

# ECONOMETRÍA I

## Tema 2: El Modelo de Regresión Lineal Simple

Patricia Moreno  
Juan Manuel Rodríguez Poo  
Alexandra Soberon  
Departamento de Economía

- El Modelo de Regresión Lineal Simple nos permite explicar  $y$  en términos de  $x$ .
- Sea

$$y = \beta_0 + \beta_1 x + u,$$

donde

- $y$ : variable dependiente, endógena, explicada o regresando...
- $x$ : variable independiente, exógena, explicativa, de control, regresor...
- $\beta_0$  y  $\beta_1$ : parámetros poblacionales.
- $u$ : término de error o perturbación no observable.

- $\beta_1$ : parámetro de pendiente. Mide la relación entre  $x$  e  $y$ , es decir, cómo cambia  $y$  cuando se producen modificaciones en  $x$ .
- $\beta_0$ : término constante. Es el valor de  $y$  cuando  $x$  y  $u$  son cero.
- Si todos los demás factores contenidos en  $u$  se mantienen constantes ( $\Delta u = 0$ ),  $x$  tiene un efecto lineal sobre  $y$ , es decir,

$$\Delta y = \beta_1 \Delta x \quad \text{si} \quad \Delta u = 0.$$

$$y = \beta_0 + \beta_1 x + u.$$

- **Cultivo de soja y fertilizante:** Si  $y$  = cosecha y  $x$  = cantidad de fertilizante, el término de error ( $u$ ) recoge factores como:
  - calidad de la tierra.
  - lluvia.
- **Ecuación salarial simple:** Si  $y$  = salario y  $x$  = años de estudio, el término de error ( $u$ ) recoge factores no observables como:
  - experiencia laboral.
  - capacidad o habilidad.
  - antigüedad en la empresa.

- **Linealidad en los parámetros:**  $y = \beta_0 + \beta_1 x + u$ ,  
es decir, un cambio unitario en  $x$  tiene el mismo efecto sobre  $y$   
con independencia del valor inicial de  $x$ , i.e.

$$\Delta x = 1 \implies \Delta y = \beta_1, \quad \forall x, \Delta u = 0.$$

- **Media condicional cero:**  $E(u|x) = 0 \forall x$ . Para cualquier valor de  $x$ , la media del término de error no observable es siempre la misma e igual a cero.

$$E(u|x) = E(u) = 0.$$

- El supuesto  $E(u|x) = E(u) = 0$  nos lleva a


$$E(y|x) = \beta_0 + \beta_1 x.$$

- Esta expresión nos proporciona el valor de la **función de regresión poblacional**. En este caso es lineal.
- Nos indica cómo varía el valor medio de  $y$  ante cambios en  $x$ , es decir,

$$\frac{\partial E(y|x)}{\partial x} = \beta_1$$

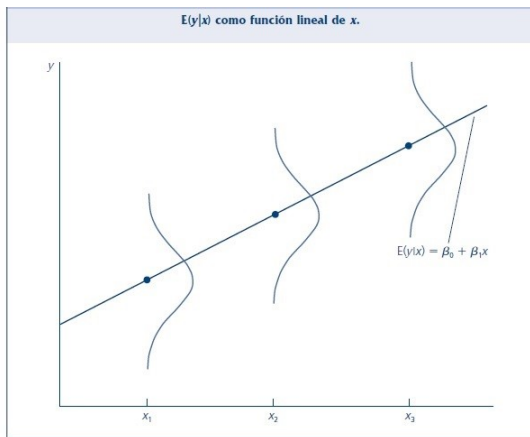
- Así,  $E(y|x) = \beta_0 + \beta_1 x$  es la parte explicada por  $x$  y  $u$  es la parte no explicada por  $x$ .

## Calificaciones en el examen vs. ratio estudiantes-maestros



Fuente: Stock & Watson (2011)

$E(y|x)$  es una función lineal de  $x$ , donde para cualquier  $x$  la distribución de  $y$  está centrada alrededor de  $E(y|x)$ .



Fuente: Wooldridge (2005).



- **Idea básica de la regresión:** estimar los parámetros poblacionales  $(\beta_0, \beta_1)$  a partir de un conjunto de datos.
- Siendo  $\{(x_i, y_i) : i = 1, \dots, n\}$  una muestra aleatoria de tamaño  $n$  tomada de una población desconocida, para cada observación  $i$  tenemos

$$y_i = \beta_0 + \beta_1 x_i + u_i$$

- **Supuesto necesario estimadores OLS:**  $E(u|x) = E(u) = 0$  que también implica  $Cov(x, u) = E(xu) = 0$ .
- ¿Por qué? Recuerda de la probabilidad básica que

$$Cov(x, y) = E(xy) - E(x)E(y).$$

- Dado que  $u = y - \beta_0 - \beta_1 x$ , es posible expresar los parámetros desconocidos en términos de  $x, y, \beta_0$  y  $\beta_1$ . Así, obtenemos dos **restricciones de momento**:

$$E[y - \beta_0 - \beta_1 x] = 0$$

$$E[x(y - \beta_0 - \beta_1 x)] = 0.$$

- **Método de los momentos**: proceso de estimación que implica la imposición de restricciones de momentos poblacionales sobre los momentos muestrales.
- ¿Qué implica todo esto? Sea una muestra aleatoria de observaciones de  $y$ ,  $\{y_i\}_{i=1}^n$ , para estimar  $E(y)$  utilizamos la media muestral  $\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i$ .

- **Objetivo:** elegir los valores de los parámetros poblacionales que aseguran que las versiones muestrales de las restricciones de momento son ciertas:

$$n^{-1} \sum_{i=1}^n (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i) = 0$$

$$n^{-1} \sum_{i=1}^n x_i (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i) = 0$$

- Dada la definición de la media muestral y aprovechando las propiedades básicas de la suma, podemos reescribir la primera condición como

$$\bar{y} = \hat{\beta}_0 + \hat{\beta}_1 \bar{x},$$

## MCO: método de los momentos

Reemplazando la expresión de  $\hat{\beta}_0$

$$\sum_{i=1}^n x_i (y_i - (\bar{y} - \hat{\beta}_1 \bar{x}) - \hat{\beta}_1 x_i) = 0$$

y agrupando términos,

$$\sum_{i=1}^n x_i (y_i - \bar{y}) = \hat{\beta}_1 \sum_{i=1}^n x_i (x_i - \bar{x}).$$

Utilizando las relaciones  $\sum_{i=1}^n (x_i - \bar{x})x_i = \sum_{i=1}^n (x_i - \bar{x})^2$  y  $\sum_{i=1}^n (y_i - \bar{y})x_i = \sum_{i=1}^n (y_i - \bar{y})(x_i - \bar{x})$ ,

$$\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) = \hat{\beta}_1 \sum_{i=1}^n (x_i - \bar{x})^2.$$

- Los **estimadores MCO** resultantes son:

$$\hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x},$$

$$\hat{\beta}_1 = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2}.$$

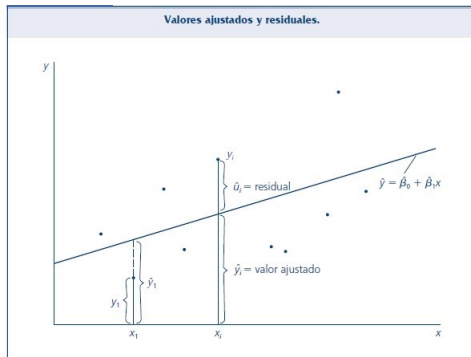
- **Objetivo:** estudiar la relación entre el rendimiento sobre el capital de una empresa y el sueldo de los directores generales de dicha empresa (CEO).
- **Variables disponibles:**
  - *salary*: sueldo anual de los CEOs.
  - *roe*: rendimiento del capital medio de las empresas.
- **Modelo:**  $salary = \beta_0 + \beta_1 roe + u$
- **Recta de regresión:**  $\widehat{salary} = 963,191 + 18,501 roe$ .
- ¿Cuál es el cambio predicho en *salary* ante un aumento unitario en *roe*?
- ¿Cuál es el sueldo predicho si  $roe = 30$ ?

- El estimador de la pendiente  $\hat{\beta}_1$  es simplemente la covarianza muestral entre  $x$  y  $y$  dividida entre la varianza muestral de  $x$ .
- Si  $x$  e  $y$  están correlacionadas positivamente,  $\hat{\beta}_1$  será positiva.
- Si  $x$  e  $y$  están correlacionadas negativamente,  $\hat{\beta}_1$  será negativa.
- Para obtener  $\hat{\beta}_1$  la condición necesaria es que  $x$  varíe a lo largo de la muestra.

# Función de regresión muestral

Una vez obtenidos los estimadores podemos calcular el valor ajustado (predicho):

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x$$



Fuente: Wooldridge (2005)



# MCO: criterio de minimización de residuos

- **Criterio MCO:** escoger  $\hat{\beta}_0$  y  $\hat{\beta}_1$  tal que la suma de residuos al cuadrado,  $E(u_i^2)$ , sea lo más pequeña posible.
- **Residuos:** diferencia existente entre el valor observado  $y_i$  y el valor ajustado o predicho  $\hat{y}_i$ :

$$\hat{u}_i = y_i - \hat{y}_i = y_i - (\hat{\beta}_0 + \hat{\beta}_1 x_i)$$

- Análogo muestral del modelo del problema a minimizar  $E(u_i^2)$

$$\min_{\beta_0, \beta_1} \sum_{i=1}^n (\hat{u}_i)^2 = \min_{\beta_0, \beta_1} \sum_{i=1}^n (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i)^2.$$

- Las condiciones de primer orden son

$$\sum_{i=1}^n (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i) = 0,$$
$$\sum_{i=1}^n x_i (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i) = 0.$$

- Estas condiciones de primer orden son el análogo muestral de las condiciones de primer orden poblacionales, es decir,

$$E(u) = 0,$$

$$\text{Cov}(x, u) = 0.$$

- La suma (y la media muestral) de los residuos MCO son cero,

$$\sum_{i=1}^n \hat{u}_i = 0.$$

- La covarianza muestral entre los regresores y los residuos MCO es cero,

$$\sum_{i=1}^n x_i \hat{u}_i = 0.$$

- La covarianza muestral entre los valores ajustados y los residuos MCO es cero,

$$\sum_{i=1}^n \hat{y}_i \hat{u}_i = 0.$$

- El punto  $(\bar{x}, \bar{y})$  siempre se encuentra sobre la recta ajustada, es decir

$$\bar{y} = \hat{\beta}_0 + \hat{\beta}_1 \bar{x}.$$

- $y_i$  puede ser descompuesto entre el valor ajustado y su residuo asociado, que están incorrelacionados, es decir,

$$y_i = \hat{y}_i + \hat{u}_i.$$

- **Coefficiente de determinación ( $R^2$ ):** se interpreta como el porcentaje de la variación muestral de  $y$  que es explicado por  $x$  y se calcula como la fracción de la suma total de los cuadrados (SST) que es explicada por el modelo:

$$R^2 = \frac{SSE}{SST} = 1 - \frac{SSR}{SST}.$$

donde

- Suma Total de los Cuadrados (SST):  $SST = \sum_{i=1}^n (y_i - \bar{y})^2$ .
  - Suma Explicada de los Cuadrados (SSE):  $SSE = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$ .
  - Suma de los Cuadrados de los Residuos (SSR):  $SSR = \sum_{i=1}^n \hat{u}_i^2$ .
- $SST = SSE + SSR$ .

- $SST = SSE + SSR$ . Prueba:

$$\begin{aligned}\sum_{i=1}^n (y_i - \bar{y})^2 &= \sum_{i=1}^n [(y_i - \hat{y}_i) + (\hat{y}_i - \bar{y})]^2 \\ &= \sum_{i=1}^n [\hat{u}_i + (\hat{y}_i - \bar{y})]^2 \\ &= \sum_{i=1}^n \hat{u}_i^2 + 2 \sum_{i=1}^n \hat{u}_i (\hat{y}_i - \bar{y}) + \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 \\ &= SSR + 2 \sum_{i=1}^n \hat{u}_i (\hat{y}_i - \bar{y}) + SSE,\end{aligned}$$

donde sabemos que  $\sum_{i=1}^n \hat{u}_i (\hat{y}_i - \bar{y}) = 0$ .

- ¿Cómo cambios en las unidades de medida de la variable dependiente o de la independiente afecta a las estimaciones MCO?

$$\widehat{salary} = 0,963191 + 0,018501roe$$

- Cambio en (Y): si  $Y$  es multiplicada por  $c = 1000$ ,

$$\widehat{salary} = 963,191 + 18,501roe$$

- Cambio en (X): si definimos  $roedec = roe/100$ ,

$$\widehat{salary} = 963,191 + 1850,1roedec$$

- Las relaciones lineales no son suficientes para describir las relaciones económicas.
- **Modelo lineal:** implica que el incremento de  $y$  ante cambios en  $x$  es siempre igual, independientemente del nivel de  $x$ :

$$salary = \beta_0 + \beta_1 roe + u$$

- **Elasticidad constante (log-log):** la relación entre  $x$  e  $y$  se establece en términos de incrementos relativos.

$$\log(salary) = \beta_0 + \beta_1 \log(roe) + u,$$

donde  $\beta_1$  es la elasticidad de  $salary$  respecto a  $roe$ . Así,

$$\% \Delta salary = \beta_1 \% \Delta roe.$$



- **Semielasticidad (log-level):** el cambio se produce en términos porcentuales.

$$\log(\text{salary}) = \beta_0 + \beta_1 \text{roe} + u$$

Si  $\Delta u = 0$ , entonces  $(100 \cdot \beta_1)$  es la semielasticidad de *salary* respecto a *roe*,

$$\% \Delta \text{salary} = (100 \cdot \beta_1) \Delta \text{roe}.$$

- **Semielasticidad (level-log):** controlamos incrementos relativos de  $x$ ,

$$\text{salary} = \beta_0 + \beta_1 \log(\text{roe}) + u,$$

donde  $\Delta Y = \frac{\beta_1}{100} \% \Delta x$ .

| <b>Modelo</b>      | <b>Var. Dep</b> | <b>Var. Indep</b> | <b>Interpretación</b>                  |
|--------------------|-----------------|-------------------|--|
| <b>Nivel-nivel</b> | $Y$             | $X$               | $\Delta Y = \beta_1 \Delta X$          |
| <b>Nivel-log</b>   | $Y$             | $\log(X)$         | $\Delta Y = (\beta_1/100) \% \Delta X$ |
| <b>Log-nivel</b>   | $\log(Y)$       | $X$               | $\% \Delta Y = (100\beta_1) \Delta X$  |
| <b>Log-log</b>     | $\log(Y)$       | $\log(X)$         | $\% \Delta Y = \beta_1 \% \Delta X$    |

- Supuestos necesarios:

- **Linealidad:** el modelo poblacional es lineal en parámetros,  
$$y = \beta_0 + \beta_1 x + u.$$
  - **Muestreo aleatorio:** Contamos con una muestra aleatoria de tamaño  $n$ ,  $\{(x_i, y_i) : i = 1, 2, \dots, n\}$ . Así, el modelo muestral es  
$$y_i = \beta_0 + \beta_1 x_i + u_i.$$
  - **Media condicional cero:**  $E(u|x) = 0$  de modo que  $E(u_i|x_i) = 0$ .
  - **Variación muestral de la variable explicativa:** no todos los valores muestrales de  $x$  son iguales.
- Para analizar el sesgo del estimador MCO es necesario reescribirlo en términos de los parámetros poblacionales.

# Insesgadez de los estimadores MCO

- Estimador de la pendiente:

$$\hat{\beta}_1 = \frac{\sum_{i=1}^n (x_i - \bar{x})y_i}{\sum_{i=1}^n (x_i - \bar{x})^2} = \frac{\sum_{i=1}^n (x_i - \bar{x})y_i}{s_x^2}$$

- Numerador:

$$\begin{aligned} \sum_{i=1}^n (x_i - \bar{x})y_i &= \sum_{i=1}^n (x_i - \bar{x})(\beta_0 + \beta_1 x_i + u_i) \\ &= \sum_{i=1}^n (x_i - \bar{x})\beta_0 + \sum_{i=1}^n (x_i - \bar{x})\beta_1 x_i + \sum_{i=1}^n (x_i - \bar{x})u_i \\ &= \beta_0 \sum_{i=1}^n (x_i - \bar{x}) + \beta_1 \sum_{i=1}^n (x_i - \bar{x})x_i + \sum_{i=1}^n (x_i - \bar{x})u_i \\ &= \beta_1 s_x^2 + \sum_{i=1}^n (x_i - \bar{x})u_i, \end{aligned}$$

dado que  $\sum_{i=1}^n (x_i - \bar{x}) = 0$  y  $\sum_{i=1}^n (x_i - \bar{x})x_i = \sum_{i=1}^n (x_i - \bar{x})^2$ .

# Insesgadez de los estimadores MCO

- De este modo,

$$\hat{\beta}_1 = \beta_1 + \frac{\sum_{i=1}^n (x_i - \bar{x}) u_i}{s_x^2}.$$

- Definiendo  $d_i = (x_i - \bar{x})$ ,

$$\hat{\beta}_1 = \beta_1 + \left( \frac{1}{s_x^2} \right) \sum_{i=1}^n d_i u_i.$$

- Finalmente,

$$E(\hat{\beta}_1) = \beta_1 + \left( \frac{1}{s_x^2} \right) \sum_{i=1}^n d_i E(u_i) = \beta_1$$

- Los estimadores MCO de  $\beta_0$  y  $\beta_1$  son insesgados.
- La prueba de insesgadez de los estimadores MCO depende de los 4 supuestos. Si uno sólo falla entonces los estimadores MCO no son necesariamente insesgados.
- La insesgadez es una descripción de los estimadores. En concreto, nos indica si está cerca o lejos del verdadero parámetro.

- La propiedad de insesgadez es una descripción de los estimadores que nos indica que si disponemos de un  $n^{\circ}$  finito de muestras de tamaño  $n$  de la misma población y estimamos el mismo modelo con cada una de las muestras:
  - tendremos una distribución de valores estimados de  $\beta_j$ , con una realización numérica distinta para cada muestra.
  - la media de la distribución de dichos valores estimados de  $\beta_j$  coincidirá con el parámetro poblacional  $\beta_j$ .

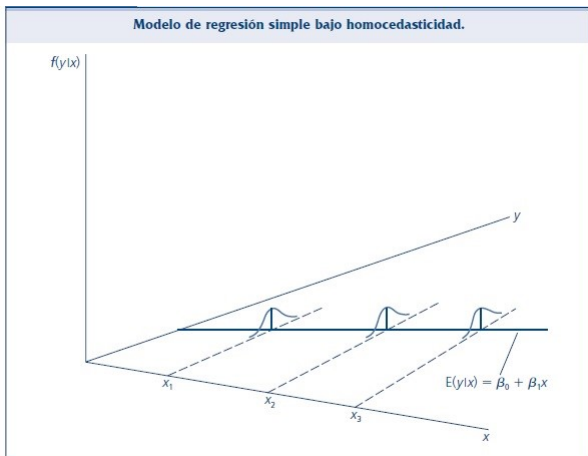
- Además de saber que la distribución muestral de  $\hat{\beta}_1$  está centrada en  $\beta_1$ , también es relevante saber qué tanto puede esperarse que  $\hat{\beta}_1$  se aleje, en promedio, de  $\beta_1$ .
- Así seremos capaces de elegir el mejor estimador de una amplia gama de estimadores insesgados.



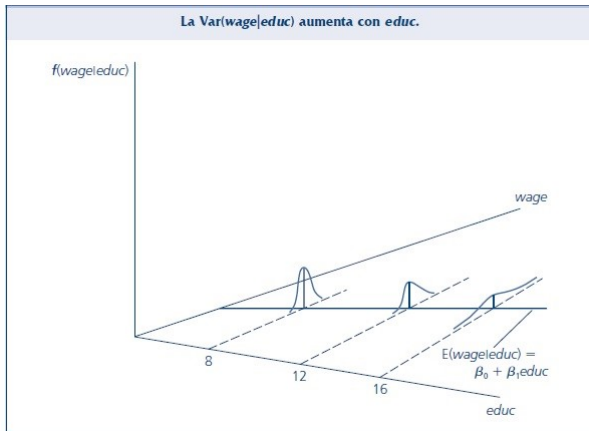
- Supuesto adicional:  $Var(u|x) = \sigma^2$  (**homocedasticidad**) y dado que  $Var(u|x) = E(u^2|x) - [E(u|x)]^2$  y  $E(u|x) = 0$ ,

$$\sigma^2 = E(u^2|x) = E(u^2) = Var(u).$$

- Así,  $\sigma^2$  es la varianza incondicional, también conocida como la varianza del error.
- $\sigma$  (la raíz cuadrada de la varianza del error) es conocida como la desviación estándar del error.



Fuente: Wooldridge (2005)



Fuente: Wooldridge (2005)

# Varianza del estimador OLS

$$\begin{aligned}
 \text{Var}(\hat{\beta}_1) &= \text{Var}\left(\beta_1 + \left(\frac{1}{s_x^2} \sum_{i=1}^n d_i u_i\right)\right) \\
 &= \left(\frac{1}{s_x^2}\right)^2 \text{Var}\left(\sum_{i=1}^n d_i u_i\right) \\
 &= \left(\frac{1}{s_x^2}\right)^2 \sum_{i=1}^n d_i^2 \text{Var}(u_i) \\
 &= \left(\frac{1}{s_x^2}\right)^2 \sum_{i=1}^n d_i^2 \sigma^2 = \sigma^2 \left(\frac{1}{s_x^2}\right)^2 \sum_{i=1}^n d_i^2 \\
 &= \sigma^2 \left(\frac{1}{s_x^2}\right)^2 s_x^2 = \frac{\sigma^2}{s_x^2}
 \end{aligned}$$

- Cuanto mayor sea la varianza del error ( $\sigma^2$ ) mayor será la varianza del estimador de la pendiente  $Var(\hat{\beta}_1)$ .
- A medida que aumenta la variabilidad de las  $x_i$ , la varianza del estimador de la pendiente  $Var(\hat{\beta}_1)$  será menor.
- Como resultado, a medida que se incrementa el tamaño de la muestra  $n$  también aumentará la varianzación total de las  $x_i$  obteniendo una menor  $Var(\hat{\beta}_1)$ .
- **Problema:** la varianza del error ( $\sigma^2$ ) es desconocida.

# Estimación de la varianza del error $\sigma^2$

- Dado que los errores,  $u_i$ , no pueden ser observados nosotros nos conocemos la varianza del error,  $\sigma^2$ .
- Lo que podemos observar son los residuos de modo que podemos usarlos para estimar la varianza del error:

$$\begin{aligned}\hat{u}_i &= y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i \\ &= u_i - (\hat{\beta}_0 - \beta_0) - (\hat{\beta}_1 - \beta_1) x_i.\end{aligned}$$

- Reemplazando los errores por los residuos, un estimador factible de  $\sigma^2$  sería

$$\tilde{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n \hat{u}_i^2.$$

# Estimación de la varianza del error $\sigma^2$

- **Problema:** Este estimador es factible pero sesgado. Como los residuos verifican  $n^{-1} \sum_{i=1}^n \hat{u}_i = 0$  y  $n^{-1} \sum_{i=1}^n \hat{u}_i x_i = 0$ , sólo hay  $(n - 2)$  residuos independientes (**grados de libertad**).
- Un estimador insesgado factible de  $\sigma^2$  es

$$\hat{\sigma}^2 = \frac{1}{(n - 2)} \sum_{i=1}^n \hat{u}_i^2 = \frac{SSR}{(n - 2)}.$$

- Tanto  $\tilde{\sigma}^2$  como  $\hat{\sigma}^2$  son estimadores consistentes de  $\sigma^2$ . Para tamaños muestrales moderados es irrelevante cuál de los dos utilizar dado que siempre que  $n$  no sea muy pequeño nos proporcionarán estimaciones numéricas muy similares.

- En el caso poblacional vimos que la función de esperanza condicional  $E(y|x)$  es la proyección lineal de  $y$  dado  $x$ , en el sentido de que minimiza  $E(u^2)$ .
- Por analogía, en el caso de la estimación MCO a partir de una muestra de los coeficientes del modelo de regresión clásico tenemos  $Var(u|x) = \sigma^2$  de modo que  $sd(\hat{\beta}_1) = \frac{\sigma}{s_x}$ .
- De este modo,  $\hat{\sigma} = \sqrt{\hat{\sigma}^2}$  es el Error Estándar de la regresión.
- Reemplazando  $\sigma$  por  $\hat{\sigma}$  obtenemos el **Error Estándar** de  $\hat{\beta}_1$ ,

$$se(\hat{\beta}_1) = \frac{\hat{\sigma}}{(\sum_{i=1}^n (x_i - \bar{x})^2)^{1/2}}.$$



- **Supuestos:**

- Linealidad en los parámetros del modelo.
- Muestreo aleatorio.
- Variación muestral en la variable explicativa.
- Media condicional cero.
- Homocedasticidad.

- **Teorema:** En el contexto del modelo de regresión lineal, bajo los 4 supuestos anteriores  $\hat{\beta}_0$  y  $\hat{\beta}_1$  son los estimadores de menor varianza entre los estimadores lineales e insesgados.

# Regresión a través del origen

- En ocasiones se impone la restricción de que cuando  $x = 0$  el valor esperado de  $y$  es cero. Ej: si el ingreso es cero ( $x = 0$ ), la recaudación de impuestos de las rentas del trabajo y debe ser cero.
- **Regresión a través del origen:**

$$\tilde{y} = \tilde{\beta}_1 x.$$

- **Problema de suma de cuadrados residual:**

$$\sum_{i=1}^n (y_i - \tilde{\beta}_1 x_i)^2.$$

- **Estimador MCO:**

$$\tilde{\beta}_1 = \frac{\sum_{i=1}^n x_i y_i}{\sum_{i=1}^n x_i^2}.$$