

**INFERENCIA EN REGRESION  
NO LINEAL**

**SERGIO YANEZ CANAL**

**Abril 1990**

**UNIVERSIDAD NACIONAL DE COLOMBIA  
SECCIONAL MEDELLIN  
FACULTAD DE CIENCIAS  
DEPARTAMENTO DE MATEMATICAS**

*Profesor Asociado*



**UNIVERSIDAD NACIONAL**  
**BIBLIOTECA CENTRAL**

I  
519.536  
y15

## TABLA DE CONTENIDO

	Pág.
RESUMEN	
1. INTRODUCCION	1
2. LOS MINIMOS CUADRADOS EN REGRESION NO LINEAL	4
2.1 LA APROXIMACION LINEAL	6
2.2 INFERENCIA ASINTOTICA	7
3. EL SESGO EN REGRESION NO LINEAL	9
4. APLICACION	11
5. CONSIDERACIONES FINALES	18
BIBLIOGRAFIA	20
APENDICE	23

UNIVERSIDAD NACIONAL  
BIBLIOTECA CENTRAL

30287

## INFERENCIA EN REGRESION NO LINEAL

SERGIO YANEZ CANAL

UNIVERSIDAD NACIONAL DE COLOMBIA

SECCIONAL MEDELLIN

### RESUMEN

Bajo el supuesto de errores i.i.d.  $N(0, \sigma^2)$  los estimadores mínimo-cuadráticos de regresión lineal son los mejores estimadores lineales insesgados. Bajo idénticos supuestos estos resultados son ciertos en regresión no lineal, pero asintóticamente. Ahora bien, en muestras pequeñas, que es el caso común en la práctica, ninguna de dichas propiedades se cumple. Se presenta en este trabajo el porcentaje de sesgo de las estimaciones como medida de validez de las inferencias asintóticas. Se ilustra el método con un modelo de demanda residencial de energía eléctrica para Medellín.

Medellín, abril 1990

## 1. INTRODUCCION

Sea,

$$y = X\beta + \epsilon \quad y = x\beta + \epsilon \quad (1.1)$$

un modelo de regresión lineal donde los  $\epsilon_i, i=1, \dots, n$  son independientes e idénticamente distribuidos. (i.i.d)

$N(0, \sigma^2)$ . Bajo estas condiciones se sabe que los estimadores mínimo-cuadráticos (M.C.) de los parámetros son los mejores estimadores lineales insesgados, normalmente distribuidos y de mínima varianza, cualquiera sea el tamaño muestral "n".

Así se tienen los siguientes resultados:

$$\beta_M = (X'X)^{-1}X'Y \quad (1.2)$$

$$\beta_M \sim N(\beta, \sigma^2(X'X)^{-1}) \quad (1.3)$$

donde  $\beta_M$  es el vector de estimadores M.C. de  $\beta$ .

A partir de (1.3) se pueden construir todas las inferencias usuales sobre los parámetros de regresión.

Para el caso de la predicción de una nueva observación  $Y_0$  correspondiente a  $x_0$ , esto es

$$Y_0 = x_0\beta \quad (1.4)$$

se sabe que

$$\sigma^2(Y_0) = \sigma^2(1 + x_0'(X'X)^{-1}x_0) \quad (1.5)$$



y de aquí se puede construir un intervalo de confianza para la predicción utilizando un estadístico "t".

Los resultados anteriores son bien conocidos y los detalles se pueden ver en cualquier libro básico de regresión como Neter et al (1983).

Ahora bien, para modelos no lineales de regresión, los estimadores M.C. se obtienen iterativamente por medio de una aproximación lineal y como muestran Draper & Smith (1981) los resultados obtenidos bajo la condición de errores i.i.d.  $N(0, \sigma^2)$  son análogos al caso lineal pero de carácter asintótico.

Seber & Wild (1989) señalan que el carácter asintótico de dicha aproximación obliga a analizar qué pasa en el caso de muestras pequeñas, pues se conoce, que inclusive bajo la condición de que los errores sean i.i.d.  $N(0, \sigma^2)$ , los estimadores M.C. son sesgados, no se distribuyen normalmente y no son de mínima varianza.

La situación de muestras pequeñas es el caso más corriente en la práctica, lo cual amerita su estudio, pues a diferencia de los estimadores M.C. en un modelo lineal, en el caso no lineal dichos estimadores tienen propiedades desconocidas para muestras finitas.

Siguiendo a Ratkowsky (1983) se mostrará en este trabajo como el sesgo se puede utilizar como una medida del grado de no linealidad del modelo, para determinar la validez

de las inferencias cuya justificación reposa en los supuestos de linealidad.

En general, se puede afirmar que el trabajo con modelos no lineales de regresión procede por analogía con los modelos lineales, en busca de las propiedades óptimas de los M.C. en este último caso. Por ello es importante cuantificar el grado de no linealidad en muestras pequeñas y determinar hasta que punto se puede tolerar dicha medida para que no se afecten las inferencias, que como ya se mencionó dependen exclusivamente de los supuestos de linealidad.

## 2. LOS MINIMOS CUADRADOS EN REGRESION NO LINEAL

$$\text{Sea, } y_i = f(x_i; \beta) + \epsilon_i \quad (i=1, 2, \dots, n) \quad (2.1)$$

donde  $y_i$  es la variable dependiente,  $\epsilon_i$  es el error aleatorio con  $E(\epsilon_i) = 0$ ,  $x_i$  es un vector  $N \times 1$  de variables independientes y  $\beta$  es un vector  $K \times 1$  de parámetros.

Se considerarán modelos de regresión intrínsecamente no lineales, es decir que no pueden ser transformados en modelos lineales.

Estos modelos son de gran aplicabilidad en diversos campos. Como ejemplo se pueden mencionar los modelos de crecimiento no lineales, ver Draper & Smith (1981), de importancia en biología, ecología, demografía, química y economía entre otros. El modelo logístico, en particular, es un caso de dichos modelos que ilustra el carácter de no linealidad intrínseca:

$$Y = \frac{\alpha}{1 + \exp(\beta - \tau x)} \quad (2.2)$$



Otro ejemplo, es el siguiente modelo de demanda de energía eléctrica en el sector residencial, que se usará en la sección 4 de este trabajo:

$$Q = k \left[ \alpha \quad C^{\beta/D} \quad Y^{\tau} \right]^{D/(D-\beta)} + \epsilon \quad (2.3)$$

Obsérvese que en (2.2) y en (2.3) el número de parámetros no coincide con el número de variables independientes y por lo tanto para los modelos no lineales, en general, no existe una forma matricial equivalente a (1.1). Los estimadores M.C. de  $\beta$ , escritos  $\beta_M$ , minimizan la suma de cuadrados de los errores

$$S(\beta) = \sum_1 [y_i - f(x_i; \beta)]^2 \quad (2.4)$$

pero en el caso no lineal se obtienen por medio de una aproximación lineal, que se presenta en (2.1). Los resultados numéricos se obtienen por medio de métodos iterativos, variantes del método de Gauss-Newton.

Los estimadores M.C. en regresión no lineal, son utilizados para hacer inferencias aproximadas aplicando resultados asintóticos a muestras finitas. Se puede probar que bajo ciertas condiciones (no se exige normalidad de los errores) son estimadores consistentes y asintóticamente normales, ver por ejemplo Judge et al (1982). Si se asume normalidad de los errores entonces los estimadores M.C. son también estimadores máximo-verosímiles.



## 2.1 La aproximación lineal

Se usará la siguiente notación  $f_1(\beta) = f(x_1; \beta)$ , (2.5)

$$f(\beta) = (f_1(\beta), f_2(\beta), \dots, f_n(\beta))' \quad (2.6)$$

$$F(\beta) = \frac{\delta f(\beta)}{\delta \beta'} = \left[ \left( \frac{\delta f_1(\beta)}{\delta \beta_j} \right) \right]_{n \times k} \quad (2.7)$$

$$F = F(\beta^*) \quad ; \quad F_M = F(\beta_M) \quad (2.8)$$

donde  $\beta^*$  es el verdadero valor de  $\beta$  y  $\beta_M$  es el estimativo mínimo cuadrático.

La idea es aproximar  $f_1(\beta)$  por el término lineal de la expansión en series de Taylor, que es la mejor aproximación lineal

$$f_1(\beta) \approx f_1(\beta^*) + \sum_{j=1}^K \left[ \frac{\delta f_1(\beta)}{\delta \beta_j} \right] (\beta_j - \beta_j^*) \quad (2.9)$$

$$f(\beta) \approx f(\beta^*) + F(\beta - \beta^*) \quad (2.10)$$

sustituyendo el lado derecho en  $Y = f(\beta) + \epsilon$ , tenemos

$$Y = f(\beta^*) + F(\beta - \beta^*) + \epsilon \quad (2.11)$$

$$Y - f(\beta^*) + F\beta^* = F\beta + \epsilon \quad (2.12)$$

$$Y^* = F\beta + \epsilon \quad (2.13)$$

donde  $Y^* = Y - f(\beta^*) + F\beta^*$

Malinvaud (1970) llama a (2.13) el pseudo-modelo lineal, que es el análogo de (1.1) en regresión lineal y así se obtiene

$$\beta_M = (F'F)^{-1}F'Y^* \quad (2.14)$$

expresión análoga a (1.2)

El valor de  $\beta_M$  suficientemente cercano a  $\beta^*$  se obtiene por métodos iterativos a partir de (2.11) minimizando la suma de cuadrados (2.4). Una completa descripción de los distintos métodos computacionales para M.C. no lineales, así como una discusión sobre los valores iniciales se puede encontrar en Seber & Wild (1989).

$F$  se puede reemplazar por  $F_M$ , para estimar.

Es claro de esta aproximación, que existe una discrepancia entre  $\beta_M$  y  $\beta^*$ , de la cual podemos obtener el sesgo de los estimativos de los parámetros en el método M.C. en regresión no lineal. En la sección 3 se examinará dicho sesgo.

## 2.2 Inferencia asintótica

Dado que los  $\epsilon_i$  sean i.i.d.  $N(0, \sigma^2)$  en (2.1) se puede probar para  $n$  grande

$$\beta_M \sim N_k(\beta, \sigma^2(F'F)^{-1}) \quad (2.15)$$

resultado análogo a (1.3) y a partir del cual se pueden construir todas las inferencias usuales sobre los parámetros de regresión.  $F$  se estima por  $F_M$  y  $\sigma^2$  por  $s^2 = S(\beta_M)/(n-k)$ .

El resultado (2.15) es de carácter asintótico y su aplicación para muestras pequeñas depende del grado de no

linealidad del modelo que se medirá con base en el sesgo de los parámetros en la sección 3.

El resultado (2.15) se puede encontrar en cualquier libro básico de regresión como Neter et al (1983). Para el caso de la predicción de una nueva observación  $Y_0$  correspondiente a  $x_0$ , Seber & Wild (1989) partiendo de la expansión en series de Taylor.

$$f(x_0; \beta_M) \approx f(x_0; \beta) + f_{\beta}'(\beta_M - \beta) \quad (2.16)$$

$$f(x_0; \beta_M) - f(x_0; \beta) \approx f_{\beta}'(\beta_M - \beta) \quad (2.17)$$

donde  $f_{\beta}'$  es el vector  $1 \times K$  de primeras derivadas de  $f(x_0; \beta)$  con respecto a cada uno de los elementos de  $\beta$ , prueba que

$$\sigma^2(Y_0) = \sigma^2(1 + f_{\beta}'(F'F)^{-1}f_{\beta}) \quad (2.18)$$

resultado análogo a (1.5) y del cual se puede construir un intervalo de confianza para la predicción utilizando un estadístico "t".

Así, también, estos resultados son ciertos solo asintóticamente y su validez en muestras pequeñas dependerá del grado de no-linealidad del modelo.

### 3. EL SESGO EN REGRESION NO LINEAL

Box (1971) partiendo de una expansión del modelo en series de Taylor hasta el término de segundo orden, encontró la siguiente fórmula para el sesgo de  $\beta_M$

$$\text{sesgo}(\beta_M) = E(\beta_M - \beta^*) = - \frac{\sigma^2}{2} (\sum_u f_u f_u')^{-1} \sum_t f_t t_r \left[ (\sum_u f_u f_u')^{-1} H_t \right] \quad (3.1)$$

donde  $f_u (= f_t)$  es el vector  $k \times 1$  de primeras derivadas de  $f(X_t; \beta)$  y  $H_t$  es la matriz  $k \times k$  de segundas derivadas con respecto a cada uno de los elementos de  $\beta$ , evaluados en  $X_t$ , donde  $t=1, 2, \dots, n$ . En la práctica  $s^2$  y  $\beta_M$  son usados en lugar de  $\sigma^2$  y  $\beta$ .

Para la predicción  $Y_o$ , Box (1971) derivó una fórmula para

el sesgo de  $Y_o$ , a partir del sesgo ( $\beta_M$ )

$$\text{sesgo}(Y_o) = E(Y_o - f(x_o; \beta)) = f_o' \text{sesgo}(\beta_M) + \frac{1}{2} t_r [H_o \text{Cov}(\beta_M)] \quad (3.2)$$

donde  $\text{Cov}(\beta_M) = s^2 (F_M' F_M)^{-1}$  es la matriz de varianza-covarianza de  $\beta_M$  asintótica dada por (2.15) y que es calculada por la mayoría de los algoritmos cuasi-Newton



utilizados para encontrar los estimadores M.C. en regresión no lineal.

Ratkowsky(1983), muestra por medio de estudios de simulación que el porcentaje de sesgo

$$\% \text{sesgo}(\beta_{IM}) = \frac{\text{sesgo}(\beta_{IM})(100)}{\beta_{IM}} \quad (3.3)$$

es una cantidad útil en la medida en que un valor absoluto en exceso del 1%, es una buena regla práctica para determinar el grado de no linealidad del modelo. En otras palabras si el porcentaje de sesgo en valor absoluto es mayor que 1%, las inferencias asintóticas de la sección 3 no son válidas. Ratkowsky (1983), muestra también que en el caso de la proyección

$$\% \text{sesgo}(Y_o) = \frac{\text{sesgo}(Y_o)(100)}{Y_o} \quad (3.4)$$

se puede utilizar en el mismo sentido (3.3) para decidir si las inferencias asintóticas de la sección 3 son válidas. Obsérvese el término de la derecha en (3.2), el primer sumando comparado con (2.17) muestra que esta es la contribución del sesgo( $\beta_M$ ) al sesgo( $Y_o$ ) y el segundo sumando será la contribución debida a la aproximación lineal (2.17).

#### 4. APLICACION

El modelo que se usará es tomado de: Vélez, C.E., Botero, J. y Yáñez, S., (1987). La demanda residencial de Energía Eléctrica en dos ciudades colombianas: un modelo económico. Memorias 7° Encuentro Latinoamericano de la Econometric Society. Sao Paulo, Brasil. Artículo basado en el segundo capítulo del reporte de investigación Botero et al (1986) financiado por Interconexión Eléctrica S.A. -ISA- y realizado por el Centro de Investigaciones Económicas -CIE- de la Universidad de Antioquia.

El modelo para el caso de Medellín es el siguiente:

$$Q_t = k \left[ \begin{array}{ccc} \alpha & C_t & \beta/D_t + \tau \\ & & Y_t \end{array} \right] D_t / (D_t - \beta) + \varepsilon_t \quad (4.1)$$

donde  $t = 1970, 1971, \dots, 1983$ ;  $n = 14$  datos;  $Q_t =$  consumo del suscriptor medio,  $C_t =$  representa el intercepto de la función de oferta cuando el precio es uno;  $D_t =$  elasticidad de la oferta respecto al precio;  $Y_t =$

ingreso per capita;  $k$  = parámetro constante;  $\alpha$  = parámetro que representa el efecto de las preferencias y necesidades de los subscriptores sobre la demanda;  $\beta$  = parámetro que representa la elasticidad de la demanda con respecto al precio;  $\tau$  = parámetro que representa la elasticidad de la demanda con respecto del ingreso;  $\varepsilon_t$  = término de error del modelo.

El modelo se ajustó utilizando el modulo NONLIN del paquete estadístico SYSTAT que utiliza algoritmos cuasi-Newton para encontrar los estimadores M.C., al respecto ver Wilkinson (1988).

El ajuste fue satisfactorio razonando por analogía al caso lineal. Con base en los resultados de consumo de energía eléctrica en el sector residencial para Medellín de 1984 y 1985 que ya se conocían, se observaba el buen comportamiento del modelo respecto a predicciones. La interpretación de los parámetros desde el punto de vista económico concluía que los estimativos eran perfectamente aceptables. Así utilizando criterios estadísticos y económicos se concluyó que el modelo estaba bien especificado. El modelo se utilizó para hacer inferencias basadas en la interpretación de los estimativos de los parámetros y para proyectar demanda de energía eléctrica por subscriptor medio desde 1984 hasta el 2005.



Para el caso de interés de este trabajo, calcularemos el porcentaje de sesgo para los parámetros y la predicción para determinar la validez de las inferencias que se hicieron siguiendo los criterios asintóticos expuestos en la sección 3, siendo el tamaño muestral en este caso pequeño,  $n=14$  datos. (Ver apéndice página 22 Datos).

Ratkowsky (1983) observa que para un parámetro que represente un término constante en el modelo el porcentaje de sesgo puede ser arbitrariamente grande o pequeño y por ello recomienda que este tipo de análisis no se haga con dichos parámetros.

Así, utilizaremos el siguiente modelo:

$$G = 2.8 \left[ \begin{array}{c} \alpha \\ C \\ \beta/D \\ Y \\ \tau \end{array} \right]^{D/(D-\beta)} + \epsilon \quad (4.2)$$

donde  $k=2.8$  es el valor obtenido al ajustar (4.1).

Se ajustó (4.2) utilizando el módulo NONLIN del SYSTAT y se observa que el ajuste es bueno, razonando por analogía al caso lineal. No hay evidencias de autocorrelación ni de heterocedasticidad. Se observa una correlación alta entre  $\alpha$  y  $\tau$  que podría indicar problemas de colinealidad, pero ambas tienen "t" significativa y al ajustar (4.1) omitiendo alguno de los dos se obtiene una varianza residual mucho más alta que (4.1). A la manera de los modelos lineales se puede afirmar que mientras la



supuesta colinealidad se mantenga, las proyecciones no se ven afectadas. Es pertinente agregar que en modelos lineales los problemas de colinealidad se analizan sobre  $(X'X)$  que en modelos no-lineales equivaldría a examinar  $(F'F)$  en cada iteración, trabajo que no se ha hecho hasta el presente. Con estas observaciones se considera a (4.2) un modelo apropiado.

En el cuadro 1 se puede observar que el porcentaje de sesgo para  $\beta$  y  $\tau$  superan el 1% lo cual indica un grado de no-linealidad alto en el modelo. El caso de  $\tau$  es 18.8%, (además comparando dicho sesgo con el error estandar se tiene un resultado de 4.4) lo cual indica que la influencia de  $\tau$  sobre la no-linealidad es muy grande y sugiere que el modelo no está bien especificado respecto a  $\tau$  y a la variable asociada  $Y$ . Obsérvese, también, en el cuadro 2, la alta influencia de  $\tau$  sobre las proyecciones, si corregimos los sesgos de los parámetros, el sesgo obtenido al comparar las proyecciones con los parámetros originales y las proyecciones con los parámetros corregidos es del orden del 36% para los años desde 1984 a 1990. También en el cuadro 2 se ve que la sobrestimación de las proyecciones es debida exclusivamente a  $\tau$ .

CUADRO 1

PARAM	VALOR	E.S.	SESGO	%SESGO	ABS (SES/E.S.)
$\alpha$	168.040	16.661	-0.606872550	-0.361%	0.03642473
$\beta$	-0.048	0.010	-0.001989626	4.145%	0.19896262
$\tau$	0.306	0.013	0.057778291	18.882%	4.44448398

CUADRO 2

ANO	PROYEC	$\tau=0.248222$	$\beta=.046011$	$\tau=0.248222$ $\alpha=168.6468$ $\beta=.046011$	SESGO	%SESGO
1984	5294.056	3392.065	5267.760	3389.161	1904.895	35.982%
1985	5468.177	3494.303	5433.661	3487.030	1981.147	36.230%
1986	5522.694	3522.537	5487.769	3515.171	2007.524	36.350%
1987	5591.336	3558.010	5555.893	3550.527	2040.809	36.499%
1988	5652.247	3589.420	5616.345	3581.832	2070.415	36.630%
1989	5705.114	3616.630	5668.812	3608.951	2096.162	36.742%
1990	5758.472	3644.044	5721.766	3636.274	2122.198	36.853%

Ahora bien, respecto al sesgo de las proyecciones, se puede decir que el efecto del sesgo de  $\tau$ , sobre-estima las proyecciones altamente, como ya se observó en el cuadro 2. En la fórmula (3.2) el efecto del sesgo de los parámetros se ve en el cuadro 3, en la columna (f\*SPA) y el efecto de la aproximación en la columna (TRAZA/2), es claro que el porcentaje de sesgo se debe completamente a  $\tau$  y es de una magnitud similar a la señalada en el cuadro 2. (La columna E.S (PRO) del cuadro 3, muestra el error estandar de la

proyecciones calculadas de acuerdo a (2.18) y son resultados aparentemente aceptables).

CUADRO 3

ANO	PROYEC	E.S(PRO)	f*SPA	TRAZA/2	SES60	%(f*SPA)	%(TR/2)	%SES60
1984	5294.056	397.239	2310.671	-45.175	2265.496	43.647%	-0.853%	42.793%
1985	5468.177	443.637	2393.719	-44.586	2349.133	43.775%	-0.815%	42.960%
1986	5522.694	447.376	2427.863	-45.224	2382.639	43.962%	-0.819%	43.143%
1987	5591.336	452.118	2470.996	-46.030	2424.966	44.193%	-0.823%	43.370%
1988	5652.247	456.357	2509.404	-46.748	2462.657	44.397%	-0.827%	43.570%
1989	5705.114	460.059	2542.839	-47.372	2495.467	44.571%	-0.830%	43.741%
1990	5758.472	463.817	2576.679	-48.004	2528.675	44.746%	-0.834%	43.912%

Desde el punto de vista estadístico se concluye que el modelo debe ser revisado, concretamente la especificación respecto al ingreso per-cápita (Y) la variable asociada al parámetro  $\tau$ . Tal como está, el modelo es altamente no-lineal y las inferencias respecto a los parámetros y a la predicción no tienen ninguna validez estadística, a pesar de que los diagnósticos realizados sobre (4.2) eran "buenos", utilizando criterios análogos a los utilizados en regresión lineal.

Este ejemplo ilustra con claridad, como a pesar de que el trabajo en regresión lineal se hace por analogía a la regresión lineal, sus estimadores se comportan de manera completamente diferente, dependiendo del grado de no linealidad ("Alejamiento de la proximidad a la linealidad") en muestras pequeñas, de forma que las

inferencias asintóticas pueden carecer de toda validez. Por ello el modelaje en regresión no lineal se debe realizar con gran cuidado y exige se determine, antes que todo, el grado de no-linealidad del modelo.



## 5. CONSIDERACIONES FINALES

El estudio de los modelos no lineales de regresión es un campo relativamente nuevo. Su desarrollo importante es en la década de los 80's, a partir de los trabajos de Bates & Watts (1980) y Ratkowsky (1983) quienes utilizando los trabajos pioneros de Beale (1960) y Box (1971) presentan reglas prácticas para la determinación del grado de no-linealidad del modelo. El método expuesto en este artículo es desarrollado por Ratkowsky (1983) y se recomienda se utilice conjuntamente con las medidas de curvatura de Bates & Watts (1980) así como también, con estudios de simulación sobre las propiedades muestrales de los estimadores M.C.. Se escogió, en este trabajo, la medida de porcentaje de sesgo por aparecer como más natural desde el punto de vista estadístico para ilustrar el hoy complejo campo de la regresión no-lineal. Es pertinente anotar que Bates & Watts (1980) muestran la relación del sesgo aquí utilizado, con sus medidas de curvatura.

En el momento de la implementación del modelo de la sección 4, la bibliografía que conocíamos escasamente citaba el artículo de Bates & Watts (1980), pero no destacaba la importancia central de dicho artículo en el desarrollo de la regresión no-lineal, hoy claramente reconocida. Las referencias más utilizadas fueron: Draper & Smith (1981) y Amemiya (1983), este último especialista en modelos no lineales en econometría. Miller (1974) señalaba la no validez del jackknife en modelos no lineales como reducidos de sesgo. Simonoff & Tsai (1986) desarrollan métodos basados en jackknife para regresión no lineal, teniendo en cuenta los efectos de no linealidad. Los análisis de residuales son revisados por Cook & Tsai (1985) al incluir las medidas de no linealidad. En fin, se puede afirmar con Seber & Wild (1989) que hasta hace pocos años la situación de los modelos no lineales era en general deficiente y que las medidas de no linealidad son una de las principales razones de su reciente desarrollo.

Para terminar se puede citar el epígrafe, al capítulo 7g sobre Medidas de Curvatura de no linealidad, del libro de Bates & Watts (1988): "La gran tragedia de la Ciencia: la muerte violenta de una bella hipótesis por una fea realidad". Thomas Huxley.

**BIBLIOGRAFIA**

Amemiya, T. (1983). "Non-Linear Regression Models" capitulo 6g en Griliches, Z. e Intrilligator, M.D. Handbook of Econometric, volumen 1. North Holland: Amsterdam.

Bates, D. M., y Watts, D.G.(1980).Relative curvature measures of nonlinearity. J.R. Stat. Soc. B, 42,1-25.

Bates, D.M. y Watts, D.G. (1988). Nonlinear Regression Analysis & its aplicaciones. Wiley: New York.

Beale,E.M.L.(1960). Confidence regions in non-linear estimation. J.R. Stat. Soc. B, 22, 41-88.

Botero, J., Vélez, C. E., García, G., Castaño, E. y Yañez, S. (1986). Revisión y reestimación del submodelo de demanda de energía eléctrica en Colombia. Copia a máquina. Medellín: Centro de Investigaciones Económicas. Universidad de Antioquia.

Box, M. J. (1971). Bias in nonlinear estimation. *J. R. Stat. Soc. B*, 33, 171-201.

Cook, R. D. y, Tsai, C. L. (1985). Residuals in nonlinear regression. *Biometrika*, 72, 23-29.

Draper, N. R. y Smith, H. (1981). *Applied Regression Analysis*, 2a. ed. Wiley: New York.

Judge, G. G., Hill, R. C. Griffiths, W. E., Lütkepohl, H. y Lee, T. C. (1982). *Introduction to the theory and practice of econometrics*. Wiley: New York.

Malinvaud, E. (1970). *Statistical Methods of Econometrics*. North Holland:Amsterdam.

Miller, R. G. (1974). An Unbalanced jackknife. *The Annals of statistics*, 2, 880-891



Neter, J., Wasserman, W. y Kutner, M. H. (1983).

Applied Linear regression Models. Richard D. Irwin Inc.: Homewood, Illinois.

Ratkowsky, D. A. (1983). Nonlinear Regression

Modeling. Marcel Dekker: New York.

Simonoff, J. S. y Tsai, C. L. (1986). Jackknife -

Based estimators and confidence regions in Nonlinear Regression. Technometrics, 28, 103-112. N

Vélez, C. E., Botero, J. y Yáñez, S. (1987). La

Demanda residencial de energía eléctrica en dos ciudades colombianas: un modelo económico. Memorias 7° Encuentro Latinoamericano de la Econometric Society: Sao Paulo, Brasil.

Wilkinson, L. (1988). SYSTAT: The System for

Statistics. Evanston IL. SYSTAT INC.

30287

APENDICE

## DATOS

ANO	Q	C	D	Y
1970	5085.67	11.7759	3.397849	2131.45
1971	5264.38	12.1618	3.397850	2178.88
1972	5405.16	12.5533	3.397859	2234.97
1973	5421.76	13.1482	3.397855	2254.76
1974	5491.53	11.5193	2.166305	2155.26
1975	5568.71	11.3147	1.871091	1952.31
1976	5706.80	11.6683	1.871092	2061.94
1977	5262.11	12.1165	1.871080	2086.44
1978	5894.44	11.3513	1.871092	2509.63
1979	5722.57	11.3732	1.871101	2352.96
1980	5740.32	11.4748	1.871093	2212.89
1981	5533.26	11.3799	1.871090	2086.46
1982	5540.29	11.3062	1.871971	1959.00
1983	5485.16	10.5753	1.451865	1839.46
1984		11.7664	2.074939	1856.02
1985		10.4766	1.688200	1863.44
1986		10.4766	1.688200	1923.07
1987		10.4766	1.688200	1999.99
1988		10.4766	1.688200	2069.99
1989		10.4766	1.688200	2132.09
1990		10.4766	1.688200	2196.05