

# REGRESION Y CORRELACION LINEALES

# Relaciones entre variables y regresión

• El término **regresión fue introducido por Galton** (1889) refiriéndose a la “ley de la regresión universal”:

– “Cada peculiaridad en un hombre es compartida por sus descendientes, pero **en media**, en un grado menor.”

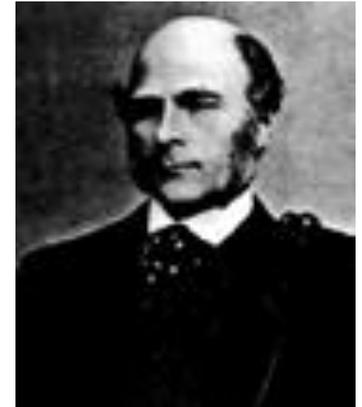
- **Regresión a la media**

– Su trabajo se centraba en la descripción de los rasgos físicos de los descendientes (una variable) a partir de los de sus padres (otra variable).

– **Pearson** realizó un estudio con más de 1000 registros de grupos familiares observando una relación del tipo:

- **Altura del hijo = 85cm + 0,5 altura del padre (aprox.)**

- **Conclusión:** los padres muy altos tienen tendencia a tener hijos que heredan parte de esta altura, aunque tienen tendencia a acercarse (*regresar*) a la media. Lo mismo puede decirse de los padres muy bajos.



Francis Galton



Karl Pearson

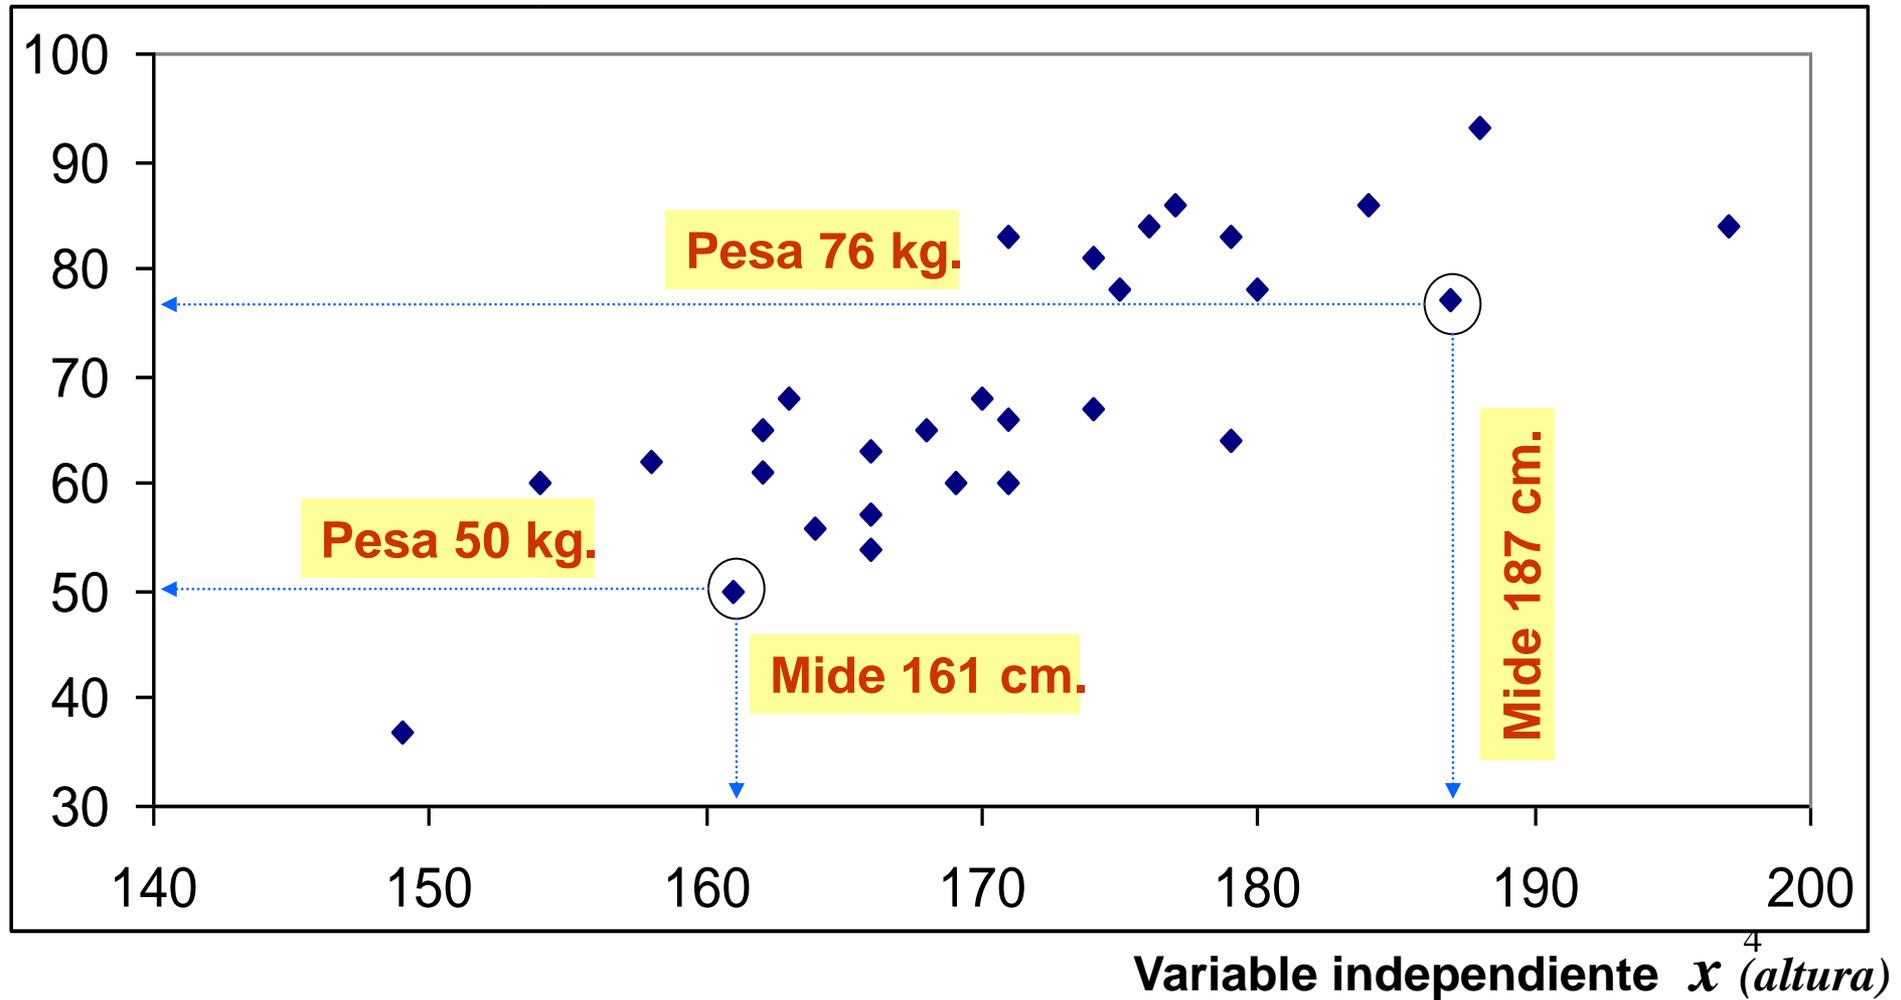
# Regresión

- Describir la relación entre dos variables numéricas
- El análisis de regresión sirve para **predecir** una medida en función de otra medida (o varias).
  - **Y = Variable dependiente**
    - predicha
    - explicada
  - **X = Variable independiente**
    - predictora
    - explicativa
  - ¿Es posible descubrir una relación?
    - **$Y = f(X) + \text{error}$** 
      - f es una función de un tipo determinado
      - el error es aleatorio, pequeño, y no depende de X

# Diagramas de **dispersión** , nube de puntos o “Scaterplot”

Tenemos las alturas y los pesos de 30 individuos representados en un diagrama de dispersión.

Variable dependiente  $y$  (*peso*)



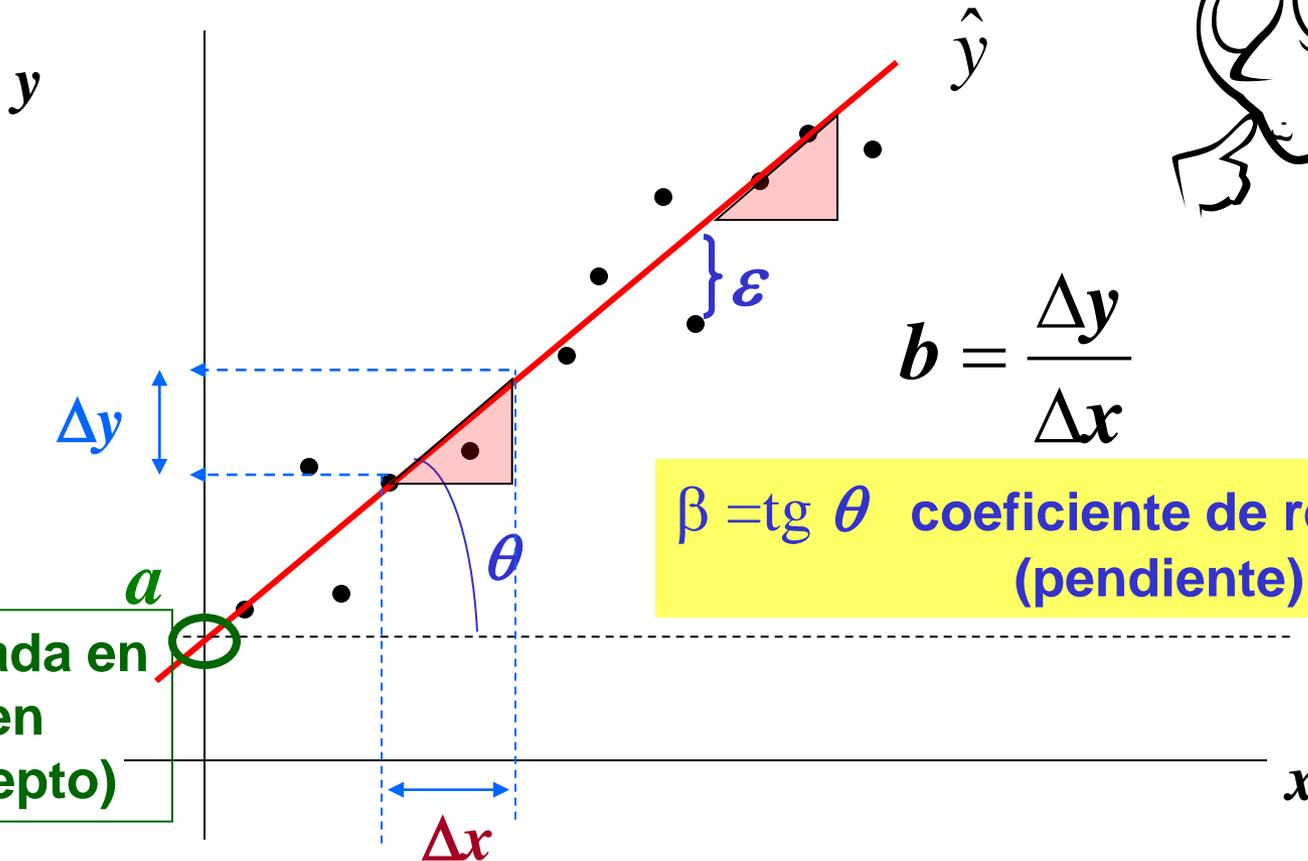
# REGRESION LINEAL SIMPLE

Finalidad

Estimar los valores de  $y$  (variable dependiente) a partir de los valores de  $x$  (variable independiente)

Modelo

$$y = \alpha + \beta x + \varepsilon$$

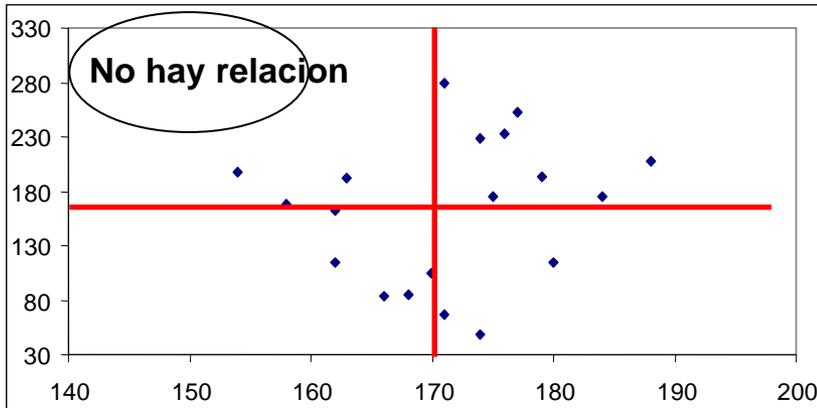


$$b = \frac{\Delta y}{\Delta x}$$

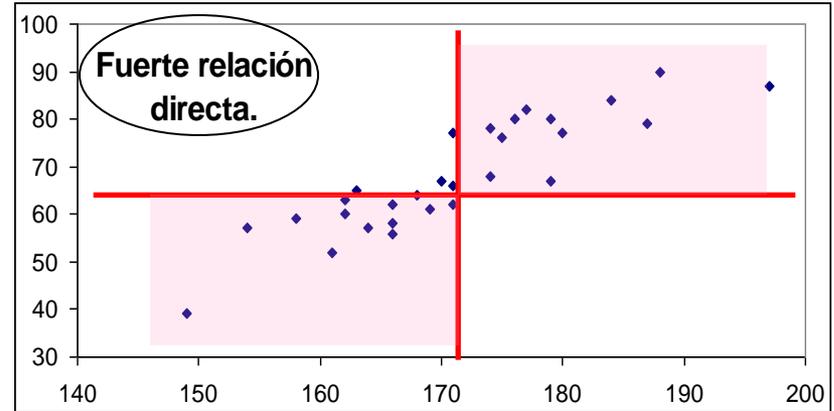
$\beta = \text{tg } \theta$  coeficiente de regresión (pendiente)

Ordenada en el origen (intercepto)

# Relación directa e inversa

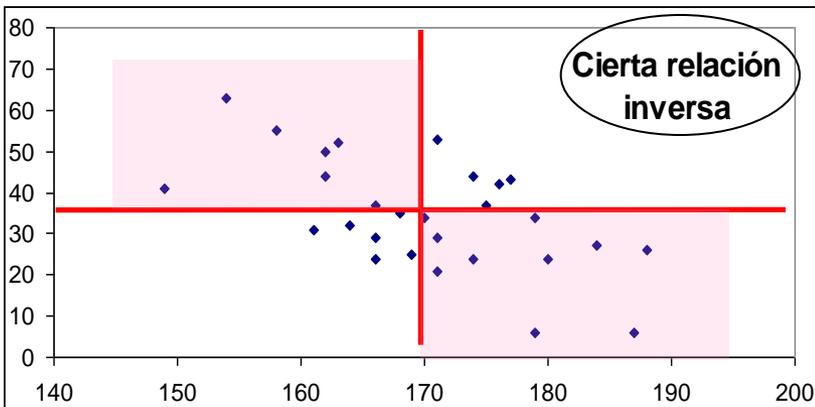


Para valores de X por encima de la media tenemos valores de Y por encima y por debajo en proporciones similares.



- Para los valores de X mayores que la media le corresponden valores de Y mayores también.

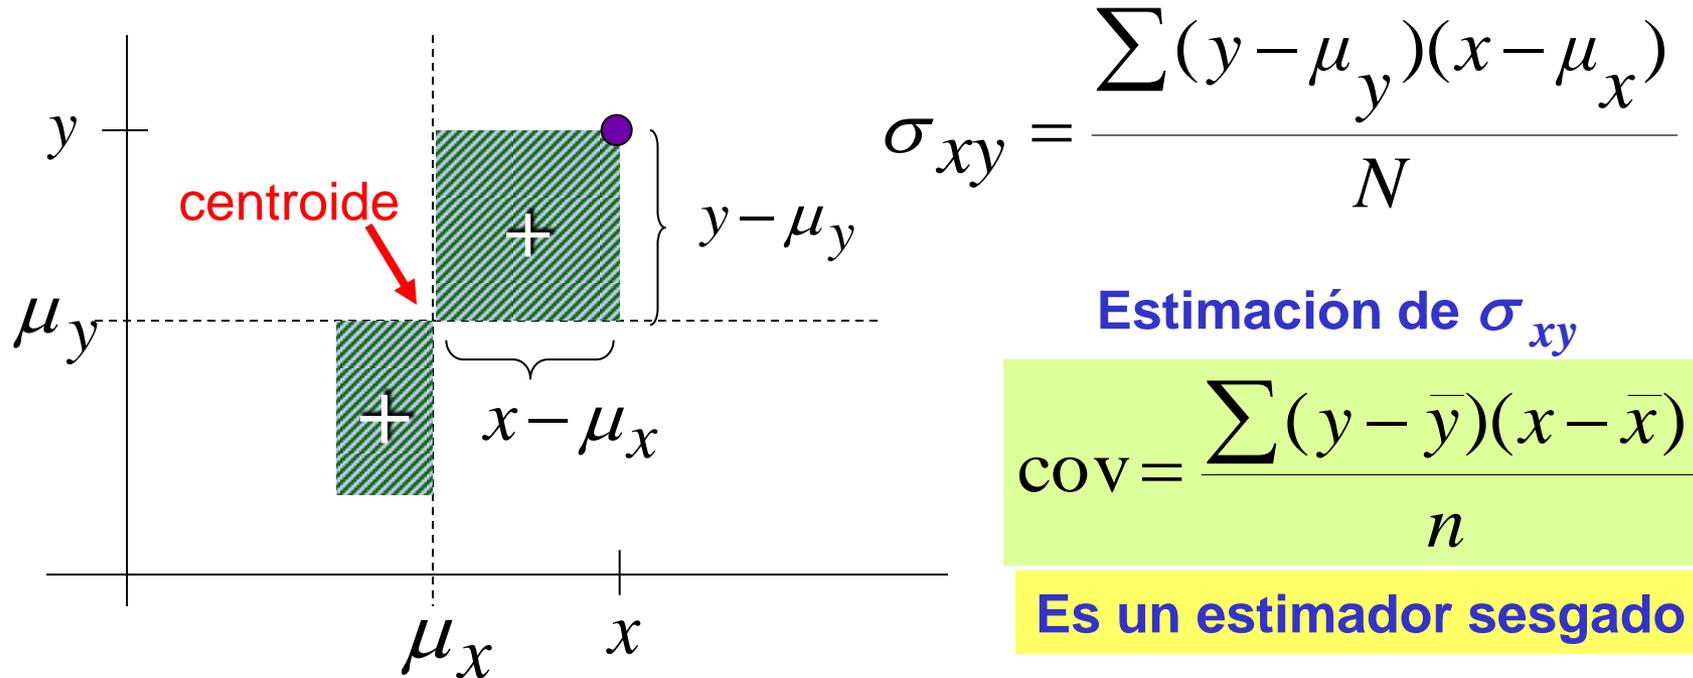
- Para los valores de X menores que la media le corresponden valores de Y menores también. : **relación directa.**



Para los valores de X mayores que la media le corresponden valores de Y menores. Esto es **relación inversa** o decreciente.

# COVARIANZA

Es una medida de la variación lineal conjunta de dos variables



- $\sigma_{xy} < 0$  asociación lineal con pendiente negativa
- $\sigma_{xy} = 0$  ausencia de asociación lineal
- $\sigma_{xy} > 0$  asociación lineal con pendiente positiva

■ El **signo de la covarianza** nos dice si el aspecto de la nube de puntos es creciente o no, pero **no** nos dice nada sobre el **grado de relación** entre las variables.

## Coef. de correlación lineal de Pearson

**r** Valor en la muestra

**$\rho$**  (Rho ) en la población

El **coeficiente de correlación lineal de Pearson** de dos variables,  $r$ , indica si los puntos tienen una **tendencia a disponerse alineadamente** (excluyendo rectas horizontales y verticales).

# CORRELACION LINEAL

## Finalidad

Medir la intensidad de la asociación lineal entre dos variables aleatorias

coeficiente de correlación

$$\rho = \sigma_{xy} / \sigma_x \sigma_y$$

$$r = s_{xy} / s_x s_y$$

covarianza poblacional

coeficiente de determinación

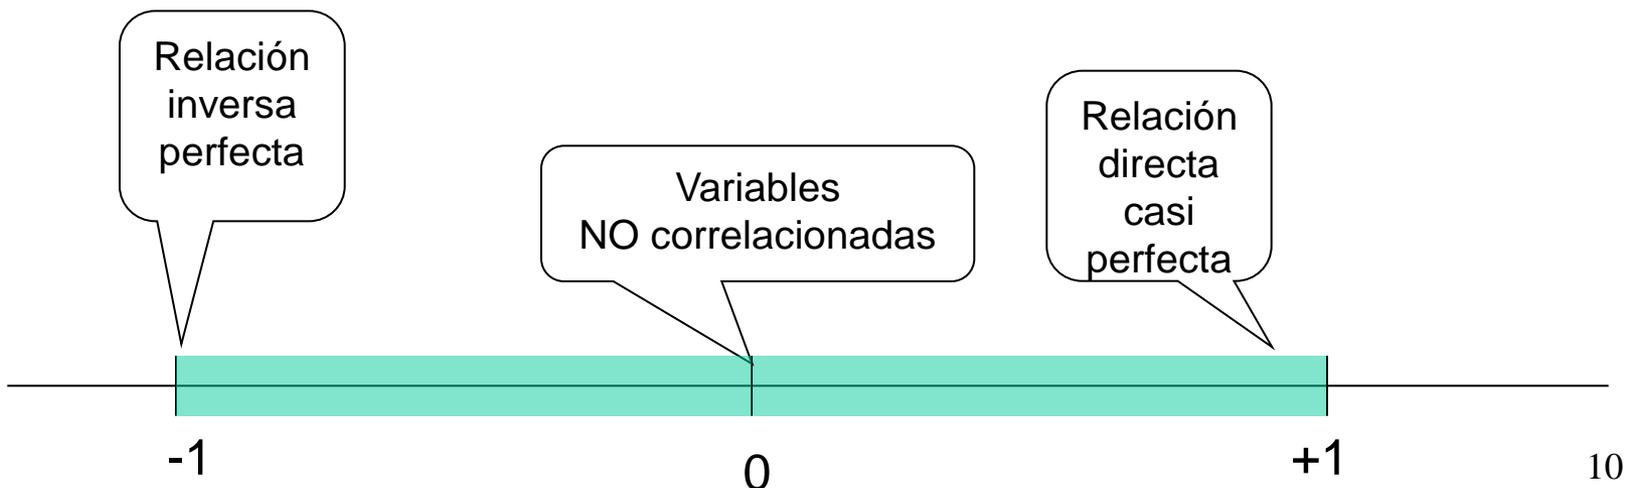
$$\rho^2$$

$$r^2$$

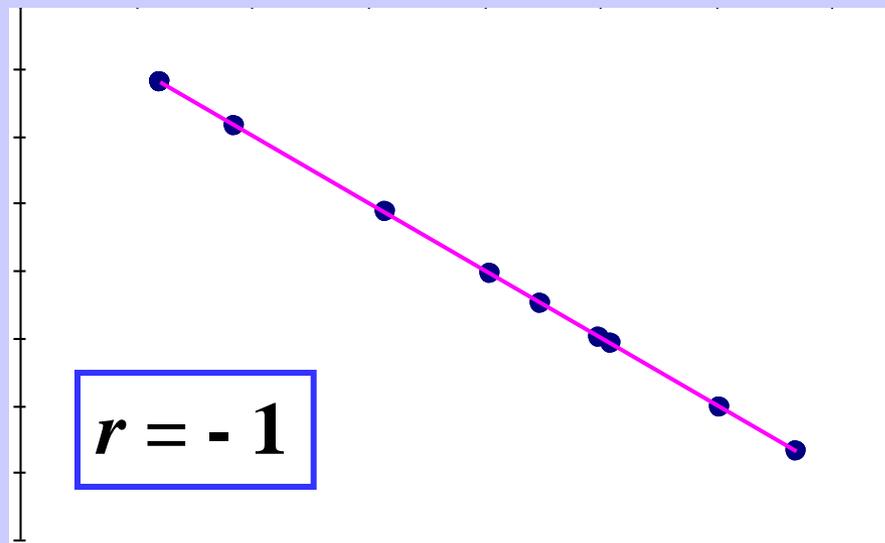
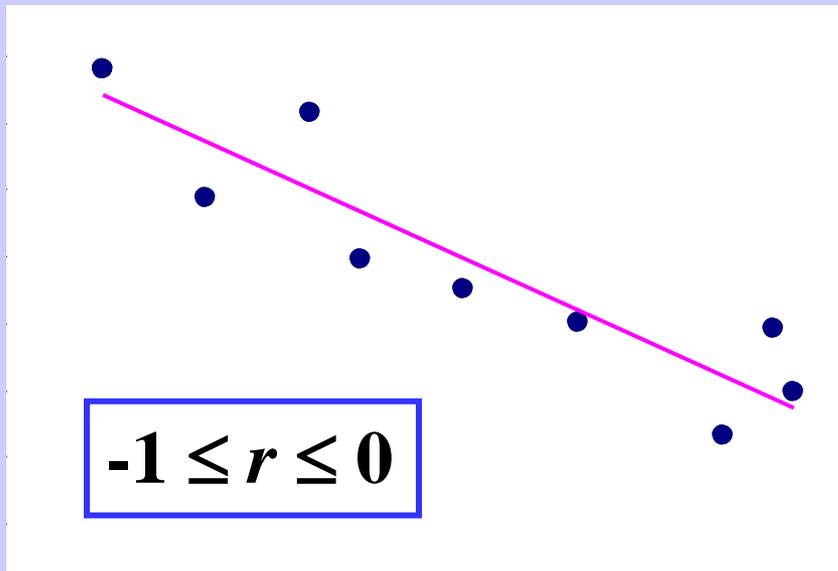
**Proporción de varianza compartida por las dos variables**

# Propiedades de $r$

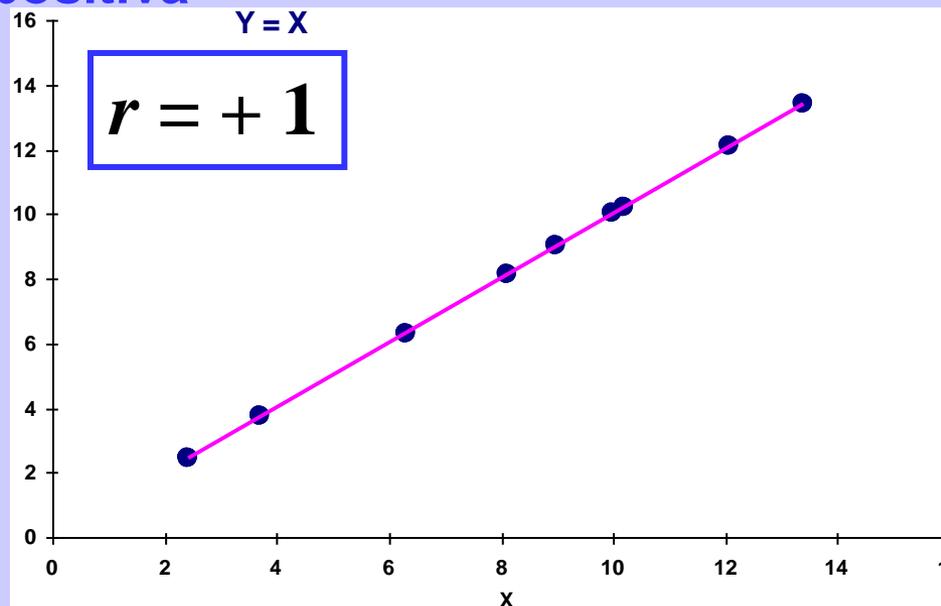
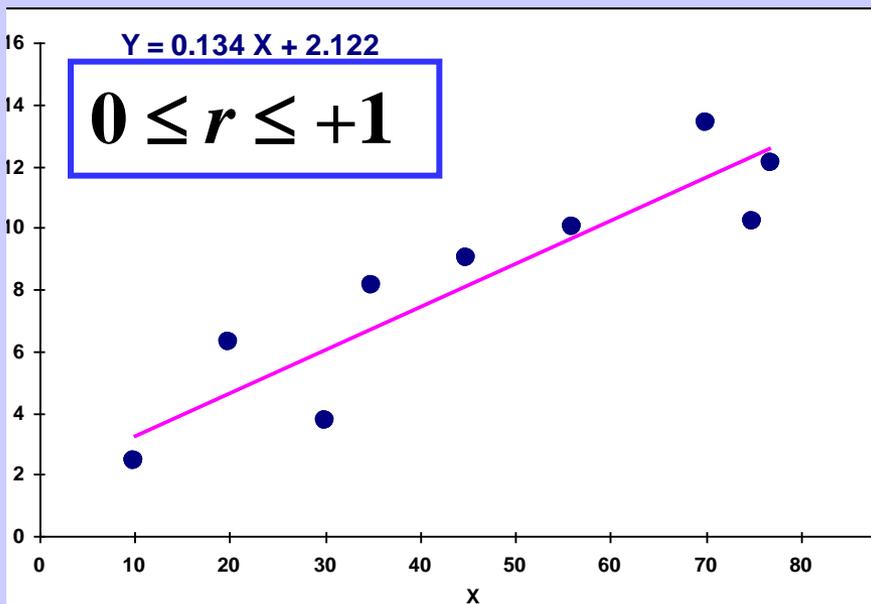
- Es adimensional
- Sólo toma valores entre  $-1$  y  $+1$
- Las variables **NO** están correlacionadas  $\Leftrightarrow r=0$
- **Relación lineal perfecta** entre dos variables  $\Leftrightarrow r = +1$  o  $r=-1$ 
  - Excluimos los casos de puntos alineados horiz. o verticalmente.
- Cuanto más cerca esté  $r$  de  $+1$  o  $-1$  mejor será el grado de relación lineal.
  - Siempre que no existan observaciones anómalas.

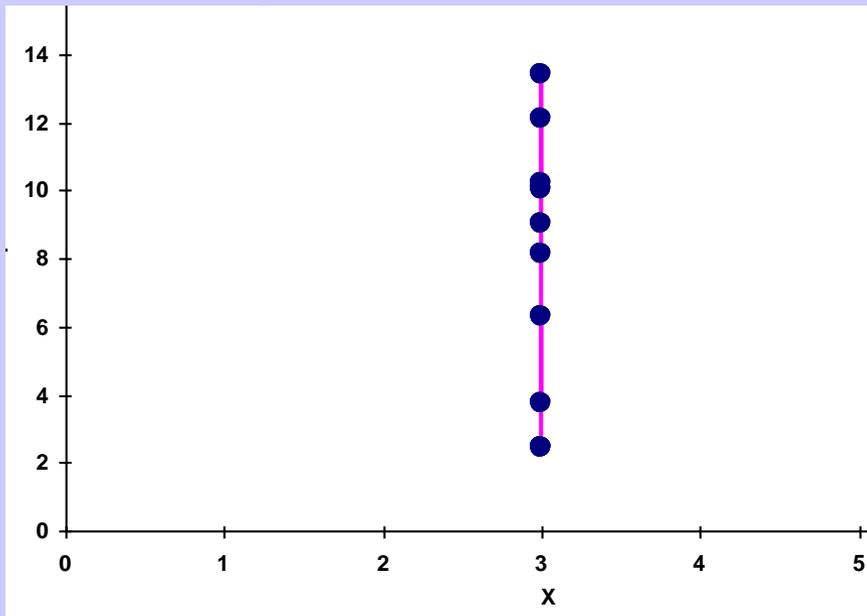
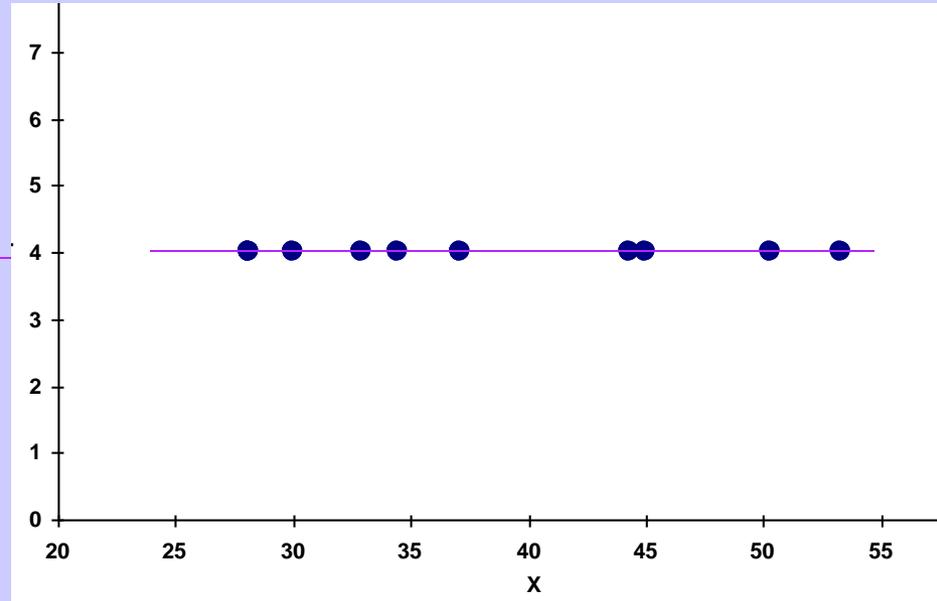
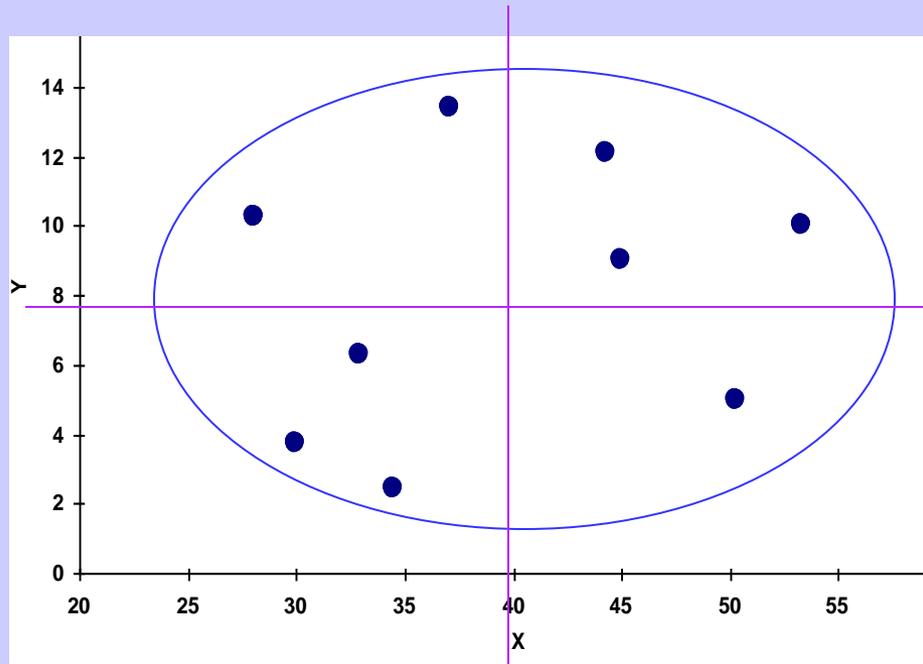


## Correlación negativa



## Correlación positiva

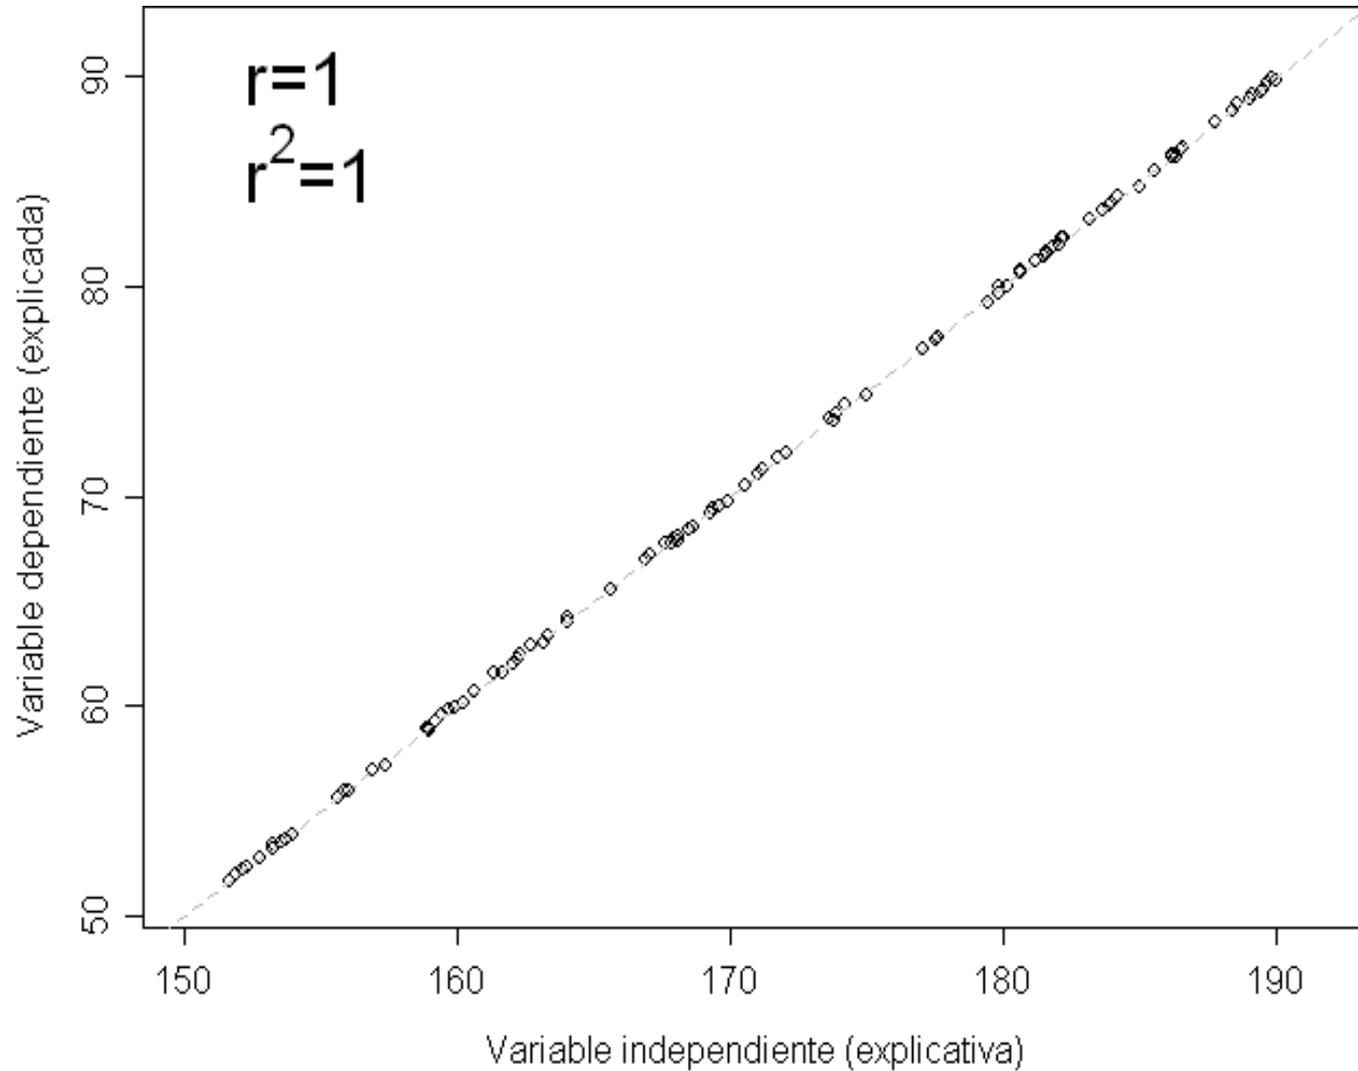




$$r = 0$$

Ausencia de correlación

## Animación: Evolución de r y diagrama de dispersión



ESTIMACION DE  $\rho$  (rho)

$$r = \frac{Cov}{s_x \cdot s_y}$$

PRUEBA DE

$$H_0: \rho = 0$$

$$t_{calc} = \frac{r \sqrt{n-2}}{\sqrt{1-r^2}}$$

Se compara con el valor crítico ( $t$  tabulado)

## CONSIDERACIONES PARA LA VALIDEZ DEL TEST

Los residuos (  $e$  ) deben ser :

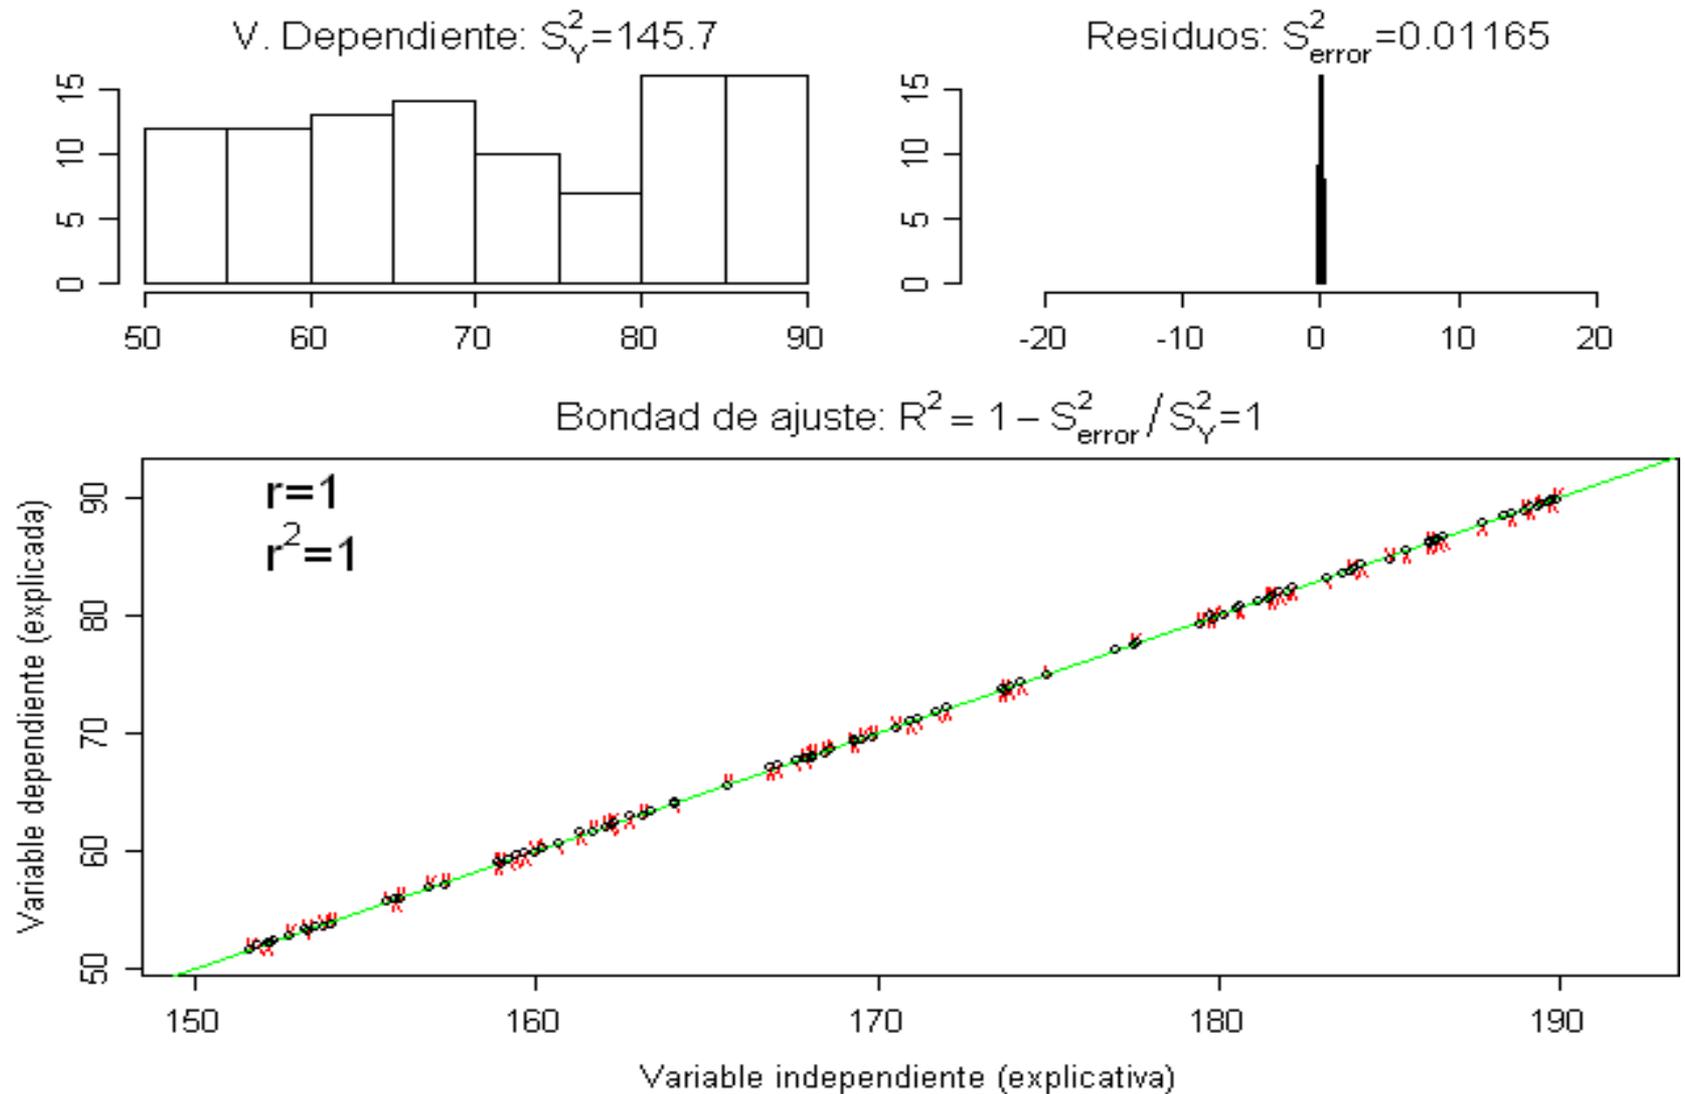
- Normales

- Homocedasticos

- Independientes

Testar la  $H_0: \rho = 0$  equivale a ensayar la  $H_0: \beta = 0$

## Animación: Residuos del modelo de regresión



## ESTADISTICOS USUALES

Varianza residual (insesgada)

$$\hat{s}_{y.x}^2 = \frac{\sum (y - \hat{y})^2}{n-2} = \frac{\sum \varepsilon^2}{n-2}$$

Error tipico de estimación de  $y$

$$\hat{s}_{y.x} = \sqrt{\hat{s}_{y.x}^2}$$

Error tipico de estimación de  $b$

$$\hat{s}_b = \hat{s}_{y.x} / \sqrt{SCX}$$

Coficiente de Determinación  $R^2$

$$R^2 = \frac{SCRegresión}{SCtotal} \quad (0 \leq R^2 \leq 1)$$

$$R^2 = 1 - \frac{S_e^2}{S_Y^2}$$

# ¿Cómo medir la bondad de una regresión?

Imaginemos un diagrama de dispersión, y vamos a tratar de comprender en primer lugar qué es el error residual, su relación con la varianza de  $Y$ , y de ahí, cómo medir la bondad de un ajuste.

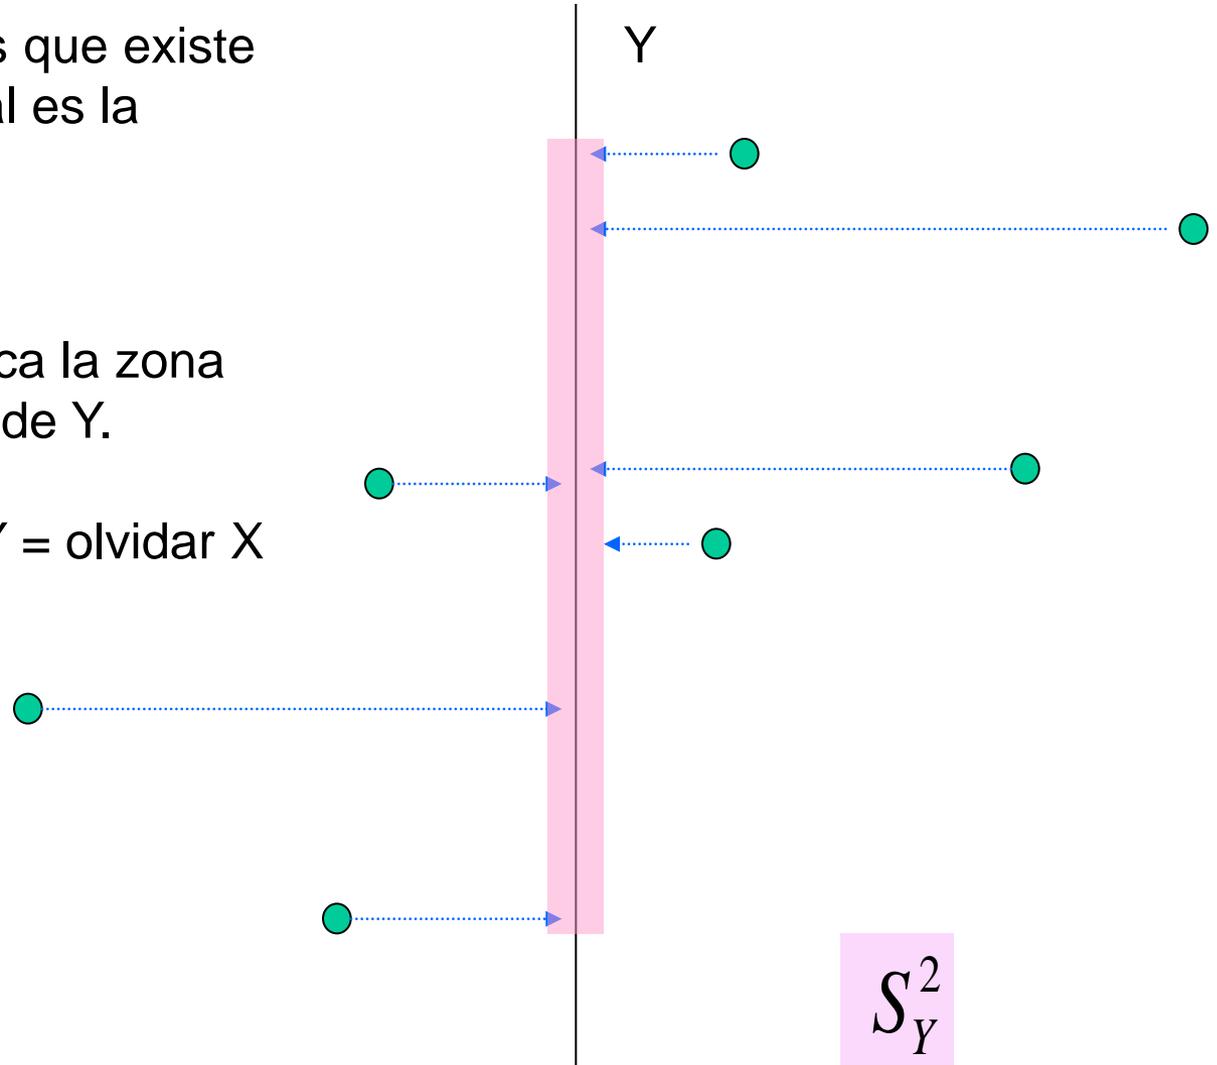


# Interpretación de la variabilidad en Y

En primer lugar olvidemos que existe la variable X. Veamos cuál es la variabilidad en el eje Y.

La franja sombreada indica la zona donde varían los valores de Y.

Proyección sobre el eje Y = olvidar X

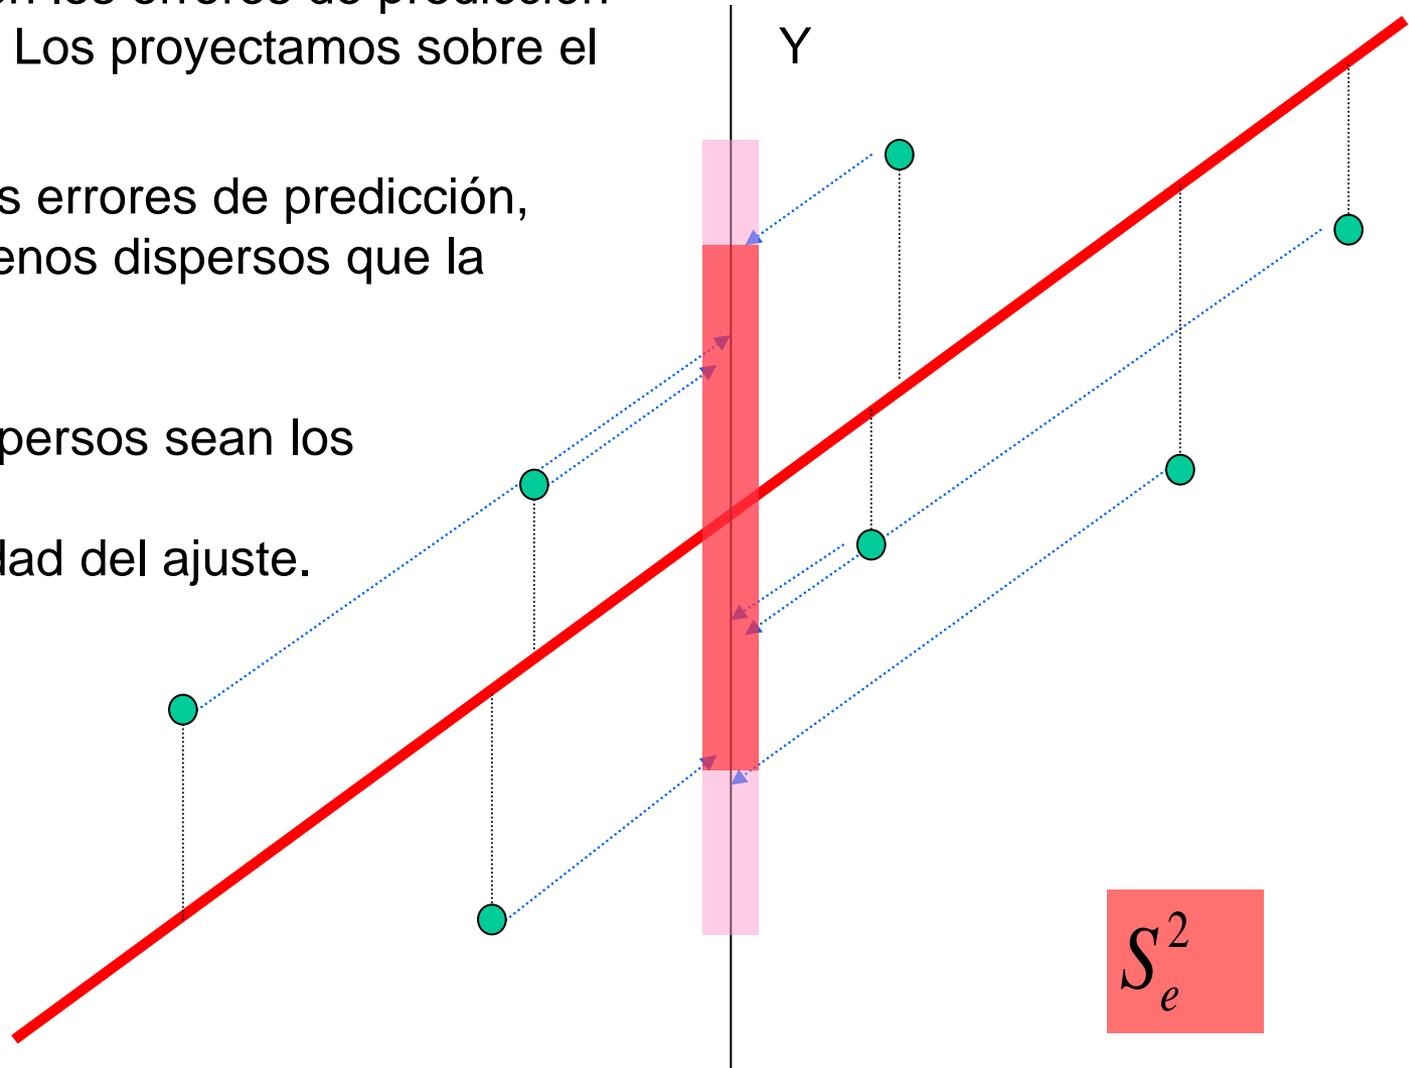


# Interpretación del residuo ( $y - \hat{y}$ )

Fijémonos ahora en los errores de predicción (líneas verticales). Los proyectamos sobre el eje Y.

Se observa que los errores de predicción, residuos, están menos dispersos que la variable Y original.

Cuanto menos dispersos sean los residuos, mejor será la bondad del ajuste.

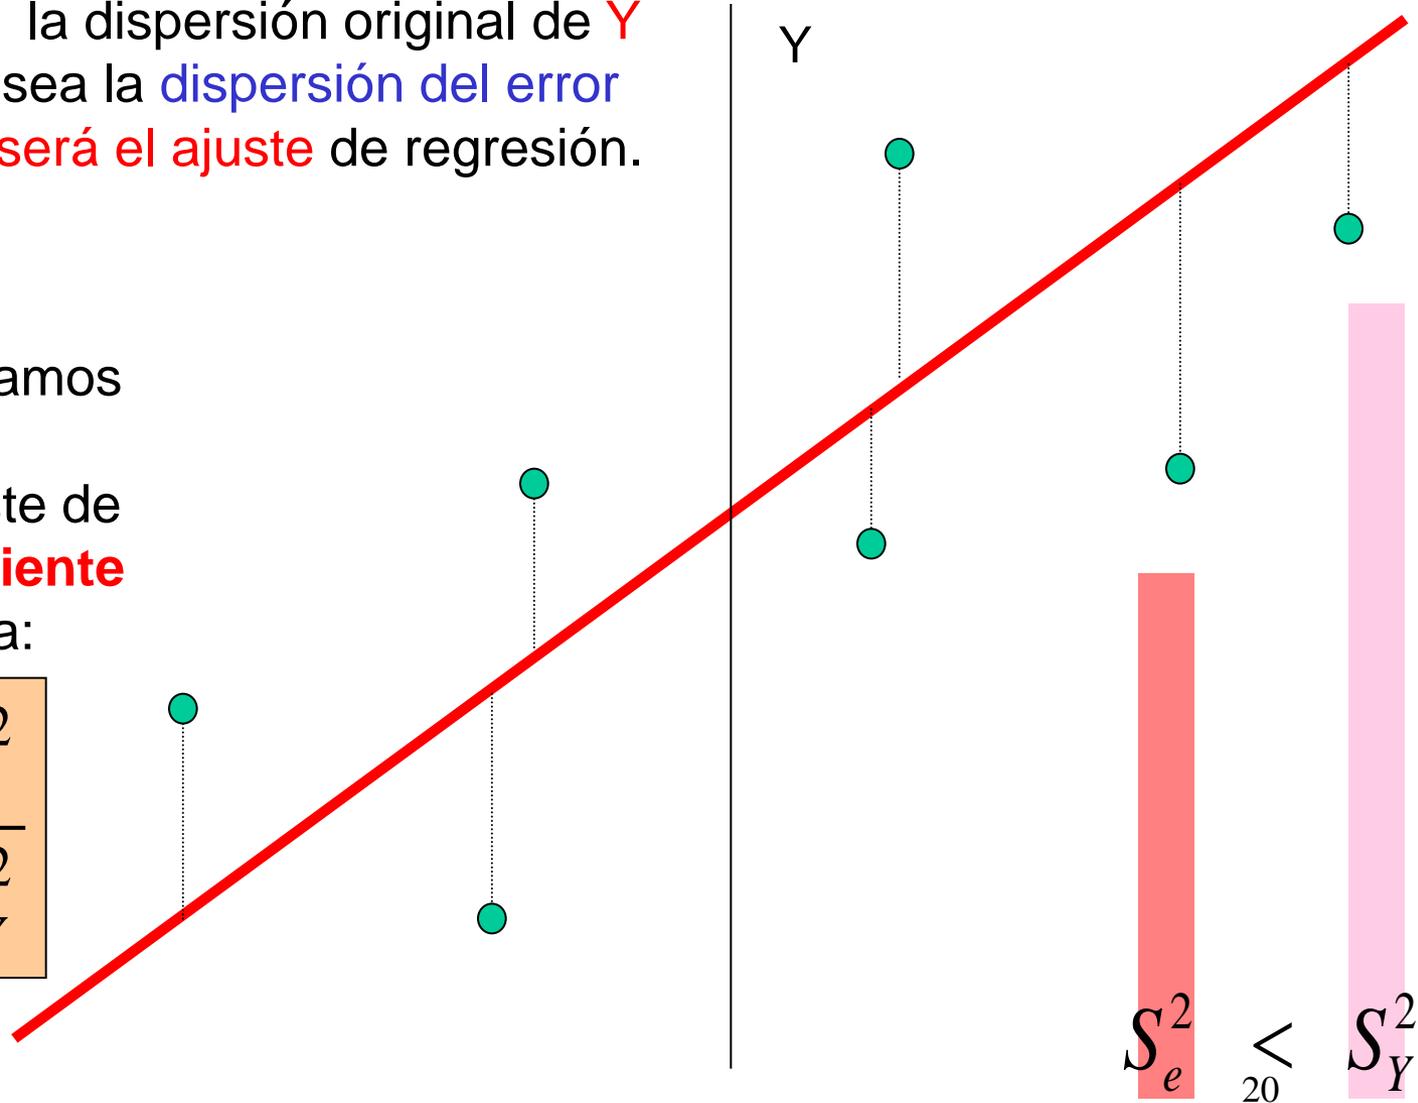


# Bondad de un ajuste

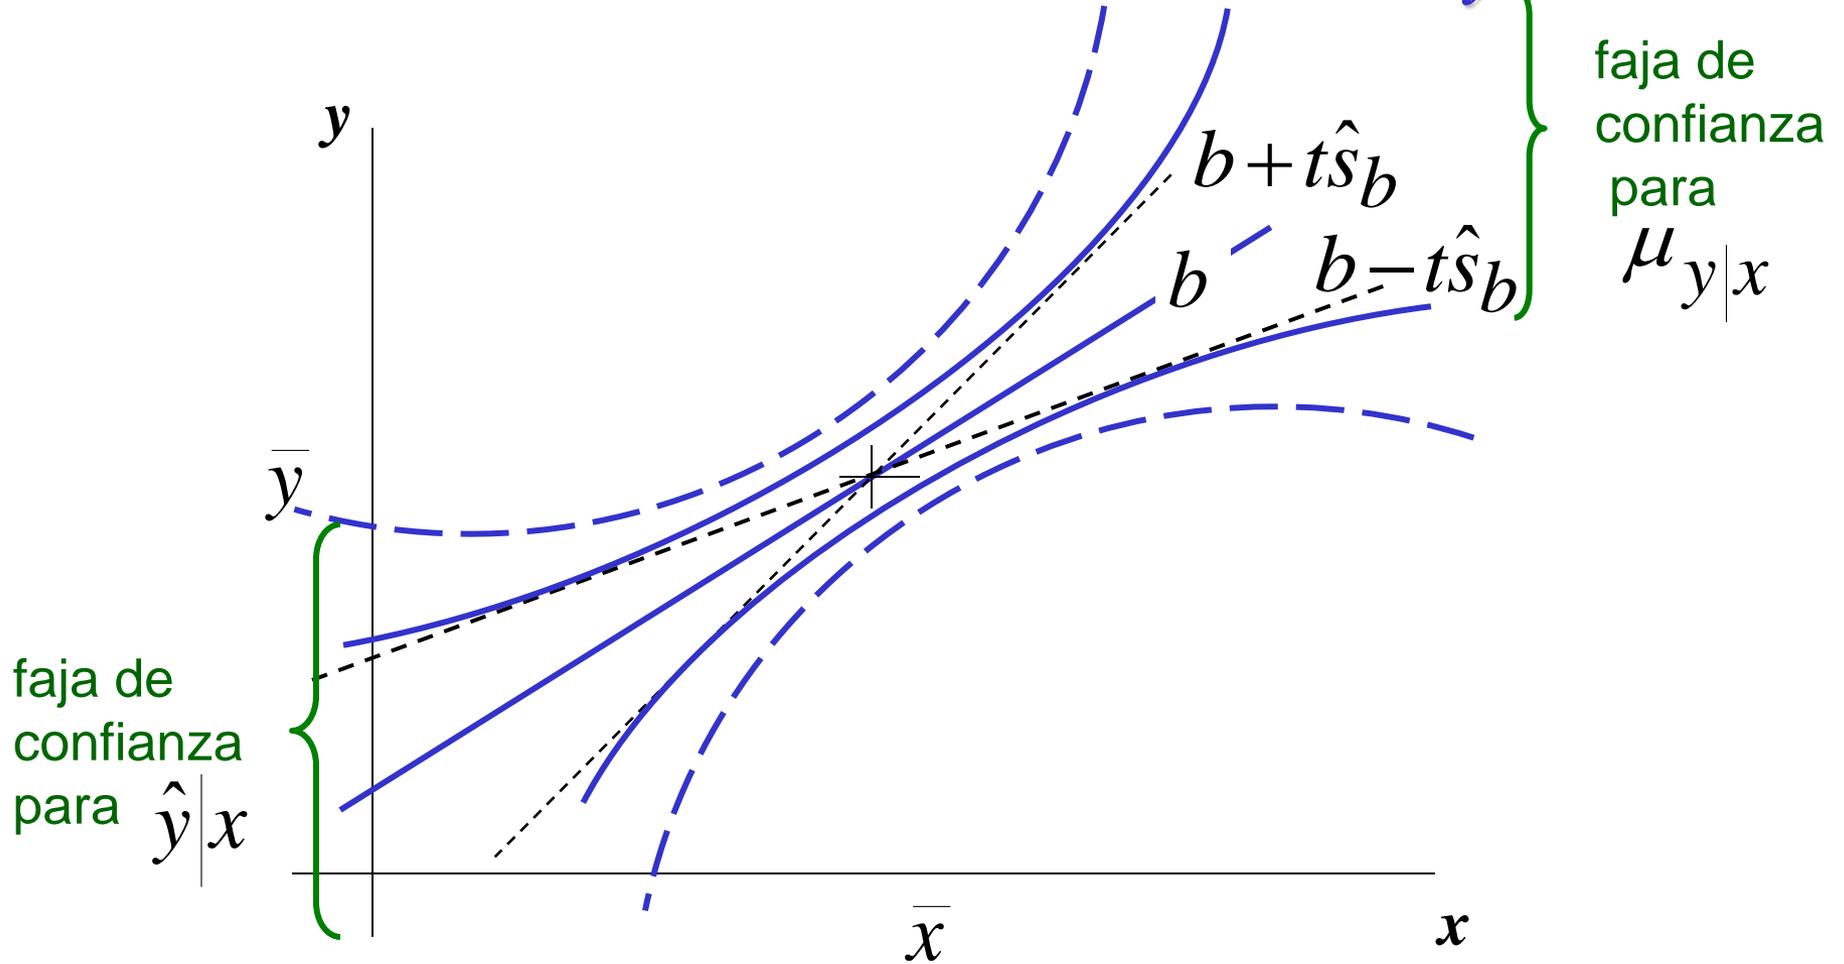
- Resumiendo:
- La dispersión del error residual será una fracción de la dispersión original de  $Y$
  - Cuanto **menor** sea la **dispersión del error residual** **mejor será el ajuste** de regresión.

Eso hace que definamos como medida de bondad de un ajuste de regresión, o **coeficiente de determinación** a:

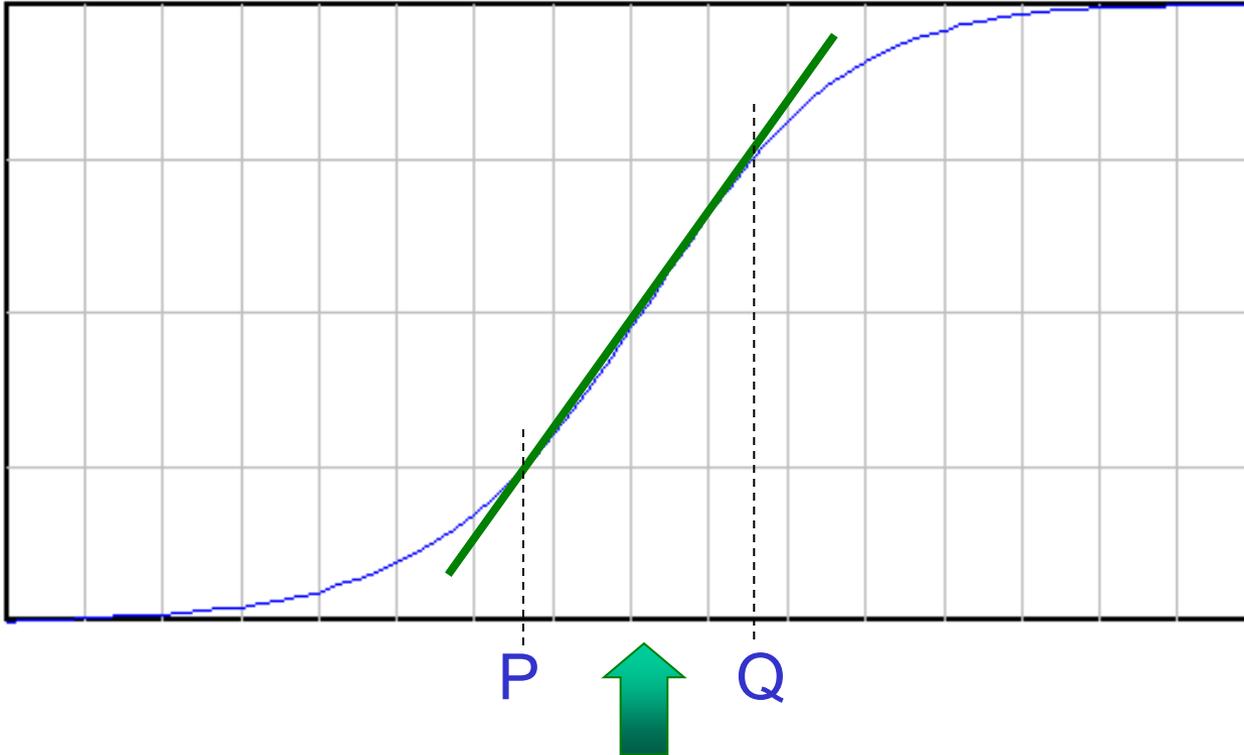
$$R^2 = 1 - \frac{S_e^2}{S_Y^2}$$



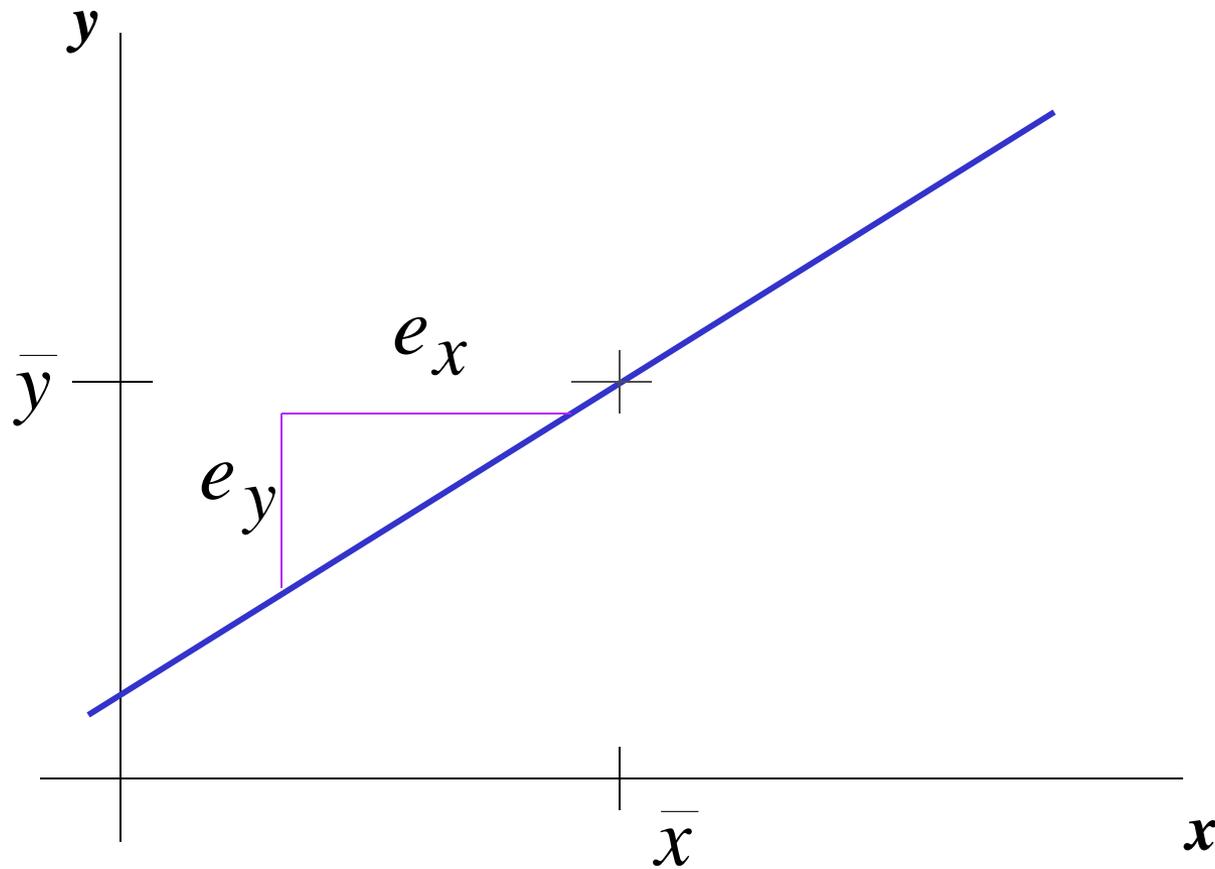
## Consecuencia sobre las estimaciones de $y$



A medida que los valores se alejan del centroide  $(\bar{x}, \bar{y})$   
las estimaciones de  $y$  son más imprecisas



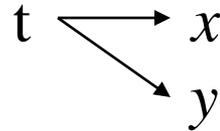
Buen ajuste a la recta en el intervalo PQ  
**NO** implica que la relación sea lineal fuera del mismo



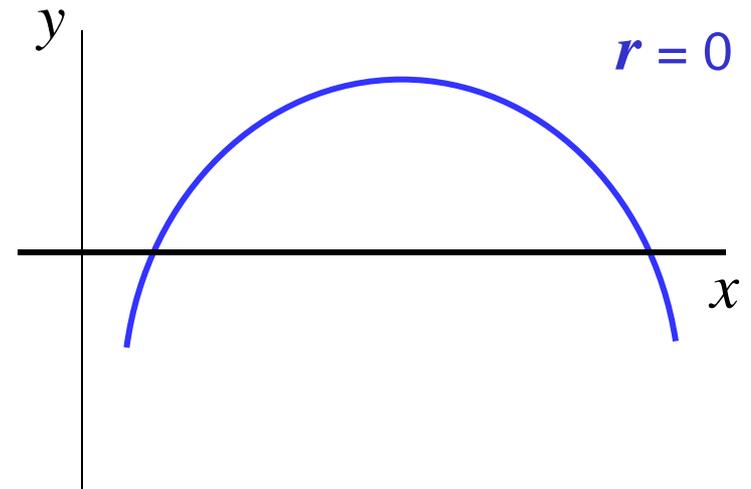
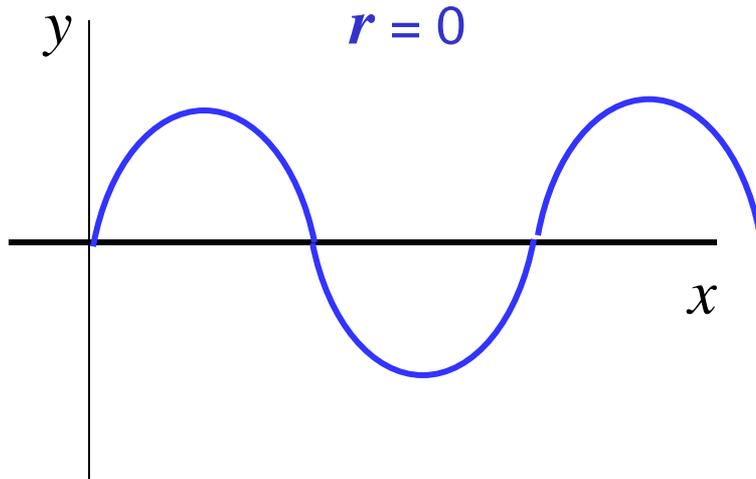
La recta de regresión de  $y$  sobre  $x$  no es la misma que la de  $x$  sobre  $y$ , salvo que todos los puntos estén sobre la recta

## Precauciones en la interpretación de $r$

- $r$  significativo NO implica relación de causalidad entre las variables



- $r = 0$  NO implica ausencia de asociación entre las variables



# Los problemas de regresión y de correlación lineales se parecen pero difieren

- En la finalidad
- En las variables

REGRESION	CORRELACION
$x$ variable independiente fija	<b>NO</b> hay distinción entre variable dependiente e independiente
$y$ variable dependiente aleatoria	$x$ e $y$ son variables aleatorias

## Cálculos en correlación y regresión

- Entrar  $x$  → Hallar  $\bar{x}$  y  $s_x$  → Borrar la memoria estadística
- Entrar  $y$  → Hallar  $\bar{y}$  y  $s_y$  → Borrar la memoria estadística
- Entrar los productos  $(x \cdot y)$  → Hallar  $\overline{xy}$
- Calcular:  $Cov = \overline{xy} - \bar{x} \cdot \bar{y}$

$$r = \frac{Cov}{s_x \cdot s_y} \rightarrow \text{Testar: } \boxed{H_0: \rho = 0}$$

$$b = \frac{rs_y}{s_x}$$

$$a = \bar{y} - b\bar{x}$$

$$y = a - bx$$