

LÍNEAS BASES Y EVALUACIÓN DE LOS IMPACTOS SOCIOECONÓMICOS DEL CAMBIO CLIMÁTICO EN AMÉRICA LATINA DDSAH-CEPAL

**COMPONENTE SOCIOECONÓMICO
PROGRAMA EUROCLIMA**



Análisis econométrico con datos de sección cruzada



NACIONES UNIDAS

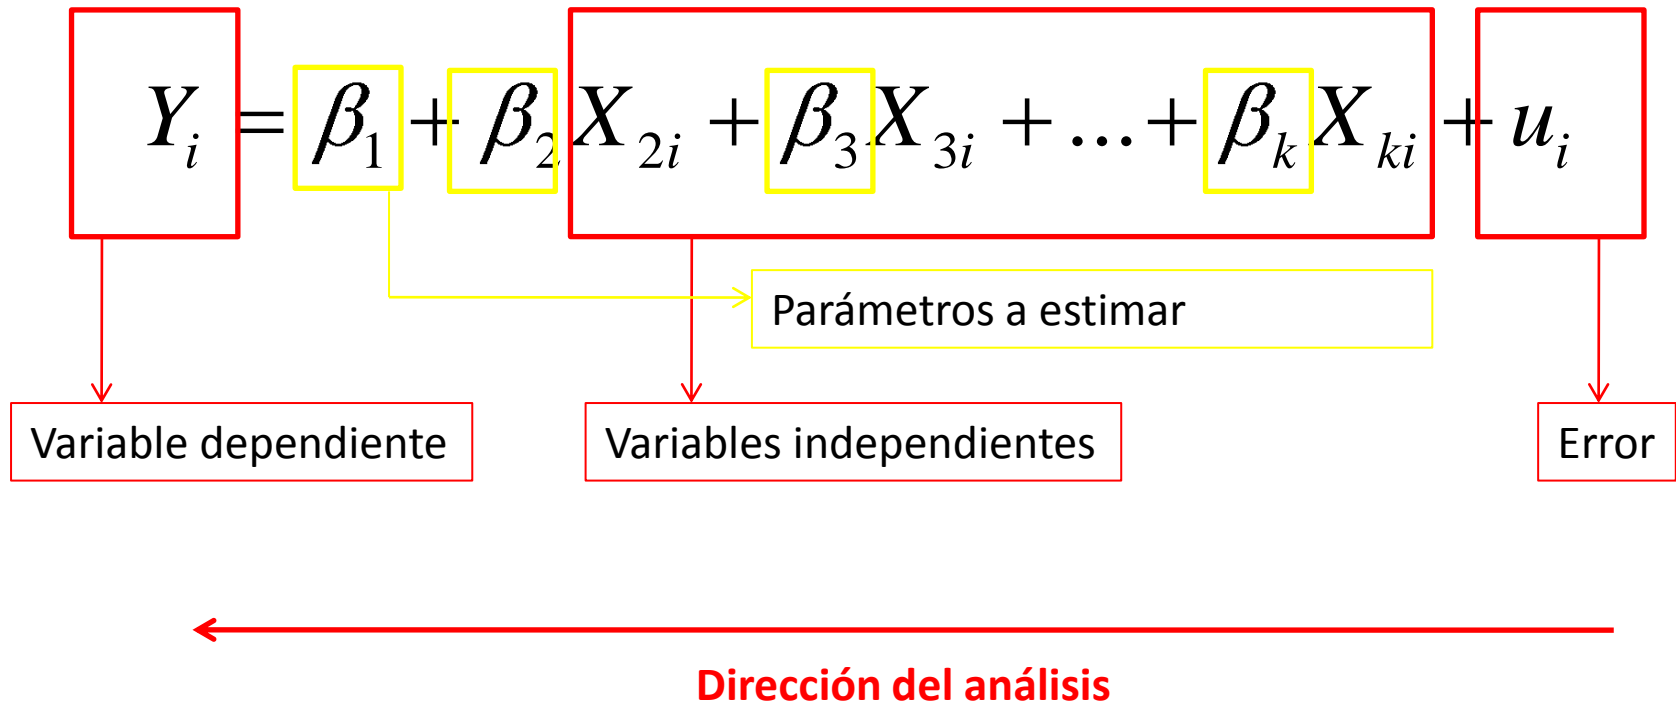
CEPAL

TABLA DE CONTENIDO

1. Introducción: el modelo de regresión y supuestos
2. Modelo de regresión lineal simple (**ejemplo**)
3. Modelo de regresión lineal múltiple (**ejemplo**)
4. Estimación
5. Inferencia
6. Formas funcionales de los modelos econométricos
7. Regresión con Variable Independiente Dicotómica
8. Violación de los supuestos del modelo de regresión
9. **Ejemplo de aplicación**



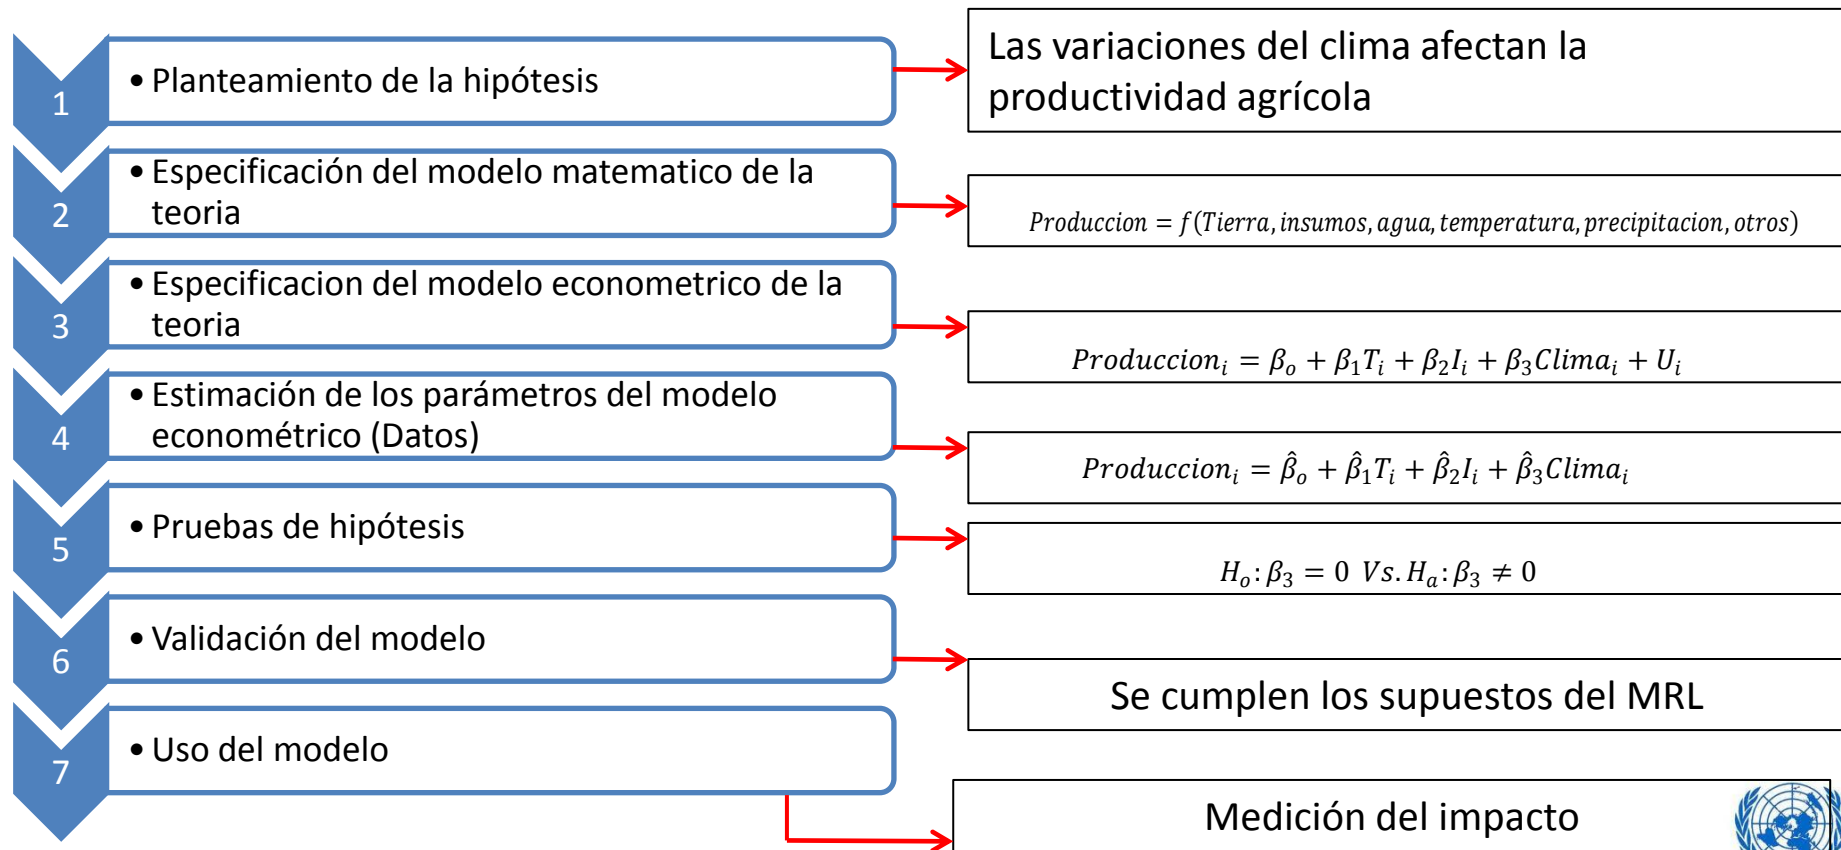
1. Introducción: el modelo de regresión y supuestos



1. Estimar el impacto (“+” o “-”) de cada VI sobre la VD
2. Cuantificar cada impacto

1. Introducción: el modelo de regresión y supuestos

Econometría: “parte de los métodos cuantitativos que emplea el economista”. Es la unión de la teoría económica, la estadística y la matemática que busca establecer relaciones entre variables económicas para predecir el impacto de una o mas variables sobre la variable denominada “respuesta”. (Gujarati, Wooldridge, Judge)



$$Y_i = \beta_0 + \beta_1 X_i + u_i \text{ con } i = 1, 2, \dots, n \text{ individuos}$$

Y_1	X_1
Y_2	X_2
.	.
Y_i	X_i
.	.
Y_n	X_n

$$Y_t = \beta_0 + \beta_1 X_t + u_t \text{ con } t = 1, 2, \dots, t$$

Y_{1980}	X_{1980}
Y_{1981}	X_{1981}
.	.
Y_t	X_t
:	.
Y_{2009}	X_{2009}
Y_{2010}	X_{2010}

$$Y_{it} = \beta_0 + \beta_1 X_{it} + u_{it} \text{ con } i = 1, 2, \dots, n \text{ individuos}; t = 1, 2, \dots, t$$

Individuo	Tiempo	Y	X
i=1	t=1	Y_{11}	X_{11}
	T=2	Y_{12}	X_{12}
	.	.	.
	.	.	.
	.	.	.
	T=t	Y_{1t}	X_{1t}
i=2	t=1	Y_{21}	X_{21}
	T=2	Y_{22}	X_{22}
	.	.	.
	.	.	.
	.	.	.
	T=t	Y_{2t}	X_{2t}
i=i	t=1	Y_{i1}	X_{i1}
	T=2	Y_{i2}	X_{i2}
	.	.	.
	.	.	.
	.	.	.
	T=t	Y_{it}	X_{it}
i=n	t=1	Y_{n1}	X_{n1}
	T=2	Y_{n2}	X_{n2}
	.	.	.
	.	.	.
	.	.	.
	T=t	Y_{nt}	X_{nt}

1. Introducción: el modelo de regresión y supuestos

Supuesto 1: Modelo de Regresión Lineal

El modelo de regresión es lineal en los parámetros,

$$Y_i = \beta_1 + \beta_2 X_i + u_i$$

ó

$$Y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \dots + \beta_k X_{ki} + u_i$$

Para el modelo de regresión lineal múltiple.

Supuesto 2: Los valores de X son fijos en muestreo repetido.

Los valores que toma el regresor X_j ($\forall j = 1, 2, 3, \dots, k$) son considerados fijos en muestreo repetido. Más técnicamente, se supone no estocástica.

Supuesto 3: El valor medio de la perturbación u_i es igual a cero.

Dado el valor de X , la media, o el valor esperado del término aleatorio de perturbación u_i es cero. Técnicamente, el valor de la media condicional de u_i es cero. Simbólicamente, se tiene

$$E[u_i / X_i] = 0$$

ó

$$E[u_i / X_{2i}, X_{3i}, \dots, X_{ki}] = 0$$

1. Introducción: el modelo de regresión y supuestos

Supuesto 4: Homoscedasticidad o igual varianza de u_i

Dado el valor de X , la varianza de u_i es la misma para todas las observaciones.

Esto es, las varianzas condicionales de u_i son idénticas. Simbólicamente, se tiene que

$$\text{var}[u_i / X_i] = E[u_i - E[u_i] / X_i]^2$$

$$\text{var}[u_i / X_i] = E[u_i^2 / X_i]$$

$$\text{var}[u_i / X_i] = \sigma^2$$

Supuesto 5: No auto correlación entre las perturbaciones.

Dados dos valores cualquiera de X , X_i y X_j ($i \neq j$), la correlación entre dos u_i y u_j cualquiera ($i \neq j$) es cero. Simbólicamente,

$$\text{cov}(u_i, u_j / X_i, X_j) = E[u_i - E[u_i] / X_i][u_j - E[u_j] / X_j]$$

$$\text{cov}(u_i, u_j / X_i, X_j) = E[u_i / X_i][u_j / X_j]$$

$$\text{cov}(u_i, u_j / X_i, X_j) = 0$$

Supuesto 6: La covarianza entre u_i y X_i es cero, o $E[u_i, X_i] = 0$.

Formalmente,

$$\text{cov}[u_i, X_i] = E[u_i - E[u_i]][X_i - E[X_i]]$$

$$\text{cov}[u_i, X_i] = E[u_i(X_i - E[X_i])] \quad E[u_i] = 0$$

$$\text{cov}[u_i, X_i] = E[u_i X_i] - E[X_i]E[u_i] \quad E[X_i]_{no_estocastica}$$

$$\text{cov}[u_i, X_i] = E[u_i X_i], \quad E[u_i] = 0$$

$$\text{cov}[u_i, X_i] = 0$$

1. Introducción: el modelo de regresión y supuestos

Supuesto 7: **El número de observaciones n debe ser mayor que el número de parámetros por estimar.**

Supuesto 8: **Variabilidad en los valores de X .**

No todos los valores de X en una muestra dada deben ser iguales. Técnicamente, $Var[X]$ debe ser un número positivo finito.


Supuesto 9: **El modelo de regresión está correctamente especificado.**

Alternativamente, no hay un sesgo de especificación o error en el modelo utilizado en el análisis empírico.

La omisión de variables importantes del modelo, o la escogencia de una forma funcional equivocada, o la consideración de supuestos estocásticos equivocados sobre las variables del modelo, harán muy cuestionable la validez de la interpretación de la regresión estimada.


Supuesto 10: **No hay multicolinealidad perfecta**

2. Modelo de regresión lineal simple



La función de regresión poblacional denota la media poblacional de la distribución de Y dado un X_i , que está relacionado con una forma funcional $f(x_i)$

2. Modelo de regresión lineal simple

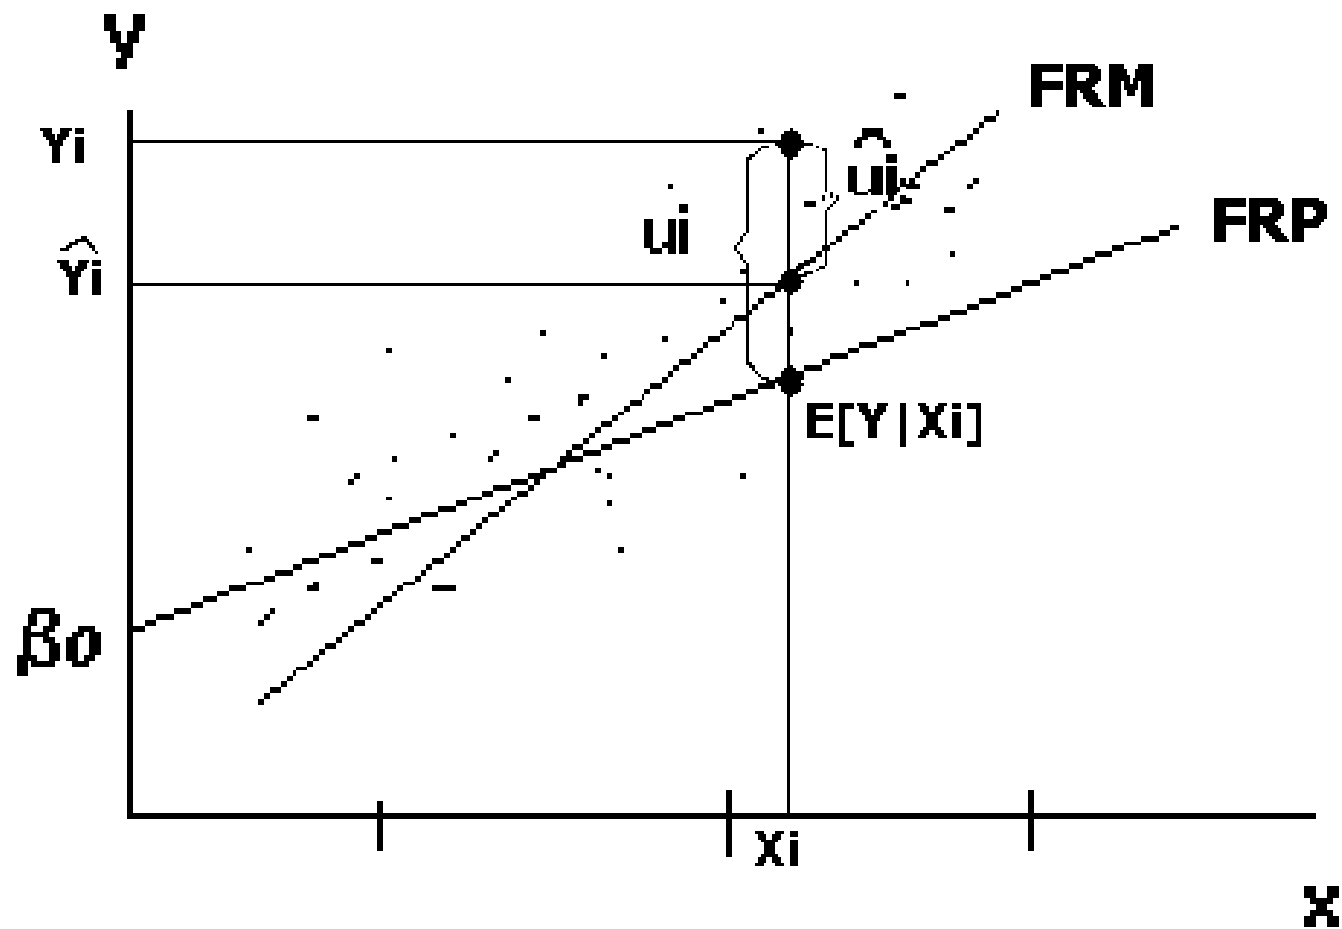


$$Y_i = \beta_0 + \beta_1 X_i + U_i$$

$$\hat{Y}_i = \hat{\beta}_1 + \hat{\beta}_2 X_i$$

Two red arrows point from the β_0 term in the first equation to the $\hat{\beta}_1$ term in the second equation, and from the β_1 term in the first equation to the $\hat{\beta}_2$ term in the second equation.

2. Modelo de regresión lineal simple



- Minimizar la suma de cuadrados de los errores estimados
- Son los estimadores que minimizan la SCE

Estimadores de MCO

- Min {SCE}

$$\hat{\beta}_0 = \bar{Y} - \hat{\beta}_1 \bar{X}$$

$$\hat{\beta}_1 = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sum (X_i - \bar{X})^2}$$

3. Modelo de regresión lineal múltiple

$$Y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \dots + \beta_k X_{ki} + u_i \quad i=1,2,\dots,n$$

$$\begin{bmatrix} Y_1 \\ Y_2 \\ \cdot \\ \cdot \\ \cdot \\ Y_N \end{bmatrix} = \begin{bmatrix} 1 & X_{21} & 0 & \cdot & \cdot & \cdot & X_{k1} \\ 1 & X_{22} & 0 & \cdot & \cdot & \cdot & X_{k2} \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ 1 & X_{2n} & 0 & \cdot & \cdot & \cdot & X_{kn} \end{bmatrix} \begin{bmatrix} \beta_1 \\ \beta_2 \\ \cdot \\ \cdot \\ \cdot \\ \beta_k \end{bmatrix} = \begin{bmatrix} u_1 \\ u_2 \\ \cdot \\ \cdot \\ \cdot \\ u_n \end{bmatrix}$$

Matriz de VI

Vector de Error

$$Y_{(nx1)} = X_{(nx(k+1))} B_{((k+1)x1)} + U_{(nx1)}$$

Vector de VD

Vector de Parámetros

4. Estimación: por Mínimos cuadrados ordinarios (MCO)

$$Y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \dots + \beta_k X_{ki} + u_i \quad i=1,2,\dots,n$$

$$\vec{Y} = \vec{X}\vec{B} + \vec{U}$$

$$\hat{B} = (X^t X)^{-1} X^t y$$

Estimador por MCO de B

$$\text{Var}[\hat{B}] = (X^t X)^{-1} \sigma^2$$

Estimador por de la VAR (B)

$$\begin{bmatrix} \beta_1 \\ \beta_2 \\ \cdot \\ \cdot \\ \cdot \\ \beta_k \end{bmatrix} \rightarrow \begin{bmatrix} \hat{\beta}_1 \\ \hat{\beta}_2 \\ \cdot \\ \cdot \\ \cdot \\ \hat{\beta}_k \end{bmatrix} \rightarrow \begin{bmatrix} \text{var}(\hat{\beta}_1) \\ \text{var}(\hat{\beta}_2) \\ \cdot \\ \cdot \\ \cdot \\ \text{var}(\hat{\beta}_k) \end{bmatrix}$$

5. Inferencia: realmente es modelo es bueno?

Pruebas de inferencia individual

$$Y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \dots + \beta_k X_{ki} + u_i$$

$$\hat{\beta}_2$$

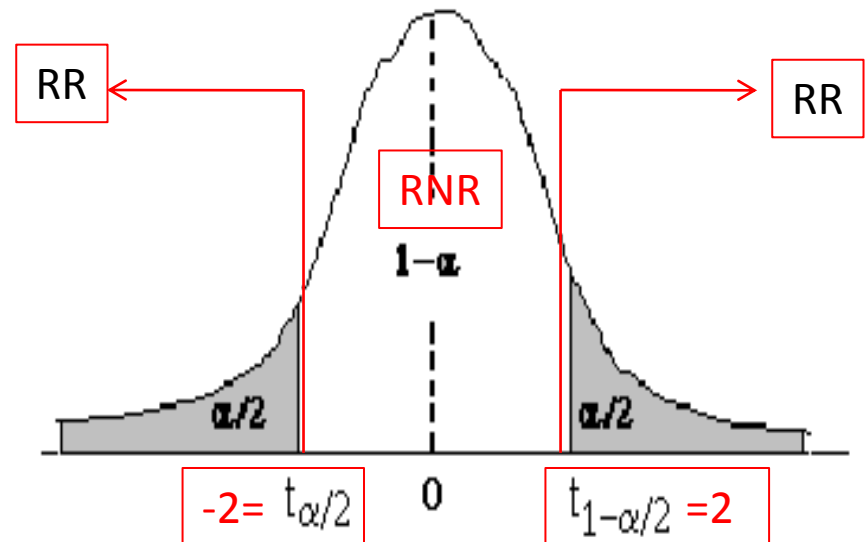
Realmente la variable X2 afecta a la VD?

$$H_0: \beta_2 = 0 \text{ Vs. } H_a: \beta_2 \neq 0$$

$$\text{var}(\hat{\beta}_2)$$

$$t = \frac{\hat{\beta}_2}{\sqrt{\text{var}(\hat{\beta}_2)}} \sim t_{n-(k+1)}$$

$$T(0.95; n > 30) = 2$$



5. Inferencia: realmente es modelo es bueno?

Pruebas de inferencia Global

$$Y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \dots + \beta_k X_{ki} + u_i$$

Al mismo tiempo, las variables X_2, X_3, \dots, X_k ,
explican a la VD ?

<i>Fuente de Variación</i>	<i>Suma de cuadrados</i>	<i>Grados de libertad</i>	<i>Medias cuadráticas</i>	<i>F</i>
Regresión	SCReg	glReg=K+1	$CMReg = \frac{SCReg}{glReg}$	$F = \frac{CMReg}{CMErr} \sim F_{glReg, glErr}$
Error	SCErr	glErr=N-(K+1)	$CMErr = \frac{SCErr}{glErr}$	
Total	STC	N-1	$H_0: \beta_1 = \beta_2 = \dots = \beta_k = 0$ $H_0: \beta_1 \neq \beta_2 \neq \dots \neq \beta_k = 0$	

5. Inferencia: realmente es modelo es bueno?

Pruebas de inferencia Global

$$Y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \dots + \beta_k X_{ki} + u_i$$

TOTAL



STC

REGRESION



SCReg

ERROR



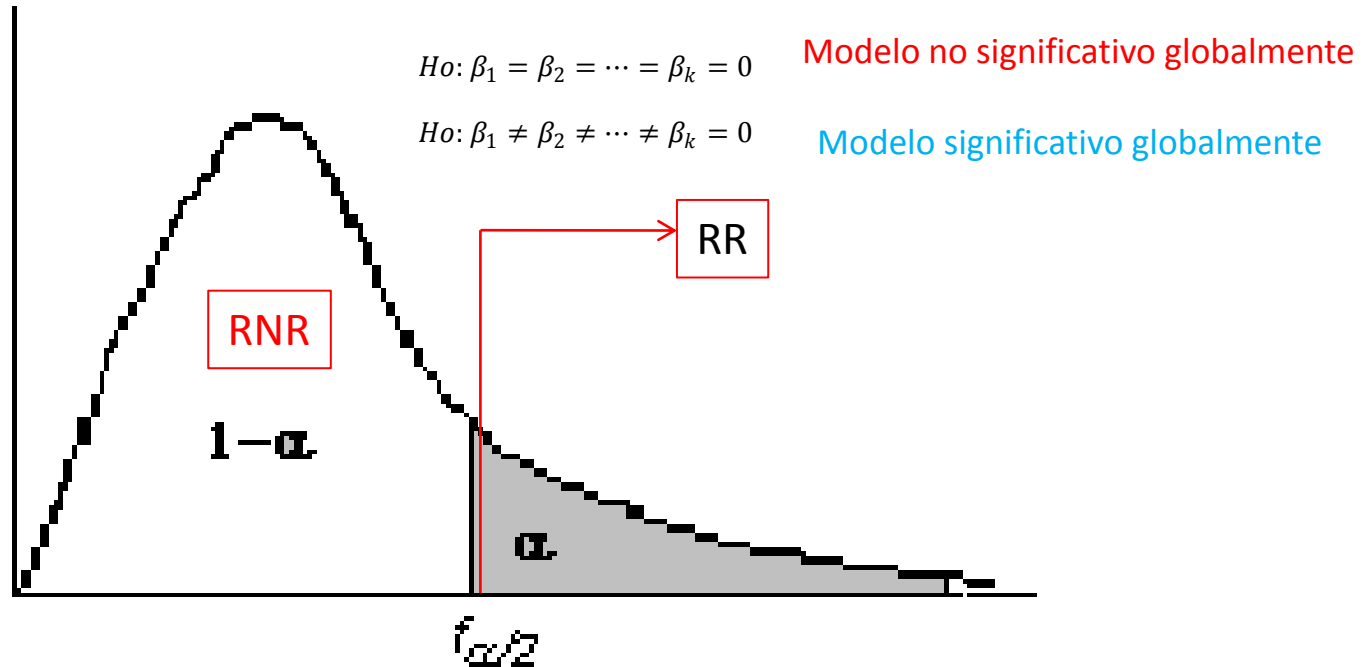
STErr

=

+

5. Inferencia: realmente es modelo es bueno?

Pruebas de inferencia Global



	STC	SCReg	SCErr	
MODELO 1	100	90	10	MODELO GLOBALMENTE SIGNIFICATIVO
MODELO 2	100	20	80	MODELO NO SIGNIFICATIVO



6. Formas funcionales de los modelos econométricos

Pueden ser consideradas distintas formas funcionales en que se relacionan la VD y las VI

$$Y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \dots + \beta_k X_{ki} + u_i$$

Lineal

Lineal

$$\frac{\partial Y}{\partial X_k} = \frac{\partial}{\partial X_k} (\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + U_i) = \beta_k$$

Efecto marginal “ante un cambio absoluto de la VI “Xk”, la VD responde en promedio en β_k manteniendo las demás variables constantes”

$$\eta = \text{elasticidad} = \frac{\%Y}{\%X_k} = \frac{\frac{\Delta Y}{Y}}{\frac{\Delta X_k}{X}} = \frac{\Delta Y}{\Delta X_k} * \frac{X_k}{Y} = \frac{\partial Y}{\partial X_k} * \frac{X_k}{Y} = \beta_k * \frac{X_k}{Y}$$

Elasticidad “ante un cambio porcentual de la VI “Xk”, la VD responde en promedio en $\beta_k * \frac{X_k}{Y}$ ”

6. Formas funcionales de los modelos econométricos

MODELO	ECUACION	INTERPRETACION DE LOS COEFICIENTES (Bk)	ELASTICIDAD (η)
Lineal -Lineal	$Y_i = \beta_0 + \beta_1 X_i + U_i$	Efecto marginal	$\beta_k * \frac{X_k}{Y}$
Logaritmico - Lineal	$LN Y_i = \beta_0 + \beta_1 X_i + U_i$	Semielasticidad	$\beta_k * X_k$
Logaritmico - Logaritmico	$LN Y_i = \beta_0 + \beta_1 LN X_i + U_i$	Elasticidad	β_k
Lineal - Logaritmico	$Y_i = \beta_0 + \beta_1 LN X_i + U_i$	Semielasticidad	$\frac{\beta}{Y}$

$$Y = a_0 + a_1 * X_1 + a_2 * X_2 + a_3 * X_1^2 + a_4 * X_2^2 + a_5 * X_1 X_2 + \varepsilon$$

$$Y = a_0 + a_1 * \sqrt{X_1} + a_2 * \sqrt{X_2} + a_3 * X_1 + a_4 * X_2 + a_5 * \sqrt{X_1 X_2} + \varepsilon$$

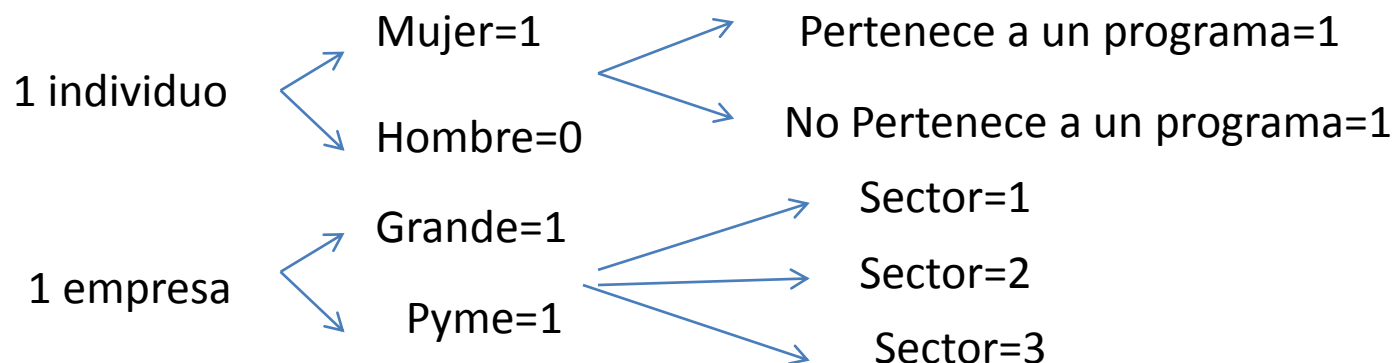
Formas
funcionales
polinómicas

$$Y = A * X_1^\alpha * X_2^\beta e^u$$

Modelo Coob -
Douglas

7. Regresión con Variable Independiente Dicotómica

- ✓ Las variables explicadas no solo dependen de VI continuas.... También dependen de variables dicótomas, categóricas, de casilla, discretas, indicadoras, binarias...
- ✓ Cuatro formas de medir en estadísticas:
 - ✓ **VARIABLES NOMINALES:** Genero (dos categorías), Raza (mas de dos categorías)
 - ✓ **VARIABLES ORDINALES:** estrato (1, 2, 3, 4, 5, y 6) , Tamaño del predio (Grande, Mediano, Pequeño), Tamaño de la industria,
 - ✓ **VARIABLES CONTINUA**
 - ✓ **VARIABLE DE RAZON**



7. Regresión con Variable Independiente Dicotómica

El tratamiento de este tipo de variables será el siguiente:

1. Se define la variable dummy D_i , como:
 - $D_i=1$ si la unidad de análisis posee la característica
 - $D_i=0$ si la unidad de análisis no posee la característica
2. Siempre se tomara el “1” como referencia:
3. Si la variable dummy presenta mas de dos categorías, se crearan $(k-1)$ dummy , donde K es el numero de categorías.
 1. Tamaño de las empresas (grande (G), Mediana (M) y Pyme (P). Aquí $K=3$, entonces se crean 2 dummy
 - $D1=1$ si la empresa es grande
 - $D1=0$ de lo contrario
 - $D2=1$ si la empresa es Mediana
 - $D2=0$ de lo contrario

Se deja a la categoría
(P) como referencia

7. Regresión con Variable Independiente Dicotómica

Se pueden presentar varios casos:

- Una variable dependiente continua y una variable independiente dicótoma de dos categorías
- Una variable dependiente continua y dos variables independientes: una continua y una dicótoma de dos categorías
- Una variable dependiente continua y dos variables independientes: una continua y una dicótoma de dos categorías
- Una variable dependiente continua y dos variables independientes: una continua y una dicótoma de dos categorías mas una interacción



7. Regresión con Variable Independiente Dicotómica

DESCRIPCION	MODELO
Una variable dependiente continua y una variable independiente dicótoma de dos categorías	$Y_i = \beta_0 + \beta_1 D_i + U_i$ $D_i = 1 \text{ si posee la característica}$ $D_i = 0 \text{ si no posee la característica}$
Una variable dependiente continua y dos variables independientes: una continua y una dicótoma de dos categorías	$Y_i = \beta_0 + \beta_1 X_i + \beta_2 D_i + U_i$ $D_i = 1 \text{ si posee la característica}$ $D_i = 0 \text{ si no posee la característica}$
Una variable dependiente continua y dos variables independientes: una continua y una dicótoma de dos categorías más la interacción	$Y_i = \beta_0 + \beta_1 X_i + \beta_2 D_i + \beta_{3*} * X_i * D_i + U_i$ $D_i = 1 \text{ si posee la característica}$ $D_i = 0 \text{ si no posee la característica}$
Una variable dependiente continua y tres variables independientes: una continua y dos dicótomas de dos categorías	$Y_i = \beta_0 + \beta_1 D_{1i} + \beta_2 D_{2i} + \beta_3 X_i + U_i$ $D_{1i} = 1 \text{ si posee la característica}$ $D_{1i} = 0 \text{ si no posee la característica}$ $D_{2i} = 1 \text{ si posee la característica}$ $D_{2i} = 0 \text{ si no posee la característica}$
Una variable dependiente continua y tres variables independientes: una continua y dos dicótomas de dos categorías con interacción entre las dummy	$Y_i = \beta_0 + \beta_1 D_{1i} + \beta_2 D_{2i} + \beta_3 D_{1i} * D_{2i} + \beta_4 X_i + U_i$ $D_{1i} = 1 \text{ si posee la característica}$ $D_{1i} = 0 \text{ si no posee la característica}$ $D_{2i} = 1 \text{ si posee la característica}$ $D_{2i} = 0 \text{ si no posee la característica}$
Una variable dependiente continua y dos variables independientes: una continúa y una dicótoma de más de dos categorías con k=4	$Y_i = \beta_0 + \beta_1 D_{1i} + \beta_2 D_{2i} + \beta_3 D_{3i} + \beta_4 X_i + U_i$ $D_{1i} = 1 \text{ si posee la característica}$ $D_{1i} = 0 \text{ si no posee la característica}$ $D_{2i} = 1 \text{ si posee la característica}$ $D_{2i} = 0 \text{ si no posee la característica}$ $D_{3i} = 1 \text{ si posee la característica}$ $D_{3i} = 0 \text{ si no posee la característica}$

7. Regresión con Variable Independiente Dicotómica

Una variable dependiente continua y una variable independiente dicotoma de dos categorías

$$Y_i = \beta_0 + \beta_1 D_i + U_i$$

Mide la diferencia promedio en la variable respuesta Y de tener y no tener la característica

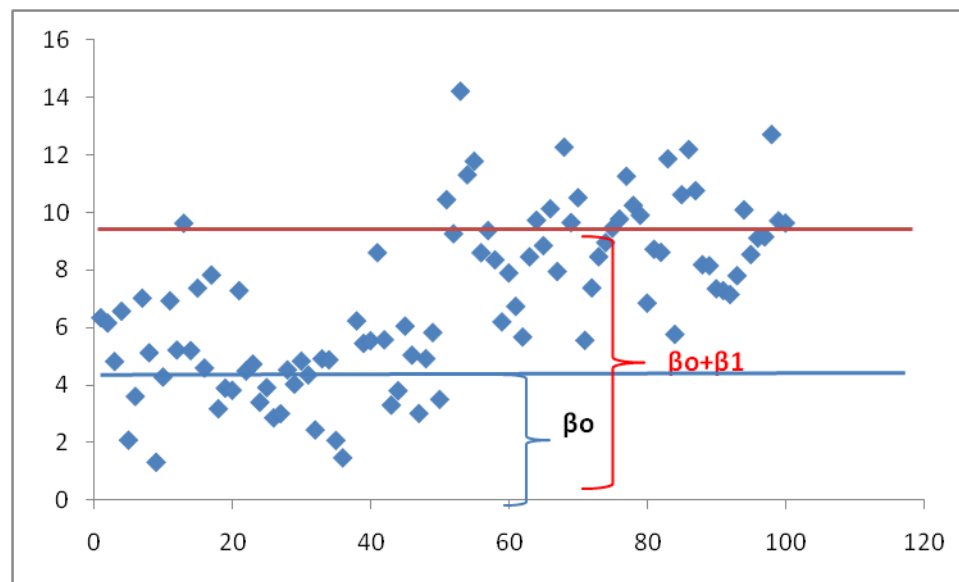
$D_i = 1$ si posee la característica

$D_i = 0$ si no posee la característica

$$E[Y_i/D_i = 1] = \beta_0 + \beta_1$$

$$E[Y_i/D_i = 0] = \beta_0$$

$$E[Y_i/D_i = 1] - E[Y_i/D_i = 0] = \beta_1$$



7. Regresión con Variable Independiente Dicotómica

Una variable dependiente continua y dos variables independientes: una continua y una dicótoma de dos categorías

$$Y_i = \beta_0 + \beta_1 X_i + \beta_2 D_i + U_i$$

Mide la diferencia promedio en la variable respuesta Y de tener y no tener la característica

$D_i = 1$ si posee la característica


$D_i = 0$ si no posee la característica

$$E[Y_i/D_i = 1] = (\beta_0 + \beta_2) + \beta_1 X_i$$

$$E[Y_i/D_i = 0] = \beta_0 + \beta_1 X_i$$

$$E[Y_i/D_i = 1] - E[Y_i/D_i = 0] = \beta_2$$

$$H_0: \beta_2 = 0 \text{ Vs. } H_a: \beta_2 \neq 0$$







7. Regresión con Variable Independiente Dicotómica

Una variable dependiente continua y dos variables independientes: una continua y una dicótoma de dos categorías más la interacción

$$Y_i = \beta_0 + \beta_1 X_i + \beta_2 D_i + \beta_3 * X_i * D_i + U_i$$

$D_i = 1$ si posee la característica

$D_i = 0$ si no posee la característica



8. Violación de los supuestos del modelo de regresión

✓ MULTICOLINEALIDAD

✓ HETEROCEDASTICIDAD

✓ AUTOCORRELACION

✓ NORMALIDAD DE LOS ERRORES



NACIONES UNIDAS

CEPAL

MULTICOLINEALIDAD

Relaciones lineales entre variables independientes

$$Y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \dots + \beta_k X_{ki} + u_i$$

Diagram illustrating the relationship between independent variables in a regression model, showing correlations between variables X_2 , X_3 , and X_k .

The equation is annotated with brackets and labels indicating correlations:

- A bracket above the terms $\beta_2 X_{2i} + \beta_3 X_{3i} + \dots + \beta_k X_{ki}$ is labeled $Corr(X_2, X_k)$.
- A bracket below the terms $\beta_2 X_{2i} + \beta_3 X_{3i}$ is labeled $Corr(X_2, X_3)$.
- A bracket below the terms $\beta_3 X_{3i} + \dots + \beta_k X_{ki}$ is labeled $Corr(X_3, X_k)$.

La multicolinealidad puede deberse a los siguientes factores:

- El método de recolección de información empleado.
- Restricciones sobre el modelo o en la población que es objeto de muestreo.
- Especificación del modelo.
- Un modelo sobredeterminado

MULTICOLINEALIDAD

Consecuencias prácticas de la multicolinealidad

- ✓ Aun cuando los estimadores de MCO son MELI, estos presentan varianzas y covarianzas grandes, que hacen difícil la estimación precisa.
- ✓ Factor inflador de varianza
- ✓ los intervalos de confianza tienden a ser mucho más amplios, conduciendo a una aceptación más fácil de la hipótesis nula .
- ✓ El estadístico de los coeficientes tiende a ser no significativo.
- ✓ Aun cuando el estadístico de uno o más coeficientes sea estadísticamente no significativo, el R^2 , la media global de bondad de ajuste, puede ser muy grande
- ✓ Los estimadores MCO y sus errores estándar pueden ser sensibles a pequeños cambios en la información.

Como detectarla?

- ✓ Un elevado pero pocas razones significativas (y un valor F significativo)
- ✓ Altas correlaciones entre parejas de Regresores
- ✓ Regresiones Auxiliares:
- ✓ Valores Propios e Índice de Condición
- ✓ Factores de Tolerancia y de Inflación de Varianza


- ✓ **Medidas remediales**
- ✓ **Información a priori**
- ✓ **Combinación de información de corte transversal y de series de tiempo**
- ✓ **Eliminación de una(s) variable(s) y el sesgo de especificación:**
- ✓ **Transformación de variables:**
- ✓ **Datos nuevos o adicionales**
- ✓ **Reducción de la colinealidad en las regresiones polinomiales**



HETEROCEDASTICIDAD

La heteroscedasticidad se presenta cuando las varianzas de u_i no son las mismas a lo largo de las observaciones. Simbólicamente,

$$E[u_i] = \sigma_i^2$$



- ✓ A medida que aumentan las variables independientes las varianzas se hacen mayores.
- ✓ Presencia de factores atípicos.
- ✓ La inclusión o exclusión de una observación de este tipo
- ✓ Incorrecta especificación del modelo



HETEROCEDASTICIDAD

Consecuencias de utilizar MCO en presencia de heteroscedasticidad

- ✓ Los intervalos de confianza basados en los estimadores de MCO son muy amplios.
- ✓ Como resultado, es probable que las pruebas F den resultados imprecisos
- ✓ La característica más sobresaliente de estos resultados es que los MCO, con o sin corrección por heteroscedasticidad, sobreestiman consistentemente el verdadero error estándar obtenido mediante el procedimiento correcto.

Como detectarla?: Prueba de White.

Como corregirla:

Cuando es conocida: Método de Mínimos Cuadrados Ponderados

Cuando es desconocida: Método de Mínimos Cuadrados Generalizados

$$P\Omega P^t = I_{n \times n}$$
$$PY = PXB + Pu$$
$$Y^* = X^*B^* + u^*$$



Autocorrelacion

$$Y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \dots + \beta_k X_{ki} + u_i$$


Dados dos valores cualquiera de X , X_i y X_j ($i \neq j$), la correlación entre dos u_i y u_j cualquiera ($i \neq j$) es cero. Simbólicamente,

$$\text{cov}(u_i, u_j / X_i, X_j) = E[u_i - E[u_i] / X_i][u_j - E[u_j] / X_j]$$


$$\text{cov}(u_i, u_j / X_i, X_j) = E[u_i / X_i][u_j / X_j]$$

$$\text{cov}(u_i, u_j / X_i, X_j) = 0$$

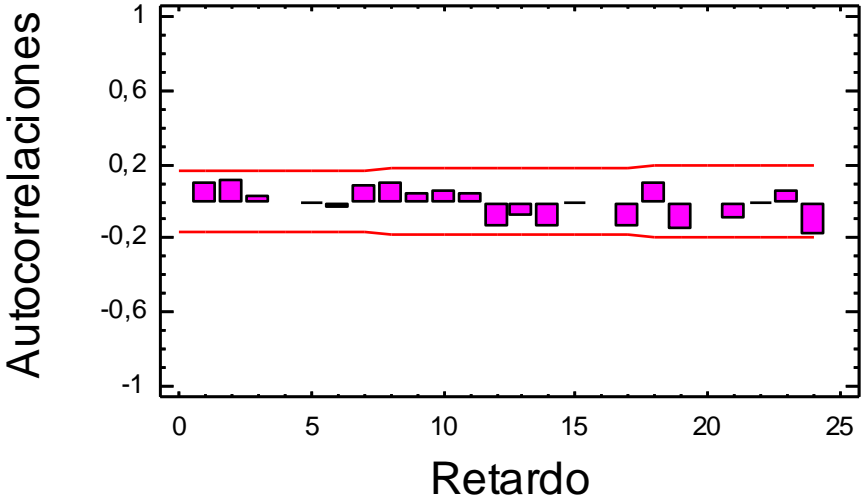
$$\begin{bmatrix} Y_1 \\ Y_2 \\ \cdot \\ \cdot \\ \cdot \\ Y_N \end{bmatrix} = \begin{bmatrix} 1 & X_{21} & 0 & \cdot & \cdot & \cdot & X_{k1} \\ 1 & X_{22} & 0 & \cdot & \cdot & \cdot & X_{k2} \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ 1 & X_{2n} & 0 & \cdot & \cdot & \cdot & X_{kn} \end{bmatrix} \begin{bmatrix} \beta_1 \\ \beta_2 \\ \cdot \\ \cdot \\ \cdot \\ \beta_k \end{bmatrix} = \begin{bmatrix} u_1 \\ u_2 \\ \cdot \\ \cdot \\ \cdot \\ u_n \end{bmatrix}$$



Errores autocorrelacionados



Errores no autocorrelacionados



Ejemplos.....

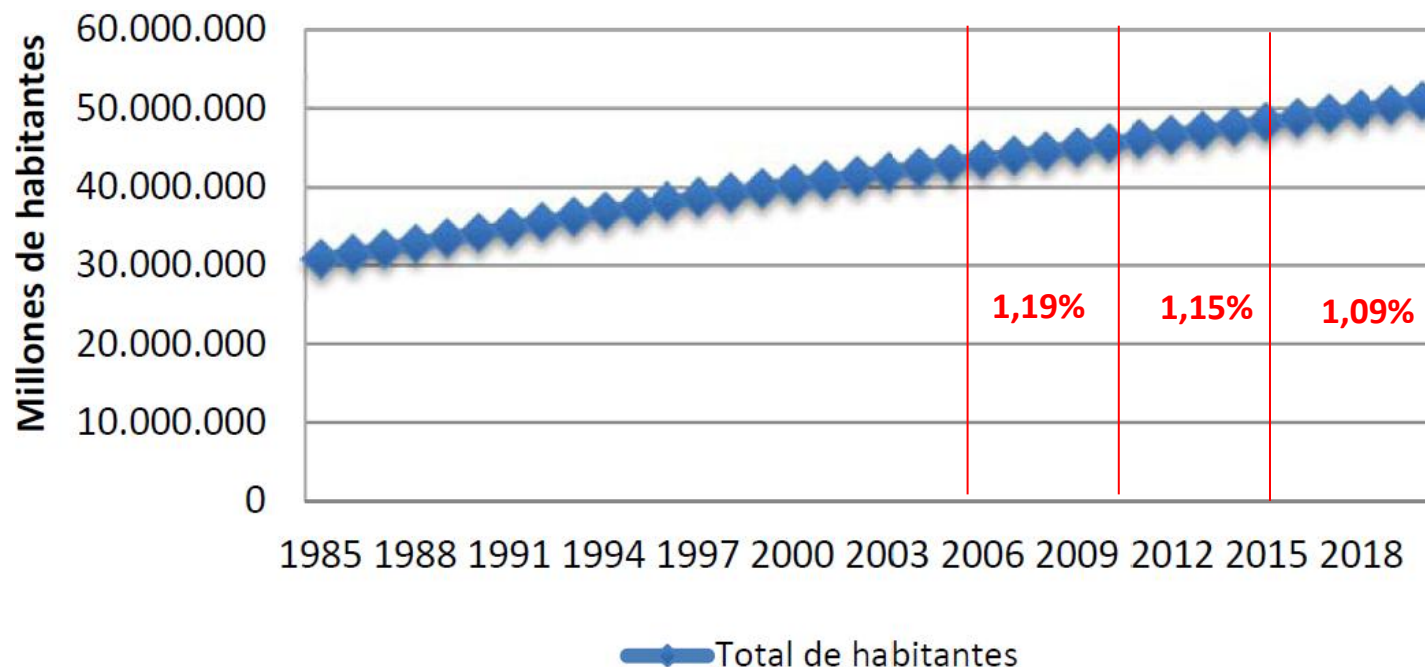


NACIONES UNIDAS

CEPAL

Proyecciones de población DANE. 1985 – 2020

- Población inicial: 42.888.592 a 2005
- Tasa de crecimiento 2000-2005: 1,25%
- Tasa de crecimiento proyectada 2015-2020: 1,09%
- Población final: 50.249.912 a 2020



$$N(t) = k_1 + \frac{k_2}{(1 + \exp(\alpha_0 + \alpha_1 t))}$$

Dónde:

$N(t)$: Población estimada en el tiempo t

k_1 : Límite inferior de la función logística

k_2 : Límite superior de la función logística (Valor donde se estabiliza la población en el largo plazo)

α_0 y α_1 : parámetros a estimar para la función logística con base en modelos econométricos y la información censal anterior.

Para la obtención de los pronósticos de población se emplearon valores para los parámetros $k_1 = 350.000$ y $k_2 = 83.000.000$. - Flórez C. (2000). Las transformaciones demográficas en Colombia durante el sigloXX.

$$N(t) - k_1 = \frac{k_2}{(1 + \exp(\alpha_0 + \alpha_1 t))}$$

$$(1 + \exp(\alpha_0 + \alpha_1 t)) = \frac{k_2}{N(t) - k_1}$$

$$\exp(\alpha_0 + \alpha_1 t) = \left[\frac{k_2}{N(t) - k_1} - 1 \right]$$

$$\alpha_0 + \alpha_1 t = \ln \left[\frac{k_2}{N(t) - k_1} - 1 \right]$$

Reorganizando:

$$\ln \left[\frac{k_2}{N(t) - k_1} - 1 \right] = \alpha_0 + \alpha_1 t$$

Variable dependiente

Variable independiente

Censo	t	Población	U*	Ln (U)=Z
1938	0	9.066.218	8,52247867	2,14270722
1961	13	12.379.910	5,89946974	1,77486247
1964	26	18.337.973	3,61419416	1,28486892
1973	35	23.881.851	2,52713435	0,92708599
1985	47	31.593.587	1,65654517	0,50473421
1993	55	37.422.791	1,23883872	0,21417443
2005	67	41.468.384	1,01856182	0,01839165

Variable independiente

Variable dependiente

Tabla 1. Resultados de la estimación por MCO para los parámetros α_0 y α_1

	<i>Parámetros</i>	<i>Coefficientes</i>	<i>Error típico</i>	<i>Estadístico t</i>	<i>Probabilidad</i>
Intercepción	α_0	2,146394439***	0,057073084	37,60782294	2,50397E-07
t	α_1	-0,033571754***	0,001390491	-24,14381077	2,27157E-06

***Significativo al 1%. R2= 0.99. Prob (F)= 0.000. n=7 observaciones.

Variable dependiente **Ln (U)=Z**

De esta manera, la función logística queda completamente especificada con los siguientes parámetros:

$$N(t) = 350.000 + \frac{83.000.000}{(1 + \exp(2,146394439 - 0,033571754t))}$$



NACIONES UNIDAS

CEPAL



NACIONES UNIDAS

CEPAL



NACIONES UNIDAS

CEPAL



NACIONES UNIDAS

CEPAL

Gracias por su atención

Harold Coronado Arango



NACIONES UNIDAS

CEPAL