} = \frac{\varepsilon'M'AM\varepsilon}{\varepsilon'M\varepsilon} \quad (7)$$

el cual será el punto esencial de nuestro análisis.

Dadas las condiciones anteriores, enunciaremos un teorema, el cual demostraremos y a partir del cual se desprende un corolario que nos será de gran utilidad en nuestro trabajo.

TEOREMA 1:

Si Z y ε son vectores $n \times 1$ tales que $Z = M\varepsilon$, donde $M = I_n - X(X'X)^{-1}X'$ y si $r = \frac{Z'AZ}{Z'Z}$, donde A es una matriz real simétrica, entonces:

a.) Existe una transformación ortogonal $\varepsilon = M\zeta$, tal que:

$$r = \frac{\sum_{i=1}^{n-k} v_i \zeta_i^2}{\sum_{i=1}^{n-k} \zeta_i^2} \quad (8)$$

donde v_1, v_2, \dots, v_{n-k} son las raíces propias de $M \cdot A$, menos k ceros.

b.) Si s de las columnas de X son combinaciones lineales de s vectores propios de A , y si las raíces de A asociadas con los restantes vectores propios $n-s$ de A son reenumerados tal que:

$$\lambda_1 \leq \lambda_2 \leq \lambda_3 \leq \dots \leq \lambda_{n-s}$$

entonces,

$$\lambda_i \leq v_i \leq \lambda_{i+k-s} \quad (i = 1, 2, \dots, n-k) \quad (9)$$

DEMOSTRACION:

a.) Demostraremos que existe una transformación ortogonal $\varepsilon = H\zeta$ tal que:

$$r = \frac{\sum_{i=1}^{n-k} v_i \zeta_i^2}{\sum_{i=1}^{n-k} \zeta_i^2}$$

En efecto, sabemos que existe una matriz ortogonal L tal que:

$$L^M L = \left[\begin{array}{c|c} I_{n-k} & 0 \\ \hline 0 & 0 \end{array} \right]$$

donde I_{n-k} es la matriz de unidades de orden $n-k$ y 0 representa una matriz cero con apropiados números de filas y columnas.

Así,

$$\begin{aligned} L^M A M L &= (L^M L)(L^A L)(L^M L) \\ &= \left[\begin{array}{c|c} I_{n-k} & 0 \\ \hline 0 & 0 \end{array} \right] \left[\begin{array}{c|c} B_1 & B_3 \\ \hline B_2 & B_4 \end{array} \right] \left[\begin{array}{c|c} I_{n-k} & 0 \\ \hline 0 & 0 \end{array} \right] \\ &= \left[\begin{array}{c|c} B_1 & 0 \\ \hline 0 & 0 \end{array} \right] \end{aligned} \quad (10)$$

donde $\left[\begin{array}{c|c} B_1 & B_3 \\ \hline B_2 & B_4 \end{array} \right]$ es la partición apropiada de la matriz real simétrica $L^A L$.

Sea N_1 la matriz ortogonal que diagonaliza a B_1 o sea que,

$$N_1^T B_1 N_1 = \left[\begin{array}{c} v_1 \\ \\ v_2 \quad 0 \\ \vdots \quad \vdots \\ 0 \quad \vdots \quad v_{n-k} \end{array} \right] \quad (11)$$

entonces, $N = \left[\begin{array}{c|c} N_1 & 0 \\ \hline 0 & I_k \end{array} \right]$ es ortogonal, de modo que $H = L \cdot N$ es

ortogonal.

Por consiguiente,

$$\begin{aligned}
 H'MH &= N'L'MLN = N' \begin{bmatrix} I_{n-k} & \vdots & 0 \\ \dots & \dots & \dots \\ 0 & \vdots & 0 \end{bmatrix} N \\
 &= \begin{bmatrix} I_{n-k} & \vdots & 0 \\ \dots & \dots & \dots \\ 0 & \vdots & 0 \end{bmatrix} \quad (12)
 \end{aligned}$$

Por lo tanto,

$$\begin{aligned}
 H'M A M H &= (H'M H)(H'A H)(H'M H) \\
 &= \begin{bmatrix} I_{n-k} & \vdots & 0 \\ \dots & \dots & \dots \\ 0 & \vdots & 0 \end{bmatrix} \begin{bmatrix} N_1' B_1 N_1 & \vdots & 0 \\ \dots & \dots & \dots \\ 0 & \vdots & 0 \end{bmatrix} \begin{bmatrix} I_{n-k} & \vdots & 0 \\ \dots & \dots & \dots \\ 0 & \vdots & 0 \end{bmatrix} \\
 &= \begin{bmatrix} v_1 & & & \vdots & & \\ & v_2 & & & & 0 \\ & & v_3 & & & \\ & & & \ddots & & \\ & & & & v_{n-k} & \\ \dots & & & & & \vdots \\ & 0 & & & & 0 \end{bmatrix} \quad (13)
 \end{aligned}$$

Si hacemos $\epsilon = H\zeta$, se tiene que,

$$r = \frac{\sum_{i=1}^{n-k} v_i \zeta_i^2}{\sum_{i=1}^{n-k} \zeta_i^2}$$

Cuando $\epsilon'M A M \epsilon = \text{constante}$ y $\epsilon'M \epsilon = \text{constante}$, se tiene que son hipercilindros con generadores paralelos.

Sabemos que $v_1, v_2, v_3, \dots, v_{n-k}$ son las raíces propias de $M A M$ menos k ceros, o sea que son las raíces propias de $M^2 A$, pero, como $M^2 = M$, entonces, $M^2 A = M A$; por lo tanto $v_1, v_2, v_3, \dots, v_{n-k}$ son las raíces propias de $M A$ menos

κ ceros.

Si efectuamos la transformación real no singular de las $\{X_i\}$, $P = XG$, se tiene que $M = \mathbf{I}_n - P(P'P)^{-1}P'$, es decir, M es invariante bajo este tipo de transformación; si escogemos G de modo que los vectores columnas $P_1, P_2, P_3, \dots, P_k$; de P son ortogonales.

$$\text{i.e.} \quad P_i'P_j = \begin{cases} 1 & \text{si } i = j \\ 0 & \text{si } i \neq j \end{cases} \quad (14)$$

tenemos que $P'P = \mathbf{I}_n$.

Esto nos indica que podemos cambiar las variables independientes originales por un conjunto ortogonal sin afectar los residuos. Por lo tanto,

$$\begin{aligned} M &= \mathbf{I}_n - (P_1P_1' + P_2P_2' + \dots + P_kP_k') \\ &= (\mathbf{I}_n - P_1P_1')(\mathbf{I}_n - P_2P_2') \dots (\mathbf{I}_n - P_kP_k') \\ &= M_1M_2M_3 \dots M_k \end{aligned} \quad (15)$$

donde cada M_i tiene la misma forma de M ; es claro que los M_i conmutan, o sea que en términos algebraicos podemos ajustar regresiones sobre variables ortogonales separadamente y en cualquier orden sin afectar el resultado final.

Dada la forma de las matrices M_i tenemos que, cualquier resultado que establezcamos acerca de las raíces de M_1A en términos de las de A , será cierto para las raíces de M_2M_1A en término de las de M_1A y así sucesivamente. Esto sugiere un método para desarrollar un conocimiento de las raíces de $M_kM_{k-1} \dots M_2M_1A$ en etapas partiendo de las raíces de A , las cuales se asumen conocidas.

Por lo anteriormente dicho, estudiaremos las raíces propias de M_1A ; $\theta_1, \theta_2, \theta_3, \dots, \theta_{n-1}, 0$; las cuales son raíces de la

$$\begin{vmatrix}
 \theta - \lambda_1 + 1_1^2 \lambda_1 & 1_1 1_2 \lambda_2 & 1_1 1_3 \lambda_3 & \dots & 1_1 1_n \lambda_n \\
 -(\theta - \lambda_1) 1_2 / 1_1 & (\theta - \lambda_2) & 0 & \dots & 0 \\
 -(\theta - \lambda_1) 1_3 / 1_1 & 0 & (\theta - \lambda_3) & \dots & 0 \\
 \vdots & \vdots & \vdots & \ddots & \vdots \\
 \vdots & \vdots & \vdots & \vdots & \vdots \\
 -(\theta - \lambda_1) 1_n / 1_1 & 0 & 0 & \dots & (\theta - \lambda_n)
 \end{vmatrix} = 0 \quad (20)$$

Este determinante es de la forma:

$$\begin{vmatrix}
 a_{11} & a_{12} & a_{13} & a_{14} & \dots & a_{1n} \\
 a_{21} & a_{22} & 0 & 0 & \dots & 0 \\
 a_{31} & 0 & a_{33} & 0 & \dots & 0 \\
 a_{41} & 0 & 0 & a_{44} & \dots & 0 \\
 \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\
 \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\
 a_{n1} & 0 & 0 & 0 & \dots & a_{nn}
 \end{vmatrix} = 0 \quad (21)$$

Donde resolviendo por menores se tiene que este determinante es igual a:

$$|\mathbb{I}_n \theta - (\mathbb{I}_n - 11') \Lambda| = \prod_{j=1}^n a_{jj} - \sum_{j=2}^n \prod_{\substack{i=2 \\ j \neq i}}^n a_{jj} a_{ii} a_{ji} \quad (22)$$

Así, reemplazando los a_{jj} por los valores correspondientes dados en el determinante, es decir:

$$\begin{aligned}
 a_{11} &= (\theta - \lambda_1) + 1_1^2 \lambda_1 & a_{jj} &= (\theta - \lambda_j); \quad \forall j: j \neq 1 \\
 a_{j1} &= -(\theta - \lambda_1) 1_j / 1_1 & a_{ii} &= 1_1 1_i \lambda_i; \quad \forall i: i \neq 1
 \end{aligned} \quad (23)$$

se tiene que:

$$\begin{aligned} \prod_{j=1}^n a_{jj} &= a_{11} \prod_{j=2}^n a_{jj} = \{(\theta - \lambda_1) + 1^2 \lambda_1\} \prod_{j=2}^n (\theta - \lambda_j) \\ &= \prod_{j=1}^n (\theta - \lambda_j) + 1^2 \lambda_1 \prod_{j=2}^n (\theta - \lambda_j) \end{aligned} \quad (24)$$

$$a_{j1} \cdot a_{1i} = -(\theta - \lambda_i) \frac{1}{1} \cdot \frac{1}{1} \cdot 1 \cdot \lambda_i = -(\theta - \lambda_i) \frac{1^2 \lambda_i}{1}$$

Luego, sustituyendo estos valores en la ecuación (22) se tiene que:

$$\begin{aligned} |I_n \theta - (I_n - 11') \Lambda| &= \prod_{j=1}^n (\theta - \lambda_j) + 1^2 \lambda_1 \prod_{i=2}^n (\theta - \lambda_i) + \sum_{i=2}^n 1^2 \lambda_i \prod_{\substack{j=1 \\ j \neq i}}^n (\theta - \lambda_j) \\ &= \prod_{j=1}^n (\theta - \lambda_j) + \sum_{i=1}^n 1^2 \lambda_i \prod_{\substack{j=1 \\ j \neq i}}^n (\theta - \lambda_j) = 0 \end{aligned} \quad (25)$$

Si reducimos (25) y sacamos un factor θ correspondiente a la raíz cero conocida de $M_1 \cdot A$, obtendremos:

$$\sum_{i=1}^n 1^2 \lambda_i \prod_{\substack{j=1 \\ j \neq i}}^n (\theta - \lambda_j) = 0 \quad (26)$$

donde $\theta_1, \theta_2, \theta_3, \dots, \theta_{n-1}$ son las raíces de ésta ecuación.

Demostraremos que (26) se deduce de (25), para ello usaremos el Método de Inducción.

$$1.) \text{ Sea } n = 2: \prod_{i=1}^2 (\theta - \lambda_j) + \sum_{i=1}^2 1^2 \lambda_i \prod_{\substack{j=1 \\ j \neq i}}^2 (\theta - \lambda_j) = 0 \text{ con } \sum_{i=1}^2 1^2 = 1$$

$$\begin{aligned} \Rightarrow \prod_{i=1}^2 (\theta - \lambda_j) + \sum_{i=1}^2 1^2 \lambda_i \prod_{\substack{j=1 \\ j \neq i}}^2 (\theta - \lambda_j) &= (\theta - \lambda_1)(\theta - \lambda_2) + 1^2 \lambda_1 (\theta - \lambda_2) + \\ &\quad + 1^2 \lambda_2 (\theta - \lambda_1) \\ &= \theta^2 - \theta \lambda_1 - \theta \lambda_2 + \lambda_1 \lambda_2 + 1^2 \lambda_1 \theta - 1^2 \lambda_1 \lambda_2 + 1^2 \lambda_2 \theta - 1^2 \lambda_2 \lambda_1 \\ &= \theta(\theta - \lambda_1 - \lambda_2 + 1^2 \lambda_1 + 1^2 \lambda_2) + \lambda_1 \lambda_2 (1 - 1^2 - 1^2) \\ &= \theta(\theta - \lambda_1 - \lambda_2 + 1^2 \lambda_1 + 1^2 \lambda_2) + \lambda_1 \lambda_2 \cdot 0 \end{aligned}$$

$$\begin{aligned}
\prod_{j=1}^2 (\theta - \lambda_j) + \sum_{i=1}^2 l_i^2 \lambda_i \prod_{i \neq j}^2 (\theta - \lambda_j) &= \theta(\theta - \lambda_1 - \lambda_2 + l_1^2 \lambda_1 + l_2^2 \lambda_2 + l_1^2 \lambda_1 - l_2^2 \lambda_1 + \\
&\quad + l_1^2 \lambda_2 - l_2^2 \lambda_2) \\
&= \theta(\theta - \lambda_1 \{1 - (l_1^2 + l_2^2)\} - \lambda_2 \{1 - (l_1^2 + l_2^2)\} - l_1^2 \lambda_2 - l_2^2 \lambda_1) \\
&= \theta(\theta - \lambda_1 0 - \lambda_2 0 - l_1^2 \lambda_2 - l_2^2 \lambda_1) \\
&= \theta(\theta \{l_1^2 + l_2^2\} - l_1^2 \lambda_2 - l_2^2 \lambda_1) \\
&= \theta(l_1^2 \{\theta - \lambda_2\} + l_2^2 \{\theta - \lambda_1\}) \\
&= \theta \left[\sum_{i=1}^2 l_i^2 \prod_{i \neq j}^2 (\theta - \lambda_j) \right] \\
\sum_{i=1}^2 l_i^2 \prod_{i \neq j}^2 (\theta - \lambda_j) &= 0
\end{aligned}$$

2.) Hipotesis de Inducción:

$$\text{Sea } n = k: \prod_{j=1}^k (\theta - \lambda_j) + \sum_{i=1}^k l_i^2 \lambda_i \prod_{i \neq j}^k (\theta - \lambda_j) \quad \text{con } \sum_{i=1}^k l_i^2 = 1$$

$$\implies \prod_{j=1}^k (\theta - \lambda_j) + \sum_{i=1}^k l_i^2 \lambda_i \prod_{i \neq j}^k (\theta - \lambda_j) = \theta \left[\sum_{i=1}^k l_i^2 \prod_{i \neq j}^k (\theta - \lambda_j) \right]$$

Por demostrar:

Para $n = k + 1$, si $\sum_{i=1}^{k+1} l_i^2 = 1$, entonces,

$$\prod_{j=1}^{k+1} (\theta - \lambda_j) + \sum_{i=1}^{k+1} l_i^2 \lambda_i \prod_{i \neq j}^{k+1} (\theta - \lambda_j) = \theta \left[\sum_{i=1}^{k+1} l_i^2 \prod_{i \neq j}^{k+1} (\theta - \lambda_j) \right]$$

En efecto,

$$\begin{aligned}
\prod_{j=1}^{k+1} (\theta - \lambda_j) + \sum_{i=1}^{k+1} l_i^2 \lambda_i \prod_{i \neq j}^{k+1} (\theta - \lambda_j) &= (\theta - \lambda_{k+1}) \prod_{j=1}^k (\theta - \lambda_j) + \\
&\quad (\theta - \lambda_{k+1}) \sum_{i=1}^k l_i^2 \lambda_i \prod_{i \neq j}^k (\theta - \lambda_j) + \\
&\quad l_{k+1}^2 \lambda_{k+1} \prod_{i=1}^k (\theta - \lambda_j)
\end{aligned}$$

$$\begin{aligned} \Rightarrow \prod_{j=1}^{k+1} (\theta - \lambda_j) + \sum_{i=1}^{k+1} l_i^2 \lambda_i \prod_{j \neq i}^{k+1} (\theta - \lambda_j) &= (\theta - \lambda_{k+1}) \prod_{j=1}^k (\theta - \lambda_j) + (\theta - \lambda_{k+1}) \sum_{i=1}^k l_i^2 \lambda_i \cdot \\ &\prod_{j \neq i}^k (\theta - \lambda_j) + l_{k+1}^2 \lambda_{k+1} \prod_{j \neq k}^k (\theta - \lambda_j) (\theta - \lambda_{k+1}) - l_{k+1}^2 \lambda_k \prod_{j \neq k}^k (\theta - \lambda_j) \cdot \\ &\cdot (\theta - \lambda_{k+1}) + l_{k+1}^2 \lambda_{k+1} \prod_{j=1}^k (\theta - \lambda_j) \end{aligned}$$

Si hacemos $l_k^2 + l_{k+1}^2 = l_k^{2*}$ y además $l_i^{2*} = l_i^2$ con $1 \leq i \leq k-1$ (*)

se tiene que:

$$\begin{aligned} \prod_{j=1}^{k+1} (\theta - \lambda_j) + \sum_{i=1}^{k+1} l_i^2 \lambda_i \prod_{j \neq i}^{k+1} (\theta - \lambda_j) &= (\theta - \lambda_{k+1}) \prod_{j=1}^k (\theta - \lambda_j) + (\theta - \lambda_{k+1}) \cdot \\ &\sum_{i=1}^k l_i^{2*} \lambda_i \prod_{j \neq i}^k (\theta - \lambda_j) - l_{k+1}^2 \lambda_k \prod_{j \neq k}^k (\theta - \lambda_j) (\theta - \lambda_{k+1}) + \\ &+ l_{k+1}^2 \lambda_{k+1} \prod_{j=1}^k (\theta - \lambda_j) \\ &= (\theta - \lambda_{k+1}) \left[\prod_{j=1}^k (\theta - \lambda_j) + \sum_{i=1}^k l_i^{2*} \lambda_i \prod_{j \neq i}^k (\theta - \lambda_j) \right] - \\ &- l_{k+1}^2 \lambda_k \prod_{j \neq k}^{k+1} (\theta - \lambda_j) (\theta - \lambda_{k+1}) + l_{k+1}^2 \lambda_{k+1} \prod_{j=1}^k (\theta - \lambda_j) \\ &= (\theta - \lambda_{k+1}) \theta \left[\sum_{i=1}^k l_i^{2*} \prod_{j \neq i}^k (\theta - \lambda_j) \right] + l_{k+1}^2 \prod_{j=1}^{k-1} (\theta - \lambda_j) \left[\lambda_{k+1} (\theta - \lambda_k) - \right. \\ &\left. - \lambda_k (\theta - \lambda_{k+1}) \right] \\ &= \theta \left[\sum_{i=1}^k l_i^{2*} \prod_{j \neq i}^{k+1} (\theta - \lambda_j) \right] + l_{k+1}^2 \prod_{j=1}^{k-1} (\theta - \lambda_j) \theta (\lambda_{k+1} - \lambda_k) \\ &= \theta \left[\sum_{i=1}^k l_i^2 \prod_{j \neq i}^{k+1} (\theta - \lambda_j) + l_{k+1}^2 \prod_{j \neq k}^{k+1} (\theta - \lambda_j) + l_{k+1}^2 \prod_{j=1}^{k-1} (\theta - \lambda_j) (\lambda_{k+1} - \lambda_k) \right] \end{aligned}$$

Esto último se obtuvo haciendo uso de (*)

Así, tenemos que:

$$\begin{aligned}
 \prod_{j=1}^{k+1} (\theta - \lambda_j) + \sum_{i=1}^{k+1} l_i^2 \lambda_i \prod_{j \neq i}^{k+1} (\theta - \lambda_j) &= \theta \left[\sum_{i=1}^k l_i^2 \prod_{j \neq i}^{k+1} (\theta - \lambda_j) + l_{k+1}^2 \prod_{j=1}^{k-1} (\theta - \lambda_j) \cdot \right. \\
 &\quad \left. \cdot \{(\theta - \lambda_{k+1}) + (\lambda_{k+1} - \lambda_k)\} \right] \\
 &= \theta \left[\sum_{i=1}^k l_i^2 \prod_{j \neq i}^{k+1} (\theta - \lambda_j) + l_{k+1}^2 \prod_{j=1}^{k-1} (\theta - \lambda_j) (\theta - \lambda_k) \right] \\
 &= \theta \left[\sum_{i=1}^k l_i^2 \prod_{j \neq i}^{k+1} (\theta - \lambda_j) + l_{k+1}^2 \prod_{j=1}^k (\theta - \lambda_j) \right] \\
 &= \theta \left[\sum_{i=1}^{k+1} l_i^2 \prod_{j \neq i}^{k+1} (\theta - \lambda_j) \right]
 \end{aligned}$$

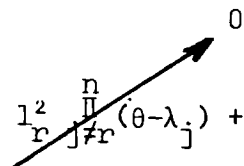
Para $n = k+1$, si se cumple que $\sum_{i=1}^{k+1} l_i^2 = 1$, se tiene que:

$$\prod_{j=1}^{k+1} (\theta - \lambda_j) + \sum_{i=1}^{k+1} l_i^2 \lambda_i \prod_{j \neq i}^{k+1} (\theta - \lambda_j) = \theta \left[\sum_{i=1}^{k+1} l_i^2 \prod_{j \neq i}^{k+1} (\theta - \lambda_j) \right]$$

Luego, de 1.) y 2.) se tiene que (26) se deduce de (25).

Notamos que cuando $l_r = 0$; $\theta - \lambda_r$ es un factor de (26), de modo que $\theta = \lambda_r$ es una solución.

En efecto,

$$\begin{aligned}
 \sum_{i=1}^n l_i^2 \prod_{j \neq i}^n (\theta - \lambda_j) &= 0 \quad \text{y si } l_r = 0 \\
 \implies \sum_{i=1}^n l_i^2 \prod_{j \neq i}^n (\theta - \lambda_j) &= \sum_{i=1}^{r-1} l_i^2 \prod_{j \neq i}^n (\theta - \lambda_j) + l_r^2 \prod_{j \neq r}^n (\theta - \lambda_j) + \\
 &\quad + \sum_{i=r+1}^n l_i^2 \prod_{j \neq i}^n (\theta - \lambda_j)
 \end{aligned}$$


$$\begin{aligned}
\implies \sum_{i=1}^n l_i^2 \prod_{j \neq i} (\theta - \lambda_j) &= \sum_{i=1}^{r-1} l_i^2 \prod_{j \neq i} (\theta - \lambda_j) + \sum_{i=r+1}^n l_i^2 \prod_{j \neq i} (\theta - \lambda_j) \\
&= (\theta - \lambda_r) \left[\sum_{i=1}^{r-1} l_i^2 \prod_{j \neq i} (\theta - \lambda_j) + \sum_{i=r+1}^n l_i^2 \prod_{j \neq i} (\theta - \lambda_j) \right] \\
&= (\theta - \lambda_r) \left[\sum_{i \neq r}^n l_i^2 \prod_{j \neq i} (\theta - \lambda_j) \right]
\end{aligned}$$

$$\text{Como } \sum_{i=1}^n l_i^2 \prod_{j \neq i} (\theta - \lambda_j) = 0$$

$$\implies \theta - \lambda_r = 0 \quad \vee \quad \sum_{i \neq r}^n l_i^2 \prod_{j \neq i} (\theta - \lambda_j) = 0$$

$$\implies \theta = \lambda_r$$

$\therefore \theta = \lambda_r$ es una solución de (26).

Esto nos indica que cuando P_1 coincide con un vector propio de A ; $\theta_1, \theta_2, \dots, \theta_{n-1}$ son iguales a las raíces propias asociadas con los restantes $n-1$ vectores propios de A . De igual forma tenemos que, si P_2 coincide con un vector propio de A , las raíces de $M_2 M_1 A$ distintas de cero son iguales a las raíces propias asociadas con los restantes $n-2$ vectores propios de A . En términos generales tenemos que, si los k vectores de regresión P_k coinciden con k de los vectores propios de A , las raíces de $M_k \dots M_2 M_1 A$ ó sean v_1, v_2, \dots, v_{n-k} son iguales a las raíces propias asociadas con los restantes $n - k$ vectores propios de A .

En efecto;

1.) Supongamos que P_1 coincide con un vector propio de A asociada-

do al valor propio λ_1 .

$$\implies AP_1 = \lambda_1 P_1 \quad (a)$$

Esto implica que P_1 asocia $\theta = 0$ en $M_1 A$; lo que es equivalente a que:

$$(M_1 A)(P_1) = 0 \quad (b)$$

En efecto,

$$\begin{aligned} (M_1 A)(P_1) &= (I - P_1 P_1') AP_1 = AP_1 - P_1 P_1' AP_1 \\ &= \lambda_1 P_1 - P_1 P_1' \lambda_1 P_1 \quad \text{por (a)} \\ &= \lambda_1 P_1 - \lambda_1 P_1 P_1' P_1 \\ &= \lambda_1 P_1 - \lambda_1 P_1 \quad \text{pues } P_1' P_1 = 1 \\ &= 0 \end{aligned}$$

$$\implies P_1 \in \text{Ker}(M_1 A) \iff \theta = 0$$

Sea ahora, β un vector propio de A asociado al valor propio

$\lambda_1 \implies \lambda_1$ es valor propio de $M_1 A$.

i.e. $A\beta = \lambda_1 \beta \implies \exists \gamma : (M_1 A)(\gamma) = \lambda_1 \gamma$

En efecto,

$$\text{Sea } \gamma = M_1 \beta \implies (M_1 A)(\gamma) = (M_1 A)(M_1 \beta)$$

$$\implies (M_1 A)\gamma = (M_1 A)(I - P_1 P_1')\beta = M_1 A\beta - M_1 A P_1 P_1' \beta$$

$$= M_1 \lambda_1 \beta - 0 P_1' \beta \quad \text{por (b)}$$

$$= \lambda_1 M_1 \beta = \lambda_1 \gamma$$

2.) Supongamos ahora que, P_2 es un vector propio de A asociado al valor propio $\lambda_2 \implies AP_2 = \lambda_2 P_2$

$$\implies \begin{cases} (M_2 M_1 A)P_1 = 0 \\ (M_2 M_1 A)P_2 = 0 \end{cases} \quad (c)$$

En efecto,

$$(M_2 M_1 A)(P_1) = M_2 (M_1 A P_1) = M_2 0 = 0$$

$$\implies P_1 \in \text{Ker}(M_2 M_1 A)$$

Ademas,

$$\begin{aligned} (M_2 M_1 A)(P_2) &= (I - P_2 P_2' - P_1 P_1')AP_2 \\ &= AP_2 - P_2 P_2' AP_2 - P_1 P_1' AP_2 \\ &= \lambda_2 P_2 - P_2 P_2' \lambda_2 P_2 - P_1 P_1' \lambda_2 P_2 \\ &= \lambda_2 P_2 - \lambda_2 P_2 P_2' P_2 - \lambda_2 P_1 P_1' P_2 \\ &= \lambda_2 P_2 - \lambda_2 P_2 \quad \text{pues } P_2' P_2 = 1 \quad P_1' P_2 = 0 \\ &= 0 \end{aligned}$$

$$\implies P_2 \in \text{Ker}(M_2 M_1 A)$$

Sea ahora, β_1 vector propio de A asociado al valor propio λ_2

$$\text{o sea que } A\beta_1 = \lambda_2 \beta_1$$

$$\implies \lambda_2 \text{ es valor propio de } M_2 M_1 A$$

$$\text{i.e. } \exists \beta_1' : (M_2 M_1 A)(\beta_1') = \lambda_2 \beta_1'$$

$$\text{En efecto, sea } \beta_1' = M_2 M_1 \beta_1$$

$$\implies (M_2 M_1 A)(\beta_1') = (M_2 M_1 A)(M_2 M_1 \beta_1) = (M_2 M_1 A)(I - P_2 P_2' - P_1 P_1')\beta_1$$

$$\begin{aligned}
\implies (M_2 M_1 A)(\beta_1') &= M_2 M_1 A \beta_1 - (M_2 M_1 A P_2) P_2' \beta_1 - (M_2 M_1 A P_1) P_1' \beta_1 \\
&= M_2 M_1 \lambda_2 \beta_1 - 0 P_2' \beta_1 - 0 P_1' \beta_1 && \text{por (c)} \\
&= \lambda_2 M_2 M_1 \beta_1 \\
&= \lambda_2 \beta_1'
\end{aligned}$$

Así, en general si los k vectores de regresión coinciden con k vectores de A , las restantes raíces $v_1, v_2, v_3, \dots, v_{n-k}$ coinciden con las restantes raíces de A .

b.) Supongamos que s vectores de regresión coinciden con los vectores propios de A o son combinaciones lineales de ellos. Si reenumeramos las raíces de modo que:

$$\lambda_1 \leq \lambda_2 \leq \dots \leq \lambda_{n-s}$$

Procederemos a demostrar que,

$$\lambda_i \leq v_i \leq \lambda_{i+k-s} \quad i = 1, 2, \dots, n-k$$

Establecemos primero un resultado análogo para el conjunto completo de los v 's y λ 's y ordenamos los v 's, λ 's y θ 's de modo que,

$$v_1 \leq v_2 \leq \dots \leq v_{n-k}$$

$$\lambda_1 \leq \lambda_2 \leq \dots \leq \lambda_n$$

$$\theta_1 \leq \theta_2 \leq \dots \leq \theta_{n-1}$$

Hemos visto que si $l_r = 0$, entonces λ_r es la raíz de (26), además, si λ_r y λ_{r+1} son iguales, tenemos que $\lambda_r = \lambda_{r+1}$ es una raíz de

(26). Estos son los dos únicos casos en los cuales los λ_i son raíces de (26).

Para las restantes raíces, consideremos la función:

$$f(\theta) = l_r^2 \prod_{j \neq i}^n (\theta - \lambda_j)$$

$$\implies f(\lambda_r) = l_r^2 \prod_{j \neq r}^n (\lambda_r - \lambda_j) \quad (27)$$

además,

$$\text{si } f(\lambda_r) > 0 \implies f(\lambda_{r+1}) \leq 0 \quad (28)$$

$$\text{si } f(\lambda_r) < 0 \implies f(\lambda_{r+1}) \geq 0 \quad (29)$$

La implicación (27) es evidente, demostraremos la condición (28) y de manera análoga se demuestra la condición (29).

En efecto, sabemos que,

$$\lambda_1 \leq \lambda_2 \leq \dots \leq \lambda_{r-1} \leq \lambda_r \leq \lambda_{r+1} \leq \dots \leq \lambda_n \quad (*)$$

Si $f(\lambda_r) = l_r^2 \prod_{j \neq r}^n (\lambda_r - \lambda_j) > 0$ se tiene que:

$$f(\lambda_{r+1}) = l_{r+1}^2 \prod_{j \neq r+1}^n (\lambda_{r+1} - \lambda_j)$$

Vamos a verificar que: $f(\lambda_{r+1}) \leq 0$

Sabemos que $\forall j: 1 \leq j \leq r-1; (\lambda_r - \lambda_j) > 0$ por (*) y además, que $f(\lambda_r) = l_r^2 \prod_{j=1}^{r-1} (\lambda_r - \lambda_j) \cdot \prod_{j=r+1}^n (\lambda_r - \lambda_j) > 0$

$$\implies \prod_{j=1}^{r-1} (\lambda_r - \lambda_j) > 0$$

además, como $l_r^2 \geq 0$ y $f(\lambda_r) > 0$ tenemos que:

$$\prod_{j=r+1}^n (\lambda_r - \lambda_j) > 0$$

Pero, como $\forall j: r+1 \leq j \leq n; (\lambda_r - \lambda_j) < 0$, entonces se tiene que $\prod_{j=r+1}^n (\lambda_r - \lambda_j)$ es el producto de un número par de factores negativos, es decir, $n - r = n - [(r+1) - 1]$ es par. Por otro lado,

$$f(\lambda_{r+1}) = 1_{r+1}^2 \prod_{j=1}^r (\lambda_{r+1} - \lambda_j) \prod_{j=r+2}^n (\lambda_{r+1} - \lambda_j)$$

donde $\forall j: 1 \leq j \leq r; (\lambda_{r+1} - \lambda_j) > 0$ por (*)

$$\implies \prod_{j=1}^r (\lambda_{r+1} - \lambda_j) > 0 \quad (a)$$

pero, como $\forall j: r+2 \leq j \leq n; (\lambda_{r+1} - \lambda_j) < 0$ por (*) y como $n - [(r+1) - 1]$ es par, entonces, se tiene que, $n - (r+1) = n - [(r+2) - 1]$ es impar y por lo tanto,

$$\prod_{j=r+2}^n (\lambda_{r+1} - \lambda_j) \leq 0 \quad \text{y} \quad 1_{r+1}^2 \geq 0 \quad (b)$$

$$\implies f(\lambda_{r+1}) = 1_{r+1}^2 \prod_{j=1}^r (\lambda_{r+1} - \lambda_j) \prod_{j=r+2}^n (\lambda_{r+1} - \lambda_j) \leq 0$$

$$\therefore f(\lambda_{r+1}) \leq 0$$

Puesto que $f(\theta)$ es continua, existe una raíz en cada intervalo

$$\lambda_r \leq \theta \leq \lambda_{r+1}$$

$$\text{Así:} \quad \lambda_i \leq \theta_i \leq \lambda_{i+1} \quad \forall i: i = 1, 2, \dots, n-1 \quad (30)$$

Para extender este resultado, observemos que $M_1 A$ tiene una raíz cero en adición a $\theta_1, \theta_2, \dots, \theta_{n-1}$.

$$\text{Supongamos que:} \quad \theta_t \leq 0 \leq \theta_{t+1}$$

entonces, las raíces de $M_1 A$ pueden ser ordenadas en la siguiente forma:

$$\theta_1 \leq \theta_2 \leq \dots \leq \theta_t \leq 0 \leq \theta_{t+1} \leq \dots \leq \theta_{n-1}$$

Sean ahora $\phi_1, \phi_2, \dots, \phi_{n-1}$ las raíces de $M_2(M_1A)$ junto con una raíz cero,

$$\implies \theta_1 \leq \phi_1 \leq \theta_2 \leq \phi_2 \leq \dots \leq \theta_t \leq \phi_t \leq 0 \leq \phi_{t+1} \leq \dots \leq \phi_{n-1} \leq \theta_{n-1}$$

pero, como M_2M_1A tiene dos raíces cero y tiene rango a lo sumo de $n-2$, entonces, uno de los dos ϕ_t v ϕ_{t+1} debe ser cero. Rechazando una de ellas y reenumerando, se tiene que,

$$\lambda_i \leq \phi_i \leq \lambda_{i+2} \quad \forall i: i = 1, 2, \dots, n-2$$

Si aplicamos el mismo argumento de manera sucesiva, tendremos que,

$$\lambda_i \leq v_i \leq \lambda_{i+k} \quad \forall i: i = 1, 2, \dots, n-k$$

Considerando el caso en que s vectores de regresión coinciden con los vectores propios de A o combinaciones lineales de ellos

tendremos, $\lambda_i \leq v_i \leq \lambda_{i+k-s} \quad \forall i: i = 1, 2, \dots, n-k$ (31)

COROLARIO 1:

$$r_L \leq r \leq r_U \quad \text{donde}$$

(32)

$$r_L = \frac{\sum_{i=1}^{n-k} \lambda_i \zeta_i^2}{\sum_{i=1}^{n-k} \zeta_i^2} \quad \text{y} \quad r_U = \frac{\sum_{i=1}^{n-k} \lambda_{i+k-s} \zeta_i^2}{\sum_{i=1}^{n-k} \zeta_i^2}$$

PRUEBA:

Sabemos que $\lambda_i \leq v_i \leq \lambda_{i+k-s} \quad \forall i: i = 1, 2, \dots, n-k$

Así, $\lambda_i \zeta_i^2 \leq v_i \zeta_i^2 \leq \lambda_{i+k-s} \zeta_i^2 \quad \forall i: i = 1, 2, \dots, n-k$

$$\implies \sum_{i=1}^{n-k} \lambda_i \zeta_i^2 \leq \sum_{i=1}^{n-k} v_i \zeta_i^2 \leq \sum_{i=1}^{n-k} \lambda_{i+k-s} \zeta_i^2$$

$$\longrightarrow \frac{\sum_{i=1}^{n-k} \lambda_i \zeta_i^2}{\sum_{i=1}^{n-k} \zeta_i^2} \leq \frac{\sum_{i=1}^{n-k} \nu_i \zeta_i^2}{\sum_{i=1}^{n-k} \zeta_i^2} \leq \frac{\sum_{i=1}^{n-k} \lambda_{i+k-s} \zeta_i^2}{\sum_{i=1}^{n-k} \zeta_i^2}$$

es decir; $r_L \leq r \leq r_U$

La importancia de este resultado es que éste conjunto de límites de r no depende del conjunto de vectores de regresión

B- DISTRIBUCION DE r

Hemos señalado que cuando los errores están distribuidos independientemente de las variables explicativas, estas variables pueden considerarse como fijas. Sin embargo hay un caso especial en el cual es más conveniente considerar las $\{X_i\}$ como variables aleatorias.

1.) REGRESION SOBRE VARIABLES ALEATORIAS:

Consideraremos el caso de un sistema normal multivariante. En tal sistema las regresiones son lineales y los errores están distribuidos independientemente de las variables independientes.

Se puede demostrar que si Y, X_1, X_2, \dots, X_n están distribuidas conjuntamente como normales tal que la regresión de Y sobre las $\{X_i\}$ pase por el origen y si observaciones sucesivas son independientes, entonces, r se distribuye como si los residuos Z_1, \dots, Z_n fuesen variables normales independientes o sea que el efecto de regresión desaparece del problema. De igual forma, cuando la regresión no pasa por el origen, r se distribuye como si las $\{Z_i\}$ fuesen residuos de la media muestral de n observaciones normales independientes.

Como en la práctica casi nunca se prueba la hipótesis de correlación serial de los errores cuando se sabe que observaciones sucesivas de las $\{X_i\}$ son independientes, es por ello que el caso planteado anteriormente no es el más importante.

M. S., Bartlett en 1934 demostró que si las $\{X_i\}$ no se consideran fijas, Z estará dirigida aleatoriamente en el n -espacio, si y solo si, las $\{X_i\}$ están distribuidamente como normales y sus observaciones sucesivas son independientes. En este caso, la dirección de Z está distribuida como si Z_1, Z_2, \dots, Z_n fuesen normales e independientes con la misma varianza. De igual forma se puede demostrar que si ajustamos una regresión incluyendo un término constante, r estará distribuida como si las $\{Z_i\}$ fuesen residuos de una media muestral de variables normales e independientes, aunque la regresión de la población pase o no pase por el origen.

2.) REGRESION SOBRE VARIABLES FIJAS:

Para examinar la distribución de r cuando las variables explicativas son fijas, asumiremos que los errores $\epsilon_1, \epsilon_2, \dots, \epsilon_n$ son normales independientes con varianza constante.

Transformando r como se hizo en I-A se tiene que:

$$r = \frac{\sum_{i=1}^{n-k} v_i \zeta_i^2}{\sum_{i=1}^{n-k} \zeta_i^2}$$

Como la transformación que se hizo es ortogonal, $\zeta_1, \zeta_2, \dots, \zeta_{n-k}$ son variables independientes $N(0, \sigma^2)$ donde la variación de r está limitada al rango (v_1, v_{n-k}) .

Bajo el supuesto de que las $\{v_i\}$ son desconocidas, R. L., Anderson [9] en 1942, dió la distribución exacta de r para dos casos especiales que son:

- 1.) Para $n - k$ par, las $\{v_i\}$ siendo iguales a pares.
- 2.) Para $n - k$ impar, siendo las $\{v_i\}$ iguales a pares con un valor mayor o menor que todos los otros.

Las expresiones para la Función de Distribución de r encontradas por Anderson fueron las siguientes:

$$P(r > r') = \prod_{i=1}^m \frac{(\tau_i - r')^{1/2(n-k)-1}}{\alpha_i} \quad (\tau_{m+1} \leq r' \leq \tau_m) \quad (33)$$

donde:

a.) Para $n - k$ par; Las $\{v_i\}$ forman $1/2(n-k)$ pares distintos denotados por $\tau_1 > \tau_2 > \dots > \tau_{1/2(n-k)}$ y

$$\alpha_i = \prod_{j \neq i}^{1/2(n-k)} (\tau_i - \tau_j) \quad (34)$$

b.) Para $n - k$ impar; las $\{v_i\}$ forman $1/2(n-k-1)$ pares distintos simultáneamente como anteriormente con una raíz aislada τ menor que todas las otras y

$$\alpha_i = \prod_{j \neq i}^{1/2(n-k-1)} (\tau_i - \tau_j) \sqrt{(\tau_i - \tau_j)} \quad (35)$$

Aquí en (b) $\tau > \tau_1$ se obtiene escribiendo $-r$ por r .

Anderson también encontró las fórmulas para la Función de Densidad.

Para el caso en el cual las $\{v_i\}$ son todas diferentes y $n-k$ es par, la $[1/2(n-k)-1]$ -ésima derivada de la Función de Densidad fué encontrada por Von Neumann en 1942, obteniendo: [10]

$$\frac{d^{1/2(n-k)-1}}{d_r^{1/2(n-k)-1}} f(r) = 0 \quad \text{si } m \text{ es par} \quad (36)$$

$$\text{y} \quad \frac{d^{1/2(n-k)-1}}{d_r^{1/2(n-k)-1}} f(r) = \frac{(-1)^{1/2(n-k-m-1)} [(n-k)/2 - 1]!}{\pi \sqrt{\prod_{i=1}^{n-k} (r - v_i)}}$$

si m es impar; con $v_m < r < v_{m+1}$: $m = 1, 2, \dots, n-k-1$

Estos resultados pueden ser usados en casos particulares si las $\{v_i\}$ son conocidas. Lo que significa que los vectores de regresión deben ser vectores propios de A y las raíces asociadas con los restantes $n-k$ vectores propios de A deben cumplir las condiciones de Anderson o de Von Neumann.

Los anteriores resultados pueden ser aplicados a la distribución de r_L y r_U , aportando las apropiadas $\{\lambda_i\}$.

Si F_L y F_U son las Funciones de Distribución de r_L y r_U respectivamente, se puede probar que:

$$F_L(r) \geq F(r) \geq F_U(r) \quad (37)$$

lo cual se obtiene notando que r_L y r son correspondencias en (30) y que $r_L \leq r$ siempre.

C- MOMENTOS DE r

El análisis anterior muestra que r es independiente de la escala de los $\{\zeta_i\}$ luego, podemos tomar a σ^2 igual a la unidad y r podemos expresarla como:

$$r = \frac{u}{v} \quad \text{donde} \quad u = \sum_{i=1}^{n-k} v_i \zeta_i^2 \quad \text{y} \quad v = \sum_{i=1}^{n-k} \zeta_i^2 \quad (38)$$

donde $\forall i: i = 1, 2, \dots, n-k; \zeta_i \sim N(0,1)$ independientes.

Probaremos que r y v se distribuyen independientemente; para ello primero partiremos de un teorema, el cual no será demostrado pues aparece demostrado en [1].

TEOREMA 2:

$$\text{Sea } X_m \sim N_m(0, I) \text{ y } r = \frac{\|X\|}{\|X\|} = (X'X)^{1/2}, \quad T(X) = \frac{X}{\|X\|}$$

entonces, r y $T(X)$ se distribuyen independientemente.

COROLARIO 2:

$$\text{Sea } \zeta = (\zeta_i)_{1 \leq i \leq n-k} \sim N_{n-k}(0, I), \text{ sean además, } r = \frac{u}{v}$$

$$\text{con } u = \sum_{i=1}^{n-k} v_i \zeta_i^2 = \zeta'D\zeta \text{ y } v = \sum_{i=1}^{n-k} \zeta_i^2 = \|\zeta\|^2$$

entonces, r y v son independientes.

DEMOSTRACION:

Sustituyendo ζ por X en el teorema 2, tendremos que $r = \|\zeta\|$ y además que $T(X) = T(\zeta) = \zeta/\|\zeta\|$, entonces, r y $T(\zeta)$ son independientes.

Sea $f(r) = \|\zeta\|$ y $g(T(\zeta)) = \zeta'D\zeta$ funciones de r y $T(\zeta)$ respectivamente, entonces tendremos que $f(r)$ y $g(T(\zeta))$ son independientes. i.e. r y v son independientes.

Así, se tiene que:

$$E(u^s) = E(r^s v^s) = E(r^s)E(v^s)$$

$$\implies E(r^s) = \frac{E(u^s)}{E(v^s)} \quad (39)$$

Como $\forall i: i = 1, 2, \dots, n-k; \zeta_i \sim N(0,1)$ independientes, entonces, $\forall i: i = 1, 2, \dots, n-k; \zeta_i^2 \sim \chi_1^2$ independientes, entonces,

$$v = \sum_{i=1}^{n-k} \zeta_i^2 \sim \chi_{n-k}^2 \implies \begin{cases} E(v) = n - k \\ E(v^2) = (n - k)(n - k + 2) \\ \text{etc.} \end{cases} \quad (40)$$

Por otro lado como $\forall i: i = 1, 2, \dots, n-k; v_i$ es una constante y además, $\zeta_i^2 \sim \chi_1^2$ independientes, entonces, $v_i \zeta_i^2$ son variables independientes y como,

$$u = \sum_{i=1}^{n-k} v_i \zeta_i^2$$

se tiene que el n -ésimo cumulante de $v_i \zeta_i^2$ está dado por:

$$K_s(v_i \zeta_i^2) = 2^{s-1} (s-1)! v_i^s \quad (41)$$

$$K\left(\sum_{i=1}^{n-k} v_i \zeta_i^2\right) = \sum_{i=1}^{n-k} \left[2^{s-1} (s-1)! v_i^s\right] = 2^{s-1} (s-1)! \sum_{i=1}^{n-k} v_i^s$$

En particular se tiene que:

$$\begin{aligned}
 (1.) \quad K_1(u) &= 2^{1-1} (1-1)! \prod_{i=1}^{n-k} v_i = \prod_{i=1}^{n-k} v_i \\
 (2.) \quad K_2(u) &= 2^{2-1} (2-1)! \prod_{i=1}^{n-k} v_i^2 = 2 \prod_{i=1}^{n-k} v_i^2 \\
 (3.) \quad K_3(u) &= 2^{3-1} (3-1)! \prod_{i=1}^{n-k} v_i^3 = 8 \prod_{i=1}^{n-k} v_i^3 \\
 (4.) \quad K_4(u) &= 2^{4-1} (4-1)! \prod_{i=1}^{n-k} v_i^4 = 48 \prod_{i=1}^{n-k} v_i^4 \\
 &\text{etc.}
 \end{aligned} \tag{42}$$

Luego,

$$\begin{aligned}
 E(r) &= \frac{E(u)}{E(v)} = \mu_1' = \frac{1}{n-k} \prod_{i=1}^{n-k} v_i = \bar{v} \\
 E(r^2) &= \frac{E(u^2)}{E(v^2)} = \mu_2' = \frac{2}{(n-k)(n-k+2)} \prod_{i=1}^{n-k} v_i^2
 \end{aligned}$$

Para obtener los momentos de r con respecto a su media $E(r)$, se tiene que:

$$r - \mu_1' = \frac{\prod_{i=1}^{n-k} (v_i - \bar{v}) \zeta_i^2}{\prod_{i=1}^{n-k} \zeta_i^2} = \frac{u'}{v} \tag{43}$$

Donde, nuevamente se tiene que, $(r - \mu_1')$ y v son independientes, por lo que, los momentos de $r - \mu_1'$ son iguales a los momentos de u' divididos entre los momentos de v .

Obteniendo los momentos de u' usando los cumulantes se tiene que:

$$K_s(u') = 2^{s-1} (s-1)! \prod_{i=1}^{n-k} (v_i - \bar{v})^s \tag{44}$$

En particular, tendremos que:

$$\begin{aligned}
 (1.) \quad K_1(u') &= 2^{1-1} (1-1)! \prod_{i=1}^{n-k} (v_i - \bar{v})^1 = \prod_{i=1}^{n-k} (v_i - \bar{v}) \\
 (2.) \quad K_2(u') &= 2^{2-1} (2-1)! \prod_{i=1}^{n-k} (v_i - \bar{v})^2 = 2 \prod_{i=1}^{n-k} (v_i - \bar{v})^2
 \end{aligned}$$

Luego, se tiene que:

$$(1.) \quad \text{Var}(r) = \sigma^2 = \frac{2 \sum_{i=1}^{n-k} (v_i - \bar{v})^2}{(n-k)(n-k+2)}$$

$$(2.) \quad m_3 = \frac{8 \sum_{i=1}^{n-k} (v_i - \bar{v})^3}{(n-k)(n-k+2)(n-k+4)} \quad (44a)$$

$$(3.) \quad m_4 = \frac{48 \sum_{i=1}^{n-k} (v_i - \bar{v})^4 + 12 \left\{ \sum_{i=1}^{n-k} (v_i - \bar{v})^2 \right\}^2}{(n-k)(n-k+2)(n-k+4)(n-k+6)}$$

son los Momentos Centrados de r ; los cuales se refieren a la regresión hacia el origen, de k variables aleatorias independientes.

Si el modelo estudiado incluye un término constante o sea, que si la regresión calculada incluye una media fija y si como es usual, esperamos distinguir las restantes variables independientes, entonces, $k = k' + 1$ en la expresión anterior, siendo k' el número de variables independientes adicionadas a la constante.

Las expresiones dadas anteriormente nos permiten calcular los momentos de r cuando los $\{v_i\}$ son conocidos pero, como en la práctica esto no siempre sucede, entonces, para estos casos no es posible calcular los momentos de r mediante el procedimiento anterior. Bajo esta última situación debemos expresar la suma de potencias $\sum v_i^s$ mediante cantidades conocidas o sea mediante la matriz A y las variables independientes.

Para poder calcular los momentos de r , bajo el hecho de que no se conocen los valores de los $\{v_i\}$ haremos uso del concepto de traza de una matriz y de algunas propiedades importantes de la misma.

DEFINICION

Sea S una Matriz Cuadrada, se define la traza de S , que se denota por $\text{tr}(S)$, como la suma de los elementos de su diagonal principal.

$$\text{i.e. } \forall S = (s_{ij}) \in M_{n \times n}; \quad \text{tr}(S) = \sum_{i=1}^n s_{ii}$$

PROPIEDADES :

$$1.) \quad \forall S \wedge T \in M_{n \times n} ; \operatorname{tr}(S + T) = \operatorname{tr}(S) + \operatorname{tr}(T) \quad (45)$$

$$2.) \quad \forall S \wedge T \in M_{n \times n} ; \operatorname{tr}(T \times S) = \operatorname{tr}(S \times T)$$

TEOREMA 3:

Sean S y T dos Matrices Cuadradas y sea $g \in \mathbb{N}$, entonces,

$$\operatorname{tr}\{(S+T)^g\} = \operatorname{tr}(S^g) + \binom{g}{1}\operatorname{tr}(S^{g-1}T) + \binom{g}{2}\operatorname{tr}(S^{g-2}T^2) + \dots + \operatorname{tr}(T^g)$$

Haciendo uso de los conceptos y propiedades enunciadas arriba tenemos que, si $\sigma_1, \sigma_2, \sigma_3, \dots, \sigma_m$ son las raíces propias de S, entonces,

$$\operatorname{tr}(S) = \sum_{i=1}^m \sigma_i \quad \text{y que en general se tiene que} \quad \operatorname{tr}(S^q) = \sum_{i=1}^m \sigma_i^q$$

De lo anterior, para nuestro caso tenemos que:

$$\operatorname{tr}(M \cdot A)^q = \sum_{i=1}^{n-k} v_i^q \quad (46)$$

puesto que $v_1, v_2, v_3, \dots, v_{n-k}$, en conjunto con k ceros son las raíces propias de M.A.

Sabemos que, $M = I_n - X(X'X)^{-1}X'$, luego, en los casos en los cuales las variables independientes son constantes conocidas, algunas veces es posible construir la matriz M directamente y así, obtener la media y la varianza de r en forma bastante directa, pero, en los modelos en los cuales las variables independientes toman valores arbitrarios se hace necesario efectuar una reducción, así:

a.) Para poder calcular la media de r se hace necesario efectuar la siguiente reducción:

$$\begin{aligned} \sum_{i=1}^{n-k} v_i &= \operatorname{tr}(M \cdot A) = \operatorname{tr}[\{I - X(X'X)^{-1}X'\}A] \\ &= \operatorname{tr}\{A - X(X'X)^{-1}X'A\} \\ &= \operatorname{tr}(A) - \operatorname{tr}[X(X'X)^{-1}X'A] \quad \text{por P. 1} \\ &= \operatorname{tr}(A) - \operatorname{tr}[X'AX(X'X)^{-1}] \quad \text{por P. 2} \quad (47) \end{aligned}$$

Para el cálculo de la varianza:

$$\begin{aligned} \sum_{i=1}^{n-k} v_i^2 &= \text{tr}[(MA)^2] = \text{tr}[(\{I - X(X'X)^{-1}X'\}A)^2] \\ &= \text{tr}[(A - X(X'X)^{-1}X'A)^2] \\ &= \text{tr}(A^2) - 2\text{tr}[X'A X(X'X)^{-1}] + \text{tr}\{X'AX(X'X)^{-1}\}^2 \quad (48) \end{aligned}$$

De igual forma se encuentran expresiones equivalentes para Σv_i^3 , Σv_i^4 , etc.

Si las variables independientes son ortogonales, se tiene que $X'X$ es una matriz diagonal; i.e. las expresiones anteriores pueden ser simplificadas así:

$$\text{tr}[X'AX(X'X)^{-1}] = \sum_{i=1}^k \frac{x_i'Ax_i}{x_i'x_i} \quad (49)$$

donde x_i representa al vector de la muestra de la i -ésima variable independiente. Se observa que cada término de la sumatoria tiene la forma de r en término de una de sus variables independientes. De manera similar se encuentran expresiones para:

$$\text{tr}[X'A^2X(X'X)^{-1}] = \sum_{i=1}^k \frac{x_i'A^2x_i}{x_i'x_i}, \text{ etc.} \quad (50)$$

Así, se tiene que:

$$\text{tr}[(X'AX(X'X)^{-1})^2] = \sum_{i=1}^k \left[\frac{x_i'Ax_i}{x_i'x_i} \right]^2 + 2 \sum_{i \neq j}^k \frac{(x_i'Ax_j)^2}{x_i'x_i x_j'x_j}$$

Por lo tanto, cuando los vectores de regresión son ortogonales, se tiene que:

$$\begin{aligned} \Sigma v_i &= \text{tr}(A) - \sum_{i=1}^k \frac{x_i'Ax_i}{x_i'x_i} \\ \Sigma v_i^2 &= \text{tr}(A^2) - 2 \sum_{i=1}^k \frac{x_i'A^2x_i}{x_i'x_i} + \sum_{i=1}^k \left(\frac{x_i'Ax_i}{x_i'x_i} \right)^2 + 2 \sum_{i \neq j}^k \frac{(x_i'Ax_j)^2}{x_i'x_i x_j'x_j} \quad (51) \end{aligned}$$

De estos resultados se tiene que;

1.) La Media de r está dada por;

$$E(r) = \frac{1}{n-k} \sum_{i=1}^{n-k} v_i = \frac{1}{n-k} \left[\text{tr}(A) - \sum_{i=1}^k \frac{x_i' A x_i}{x_i' x_i} \right] \quad (52)$$

2.) La Varianza de r está dada por:

$$\begin{aligned} \text{Var}(r) &= \frac{2}{(n-k)(n-k+2)} \sum_{i=1}^{n-k} (v_i - \bar{v})^2 = \frac{2}{(n-k+2)} \left[\frac{1}{n-k} \sum_{i=1}^{n-k} v_i^2 - \bar{v}^2 \right] \\ &= \frac{2}{(n-k)(n-k+2)} \left[\text{tr}(A^2) - 2 \sum_{i=1}^k \frac{x_i' A^2 x_i}{x_i' x_i} + \sum_{i=1}^k \left(\frac{x_i' A x_i}{x_i' x_i} \right)^2 + \right. \\ &\quad \left. + 2 \sum_{i \neq j}^k \frac{(x_i' A x_j)^2}{x_i' x_i x_j' x_j} \right] - \frac{2\bar{v}^2}{(n-k+2)} \quad (53) \end{aligned}$$

Cuando X es particionado en dos ó más conjuntos de variables ortogonales, podemos aplicar resultados similares.

D- FUNCION CARACTERISTICA DE u y v

Sabemos que un método alterno para obtener los Momentos de una variable aleatoria es a través del uso de su Función Característica, la cual siempre existe. Usaremos este hecho para encontrar la Función Característica conjunta de u y v .

$$\begin{aligned} \phi_{u,v}(t_1, t_2) &= E[\exp\{it_1 u + it_2 v\}] \\ &= E[\exp\{it_1 u(\zeta_1, \dots, \zeta_{n-k}) + it_2 v(\zeta_1, \dots, \zeta_{n-k})\}] \\ &= \int \exp\{it_1 u(\zeta_1, \dots, \zeta_{n-k}) + it_2 v(\zeta_1, \dots, \zeta_{n-k})\} f(\zeta_1, \dots, \zeta_{n-k}) \\ &\quad \cdot d\zeta_1 d\zeta_2 \cdots d\zeta_{n-k} \end{aligned}$$

Sabemos que $\forall j: 1 \leq j \leq n-k; \zeta_j \sim N(0,1)$ independientes, entonces,

$$f(\zeta_1, \zeta_2, \dots, \zeta_{n-k}) = (2\pi)^{-(n-k)/2} \exp\left\{-\frac{n-k}{2} \sum_{j=1}^{n-k} \zeta_j^2\right\}$$

$$\begin{aligned} \implies \Phi_{u,v}(t_1, t_2) &= (2\pi)^{-(n-k)/2} \int \dots \int \exp\left[it_1 \sum_{j=1}^{n-k} v_j \zeta_j^2 + it_2 \sum_{j=1}^{n-k} \zeta_j^2 - \right. \\ &\quad \left. - \frac{n-k}{2} \sum_{j=1}^{n-k} \zeta_j^2\right] d\zeta_1 d\zeta_2 \dots d\zeta_{n-k} \\ &= (2\pi)^{-(n-k)/2} \int \dots \int \exp\left\{-\frac{n-k}{2} \sum_{j=1}^{n-k} \zeta_j^2 (1-2it_1 v_j - 2it_2)\right\} d\zeta_1 \cdot \\ &\quad \cdot d\zeta_2 \dots d\zeta_{n-k} \end{aligned}$$

$$\text{Si hacemos } \sigma_j = \zeta_j (1-2it_1 v_j - 2it_2)^{1/2} \implies \begin{cases} \sigma_j^2 = \zeta_j^2 (1-2it_1 v_j - 2it_2) \\ d\sigma_j = (1-2it_1 v_j - 2it_2)^{1/2} d\zeta_j \end{cases}$$

$$\implies (1 - 2it_1 v_j - 2it_2)^{-1/2} d\sigma_j = d\zeta_j$$

$$\begin{aligned} \implies \Phi_{u,v}(t_1, t_2) &= \prod_{j=1}^{n-k} (1-2it_1 v_j - 2it_2)^{-1/2} (2\pi)^{-(n-k)/2} \int \dots \int \dots \int \\ &\quad \int \exp\left\{-\frac{n-k}{2} \sum_{j=1}^{n-k} \sigma_j^2\right\} d\sigma_1 \cdot d\sigma_2 \dots d\sigma_{n-k} \\ &= \prod_{j=1}^{n-k} (1 - 2it_1 v_j - 2it_2)^{-1/2} \\ &= (1-2it_2)^{1/2k} \prod_{j=1}^{n-k} (1-2it_1 v_j - 2it_2)^{-1/2} (1-2it_2)^{-1/2k} \\ &= (1-2it_2)^{1/2kn-k} \prod_{j=1}^{n-k} [(1-2it_2) - 2it_1 v_j] (1-2it_2)^{-k}^{-1/2} \\ &= (1-2it_2)^{1/2k} \left[\prod_{j=1}^{n-k} (1-2it_2) - 2it_1 v_j \right]^{-1/2} \end{aligned}$$

ya que, v_1, v_2, \dots, v_{n-k} en conjunto con k ceros son las raíces de la ecuación

$$|\mathbb{I}_n v - M \cdot A| = 0$$

Si consideramos el caso de una simple variable independiente, podemos obtener una expresión mucho más manejable que la anterior. Bajo estas condiciones, la Función Característica de u y v estará dada por:

$$\Phi_1(t_1, t_2) = \prod_{j=1}^{n-1} (1 - 2\theta_j i t_1 - 2i t_2)^{-1/2}$$

$$\implies \frac{1}{\Phi_1^2} = \prod_{j=1}^{n-1} (1 - 2\theta_j i t_1 - 2i t_2) \quad (54)$$

donde $\theta_1, \theta_2, \dots, \theta_{n-1}$ son las raíces de la ecuación:

$$\sum_{i=1}^n l_i^2 \prod_{j \neq i}^n (\theta - \lambda_j) = 0$$

por consiguiente,

$$\begin{aligned} \prod_{j=1}^{n-1} (\theta - \theta_j) &= \sum_{i=1}^n l_i^2 \prod_{j \neq i}^n (\theta - \lambda_j) \\ &= l_1^2 \prod_{j \neq 1}^n (\theta - \lambda_j) + l_2^2 \prod_{j \neq 2}^n (\theta - \lambda_j) + \dots + l_n^2 \prod_{j=1}^{n-1} (\theta - \lambda_j) \\ &= \frac{l_1^2 \prod_{j=1}^n (\theta - \lambda_j)}{(\theta - \lambda_1)} + \frac{l_2^2 \prod_{j=1}^n (\theta - \lambda_j)}{(\theta - \lambda_2)} + \dots + \frac{l_n^2 \prod_{j=1}^n (\theta - \lambda_j)}{(\theta - \lambda_n)} \\ &= \prod_{j=1}^n (\theta - \lambda_j) \left[\frac{l_1^2}{\theta - \lambda_1} + \frac{l_2^2}{\theta - \lambda_2} + \dots + \frac{l_n^2}{\theta - \lambda_n} \right] \\ &= \prod_{j=1}^n (\theta - \lambda_j) \sum_{j=1}^n \frac{l_j^2}{\theta - \lambda_j} \end{aligned}$$

para todos los valores de θ excepto para $\lambda_1, \lambda_2, \dots, \lambda_n$.

Luego, de (54) se tiene que:

$$\frac{1}{\Phi_1^2} = \prod_{j=1}^{n-1} (1 - 2i t_2 - 2\theta_j i t_1) \cdot \frac{(2i t_1)}{(2i t_1)} \quad \forall i=1, \dots, n-1$$

$$\begin{aligned}
\frac{1}{\phi_1^2} &= (2it_1)^{n-1} \prod_{j=1}^{n-1} \left[\frac{(1 - 2it_2) - 2\theta_j it_1}{2it_1} \right] \\
&= (2it_1)^{n-1} \prod_{j=1}^{n-1} \left[\frac{1 - 2it_2 - \theta_j}{2it_1} \right] \\
&= (2it_1)^{n-1} \prod_{j=1}^n \left[\frac{1 - 2it_2}{2it_1} - \theta_j \right] \sum_{j=1}^n \frac{l_j^2}{\frac{1 - 2it_2}{2it_1} - \lambda_j} \\
&= \prod_{j=1}^n (1 - 2\lambda_j it_1 - 2it_2) \sum_{j=1}^n \frac{l_j^2}{1 - 2it_2 - 2it_1 \lambda_j} \quad (56)
\end{aligned}$$

En esta última expresión se tiene que el factor de la mano izquierda corresponde a la Función Característica de u y v bajo el supuesto de que los $\{z_j\}$ son variables normales independientes; el factor de la mano derecha proporciona la modificación hecha para el ajuste de la regresión sobre una simple variable independiente.

De la expresión (56) se puede notar que:

i.) $\frac{1}{1 - 2it_2 - 2it_1 \lambda_j}$ con $j = 1, 2, \dots, n$ son las raíces propias de la matriz $B^{-1} = \{ (1 - 2it_2)I_n - 2it_1 A \}$

ii.) Los vectores de B^{-1} son los mismos que aquellos de A tal que l_1, l_2, \dots, l_n son los cosenos directores de el vector X relativo a pesos vectores propios. Así, se tiene que

$$\sum_{j=1}^n \frac{l_j^2}{1 - 2it_2 - 2it_1 \lambda_j} = \frac{X' B^{-1} X}{X' X}$$

iii.) Además, se tiene que: $\prod_{j=1}^n (1 - 2it_2 - 2it_1 \lambda_j) = |B|$

De las observaciones anteriores se tiene que, la expresión (56) puede

reducirse a:

$$\frac{1}{\phi_1^2} = |B| \frac{X'B^{-1}X}{X'X} \quad (57)$$

donde, podemos notar que el segundo factor de (57) toma la forma general de r .

Efectuando una extensión directa del proceso anterior para una variable independiente, se puede demostrar que para la regresión sobre k variables independientes, se tiene que la Función Característica es -
ta dada por :

$$\frac{1}{\phi^2} = |B_1| \prod_{s=1}^k \frac{X_s'B_s^{-1}X_s}{X_s'X_s} \quad (58)$$

donde $B_s = (1 - 2it_2)I_n - 2it_1M_{s-1} \dots \dots \dots M_2M_1A$

y donde los $M_i \forall i = 1, 2, \dots, k$ han sido definidos como en (15) de la sección A de este capítulo.

Debido a la propiedad reproductiva de los productos $M_k \dots \dots \dots M_2M_1A$ que se mencionó en la sección A de este capítulo, este resultado puede expresarse directamente como en (57).

Haciendo $t_2 = 0$ se tiene la Función Característica de u luego, la Cumulante y de aquí, los Momentos pueden ser obtenidos por medio de la expansión de $\log \phi$.

E- SELECCION DEL CRITERIO DE LA PRUEBA

Para decidir sobre el criterio apropiado para la prueba, es importante considerar el conjunto de hipótesis alternativas contra las cuales se va a discriminar. La clase de alternativa que vamos a considerar es tal que el correlograma de los errores se reduzca aproximadamente exponencialmente con separación creciente de las observaciones. Un modelo que se ajusta convenientemente para éste tipo de hipótesis es el Proceso Estacionario de Markov:

$$\epsilon_i = \rho\epsilon_{i-1} + u_i \quad \forall i: i = \dots, -1, 0, 1, \dots \quad (59)$$

donde $|\rho| < 1$ y $u_i \sim N(0, \sigma^2)$ y es independiente de $\epsilon_{i-1}, \epsilon_{i-2}, \dots$ y de u_{i-1}, u_{i-2}, \dots

La Hipótesis Nula H_0 es entonces, en (59): $H_0: \rho = 0$.

T. W. Anderson ^[10] demostró que no existe una prueba de ésta hipótesis que sea Uniformemente la más Potente contra las alternativas de (59), además, demostró sin embargo que, para ciertos sistemas de regresión con distribuciones cerradas de los errores a los dados por (59) se pueden obtener pruebas las cuales son uniformemente más potentes contra alternativas unilaterales de (59) y que proveen regiones del tipo B_1 para alternativas bilaterales de (59). Estos sistemas de regresión incluyen casos en los que los vectores de regresión son vectores constantes coincidiendo con los vectores propios de una matriz θ (o de combinaciones lineales de k de ellos) y en los cuales las distribuciones de los errores tienen una Función de Densidad de la forma:

$$f_u(u) = K \exp \left[-1/2\sigma^2 \{ (1+\rho^2)\epsilon'\epsilon - 2\rho\epsilon'\theta\epsilon \} \right] \quad (60)$$

Para tal caso la prueba uniformemente más potente de la hipótesis $H_0: \rho = 0$ contra $H_1: \rho > 0$ está dada por $r > r_0$ donde

$r = \frac{Z'\theta Z}{Z'Z}$, siendo Z el vector de los residuos de la regresión de Mínimos Cuadrados y siendo r_0 determinado para proporcionar una región crítica de tamaño apropiado.

Para el caso en que $H_0: \rho = 0$ contra $H_1: \rho \neq 0$, el tipo de prueba B_1 está dada por $r < r_2$, $r > r_3$, donde r_2 y r_3 están determinados tal que proporcionan una región crítica de tamaño apropiado y que satisfacen la relación:

$$\int_{r_2}^{r_3} r f(r) dr = E[r] \int_{r_2}^{r_3} f(r) dr \quad (61)$$

donde $f(r)$ es la Función de Densidad en el caso nulo.

Sabemos del Corolario 1 de la sección A de este capítulo que cualesquiera que sean los vectores de regresión, se tiene que:

$$\underset{L}{r} \leq r \leq \underset{U}{r}$$

Ahora, r_L y r_U tienen distribuciones idénticas en el caso nulo con distribuciones de r obtenida de los residuos de la regresión sobre ciertos vectores propios de la matriz A . Así, si hacemos $\theta = A$ en (60) podemos decir que, cuando el límite inferior r_L (ó superior r_U) del corolario es obtenido, el estadístico $r = (Z'AZ)/Z'Z$ proporciona una prueba uniformemente la más potente contra la alternativa unilateral de (58) y la cual es del tipo B_1 contra la alternativa bilateral.

La distribución de los errores para el Proceso Estacionario de Markov (59) tiene Función de Densidad:

$$f_u(u) = K \exp \left[-1/2\sigma^2 \left\{ (1+\rho^2) \sum_{i=1}^n \epsilon_i^2 - \rho^2 (\epsilon_1^2 + \epsilon_n^2) - 2\rho \sum_{i=2}^n \epsilon_i \epsilon_{i-1} \right\} \right] \quad (62)$$

Si en la ecuación (60) hacemos $\epsilon' \theta \epsilon = \sum_{i=2}^n \epsilon_i \epsilon_{i-1}$ se tiene que:

$$f_u(u) = K \exp \left[-1/2\sigma^2 \left\{ (1+\rho^2) \sum_{i=1}^n \epsilon_i^2 - 2\rho \sum_{i=2}^n \epsilon_i \epsilon_{i-1} \right\} \right] \quad (63)$$

pero, si en la ecuación (60) hacemos $\epsilon' \theta \epsilon = \sum_{i=1}^n \epsilon_i^2 - \frac{1}{2} \sum_{i=2}^n (\epsilon_i - \epsilon_{i-1})^2$

obtendremos que:

$$f_u(u) = K \exp \left[-1/2\sigma^2 \left\{ (1+\rho^2) \sum_{i=1}^n \epsilon_i^2 - \rho (\epsilon_1^2 + \epsilon_n^2) - 2\rho \sum_{i=2}^n \epsilon_i \epsilon_{i-1} \right\} \right] \quad (64)$$

En vista de que las expresiones (63) y (64) están muy próximas a la expresión (62), podemos asegurar que casi cualquier valor de θ nos proporcionará un buen estadístico r para probar la hipótesis $H_0: \rho=0$ contra las alternativas de (60). Entre los dos estadísticos que proporciona el valor de $\epsilon' \theta \epsilon$ dado anteriormente, no existe mucha diferencia, sin embargo se escoge una ligera modificación del segundo debido a razones de conveniencia en el cálculo (y debido a su similitud con el estadístico de Von Neumann δ^2/S^2 (1941)). |10|

Nuestro estadístico a adoptar está definido por:

$$d = \frac{\sum_{i=2}^n (Z_i - Z_{i-1})^2}{\sum_{i=1}^n Z_i^2} \quad (65)$$

Este estadístico es un caso especial del estadístico general, $r = (Z'AZ)/Z'Z$ visto anteriormente, en el cual

$$A = 1/2Ad = \begin{bmatrix} 1 & -1 & 0 & 0 & \dots & 0 & 0 \\ -1 & 2 & -1 & 0 & \dots & 0 & 0 \\ 0 & -1 & 2 & -1 & \dots & 0 & 0 \\ 0 & 0 & -1 & 2 & \dots & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \dots & \vdots & \vdots \\ \vdots & \vdots & \vdots & \vdots & \dots & \vdots & \vdots \\ \vdots & \vdots & \vdots & \vdots & \dots & \vdots & \vdots \\ 0 & 0 & 0 & 0 & \dots & 2 & -1 \\ 0 & 0 & 0 & 0 & \dots & -1 & 1 \end{bmatrix} 1/2 \quad (66)$$

y donde tomamos a $\theta = I - 1/2Ad$ para obtener la función de densidad (64).

Como los vectores propios de la matriz Ad y θ en la ecuación del párrafo anterior, son los mismos, entonces, cuando el vector de regresión es un vector propio de Ad , el estadístico d de (65) provee una Prueba Uniformemente más Potente contra las alternativas unilaterales de (64). En particular, la prueba dada por d es Uniformemente la más potente cuando los límites r_L y r_U son alcanzados.

La principal alternativa al uso de d ó un estadístico relacionado como un criterio de la prueba ha sido el uso de una de las estadísticas circulares, tales como:

$$r_c = \frac{\sum_{i=1}^n Z_i Z_{i-1}}{\sum_{i=1}^n Z_i^2} \quad d_c = \frac{\sum_{i=1}^n (Z_i - Z_{i-1})^2}{\sum_{i=1}^n Z_i^2} \quad (67)$$

en los cuales tomamos $Z_0 \equiv Z_n$.

T. W. Anderson demostró en 1948 que r_c y d_c proveen pruebas unifor-

mamente más potente contra alternativas unilaterales en una población circular con función de densidad:

$$f(u) = K \exp \left[-1/2\sigma^2 \left\{ (1+\rho^2) \sum_{i=1}^n \varepsilon_i^2 - 2\rho \sum_{i=1}^n \varepsilon_i \varepsilon_{i-1} \right\} \right] \quad (68)$$

En la práctica se presentan con mucha frecuencia casos en los cuales los vectores de regresión no son vectores propios, luego surge la interrogante siguiente. ¿Qué tan buenos son estos estadísticos como criterio de la prueba para estos casos?.

Evidentemente podemos esperar que:

- 1º La Potencia de la Prueba disminuya cuando los vectores de regresión se desvían de los vectores propios.
- 2º Los Coeficientes de Mínimos Cuadrados no son estimaciones de Máxima Verosimilitud en el caso nulo.
- 3º Cualquier prueba basada sobre residuos de Mínimos Cuadrados no será siempre razón de Verosimilitud para la prueba.

En contraposición con los 3 puntos anteriores se tiene que:

- 1º Aun se tiene una Prueba válida, aunque posiblemente de potencia reducida.
- 2º Es deseable por conveniencia tener una prueba basada sobre Residuos de Mínimos Cuadrados, aun cuando no sea una prueba óptima.
- 3º El estadístico r se encontrará necesariamente entre los límites r_L y r_U y cuando los mismos son alcanzados, la prueba será óptima.

F- ALGUNOS RESULTADOS ESPECIALES

Sabemos que el estadístico d de (65) es un caso especial de r de la ecuación (38) de este capítulo, donde $A = 1/2A_d$ está dada en (66). en vista de que ésta matriz A_d es simétrica, entonces, ella está com-

pletamente especificada por el triángulo superior izquierdo, por lo tanto podemos escribir:

$$A_d \doteq \begin{array}{ccc} 1 & -1 & 0 \\ & 2 & -1 \\ & & 2 \end{array} \quad (69)$$

Para obtener los momentos de d , debemos primero obtener las potencias de A_d ; así se tiene que:

$$A_d^2 \doteq \begin{array}{cccc} 2 & -3 & 1 & 0 \\ & 6 & -4 & 1 \\ & & 6 & -4 \\ & & & 6 \end{array} \quad A_d^3 \doteq \begin{array}{ccccc} 5 & -9 & 5 & -1 & 0 \\ & 19 & -15 & 6 & -1 \\ & & 20 & -15 & 6 \\ & & & 20 & -15 \\ & & & & 20 \end{array} \quad (70)$$

$$A_d^4 \doteq \begin{array}{cccccc} 14 & -28 & 20 & -7 & 1 & 0 \\ & 62 & -55 & 28 & -8 & 1 \\ & & 70 & -56 & 28 & -8 \\ & & & 70 & -56 & 28 \end{array}$$

Así, se tiene que si $Z' = (Z_1 \ Z_2 \ Z_3 \ Z_4 \ \dots \ Z_{n-2} \ Z_{n-1} \ Z_n)$, entonces:

$$\Delta Z = \begin{bmatrix} Z_1 - Z_2 \\ Z_2 - Z_3 \\ Z_3 - Z_4 \\ \vdots \\ Z_{n-2} - Z_{n-1} \\ Z_{n-1} - Z_n \\ Z_n \end{bmatrix}; \quad \Delta^2 Z = \begin{bmatrix} Z_1 - 2Z_2 + Z_3 \\ Z_2 - 2Z_3 + Z_4 \\ Z_3 - 2Z_4 + Z_5 \\ \vdots \\ Z_{n-2} - 2Z_{n-1} + Z_n \\ Z_{n-1} - 2Z_n \\ Z_n \end{bmatrix}; \quad \Delta^3 Z = \begin{bmatrix} Z_1 - 3Z_2 + 3Z_3 - Z_4 \\ Z_2 - 3Z_3 + 3Z_4 - Z_5 \\ Z_3 - 3Z_4 + 3Z_5 - Z_6 \\ \vdots \\ Z_{n-2} - 3Z_{n-1} + 3Z_n \\ Z_{n-1} - 3Z_n \\ Z_n \end{bmatrix}$$

$$\Delta^4 Z = \begin{bmatrix} Z_1 - 4Z_2 + 6Z_3 - 4Z_4 + Z_5 \\ Z_2 - 4Z_3 + 6Z_4 - 4Z_5 + Z_6 \\ Z_3 - 4Z_4 + 6Z_5 - 4Z_6 + Z_7 \\ \vdots \\ Z_{n-2} - 4Z_{n-1} + 6Z_n \\ Z_{n-1} - 4Z_n \\ Z_n \end{bmatrix} \quad (71)$$

Por otro lado tenemos que:

$$\begin{aligned} Z^t A_d Z &= \sum_{i=1}^{n-1} (\Delta Z_i)^2 \\ Z^t A_d^2 Z &= \sum_{i=1}^{n-2} (\Delta^2 Z_i)^2 + (Z_1 - Z_2)^2 + (Z_{n-1} - Z_n)^2 \\ Z^t A_d^3 Z &= \sum_{i=1}^{n-3} (\Delta^3 Z_i)^2 + 4Z_1^2 + 9Z_2^2 + Z_3^2 - 12Z_1 Z_2 - 6Z_2 Z_3 + 4Z_1 Z_3 + \text{una expresión simi-} \\ &\quad \text{lar en } Z_n, Z_{n-1}, Z_{n-2} \\ Z^t A_d^4 Z &= \sum_{i=1}^{n-4} (\Delta^4 Z_i)^2 + 13Z_1^2 + 45Z_2^2 + 17Z_3^2 + Z_4^2 - 48Z_1 Z_2 - 54Z_2 Z_3 - 8Z_3 Z_4 + 28Z_1 Z_3 + 12Z_2 Z_4 - \\ &\quad - 6Z_1 Z_4 + \text{una expresión similar en } Z_n, Z_{n-1}, Z_{n-2}, Z_{n-3} \end{aligned} \quad (72)$$

Luego, por la definición circular de d en (67), es decir,

$$d_c = \frac{Z^t A_{dc} Z}{Z^t Z} \quad (73)$$

se tiene que, los términos de corrección desaparecen, dando,

$$Z^t A_{dc}^s Z = \sum_{i=1}^n (\Delta^s Z_i)^2 \quad \text{donde } Z_{-i} \equiv Z_{n-i} \quad (74)$$

Von Neumann encontró en 1941 que las raíces propias de A_d están dadas por: [10]

$$\lambda_j = 2 \left\{ 1 - \cos \frac{\pi(j-1)}{n} \right\} \quad \forall j: j=1, 2, \dots, n \quad (75)$$

donde las primeras 4 sumas de potencias son:

$$\begin{aligned} \text{tr } A_d &= \sum_{j=1}^n \lambda_j = 2(n-1) & \text{tr } A_d^3 &= \sum_{j=1}^n \lambda_j^3 = 4(5n-8) \\ \text{tr } A_d^2 &= \sum_{j=1}^n \lambda_j^2 = 2(3n-4) & \text{tr } A_d^4 &= \sum_{j=1}^n \lambda_j^4 = 2(35n-64) \end{aligned} \quad (76)$$

El vector propio correspondiente a la raíz cero λ_1 es $\{1, 1, \dots, 1\}$, el cual es el vector de regresión correspondiente a un término constante en el modelo de regresión. Luego, para regresiones con una media ajustada por lo tanto, necesitamos solo considerar los restantes $\{\lambda_j\}$ los cuales reenumeramos de conformidad, tal que,

$$\lambda_j = 2\left(1 - \cos \frac{j\pi}{n}\right) \quad (j = 1, \dots, n-1)$$

luego, del corolario 1 tenemos que;

$$d_L \leq d \leq d_U$$

donde,

$$d_L = \frac{\sum_{i=1}^{n-k'-1} \lambda_i \zeta_i^2}{\sum_{i=1}^{n-k'-1} \zeta_i^2} \quad d_U = \frac{\sum_{i=1}^{n-k'-1} \lambda_{i+k'} \zeta_i^2}{\sum_{i=1}^{n-k'-1} \zeta_i^2} \quad (77)$$

siendo $k' = (k-1)$ el número de variables independientes en el modelo en adición al término constante.

Con la distribución de los errores asumida en B-2 los límites de la media de d están dados por:

$$\begin{aligned} E(d) \leq E(d_U) &= 2 - \frac{2}{n-k'-1} \sum_{j=k'+1}^{n-1} \cos \frac{\pi j}{n} \\ &\geq E(d_L) = 2 - \frac{2}{n-k'-1} \sum_{j=1}^{n-k'+1} \cos \frac{\pi j}{n} \end{aligned}$$

y la varianza de d en sus límites son (todo esto sin probar):

$$\text{var}(d) \leq \frac{16}{(n-k'-1)(n-k'+1)} \sum_{j=1}^{1/2(n-k'-1)} \cos^2 \frac{\pi j}{n} \quad (n-k' \text{ impar})$$

$$\begin{aligned} \text{var}(d) &\leq \frac{16}{(n-k^2-1)(n-k^2+1)} \sum_{j=1}^{\frac{1}{2}(n-k^2)-1} \cos^2 \frac{\pi j}{n} + \frac{8(n-k^2-2)}{(n-k^2-1)^2(n-k^2+1)} \cdot \\ &\quad \cos^2 \frac{(n-k^2)\pi}{2n} \quad (\text{con } n-k^2 \text{ par}) \\ &\geq \frac{16}{(n-k^2-1)(n-k^2+1)} \sum_{j=k^2+1}^{\frac{1}{2}(n-1)} \cos^2 \frac{\pi j}{n} \quad (n \text{ impar}) \quad (78) \\ &\geq \frac{16}{(n-k^2-1)(n-k^2+1)} \sum_{j=k^2+1}^{\frac{1}{2}(n-1)} \cos^2 \frac{\pi j}{n} \quad (n \text{ par}) \end{aligned}$$

II OTROS CRITERIOS PARA PROBAR LA AUTOCORRELACION DE LOS ERRORES

A- APROXIMACION A UNA BETA.

Sabemos que el estadístico d visto en (65) es aproximadamente igual a $2(1 - \rho)$, donde $-1 \leq \rho \leq 1$ luego, $0 \leq d \leq 4$; así, d se encuentra entre 0 y 2 para $\rho > 0$ y para $\rho < 0$, d se encuentra entre 2 y 4.

Si en una prueba de autocorrelación de errores se llega a que $d_L \leq d \leq d_U$, sabemos que la prueba es inconcluyente o sea que no da resultados definitivos sobre la existencia o no de la autocorrelación que se ha estado probando, luego, debemos encontrar un estadístico que nos proporcione resultados concluyentes aunque sea en forma aproximada. Un método para lograr esto consiste en efectuar un contraste aproximado. El método propuesto por Durbin y Watson [4] consiste en transformar d de forma tal que su intervalo de variación sea aproximadamente de 0 a 1 y que además se ajuste a una Distribución Beta con la misma media y la misma varianza que d .

Supongamos que hacemos $d^\alpha = d/4$ de tal forma que se distribuya según una Distribución Beta, entonces, su Función de Densidad estará dada por:

$$f(d^\alpha) = \frac{1}{\beta(p,q)} (d/4)^{p-1} (1 - d/4)^{q-1} \quad (79)$$

entonces se tiene que,

$$E(d) = \frac{4p}{p+q} \quad \text{y} \quad \text{var}(d) = \frac{16pq}{(p+q)(p+q+1)} \quad (80)$$

De (80) se obtiene que,

$$p = \frac{1}{4} (p+q)E(d) \quad \text{y} \quad p+q = \frac{E(d)^2 - \text{var}(d)}{E(d)} - 1 \quad (81)$$

De estas ecuaciones se deducen los valores de p y q , donde los valores de $E(d)$ y $\text{var}(d)$ se calculan mediante las ecuaciones (52) y (53) respectivamente con A dado por (66).

Para contrastar la correlación positiva se hace necesario calcular el valor crítico de d en la cola inferior de la distribución. Si $2p$ y $2q$ son valores enteros, el valor aproximado puede obtenerse de las tablas de razón de varianzas o z de Fisher. Si $2p$ y $2q$ no son enteros, una primera aproximación se halla usando los valores enteros más próximos, luego se obtiene ,

$$F = \frac{p(4-d)}{qd} \quad (82)$$

donde F se distribuye con razón de varianzas y luego se obtiene $z = 1/2 \cdot \log F$, la cual es la z de Fisher con $n_1 = 2q$ y $n_2 = 2p$ grados de libertad.

Si lo que nos interesa es contrastar la correlación negativa de los errores, entonces debemos reemplazar d por $4-d$ y luego efectuar el mismo procedimiento anterior.

$$B- \text{ LA APROXIMACION } d^* = a + bd_U \quad (83)$$

En 1957 E. J. Hannan propuso una aproximación al estadístico d de Durbin-Watson mediante el uso del límite d dado en (32), ya que como siempre se dá que $d \leq d_U$, la curva de distribución de d es mejor aproximada mediante la distribución de d_U . [12]

[1] Durbin y Watson propusieron en 1971 una combinación lineal de d de la forma $d^* = a + bd_U$ donde a y b son escogidos de tal forma

[1] Durbin y Watson, 1971 [5]

que d^* tenga los mismos dos primeros momentos de d para la matriz particular X en cuestión.

Esta nueva aproximación es más ventajosa que la aproximación Beta puesto que, uno puede hacer uso de los puntos de significación tabulados de d para valorar la significación i.e. si d_{α}^n es el punto de significación tabulado en las tablas dadas por Durbin-Watson (1951) para una prueba contra correlación serial positiva para valores específicos de n y k , entonces, se rechazará la hipótesis de independencia si se obtiene que $d^* < a + b d_{\alpha}^0$.

Del hecho de que,

$$E(d) = \frac{P}{n-k} \quad \text{y} \quad \text{Var}(d) = \frac{2}{(n-k)(n-k+2)} [Q - PE(d)]$$

con

$$P = \text{tr}(A) - \text{tr}[X'AX(X'X)^{-1}] \quad \text{y} \quad (84)$$

$$Q = \text{tr}(A^2) - 2\text{tr}[X'A^2X(X'X)^{-1}] + \text{tr}[\{X'AX(X'X)^{-1}\}^2]$$

donde $\text{tr}(A) = 2(n-1)$ y $\text{tr}(A^2) = 2(3n-4)$

se tiene que,

$$E(d) = \frac{2(n-1) - \text{tr}[X'AX(X'X)^{-1}]}{n-k} \quad \text{y} \quad (85)$$

$$\begin{aligned} \text{var}(d) &= \frac{2}{(n-k)(n-k+2)} [2(3n-4) - 2\text{tr}[X'A^2X(X'X)^{-1}] + \\ &\quad + \text{tr}[\{X'AX(X'X)^{-1}\}^2] - 4(n-1)^2 + 4(n-1)\text{tr}[X'AX(X'X)^{-1}] \\ &\quad + \{\text{tr} X'AX(X'X)^{-1}\}^2] \end{aligned}$$

Para calcular P y Q notamos que el (i,j) -ésimo elemento de $X'AX$ es,

$$\sum_{t=1}^{n-1} \Delta x_{it} \Delta x_{jt} \quad (86a)$$

y el (i,j) -ésimo elemento de $X'A^2X$ es,

$$\sum_{t=1}^{n-2} \Delta^2 x_{it} \Delta^2 x_{jt} + (x_{i2} - x_{i1})(x_{j2} - x_{j1}) + (x_{in} - x_{i,n-1})(x_{jn} - x_{j,n-1}) \quad (86b)$$

donde como vimos anteriormente, Δ es el operador de las primeras diferencias.

De las ecuaciones (40), (44a) y (76) se tiene que;

$$\begin{aligned}
 E(d_u) &= \frac{1}{n-k} \left[2(n-1) - 2 \sum_{j=1}^{k-1} \left\{ 1 - \cos \frac{\pi j}{n} \right\} \right] \\
 &= \frac{1}{n-k} \left[2(n-k) + 2 \sum_{j=1}^{k-1} \cos \frac{\pi j}{n} \right] \\
 &= 2 + \frac{2}{n-k} \sum_{j=1}^{k-1} \cos \frac{\pi j}{n} \quad (87)
 \end{aligned}$$

y

$$\text{var}(d_u) = \frac{4 \left[(n-2) - 2 \sum_{j=1}^{k-1} \cos^2 \frac{\pi j}{n} - 2 \left[\sum_{j=1}^{k-1} \cos \frac{\pi j}{n} \right]^2 / (n-k) \right]}{(n-k)(n-k+2)} \quad (88)$$

Luego, los valores de a y b son determinados mediante las relaciones,

$$\begin{aligned}
 E(d) &= a + bE(d_u) \\
 \text{var}(d) &= b \text{var}(d_u) \quad (89)
 \end{aligned}$$

POTENCIA DE LA PRUEBA
DE
DURBIN - WATSON

Dado el modelo de Regresión Lineal,

$$Y = X\beta + \epsilon \quad (1)$$

en el cual el vector ϵ de las perturbaciones es tal que, sus componentes ϵ_i siguen un Proceso Autoregresivo de Primer Orden; para probar la hipótesis $H_0: \rho = 0$, Durbin y Watson propusieron una prueba basada sobre el estadístico,

$$d = \frac{\sum_{i=2}^n (\hat{\epsilon}_i - \hat{\epsilon}_{i-1})^2}{\sum_{i=1}^n \hat{\epsilon}_i^2} \quad (2)$$

en el cual ,

$$\hat{\epsilon} = Y - X \hat{\beta} \quad \text{con} \quad \hat{\beta} = (X'X)^{-1}X'Y \quad (3)$$

Bajo la hipótesis H_0 Durbin y Watson encontraron un par de variables aleatorias límites dadas por (77 del Cap II), cuyas distribuciones no dependen de X y tal que, para cualquier d^* se tiene que,

$$\Pr(d_u < d^*) \leq \Pr(d < d^*) \leq \Pr(d_1 < d^*) \quad (4)$$

Con esta propiedad propusieron un nivel α para la prueba de $H_0: \rho = 0$ contra la alternativa $H: \rho > 0$, tal que la prueba se podía hacer en dos partes así:

- i) Se acepta H_0 si $d > d_u^*$
 No hay decisión si $d_1^* < d < d_u^*$
 Se rechaza H_0 si $d_1^* > d$ (5)

y donde $\Pr(d_u < d_u^*) = \Pr(d_1 < d_1^*) = \alpha$

- ii) Si no se obtiene decisión en la prueba, entonces, se utiliza un método aproximado para obtener el único punto apropiado de significación $d^*(X)$ para la matriz X que se esté usando; de aquí que,

$$\Pr(d < d^*(X)) = \alpha \quad (6)$$

Sabemos que un Proceso Estacionario de Markov (59 Cap. II) tiene Función de Densidad dada por (62 del Cap. II), por lo que la matriz de covarianza de ϵ está dada por,

$$V^{-1} = (1 + \rho^2)\mathbf{I} - 2\rho\theta + \rho(1 - \rho)C \quad (7)$$

donde

$$2\theta = \begin{bmatrix} 1 & 1 & 0 & 0 & \dots & 0 \\ 1 & 0 & 1 & 0 & \dots & 0 \\ 0 & 1 & 0 & 1 & \dots & 0 \\ \vdots & \vdots & \vdots & \vdots & \dots & \vdots \\ \vdots & \vdots & \vdots & \vdots & \dots & \vdots \\ \vdots & \vdots & \vdots & \vdots & \dots & \vdots \\ 0 & 0 & 0 & 0 & \dots & 1 \end{bmatrix} \quad \text{y} \quad C = \begin{bmatrix} 1 & 0 & 0 & \dots & 0 \\ 0 & 0 & 0 & \dots & 0 \\ 0 & 0 & 0 & \dots & 0 \\ \vdots & \vdots & \vdots & \dots & \vdots \\ \vdots & \vdots & \vdots & \dots & \vdots \\ \vdots & \vdots & \vdots & \dots & \vdots \\ 0 & 0 & 0 & \dots & 1 \end{bmatrix} \quad (7a)$$

Ademas, Anderson demostró que si V^{-1} es reemplazado por,

$$W^{-1} = (1 + \rho^2)\mathbf{I} - 2\rho\theta \quad (8)$$

y si los vectores de regresión, se encuentran dentro del espacio cubierto por k de los vectores característicos de W , una prueba basada sobre el estadístico d es una prueba similar Uniformemente más Potente de H_0 contra H_1 .

La Función de Potencia de la prueba de Durbin-Watson la estudiaremos asumiendo que la matriz de covarianza de ϵ es $\sigma^2 W$ en lugar de $\sigma^2 V$. Así, el estadístico d puede escribirse como;

$$d = \frac{\hat{\epsilon}' A \hat{\epsilon}}{\hat{\epsilon}' \hat{\epsilon}} = \frac{\epsilon' M A M \epsilon}{\epsilon' M \epsilon} = \frac{u' W^{1/2} M A M W^{1/2} u}{u' W^{1/2} M W^{1/2} u} \quad (9)$$

con $u \sim N(0, \sigma^2 \mathbf{I})$ y M dada por (5 Cap. II) y A dada por (66 Cap. II), o sea que,

$$A = 2(\mathbf{I} - \theta)$$

Luego, de (4) se tiene que,

$$\Pr(d < d^*) = \Pr\left[\frac{u' W^{1/2} M A M W^{1/2} u}{u' W^{1/2} M W^{1/2} u} < d^*\right]$$

$$\begin{aligned} \Rightarrow \Pr(d < d^*) &= \Pr[u'W^{1/2}M(A - d^*I)MW^{1/2}u < 0] \\ &= \Pr\left(\sum_{i=1}^n \pi_i \delta_i^2 < 0\right) \end{aligned} \quad (10)$$

donde $\pi_1 \geq \pi_2 \geq \dots \geq \pi_n$ son las Raíces Características de

$$\Gamma = W^{1/2}M(A - d^*I)MW^{1/2} \quad (11)$$

y donde $\{\delta_i\}_{1 < i < n}$ son tales que $\delta_i \sim N(0, \sigma^2)$

Nuestro propósito consiste en obtener límites inferiores y superiores de $\pi_i \quad \forall 1 \leq i \leq n$, los cuales son independientes de la matriz X.

Supongamos que:

$$\underline{\pi}_i \leq \pi_i \leq \bar{\pi}_i \quad (12)$$

entonces, para todo ρ, d^*, n y k dado se tiene que:

$$\Pr\left[\sum_{i=1}^{n-k} \bar{\pi}_i \delta_i^2 < 0\right] \leq \Pr\left[\sum_{i=1}^{n-k} \pi_i \delta_i^2 < 0\right] \leq \Pr\left[\sum_{i=1}^{n-k} \underline{\pi}_i \delta_i^2 < 0\right] \quad (13)$$

Sea p_j el Vector Característico correspondiente a la j -ésima raíz máxima de W , el cual por conveniencia denotaremos por :

$$p_j = Ch_j(W) \quad (14)$$

Si $p_j' = (p_{1j} \dots \dots \dots p_{nj})$, entonces, se tiene que:

$$\left. \begin{aligned} p_{1j} &= 1/\sqrt{n} \\ p_{ij} &= \frac{1}{\sqrt{n/2}} \cos \frac{(2i-1)(j-1)}{2n} \pi, \quad j=2, \dots, n \end{aligned} \right\} \quad (15)$$

Sabemos por (75) cap.II que las raíces propias de A están dadas por:

$$\lambda_j = 2 \left[1 - \cos \frac{(j-1)}{n} \pi \right]$$

y como $A = 2(I - \theta)$, las raíces características de θ quedarán expresadas por:

$$v_i = Ch_i(\theta) = \cos \frac{(i-1)}{n} \pi \quad (16)$$

de las cuales se obtienen las raíces características de W y de A .

A continuación desarrollaremos 2 métodos para derivar los límites de π_i , donde uno de los métodos proporciona un límite superior y el otro proporciona un límite inferior.

METODO 1:

El primer método consiste en encontrar los límites de las raíces características de Γ ignorando el hecho de que Γ tiene k raíces ceros, es decir que supondremos que Γ tiene n raíces. Esta técnica consiste en obtener las raíces características como extremos de una Forma Cuadrática Restringida. (Courant y Hilbert [13])

TEOREMA 1:

Para cualquier matriz simétrica A de orden n y cualquier vector columna arbitrario α_j , con $j = 1, \dots, i-1$

$$\max_{\substack{x' \alpha_j = 0 \\ j=1, \dots, i-1}} \frac{x'Ax}{x'x} \geq Ch_i(A) \qquad \min_{\substack{x' \alpha_j = 0 \\ j=i+1, \dots, m}} \frac{x'Ax}{x'x} \leq Ch_i(A) \quad (17)$$

donde $Ch_i(A)$ es la i -ésima raíz característica en orden descendente.

Demostración en Courant y Hilbert [13].

Los siguientes Lemas y Teoremas que a continuación se enuncian nos serán de gran utilidad para establecer el Límite Superior para todas las n raíces de Γ .

LEMA 1:

Sean B y C matrices de $p \times m$ ($p \geq m$), tal que $\text{rang}(B - C) = r$. Entonces, para cualquier matriz simétrica A , $i = 1, \dots, m-r$

$$i) \quad Ch_{i+r}(B'AB) \leq Ch_i(C'AC) \quad (18)$$

$$ii) \text{Ch}_i(B'AB) \geq \text{Ch}_{i+r}(C'AC)$$

DEMOSTRACION:

i) Sean $\alpha_{i+r+1}, \dots, \alpha_m$ los vectores característicos de $B'AB$ correspondientes a las $m-i+r$ menores raíces características.

La ecuación $(B - C)x = 0$ impone r restricciones sobre X , ya que $\text{rang}(B - C) = r$, entonces, para $i+r \leq m$ se tiene que:

$$\begin{aligned} \text{Ch}_i(C'AC) &\geq \min \left[\frac{x'C'ACx}{x'x} : x'\alpha_j = 0 \text{ con } j=i+r+1, \dots, m; (B-C)x=0 \right] \\ &= \min \left[\frac{x'B'ABx}{x'x} : x'\alpha_j = 0 \text{ con } j=i+r+1, \dots, m; (B-C)x=0 \right] \\ \Rightarrow \text{Ch}_i(C'AC) &\geq \min \left[\frac{x'B'ABx}{x'x} : x'\alpha_j = 0; j=i+r+1, \dots, m \right] \\ &= \text{Ch}_{i+r}(B'AB) \end{aligned}$$

$$\text{Ch}_i(C'AC) \geq \text{Ch}_{i+r}(B'AB)$$

ii) Esta parte se demuestra intercambiando B y C en la demostración anterior, puesto que $\text{rang}(B - C) = \text{rang}(C - B)$

LEMA 2:

Sea A una matriz simétrica tal que $\text{Ch}_i(A) > 0$, entonces, para cualquier matriz real D :

$$\text{Ch}_i(D'AD) \leq \text{Ch}_i(A) \cdot \text{Ch}_1(D'D) \quad (19)$$

DEMOSTRACION:

Si $\text{Ch}_i(D'AD) \leq 0$, entonces, el resultado es trivial. Asumamos que $\text{Ch}_i(D'AD) > 0$ y sean $\alpha_1, \alpha_2, \dots, \alpha_{i-1}$ los vectores característicos de A correspondientes a sus $i-1$ raíces características mayores, entonces,

$$\begin{aligned}
\text{Ch}_i(D'AD) &\leq \text{máx} \left[\frac{x'D'ADx}{x'x} : x'D'\alpha_j = 0; j=1, \dots, i-1; x \neq 0 \right] \\
&= \text{máx} \left[\frac{x'D'ADx}{x'x} : x'D'\alpha_j = 0; j=1, \dots, i-1; Dx \neq 0 \right] \\
&= \text{máx} \left[\frac{x'D'ADx}{x'x} \cdot \frac{x'D'Dx}{x'x} : x'D'\alpha_j = 0; j=1, \dots, i-1; Dx \neq 0 \right] \\
&= \text{máx} \left[\frac{Y'AY}{Y'Y} \cdot \frac{x'D'Dx}{x'x} : Y'\alpha_j = 0; j=1, \dots, i-1; Y=Dx \neq 0 \right] \\
&= \text{máx} \left[\frac{Y'AY}{Y'Y} : Y'\alpha_j = 0; j=1, \dots, i-1; Y \neq 0 \right] \text{máx} \left[\frac{x'D'Dx}{x'x}; x \neq 0 \right] \\
&= \text{Ch}_i(A) \cdot \text{Ch}_1(D'D)
\end{aligned}$$

$$\therefore \text{Ch}_i(D'AD) \leq \text{Ch}_i(A) \text{Ch}_1(D'D)$$

TEOREMA 2:

Sea $\Gamma = W^{1/2}M(A - d^*I)MW^{1/2}$ y $G = W^{1/2}(A - d^*I)W^{1/2}$; entonces,

$$i) \text{Ch}_{i+k}(\Gamma) \leq \text{Ch}_i(G) \quad (20)$$

$$ii) \text{Ch}_i(\Gamma) \geq \text{Ch}_{i+k}(G)$$

DEMOSTRACION :

i) Si hacemos $A = A - d^*I$; $B = MW^{1/2}$ y $C = W^{1/2}$ y sustituimos en el Lema 1. i se tiene que:

$$\begin{aligned}
\text{Ch}_{i+k}(B'AB) &= \text{Ch}_{i+k} \left[(MW^{1/2})'(A - d^*I)(MW^{1/2}) \right] \\
&\leq \text{Ch}_i \left[(W^{1/2})'(A - d^*I)(W^{1/2}) \right] \\
&= \text{Ch}_i(G)
\end{aligned}$$

$$\therefore \text{Ch}_{i+k}(\Gamma) \leq \text{Ch}_i(G)$$

ii) Utilizando el Lema 1 (ii) se prueba el resultado.

El teorema anterior nos permite obtener los límites de las raíces características de Γ . Los límites superiores de las k raíces características

mayores de Γ que no están limitadas por el teorema en su parte i se obtienen usando el Lema 2. Así se tiene que haciendo $A = A - d*I$ y $D = MW^{1/2}$ en el Lema 2 resulta que:

$$\text{Ch}_k(\Gamma) \leq \text{Ch}_k(A - d*I) \cdot \text{Ch}_1(W^{1/2}MW^{1/2}) \quad (21)$$

Si queremos obtener Límites Superiores que no dependan de X , además del Lema 2 necesitaremos hacer uso del siguiente Lema.

LEMA 3:

Sea $H = W^{1/2}MW^{-1}MW^{1/2}$, entonces,

$$\text{Ch}_1(H) \leq \frac{\{\text{Ch}_1(W) + \text{Ch}_n(W)\}^2}{4\text{Ch}_1(W)\text{Ch}_n(W)} \equiv \Delta \quad (22)$$

donde $\text{Ch}_1(H) \equiv \Delta$ si las columnas de X se encuentran en el espacio generado por

$$\left\{ \frac{p_1 + p_n}{\sqrt{2}}, \dots, \frac{p_k + p_{n-k+1}}{\sqrt{2}} \right\} \quad (23)$$

donde los $\{p_i\}$ están definidos como en (15).

DEMOSTRACION:

Sabemos que M es una matriz simétrica, idempotente y de rango $n-k$, entonces existe una matriz L_1 de $n \times (n-k)$ tal que:

$$\text{a.) } L_1^2 L_1 = I \quad \text{b.) } L_1 L_1^2 = M \quad (24)$$

Así:

$$\begin{aligned} \text{Ch}_1(H) &= \text{Ch}_1(W^{1/2}MW^{-1}MW^{1/2}) \\ &= \text{Ch}_1(W^{1/2}L_1L_1^2W^{-1}L_1L_1^2W^{1/2}) \\ &= \text{Ch}_1(L_1L_1^2W^{-1}L_1L_1^2W) \\ &= \text{Ch}_1(L_1^2L_1L_1^2W^{-1}L_1L_1^2WL_1) \\ &= \text{Ch}_1(L_1^2W^{-1}L_1L_1^2WL_1) \end{aligned}$$

$$\begin{aligned} \text{Ch}_1(H) &= \text{máx} \left[\frac{x^*(L_1^*W^{-1}L_1L_1^*WL_1)x}{x^*x} : x \neq 0 \right] \\ &= \text{máx} \left[\frac{x^*(L_1^*WL_1)x}{x^*(L_1^*W^{-1}L_1)x} : x \neq 0 \right] \end{aligned} \quad (25)$$

Luego, por la Desigualdad de Cauchy - Schwarz se tiene que:

$$\begin{aligned} \text{máx} \left[\frac{x^*(L_1^*WL_1)x}{x^*(L_1^*W^{-1}L_1)x} : x \neq 0 \right] &\leq \text{máx} \left[\frac{x^*(L_1^*WL_1)x}{x^*x} \cdot \frac{x^*(L_1^*W^{-1}L_1)x}{x^*x} \right] \\ \Rightarrow \text{Ch}_1(H) &\leq \text{máx} \left[\frac{x^*(L_1^*WL_1)x}{x^*x} \cdot \frac{x^*(L_1^*W^{-1}L_1)x}{x^*x} \right] \\ &= \text{máx} \left[\sum_{i=1}^n \text{Ch}_i(W)z_i^2 \cdot \sum_{i=1}^n \frac{1}{\text{Ch}_i(W)} z_i^2 : \sum z_i^2 = 1 \right] \end{aligned} \quad (26)$$

Si hacemos $\text{Ch}_i(W) = a_{n-i+1}$ y $z_i^2 = b_{n-i+1}$ y usamos la Desigualdad de Kantorovich, se tiene que:

$$\begin{aligned} \sum \text{Ch}_i(W)z_i^2 \cdot \sum \frac{1}{\text{Ch}_i(W)} z_i^2 &= \sum a_{n-i+1} b_{n-i+1} \cdot \sum \frac{b_{n-i+1}}{a_{n-i+1}} \\ &\leq \frac{(a_1 + a_n)^2}{4a_1 a_n} \\ &= \frac{[\text{Ch}_1(W) + \text{Ch}_n(W)]^2}{4\text{Ch}_1(W) \cdot \text{Ch}_n(W)} \\ &\equiv \Delta \\ \therefore 1 \leq \text{Ch}_1(H) &\leq \frac{[\text{Ch}_1(W) + \text{Ch}_n(W)]^2}{4\text{Ch}_1(W) \cdot \text{Ch}_n(W)} \equiv \Delta \end{aligned} \quad (27)$$

TEOREMA 3:

Si $\text{Ch}_i(G)$ es positiva, entonces para todo $i = 1, \dots, n$ se tiene que:

$$\text{Ch}_i(\Gamma) \leq \text{Ch}_i(G) \cdot \Delta \quad (28)$$

Las Raíces Características de G están dadas por:

$$\begin{aligned} \text{Ch}_i(G) &= \text{Ch}_i\{W^{1/2}(A - d^*I)W^{1/2}\} \\ &= \frac{2(1 - v_{n-i+1}) - d^*}{1 + \rho^2 - 2\rho v_{n-i+1}} \end{aligned} \quad (29)$$

DEMOSTRACION:

$$\begin{aligned} \text{Ch}_i(\Gamma) &= \text{Ch}_i[W^{1/2}M(A - d^*I)MW^{1/2}] \\ &= \text{Ch}_i[W^{1/2}MW^{-1}W^{1/2}W^{1/2}(A - d^*I)W^{1/2}W^{1/2}W^{-1}MW^{1/2}] \quad (*) \end{aligned}$$

Si hacemos $D = W^{1/2}W^{-1}MW^{1/2}$; $D' = W^{1/2}MW^{-1}W^{1/2}$ y

$G = W^{1/2}(A - d^*I)W^{1/2}$ en (*) se tiene que:

$$\text{Ch}_i(\Gamma) = \text{Ch}_i[D'D] \quad \text{con } D'D = W^{1/2}MW^{-1}MW^{1/2} = H$$

$$\implies \text{Ch}_i(\Gamma) \leq \text{Ch}_i(G) \cdot \text{Ch}_i(D'D) \quad \text{por Lema 2}$$

$$\text{Como } D'D = H \implies \text{Ch}_i(D'D) = \text{Ch}_i(H) \leq \Delta$$

$$\implies \text{Ch}_i(\Gamma) \leq \text{Ch}_i(G) \cdot \Delta$$

Por otro lado, sabemos que $A = 2(I - \theta)$

$W^{-1} = (1 + \rho^2)I - 2\rho\theta$ con θ dada por (7a), además,

$$\text{Ch}_i(G) = \text{Ch}_i[W^{1/2}(A - d^*I)W^{1/2}] \implies \text{Ch}_i(G) = \text{Ch}_i[W(A - d^*I)]$$

$$\implies |W(A - d^*I) - \text{Ch}_i(G)I| = 0$$

$$\implies |(A - d^*I) - \text{Ch}_i(G)W^{-1}| = 0$$

$$\implies |[2(I - \theta) - d^*I] - \text{Ch}_i(G)[(1 + \rho^2)I - 2\rho\theta]| = 0$$

$$\implies |(2 - d^*)I - \text{Ch}_i(G)(1 + \rho^2)I - 2\theta + 2\rho\text{Ch}_i(G)\theta| = 0$$

$$\implies |[(2 - d^*) - \text{Ch}_i(G)(1 + \rho^2)]I - 2\theta[1 - \rho\text{Ch}_i(G)]| = 0$$

$$\implies |\theta[2 - 2\rho\text{Ch}_i(G)] - [2 - d^* - (1 + \rho^2)\text{Ch}_i(G)]I| = 0$$

$$\implies \left| \theta - \frac{2 - d^* - (1 + \rho^2)\text{Ch}_i(G)}{2 - 2\rho\text{Ch}_i(G)} I \right| = 0$$

$$\implies v_j = \frac{2 - d^* - (1 + \rho^2)\text{Ch}_i(G)}{2 - 2\rho\text{Ch}_i(G)} \quad \text{para algun } j$$

$$\Rightarrow 2v_j - 2\rho v_j \text{Ch}_i(G) = 2 - d^* - (1 + \rho^2) \text{Ch}_i(G)$$

$$\Rightarrow [(1 + \rho^2) - 2\rho v_j] \text{Ch}_i(G) = 2 - d^* - 2v_j$$

$$\Rightarrow \text{Ch}_i(G) = \frac{2(1 - v_j) - d^*}{(1 + \rho^2) - 2v_j \rho} \quad (**)$$

Sabemos que : $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_{n-1} \geq \lambda_n$

con $\lambda_i = \text{Ch}_i(G) \quad \forall 1 \leq i \leq n$

ademas que si $\lambda_k \geq \lambda_p$ con $p > k$, se tiene que:

$$f(\lambda_k) = \frac{a - b\lambda_k}{2 - 2c\lambda_k} \quad \text{con } a = 2 - d^*; \quad b = (1 + \rho^2) \quad \text{y} \quad c = \rho$$

$$f(\lambda_p) = \frac{a - b\lambda_p}{2 - 2c\lambda_p}$$

$$\Rightarrow f(\lambda_p) \geq f(\lambda_k)$$

Esto significa que a medida que λ crece, $f(\lambda)$ decrece. Luego,

si hacemos $f(\lambda_i) = v_j$ con $1 \leq i, j \leq n$, se tiene que:

$$v_n \geq v_{n-1} \geq v_{n-2} \geq \dots \geq v_2 \geq v_1$$

por lo tanto tendremos que:

$$v_{n-i+1} = \frac{a - b\lambda_i}{2 - 2c\lambda_i}$$

$$\Rightarrow \text{Ch}_i(G) = \frac{2(1 - v_{n-i+1}) - d^*}{1 + \rho^2 - 2\rho v_{n-i+1}} \quad \text{por (**)}$$

METODO 2

Este método, para obtener las raíces características de Γ , toma en cuenta el hecho que las k primeras raíces características son nulas, por lo que son eliminadas y solo se obtendrán las restantes $n - k$ raíces.

Sabemos que, $A = 2(\mathbb{I} - \theta)$ luego, si $\rho \neq 0$ entonces,

$$A - d^*\mathbb{I} = \frac{1}{\rho} (W^{-1} - a\mathbb{I}) \quad \text{con } a = (1 - \rho)^2 + \rho d^* > 0 \quad (1')$$

En efecto,

$$\frac{1}{\rho} (W^{-1} - a\mathbb{I}) = \frac{1}{\rho} \left[(1 + \rho^2)\mathbb{I} - 2\rho\theta - [(1 - \rho)^2 + \rho d^*]\mathbb{I} \right]$$

ya que $W^{-1} = (1 + \rho^2)\mathbb{I} - 2\rho\theta$ y por (1')

$$\begin{aligned} \Rightarrow \frac{1}{\rho} (W^{-1} - a\mathbb{I}) &= \frac{1}{\rho} \left[(1 + \rho^2)\mathbb{I} - 2\rho\theta - (1 + \rho^2)\mathbb{I} + 2\rho\mathbb{I} - \rho d^*\mathbb{I} \right] \\ &= \frac{1}{\rho} \left[2\rho\mathbb{I} - 2\rho\theta - \rho d^*\mathbb{I} \right] \\ &= 2(\mathbb{I} - \theta) - d^*\mathbb{I} \\ &= A - d^*\mathbb{I} \end{aligned}$$

De aquí se tiene que:

$$\Gamma = \frac{1}{\rho} \left[W^{1/2} M (W^{-1} - a\mathbb{I}) M W^{1/2} \right] \quad (30)$$

Como queremos eliminar las k primeras raíces características de Γ , las cuales son nulas, debemos particionar la matriz Γ . Para ello, usaremos como en el Capítulo II, acápite A el hecho de que como M es una matriz simétrica, semi definida positiva e idempotente, existe una matriz ortogonal L tal que:

$$L^T M L = \begin{bmatrix} \mathbb{I}_{n-k} & \vdots & 0 \\ \dots & \dots & \dots \\ 0 & \vdots & 0 \end{bmatrix} \quad (31)$$

Sea L' la matriz de los Vectores Propios de M tal que $L = (L_1, L_2)$, entonces,

$$M = L \begin{bmatrix} \mathbb{I}_{n-k} & \vdots & 0 \\ \dots & \dots & \dots \\ 0 & \vdots & 0 \end{bmatrix} L' = L_1 L_1' \quad (32)$$

Así, las Raíces Características de Γ son iguales a las Raíces Características de:

$$\begin{bmatrix} \tilde{\Gamma} & 0 \\ 0 & 0 \end{bmatrix} = \begin{bmatrix} \frac{1}{\rho} [L_1^* W^{-1} L_1 - aI] L_1^* W L_1 & 0 \\ 0 & 0 \end{bmatrix} \quad (33)$$

En efecto, sabemos que,

$$\begin{aligned} \Gamma &= \frac{1}{\rho} W^{1/2} M (W^{-1} - aI) M W^{1/2} \\ \Rightarrow \Gamma &= \frac{1}{\rho} W^{1/2} L_1 L_1^* (W^{-1} - aI) L_1 L_1^* W^{1/2} \quad \text{por (32)} \\ &= \frac{1}{\rho} W^{1/2} L_1 (L_1^* W^{-1} L_1 - aL_1^* I L_1) L_1^* W^{1/2} \\ &= \frac{1}{\rho} W^{1/2} L_1 (L_1^* W^{-1} L_1 - aI) L_1^* W^{1/2} \end{aligned}$$

Luego,

$$\begin{aligned} |\Gamma - \lambda I| = 0 &\Rightarrow \left| \frac{1}{\rho} W^{1/2} L_1 (L_1^* W^{-1} L_1 - aI) L_1^* W^{1/2} - \lambda I \right| = 0 \\ &\Rightarrow \left| \frac{1}{\rho} W^{1/2} L_1 (L_1^* W^{-1} L_1 - aI) L_1^* W^{1/2} - \lambda I \right| \left| W^{1/2} L_1 \right| = 0 \\ &\Rightarrow \left| \frac{1}{\rho} W^{1/2} L_1 (L_1^* W^{-1} L_1 - aI) L_1^* W L_1 - \lambda I W^{1/2} L_1 \right| = 0 \\ &\Rightarrow \left| W^{1/2} L_1 \right| \cdot \left| \frac{1}{\rho} (L_1^* W^{-1} L_1 - aI) L_1^* W L_1 - \lambda I \right| = 0 \\ &\Rightarrow \left| \frac{1}{\rho} (L_1^* W^{-1} L_1 - aI) L_1^* W L_1 - \lambda I \right| = 0 \\ \therefore \tilde{\Gamma} &= \frac{1}{\rho} (L_1^* W^{-1} L_1 - aI) L_1^* W L_1 \end{aligned}$$

Ahora, nos corresponde obtener los límites de las raíces características de $\tilde{\Gamma}$. Para tal efecto haremos uso de dos teoremas que limitan las raíces del producto de 2 matrices y de la suma de 2 matrices en términos del producto de las raíces de las matrices individuales y

de la suma de las raíces de las matrices individuales respectivas.
Estos 2 teoremas se enuncian sin demostración y son

TEOREMA 4: (ANDERSON Y DAS GUPTA [13])

Sean A y B dos matrices simétricas de $m \times m$ definida positiva y semidefinida positiva respectivamente, entonces,

- i) $Ch_{i+j-m}(A \cdot B) \geq Ch_i(A) \cdot Ch_j(B)$ donde $i+j \geq m+1$
con $i, j = 1, \dots, m$ (34)
- ii) $Ch_{i+j-1}(A \cdot B) \leq Ch_i(A) \cdot Ch_j(B)$ donde $i+j \leq m+1$
con $i, j = 1, \dots, m$

TEOREMA 5: (AMIR - MOEZ y FASS [14])

Sean A y B dos matrices simétricas de $m \times m$, entonces,

- i) $Ch_{i+j-m}(A + B) \geq Ch_i(A) + Ch_j(B)$ donde $i+j \geq m+1$
con $i, j = 1, \dots, m$ (35)
- ii) $Ch_{i+j-1}(A + B) \leq Ch_i(A) + Ch_j(B)$ donde $i+j \leq m+1$
con $i, j = 1, \dots, m$

TEOREMA 6:

Dadas las $n - k$ raíces de Γ distintas de cero que son raíces de $\tilde{\Gamma}$, entonces,

$$Ch_i(\tilde{\Gamma}) \geq Ch_{i+k}(G) \quad (36)$$

si los vectores de regresión se encuentran dentro del espacio generado por los vectores P_{n-k+1}, \dots, P_n , entonces, se da la igualdad.

DEMOSTRACION:

Sabemos que la matriz $L'WL$ dada en (33) es definida positiva, luego, por el teorema 5 se tiene que:

$$Ch_{i+j-m}(\tilde{\Gamma}) = Ch_{i+j-m} \left[\frac{1}{\rho} (L_1'W^{-1}L_1 - aI) L_1'WL_1 \right]$$

$$\begin{aligned} \text{Ch}_{i+j-m}(\hat{\Gamma}) &= \frac{1}{\rho} \left\{ \text{Ch}_{i+j-m} \left[L_i' W^{-1} L_i \cdot L_i' W L_i - a L_i' W L_i \right] \right\} \\ &\geq \frac{1}{\rho} \left[\text{Ch}_i (L_i' W^{-1} L_i \cdot L_i' W L_i) - a \text{Ch}_j (L_i' W L_i) \right] \end{aligned}$$

donde $m = n - k$, $i, j = 1, \dots, m$ y como $i + j \geq m + 1$

$$m + 1 = n - k + 1 \implies j \geq n - k + 1 - i = n - k - i + 1$$

$$\implies \text{Ch}_{i+j-n+k}(\hat{\Gamma}) \geq \frac{1}{\rho} \left[\text{Ch}_i (L_i' W^{-1} L_i \cdot L_i' W L_i) - a \text{Ch}_{n-k-i+1} (L_i' W L_i) \right]$$

Pero, por la Desigualdad de Kantorovich sabemos que,

$$\text{Ch}_i (L_i' W^{-1} L_i \cdot L_i' W L_i) \geq 1$$

ademas, por la Desigualdad de Cauchy se tiene que:

$$\text{Ch}_{n-k-i+1} (L_i' W L_i) \leq \text{Ch}_{n-k-i+1} (W)$$

Así, tenemos que:

$$\begin{aligned} \text{Ch}_i(\hat{\Gamma}) &\geq \frac{1}{\rho} \left[1 - a \text{Ch}_{n-k-i+1} (W) \right] \quad \text{con } i = 1, \dots, n-k \\ &= \text{Ch}_{i+k} \left[W^{1/2} (A - d^* I) W^{1/2} \right] \\ &= \text{Ch}_{i+k} (G) \end{aligned}$$

Los dos métodos vistos nos permiten encontrar las raíces características de la matriz $\hat{\Gamma}$ bajo el supuesto de que el vector de regresión no incluye ningún término constante. Se demuestra que, si el vector de regresión incluye un término constante, también se pueden usar los métodos vistos solo que se deben hacer algunos cambios en algunos de los teoremas usados.

CONCLUSIONES

En el desarrollo de este trabajo hemos tenido que superar grandes dificultades, entre las cuales la principal de ellas ha sido la obtención de la bibliografía necesaria puesto que, en nuestro medio existe muy poco material al respecto, además, de lo relativamente reciente que resulta el estudio del problema que nos ocupa.

En el análisis de nuestro modelo supusimos que el mismo cumplía con cuatro hipótesis básicas, pero, en la realidad no siempre se cumple alguna o algunas de las hipótesis impuestas en el modelo. En el caso de que no se cumpla la primera hipótesis, entonces, se presenta el problema conocido como "Multicolinealidad"; en el caso de que sea la segunda hipótesis la que no se cumpla, entonces, se presenta el problema conocido como "Heteroscedasticidad"; si no se cumple la tercera, entonces, se presenta el problema conocido como "Variables Retardadas" y por último, si no se cumple la cuarta hipótesis, entonces, se presenta el problema que nos ocupa llamado "Autocorrelación de las Perturbaciones".

Cuando se tiene una sucesión de datos muestrales, antes de tratar de ajustar los datos a un modelo de regresión lineal debemos probar si los terminos de errores de la muestra son independientes o no. Como los errores en cualquier caso particular son desconocidos, entonces, basamos nuestra prueba sobre los residuos de la regresión calculada.

Se ha demostrado que para probar la hipótesis de independencia entre los errores, basandonos sobre la independencia de los residuos, no es posible el uso de las pruebas ordinarias de independencia, por lo tanto, se ha

tenido que recurrir al uso de otras pruebas poco comunes de las cuales, presentamos tres, de ellas. El primero de los criterios que presentamos llamado Criterio de Durbin-Watson se basa en el criterio del cociente de Máxima Verosimilitud de las Perturbaciones; este criterio puede conducirnos a que la prueba sea inconclusa esto es, no se obtienen resultados definitivos sobre la existencia o no de la autocorrelación de los errores. Cuando esta situación se presenta, debemos buscar otro criterio que nos conduzca a alguna conclusión; para ello proponemos dos criterios, donde no existe posibilidad de que la prueba sea inconclusa.

Sabemos que existen otros criterios para probar la Autocorrelación de las Perturbaciones que, aunque no proporcionan una Función de Potencia que sea Uniformemente la más Potente de las pruebas frente a la Prueba Bilateral de Durbin-Watson, su uso proporciona pruebas concluyentes.

Después de finalizado nuestro análisis sobre el tema que ha sido el motor de nuestro trabajo podemos concluir lo siguiente:

- 1.) Aunque el Criterio de Durbin-Watson nos proporciona una Función Potencia que es la Función de Potencia Uniformemente la más Potente, en algunos casos proporciona pruebas inconcluyentes.
- 2.) Todos los criterios que se han estudiado hasta la actualidad se basan en el Criterio del Cociente de los Residuos.
- 3.) Para poder usar el Método de los Mínimos Cuadrados en el proceso de regresión es necesario que los errores sean independientes seriálmen-

te **pués**, de lo contrario nuestras estimaciones en los problemas abordados serán sesgadas, lo cual nos conducirá a conclusiones erradas.

Sería interesante efectuar un estudio detallado de los otros criterios que hasta hoy existen para probar la independencia de las perturbaciones y comparar sus Funciones de Potencia.

Nos preguntamos si es posible encontrar un criterio para probar la independencia entre las perturbaciones que siempre nos conduzca a resultados concluyentes y que además, proporcione una Función de Potencia que sea comparable con la de Durbin-Watson.

Sería prudente investigar que sucedería si además de no cumplirse la hipótesis de independencia entre las perturbaciones, no se cumplen algunas de las otras hipótesis. ¿ Serán válidas las fórmulas utilizadas para calcular las estimaciones de los parámetros? ¿ Se podría obtener algún tipo de prueba o estadístico que nos permita estudiar esta situación?. De no ser válidas las fórmulas usadas para calcular las estimaciones de los parámetros; ¿ Que método alternativo se podría presentar para efectuar dichas estimaciones de modo que las mismas sean las mejores?.

Estas y otras interrogantes planteadas quedan pendientes y rogamos al Todopoderoso que nos proporcione la capacidad y facilidad para poder deslindar algunas de ellas.

BIBLIOGRAFIA

- [1] ROBB. J., MUIRHEAD "Aspects of Multivariate Statistical Theory" John Willy & Sons Inc. New York 1982.
- [2] JOHN A., TILLMAN " The Power of the Durbin-Watson Test" Econometrica Vol. 43 N°5 - 6 1975.
- [3] J. DURBIN and G. S. WATSON "Testing for Serial Correlation in Least Squares Regression I" Biometrika 1950 vol. 37.
- [4] J. DURBIN; G. S. WATSON "Testing for Serial Correlation in Least Squares Regression II Biometrika 1951 vol. 38.
- [5] J. DURBIN; G. S. WATSON "Testing for Serial Correlation in Least Squares Regression III" Biometrika 1971 vol. 58.
- [6] KENNETH J. WHITE and N. E. SAVIN "The Durbin-Watson Test for Serial Correlation with extreme Sample Sizes or Many Regressors" Econométrica, 1977, vol. 45, N°8.
- [7] G. S., MADDALA "Econometría" M^C Graw - Hill, 1985.
- [8] ANGEL ALCAIDE "Lecturas de Econometría" Biblioteca de Ciencias Económicas Editorial Gredos S. A., Madrid, 1972.
- [9] R. L. ANDERSON Ann. Math. Statist. 1942, vol. 13, N°1.

