

# Regresión y Correlación

Manuel Ruiz Marín

Universidad Politécnica de Cartagena

## Índice del Tema

- 5.1. Concepto de ajuste lineal.
- 5.2. El método de los mínimos cuadrados y las ecuaciones normales.
- 5.3. Ajuste por mínimos cuadrados a una recta.
  - 5.3.1. Propiedades.
- 5.4. Coeficientes de determinación y correlación lineal.
  - 5.4.1. La varianza residual.
  - 5.4.2. Relación entre las varianzas  $S_y^2$ ,  $S_{y^*}^2$ ,  $S_e^2$
  - 5.4.2. El coeficiente de determinación.
  - 5.4.3. El coeficiente de correlación lineal.
- 5.5. Regresión no lineal.
  - 5.5.1. Ajuste hiperbólico.
  - 5.5.2. Ajuste exponencial.
  - 5.5.3. Ajuste potencial.
  - 5.5.4. Ajuste parabólico.
- 5.7. Regresión lineal múltiple.
  - 5.7.1. Ajuste a un hiperplano por mínimos cuadrados.
  - 5.7.2. El coeficiente de determinación múltiple y parcial.

# ¿Qué Necesitamos Saber?

# ¿Qué Necesitamos Saber?

## ¿Qué Necesitamos Saber?

- 1 Calcular la media aritmética,  $\bar{x}$ .
- 2 Calcular la varianza  $s^2$  y desviación típica  $s$ .
- 3 Distribuciones bidimensionales.
- 4 Calcular la covarianza  $S_{xy}$ .
- 5 Cobocer las ecuaciones de la: recta, hipérbola, parábola, función exponencial, función potencial y de un hiperplano.
- 6 Representación gráfica de las funciones anteriores.
- 7 Propiedades de los logaritmos.
- 8 Derivar y determinar extremos relativos en funciones reales de variable real.
- 9 Cálculo matricial.

# ¿Qué Necesitamos Saber?

## ¿Qué Necesitamos Saber?

- 1 Calcular la media aritmética,  $\bar{x}$ .
- 2 Calcular la varianza  $s^2$  y desviación típica  $s$ .
- 3 Distribuciones bidimensionales.
- 4 Calcular la covarianza  $S_{xy}$ .
- 5 Cobocer las ecuaciones de la: recta, hipérbola, parábola, función exponencial, función potencial y de un hiperplano.
- 6 Representación gráfica de las funciones anteriores.
- 7 Propiedades de los logaritmos.
- 8 Derivar y determinar extremos relativos en funciones reales de variable real.
- 9 Cálculo matricial.

# Objeto

# Objeto

## Objeto

Analizar la existencia Establecer **relaciones funcionales** donde una serie de magnitudes (variables o atributos)  $X_1, X_2, \dots, X_p$  se supone que están relacionadas con una variable  $Y$  mediante la expresión

$$Y = f(X_1, X_2, \dots, X_p).$$

Asimismo pretendemos medir el **grado de bondad** de la relación establecida.

# Objeto

## Objeto

Analizar la existencia Establecer **relaciones funcionales** donde una serie de magnitudes (variables o atributos)  $X_1, X_2, \dots, X_p$  se supone que están relacionadas con una variable  $Y$  mediante la expresión

$$Y = f(X_1, X_2, \dots, X_p).$$

Asimismo pretendemos medir el **grado de bondad** de la relación establecida.

# Regresión con Dos Variables

# Regresión con Dos Variables

¿Que relación existe entre  $X$  e  $Y$ ?

	$y_1$	$y_2$	$\dots$	$y_s$
$x_1$	$n_{11}$	$n_{12}$	$\dots$	$n_{1s}$
$x_2$	$n_{21}$	$n_{22}$	$\dots$	$n_{2s}$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
$x_k$	$n_{k1}$	$n_{k2}$	$\dots$	$n_{ks}$

# Regresión con Dos Variables

¿Que relación existe entre  $X$  e  $Y$ ?

	$y_1$	$y_2$	$\dots$	$y_s$
$x_1$	$n_{11}$	$n_{12}$	$\dots$	$n_{1s}$
$x_2$	$n_{21}$	$n_{22}$	$\dots$	$n_{2s}$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
$x_k$	$n_{k1}$	$n_{k2}$	$\dots$	$n_{ks}$

¿Que relación existe entre  $X$  e  $Y$ ?

Existe algún tipo de **asociación**, **dependencia** o **covariación** entre las variables  $X$  e  $Y$ .

# Regresión con Dos Variables

¿Que relación existe entre  $X$  e  $Y$ ?


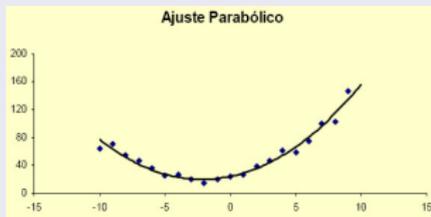

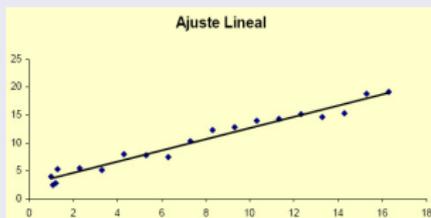
	$y_1$	$y_2$	$\dots$	$y_s$
$x_1$	$n_{11}$	$n_{12}$	$\dots$	$n_{1s}$
$x_2$	$n_{21}$	$n_{22}$	$\dots$	$n_{2s}$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
$x_k$	$n_{k1}$	$n_{k2}$	$\dots$	$n_{ks}$

¿Que relación existe entre  $X$  e  $Y$ ?

Existe algún tipo de **asociación**, **dependencia** o **covariación** entre las variables  $X$  e  $Y$ .


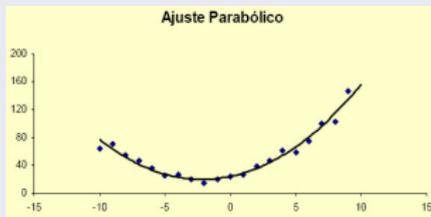

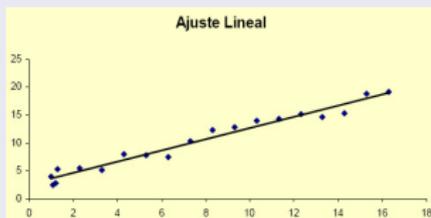
# Regresión con Dos Variables

## ¿Como seleccionar el modelo?. Diagrama de dispersión



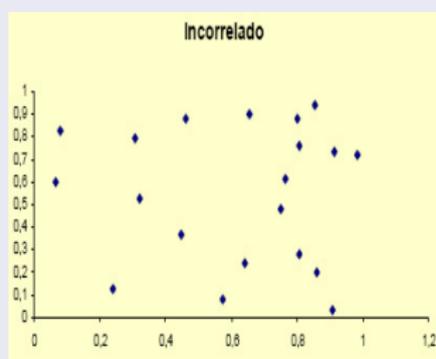

# Regresión con Dos Variables

¿Como seleccionar el modelo?. Diagrama de dispersión



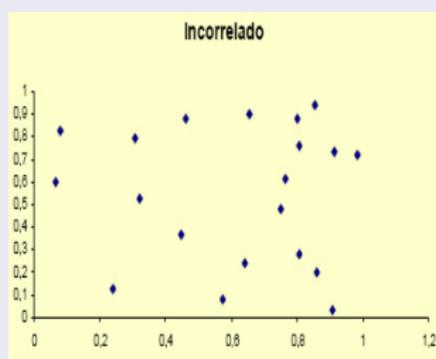
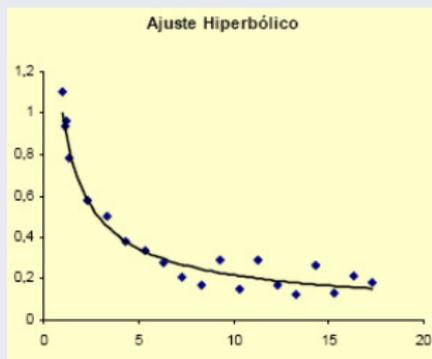
# Regresión con Dos Variables

¿Como seleccionar el modelo?. Diagrama de dispersión



# Regresión con Dos Variables


¿Como seleccionar el modelo?. Diagrama de dispersión



# Ajuste por Mínimos Cuadrados a Una Recta


# Ajuste por Mínimos Cuadrados a una Recta

## Regresión Lineal por Mínimos Cuadrados



# Ajuste por Mínimos Cuadrados a una Recta

## Regresión Lineal por Mínimos Cuadrados




## Objetivo

Hacer mínima la suma de los errores al cuadrado

$$f(a, b) = \sum_{i=1}^N e_i^2 = \sum_{i=1}^N (y_i - y_i^*)^2 = \sum_{i=1}^N (y_i - a - bx_i)^2$$

# Ajuste por Mínimos Cuadrados a una Recta

## Regresión Lineal por Mínimos Cuadrados



## Objetivo

Hacer mínima la suma de los errores al cuadrado

$$f(a, b) = \sum_{i=1}^N e_i^2 = \sum_{i=1}^N (y_i - y_i^*)^2 = \sum_{i=1}^N (y_i - a - bx_i)^2$$

## Ajuste por Mínimos Cuadrados a una Recta

## Primera Condición Para Mínimo. Ecuaciones Normales

$$\left. \begin{aligned} \frac{\partial f}{\partial a}(a, b) &= -2 \left( \sum_{i=1}^N y_i - Na - b \sum_{i=1}^N x_i \right) = 0 \\ \frac{\partial f}{\partial b}(a, b) &= -2 \left( \sum_{i=1}^N y_i x_i - a \sum_{i=1}^N x_i - b \sum_{i=1}^N x_i^2 \right) = 0 \end{aligned} \right\}$$

## Ajuste por Mínimos Cuadrados a una Recta

## Primera Condición Para Mínimo. Ecuaciones Normales

$$\left. \begin{aligned} \frac{\partial f}{\partial a}(a, b) &= -2 \left( \sum_{i=1}^N y_i - Na - b \sum_{i=1}^N x_i \right) = 0 \\ \frac{\partial f}{\partial b}(a, b) &= -2 \left( \sum_{i=1}^N y_i x_i - a \sum_{i=1}^N x_i - b \sum_{i=1}^N x_i^2 \right) = 0 \end{aligned} \right\}$$

## Segunda Condición Para Mínimo. El Hessiano

$$Hf(a, b) = \begin{pmatrix} \frac{\partial^2 f}{\partial a^2}(a, b) = 2N & \frac{\partial^2 f}{\partial a \partial b}(a, b) = 2N\bar{x} \\ \frac{\partial^2 f}{\partial b \partial a}(a, b) = 2N\bar{x} & \frac{\partial^2 f}{\partial b^2}(a, b) = 2 \sum_{i=1}^N x_i^2 \end{pmatrix}$$

$$\Delta_1 = 2N > 0 \text{ y } \Delta_2 = 4N^2 s_x^2 > 0.$$

Luego los  $a$  y  $b$  solución de las ecuaciones normales son mínimo para  $f(a, b)$ .

## Ajuste por Mínimos Cuadrados a una Recta

## Primera Condición Para Mínimo. Ecuaciones Normales

$$\left. \begin{aligned} \frac{\partial f}{\partial a}(a, b) &= -2 \left( \sum_{i=1}^N y_i - Na - b \sum_{i=1}^N x_i \right) = 0 \\ \frac{\partial f}{\partial b}(a, b) &= -2 \left( \sum_{i=1}^N y_i x_i - a \sum_{i=1}^N x_i - b \sum_{i=1}^N x_i^2 \right) = 0 \end{aligned} \right\}$$

## Segunda Condición Para Mínimo. El Hessiano

$$Hf(a, b) = \begin{pmatrix} \frac{\partial^2 f}{\partial a^2}(a, b) = 2N & \frac{\partial^2 f}{\partial a \partial b}(a, b) = 2N\bar{x} \\ \frac{\partial^2 f}{\partial b \partial a}(a, b) = 2N\bar{x} & \frac{\partial^2 f}{\partial b^2}(a, b) = 2 \sum_{i=1}^N x_i^2 \end{pmatrix}$$

$$\Delta_1 = 2N > 0 \text{ y } \Delta_2 = 4N^2 s_x^2 > 0.$$

Luego los  $a$  y  $b$  solución de las ecuaciones normales son mínimo para  $f(a, b)$ .

# Ajuste por Mínimos Cuadrados a una Recta

## Sistema de Ecuaciones Normales

$$\left. \begin{aligned} \sum_{i=1}^N y_i &= Na + b \sum_{i=1}^N x_i \\ \sum_{i=1}^N y_i x_i &= a \sum_{i=1}^N x_i + b \sum_{i=1}^N x_i^2 \end{aligned} \right\}$$

## Ajuste por Mínimos Cuadrados a una Recta

## Sistema de Ecuaciones Normales

$$\left. \begin{aligned} \sum_{i=1}^N y_i &= Na + b \sum_{i=1}^N x_i \\ \sum_{i=1}^N y_i x_i &= a \sum_{i=1}^N x_i + b \sum_{i=1}^N x_i^2 \end{aligned} \right\}$$

Dividiendo las ecuaciones por  $N$  tenemos

## Ecuaciones Normales

$$\left. \begin{aligned} \bar{y} &= a + b\bar{x} \\ \frac{1}{N} \sum_{i=1}^N y_i x_i &= a\bar{x} + b \frac{1}{N} \sum_{i=1}^N x_i^2 \end{aligned} \right\}$$

## Ajuste por Mínimos Cuadrados a una Recta

## Sistema de Ecuaciones Normales

$$\left. \begin{aligned} \sum_{i=1}^N y_i &= Na + b \sum_{i=1}^N x_i \\ \sum_{i=1}^N y_i x_i &= a \sum_{i=1}^N x_i + b \sum_{i=1}^N x_i^2 \end{aligned} \right\}$$

Dividiendo las ecuaciones por  $N$  tenemos

## Ecuaciones Normales

$$\left. \begin{aligned} \bar{y} &= a + b\bar{x} \\ \frac{1}{N} \sum_{i=1}^N y_i x_i &= a\bar{x} + b \frac{1}{N} \sum_{i=1}^N x_i^2 \end{aligned} \right\}$$

# Ajuste por Mínimos Cuadrados a una Recta

## Coeficientes de la Recta de Regresión

$$\left. \begin{aligned} b &= \frac{S_{xy}}{s_x^2} \\ a &= \bar{y} - \frac{S_{xy}}{s_x^2} \bar{x} \end{aligned} \right\}$$

# Ajuste por Mínimos Cuadrados a una Recta

## Coeficientes de la Recta de Regresión

$$\left. \begin{aligned} b &= \frac{S_{xy}}{s_x^2} \\ a &= \bar{y} - \frac{S_{xy}}{s_x^2} \bar{x} \end{aligned} \right\}$$

# El Binomio Cálculos-Gráficos

# Ajuste por Mínimos Cuadrados a una Recta

## El Binomio Cálculos-Gráficos. Cambio de Escala

El aspecto de un **diagrama de dispersión** puede **alterarse** drásticamente con un **cambio de escala**.

Un aumento en la escala puede hacernos creer en la posible existencia de un ajuste lineal para dos variables incorreladas.



# Ajuste por Mínimos Cuadrados a una Recta

## El Binomio Cálculos-Gráficos. Cambio de Escala

El aspecto de un **diagrama de dispersión** puede **alterarse** drásticamente con un **cambio de escala**.

Un aumento en la escala puede hacernos creer en la posible existencia de un ajuste lineal para dos variables incorreladas.

## El Binomio Cálculos-Gráficos. Cambio de Escala





# Ajuste por Mínimos Cuadrados a una Recta

## El Binomio Cálculos-Gráficos. Cambio de Escala

El aspecto de un **diagrama de dispersión** puede **alterarse** drásticamente con un **cambio de escala**.

Un aumento en la escala puede hacernos creer en la posible existencia de un ajuste lineal para dos variables incorreladas.

## El Binomio Cálculos-Gráficos. Cambio de Escala





# Ajuste por Mínimos Cuadrados a una Recta

## El Binomio Cálculos-Gráficos. Hacer Cálculos Sin Representar Datos

Presentamos dos modelos de regresión lineales con los mismos coeficientes y mismo grado de bondad.

Pero el ajuste lineal del **Modelo 2** no es el más adecuado para los datos proporcionados.

De ahí la **importancia de la representación gráfica**.





# Ajuste por Mínimos Cuadrados a una Recta

## El Binomio Cálculos-Gráficos. Hacer Cálculos Sin Representar Datos

Presentamos dos modelos de regresión lineales con los mismos coeficientes y mismo grado de bondad.

Pero el ajuste lineal del **Modelo 2** no es el más adecuado para los datos proporcionados.

De ahí la **importancia de la representación gráfica**.



# Propiedades de la Recta de Regresión

## Ajuste por Mínimos Cuadrados a una Recta

## Propiedades de la recta de regresión

- $\sum_{i=1}^N e_i = 0$  (por la primera ecuación normal)
- Dadas las rectas de regresión

$$\left. \begin{aligned} Y &= a + bX \\ X &= c + dY \end{aligned} \right\}$$

se cortan en el punto  $(\bar{x}, \bar{y})$ .

- Las variables  $Y^*$  y  $E$  son incorreladas, es decir  $S_{Y^*e} = 0$  (por la primera propiedad y la segunda ecuación normal).

## Ajuste por Mínimos Cuadrados a una Recta

## Propiedades de la recta de regresión

- $\sum_{i=1}^N e_i = 0$  (por la primera ecuación normal)
- Dadas las rectas de regresión

$$\left. \begin{aligned} Y &= a + bX \\ X &= c + dY \end{aligned} \right\}$$

se cortan en el punto  $(\bar{x}, \bar{y})$ .

- Las variables  $Y^*$  y  $E$  son incorreladas, es decir  $S_{Y^*e} = 0$  (por la primera propiedad y la segunda ecuación normal).

# Coefficientes de Determinación y Correlación

# Coeficientes de Determinación y Correlación

## Objetivo

Una vez determinada la recta de regresión queremos determinar si el ajuste es bueno.

## Objetivo

Encontrar un coeficiente que indique el grado de bondad del ajuste.

# Coeficientes de Determinación y Correlación

## Objetivo

Una vez determinada la recta de regresión queremos determinar si el ajuste es bueno.

## Objetivo

Encontrar un coeficiente que indique el grado de bondad del ajuste.

# Coeficientes de Determinación y Correlación

## La Varianza Residual

Como los coeficientes  $a$  y  $b$  calculados por mínimos cuadrados hacen mínima

$$f(a, b) = \sum_{i=1}^N e_i^2,$$

parece lógico que una primera medida del grado de bondad del ajuste sería calcular el valor de ese mínimo.

Obsérvese que como  $\sum_{i=1}^N e_i = 0$  tenemos que:

$$s_E^2 = \frac{1}{N} \sum_{i=1}^N e_i^2,$$

término que se le conoce como **varianza residual**.

# Coeficientes de Determinación y Correlación

## La Varianza Residual

Como los coeficientes  $a$  y  $b$  calculados por mínimos cuadrados hacen mínima

$$f(a, b) = \sum_{i=1}^N e_i^2,$$

parece lógico que una primera medida del grado de bondad del ajuste sería calcular el valor de ese mínimo.

Obsérvese que como  $\sum_{i=1}^N e_i = 0$  tenemos que:

$$s_E^2 = \frac{1}{N} \sum_{i=1}^N e_i^2,$$

término que se le conoce como **varianza residual**.

# Coeficientes de Determinación y Correlación

## Cálculo de la Varianza Residual

$$s_e^2 = \frac{1}{N} \sum_{i=1}^N e_i^2 = \frac{1}{N} \sum_{i=1}^N e_i(y_i - y_i^*) = \frac{1}{N} \sum_{i=1}^N e_i y_i - \frac{1}{N} \sum_{i=1}^N e_i y_i^*$$

Como las variables  $Y^*$  y  $E$  son incorreladas tenemos que

$\sum_{i=1}^N e_i y_i^* = 0$  y por tanto:

$$s_e^2 = \frac{1}{N} \sum_{i=1}^N e_i y_i = \frac{\sum_{i=1}^N y_i^2 - a \sum_{i=1}^N y_i - b \sum_{i=1}^N x_i y_i}{N}$$

# Coeficientes de Determinación y Correlación

## Cálculo de la Varianza Residual

$$s_e^2 = \frac{1}{N} \sum_{i=1}^N e_i^2 = \frac{1}{N} \sum_{i=1}^N e_i(y_i - y_i^*) = \frac{1}{N} \sum_{i=1}^N e_i y_i - \frac{1}{N} \sum_{i=1}^N e_i y_i^*$$

Como las variables  $Y^*$  y  $E$  son incorreladas tenemos que

$\sum_{i=1}^N e_i y_i^* = 0$  y por tanto:

$$s_e^2 = \frac{1}{N} \sum_{i=1}^N e_i y_i = \frac{\sum_{i=1}^N y_i^2 - a \sum_{i=1}^N y_i - b \sum_{i=1}^N x_i y_i}{N}$$

# Coeficientes de Determinación y Correlación

## La Varianza Residual

La Varianza residual mide la dispersión existente entre los valores observados ( $y_i$ ) y los valores ajustados ( $y_i^*$ ).

- Si  $s_e^2$  es **muy grande** la **bondad** del ajuste será **baja**.
- Si  $s_e^2$  es **muy pequeña** la **bondad** del ajuste será **alta**.
- Si  $s_e^2 = 0$  es porque todos los  $e_i = 0$  y por tanto **todos los puntos estan sobre la recta**. Habria una relación funcional perfecta.

# Coeficientes de Determinación y Correlación

## La Varianza Residual

La Varianza residual mide la dispersión existente entre los valores observados ( $y_i$ ) y los valores ajustados ( $y_i^*$ ).

- Si  $s_e^2$  es **muy grande** la **bondad** del ajuste será **baja**.
- Si  $s_e^2$  es **muy pequeña** la **bondad** del ajuste será **alta**.
- Si  $s_e^2 = 0$  es porque todos los  $e_i = 0$  y por tanto **todos los puntos estan sobre la recta**. Habria una relación funcional perfecta.

# Coeficientes de Determinación y Correlación

## Relación Entre la Varianzas $s_y^2$ , $s_{y^*}^2$ y $s_e^2$

En el caso de **ajuste lineal**, como  $Y = Y^* + E$  y  $\bar{e} = 0$  tenemos que  $\bar{y} = \bar{y}^*$  y además  $\sum_{i=1}^N y_i^* e_i = 0$ . Por tanto:

$$\begin{aligned} s_y^2 &= \frac{1}{N} \sum_{i=1}^N y_i^2 - \bar{y}^2 = \frac{1}{N} \sum_{i=1}^N (y_i^* + e_i)^2 - \bar{y}^{*2} = \\ &= \frac{1}{N} \sum_{i=1}^N y_i^{*2} - \bar{y}^{*2} + \frac{1}{N} \sum_{i=1}^N e_i^2 = s_{y^*}^2 + s_e^2 \end{aligned}$$

# Coeficientes de Determinación y Correlación

## Relación Entre la Varianzas $s_y^2$ , $s_{y^*}^2$ y $s_e^2$

En el caso de **ajuste lineal**, como  $Y = Y^* + E$  y  $\bar{e} = 0$  tenemos que  $\bar{y} = \bar{y}^*$  y además  $\sum_{i=1}^N y_i^* e_i = 0$ . Por tanto:

$$\begin{aligned} s_y^2 &= \frac{1}{N} \sum_{i=1}^N y_i^2 - \bar{y}^2 = \frac{1}{N} \sum_{i=1}^N (y_i^* + e_i)^2 - \bar{y}^{*2} = \\ &= \frac{1}{N} \sum_{i=1}^N y_i^{*2} - \bar{y}^{*2} + \frac{1}{N} \sum_{i=1}^N e_i^2 = s_{y^*}^2 + s_e^2 \end{aligned}$$

## Relación Entre la Varianzas $s_y^2$ , $s_{y^*}^2$ y $s_e^2$

$$s_y^2 = s_{y^*}^2 + s_e^2$$

# Coeficientes de Determinación y Correlación

## Relación Entre la Varianzas $s_y^2$ , $s_{y^*}^2$ y $s_e^2$

En el caso de **ajuste lineal**, como  $Y = Y^* + E$  y  $\bar{e} = 0$  tenemos que  $\bar{y} = \bar{y}^*$  y además  $\sum_{i=1}^N y_i^* e_i = 0$ . Por tanto:

$$\begin{aligned} s_y^2 &= \frac{1}{N} \sum_{i=1}^N y_i^2 - \bar{y}^2 = \frac{1}{N} \sum_{i=1}^N (y_i^* + e_i)^2 - \bar{y}^{*2} = \\ &= \frac{1}{N} \sum_{i=1}^N y_i^{*2} - \bar{y}^{*2} + \frac{1}{N} \sum_{i=1}^N e_i^2 = s_{y^*}^2 + s_e^2 \end{aligned}$$

## Relación Entre la Varianzas $s_y^2$ , $s_{y^*}^2$ y $s_e^2$

$$s_y^2 = s_{y^*}^2 + s_e^2$$

# Coeficientes de Determinación y Correlación

## Problema

- $s_e^2$  viene dada en las **unidades de medida** de la variable dependiente al **cuadrado**.
- ¿A **partir de que valores**  $s_e^2$  es suficientemente **pequeña** o **grande** como para admitir un **buen** o **mal** ajuste?.

# Coeficientes de Determinación y Correlación

## Problema

- $s_e^2$  viene dada en las **unidades de medida** de la variable dependiente al **cuadrado**.
- ¿A **partir de que valores**  $s_e^2$  es suficientemente **pequeña** o **grande** como para admitir un **buen** o **mal** ajuste?

## Solución

Determinar un coeficiente que mida el grado de bondad del ajuste lineal de manera que:

- Sea **adimensional**, es decir, carezca de unidades de medida.
- Nos **permita decidir** si el juste es **aceptable** o **no**.

# Coeficientes de Determinación y Correlación

## Problema

- $s_e^2$  viene dada en las **unidades de medida** de la variable dependiente al **cuadrado**.
- ¿A **partir de que valores**  $s_e^2$  es suficientemente **pequeña** o **grande** como para admitir un **buen** o **mal** ajuste?

## Solución

Determinar un coeficiente que mida el grado de bondad del ajuste lineal de manera que:

- Sea **adimensional**, es decir, carezca de unidades de medida.
- Nos **permita decidir** si el juste es **aceptable** o **no**.

# Coefficientes de Determinación y Correlación

## Coefficiente de Determinación

El **coeficiente de determinación**  $R^2$  determina la proporción de la varianza de la variable  $Y$  que queda explicada por la variable ajustada  $Y^*$ :

$$R^2 = \frac{s_{y^*}^2}{s_y^2} = \frac{s_y^2 - s_e^2}{s_y^2} = 1 - \frac{s_e^2}{s_y^2}$$

# Coeficientes de Determinación y Correlación

## Coeficiente de Determinación

El **coeficiente de determinación**  $R^2$  determina la proporción de la varianza de la variable  $Y$  que queda explicada por la variable ajustada  $Y^*$ :

$$R^2 = \frac{s_{y^*}^2}{s_y^2} = \frac{s_y^2 - s_e^2}{s_y^2} = 1 - \frac{s_e^2}{s_y^2}$$

## Rango de Variación de $R^2$

Como  $R^2$  es un cociente de varianzas tenemos que  $0 \leq R^2$ .

Por otro lado  $1 - R^2 = \frac{s_e^2}{s_y^2} \geq 0$  y por tanto  $R^2 \leq 1$ . Por tanto:

$$0 \leq R^2 \leq 1 \quad \Rightarrow \quad -1 \leq R \leq 1$$

# Coeficientes de Determinación y Correlación

## Coeficiente de Determinación

El **coeficiente de determinación**  $R^2$  determina la proporción de la varianza de la variable  $Y$  que queda explicada por la variable ajustada  $Y^*$ :

$$R^2 = \frac{s_{y^*}^2}{s_y^2} = \frac{s_y^2 - s_e^2}{s_y^2} = 1 - \frac{s_e^2}{s_y^2}$$

## Rango de Variación de $R^2$

Como  $R^2$  es un cociente de varianzas tenemos que  $0 \leq R^2$ .

Por otro lado  $1 - R^2 = \frac{s_e^2}{s_y^2} \geq 0$  y por tanto  $R^2 \leq 1$ . Por tanto:

$$0 \leq R^2 \leq 1 \quad \Rightarrow \quad -1 \leq R \leq 1$$

# Coefficientes de Determinación y Correlación

## Coefficiente de Correlación Lineal

Se define el **coeficiente de correlación lineal** como:

$$r = \frac{s_{xy}}{s_x s_y}$$

# Coefficientes de Determinación y Correlación

## Coefficiente de Correlación Lineal

Se define el **coeficiente de correlación lineal** como:

$$r = \frac{s_{xy}}{s_x s_y}$$

# Coeficientes de Determinación y Correlación

## Coeficiente de Correlación Lineal

**Teorema** En el caso de ajuste lineal se verifica que  $R^2 = r^2$ .

**Demostración:**

$$R^2 = \frac{s_y^2 - s_e^2}{s_y^2} = \frac{s_y^2 - \frac{\sum_{i=1}^N y_i^2 - a \sum_{i=1}^N y_i - b \sum_{i=1}^N x_i y_i}{N}}{s_y^2}$$

Por otro lado como

$$\left. \begin{aligned} a &= \bar{y} - \frac{S_{xy}}{s_x} \bar{x} \\ b &= \frac{S_{xy}}{s_x} \end{aligned} \right\}$$

tenemos que

$$R^2 = \frac{s_y^2 - (s_y^2 + \bar{y}) + (\bar{y} - \frac{S_{xy}}{s_x} \bar{x})\bar{y} + \frac{S_{xy}}{s_x} \bar{x}\bar{y} + S_{xy}}{s_y^2} = \frac{\frac{S_{xy}}{s_x^2}}{\frac{s_y^2}{s_x^2}} = \frac{S_{xy}}{s_x^2 s_y^2} = r^2$$

# Coeficientes de Determinación y Correlación

## Coeficiente de Correlación Lineal

**Teorema** En el caso de ajuste lineal se verifica que  $R^2 = r^2$ .

**Demostración:**

$$R^2 = \frac{s_y^2 - s_e^2}{s_y^2} = \frac{s_y^2 - \frac{\sum_{i=1}^N y_i^2 - a \sum_{i=1}^N y_i - b \sum_{i=1}^N x_i y_i}{N}}{s_y^2}$$

Por otro lado como

$$\left. \begin{aligned} a &= \bar{y} - \frac{S_{xy}}{s_x} \bar{x} \\ b &= \frac{S_{xy}}{s_x} \end{aligned} \right\}$$

tenemos que

$$R^2 = \frac{s_y^2 - (s_y^2 + \bar{y}) + (\bar{y} - \frac{S_{xy}}{s_x} \bar{x}) \bar{y} + \frac{S_{xy}}{s_x} \bar{x} \bar{y} + S_{xy}}{s_y^2} = \frac{\frac{S_{xy}}{s_x^2}}{\frac{s_y^2}{s_x^2}} = \frac{S_{xy}}{s_x^2 s_y^2} = r^2$$

# Coeficientes de Determinación y Correlación

## Interpretación de los Valores de $R$

- $R = 1 \Rightarrow s_e^2 = 0$ . Todos los valores teóricos coinciden con los observados. Existe **correlación perfecta positiva**.
- $R = -1 \Rightarrow s_e^2 = 0$ . Todos los valores teóricos coinciden con los observados. Existe **correlación perfecta negativa**.
- $R = 0 \Rightarrow s_{y*}^2 = 0$  y por tanto  $s_y^2 = s_e^2$ . Luego no se consigue ninguna explicación de la variable  $Y$  relacionándola con la  $X$ . La **correlación es nula**.
- $-1 \leq R \leq 0$ , la **correlación** sería **negativa**, siendo *más intensa cuanto más cerca esté de  $-1$* .
- $0 \leq R \leq 1$ , la **correlación** sería **positiva**, indicando una *mayor interrelación cuanto más próximo esté de 1*.

# Coeficientes de Determinación y Correlación

## Interpretación de los Valores de $R$

- $R = 1 \Rightarrow s_e^2 = 0$ . Todos los valores teóricos coinciden con los observados. Existe **correlación perfecta positiva**.
- $R = -1 \Rightarrow s_e^2 = 0$ . Todos los valores teóricos coinciden con los observados. Existe **correlación perfecta negativa**.
- $R = 0 \Rightarrow s_{y^*}^2 = 0$  y por tanto  $s_y^2 = s_e^2$ . Luego no se consigue ninguna explicación de la variable  $Y$  relacionándola con la  $X$ . La **correlación es nula**.
- $-1 \leq R \leq 0$ , la **correlación** sería **negativa**, siendo *más intensa cuanto más cerca esté de  $-1$* .
- $0 \leq R \leq 1$ , la **correlación** sería **positiva**, indicando una *mayor interrelación cuanto más próximo esté de 1*.

# Regresión No Lineal

# Regresión No Lineal

Ajuste Hiperbólico  $Y = a + \frac{b}{X}$

Queremos determinar el ajuste  $Y = a + \frac{b}{X}$  por mínimos cuadrados.

**Es equivalente a:**

Mediante el cambio de variable  $Z = \frac{1}{X}$  realizar el ajuste lineal

$$Y = a + bZ.$$

# Regresión No Lineal

Ajuste Hiperbólico  $Y = a + \frac{b}{X}$

Queremos determinar el ajuste  $Y = a + \frac{b}{X}$  por mínimos cuadrados.

**Es equivalente a:**

Mediante el cambio de variable  $Z = \frac{1}{X}$  realizar el ajuste lineal

$$Y = a + bZ.$$

# Regresión No Lineal

## Ajuste Exponencial $Y = ae^{bX}$

Queremos determinar el ajuste  $Y = ae^{bX}$  por mínimos cuadrados.

**Es equivalente a:**

Tomando logaritmos  $W = \ln(Y)$  y  $A = \ln(a)$  realizar el ajuste lineal

$$W = A + bX.$$

Luego los parámetros que determinan la función exponencial son

$$a = e^A \text{ y } b$$

# Regresión No Lineal

## Ajuste Exponencial $Y = ae^{bX}$

Queremos determinar el ajuste  $Y = ae^{bX}$  por mínimos cuadrados.

**Es equivalente a:**

Tomando logaritmos  $W = \ln(Y)$  y  $A = \ln(a)$  realizar el ajuste lineal

$$W = A + bX.$$

Luego los parámetros que determinan la función exponencial son

$$a = e^A \text{ y } b$$

# Regresión No Lineal

## Ajuste Potencial $Y = aX^b$

Queremos determinar el ajuste  $Y = aX^b$  por mínimos cuadrados.

**Es equivalente a:**

Tomando logaritmos  $W = \ln(Y)$ ,  $A = \ln(a)$  y  $Z = \ln(X)$  realizar el ajuste lineal

$$W = A + bZ.$$

Luego los parámetros que determinan la función exponencial son

$$a = e^A \text{ y } b$$

# Regresión No Lineal

## Ajuste Potencial $Y = aX^b$

Queremos determinar el ajuste  $Y = aX^b$  por mínimos cuadrados.

**Es equivalente a:**

Tomando logaritmos  $W = \ln(Y)$ ,  $A = \ln(a)$  y  $Z = \ln(X)$  realizar el ajuste lineal

$$W = A + bZ.$$

Luego los parámetros que determinan la función exponencial son

$$a = e^A \text{ y } b$$

# Regresión No Lineal

## Ajuste Parabólico $Y = a + bX + cX^2$

Queremos determinar el ajuste  $Y = a + bX + cX^2$  por mínimos cuadrados. Es decir, determinar  $a, b$  y  $c$  tales que minimizan:

$$f(a, b, c) = \sum_{i=1}^N e_i^2 = \sum_{i=1}^N (y_i - a - bx_i - cx_i^2)^2$$

Para obtener las ecuaciones normales:

$$\frac{\partial f}{\partial a} = -2 \sum_{i=1}^N (y_i - a - bx_i - cx_i^2) = 0$$

$$\frac{\partial f}{\partial b} = -2 \sum_{i=1}^N (y_i - a - bx_i - cx_i^2)x_i = 0$$

$$\frac{\partial f}{\partial c} = -2 \sum_{i=1}^N (y_i - a - bx_i - cx_i^2)x_i^2 = 0$$

# Regresión No Lineal

## Ajuste Parabólico $Y = a + bX + cX^2$

Queremos determinar el ajuste  $Y = a + bX + cX^2$  por mínimos cuadrados. Es decir, determinar  $a, b$  y  $c$  tales que minimizan:

$$f(a, b, c) = \sum_{i=1}^N e_i^2 = \sum_{i=1}^N (y_i - a - bx_i - cx_i^2)^2$$

Para obtener las ecuaciones normales:

$$\frac{\partial f}{\partial a} = -2 \sum_{i=1}^N (y_i - a - bx_i - cx_i^2) = 0$$

$$\frac{\partial f}{\partial b} = -2 \sum_{i=1}^N (y_i - a - bx_i - cx_i^2)x_i = 0$$

$$\frac{\partial f}{\partial c} = -2 \sum_{i=1}^N (y_i - a - bx_i - cx_i^2)x_i^2 = 0$$

## Regresión No Lineal

Ajuste Parabólico  $Y = a + bX + cX^2$ 

Por tanto las **ecuaciones normales** quedan:

$$\left. \begin{aligned} \sum_{i=1}^N y_i &= Na + b \sum_{i=1}^N x_i + c \sum_{i=1}^N x_i^2 \\ \sum_{i=1}^N y_i x_i &= a \sum_{i=1}^N x_i + b \sum_{i=1}^N x_i^2 + c \sum_{i=1}^N x_i^3 \\ \sum_{i=1}^N y_i x_i^2 &= a \sum_{i=1}^N x_i^2 + b \sum_{i=1}^N x_i^3 + c \sum_{i=1}^N x_i^4 \end{aligned} \right\}$$

Para medir la bondad del ajuste se utilizará el coeficiente de determinación

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

## Regresión No Lineal

Ajuste Parabólico  $Y = a + bX + cX^2$ 

Por tanto las **ecuaciones normales** quedan:

$$\left. \begin{aligned} \sum_{i=1}^N y_i &= Na + b \sum_{i=1}^N x_i + c \sum_{i=1}^N x_i^2 \\ \sum_{i=1}^N y_i x_i &= a \sum_{i=1}^N x_i + b \sum_{i=1}^N x_i^2 + c \sum_{i=1}^N x_i^3 \\ \sum_{i=1}^N y_i x_i^2 &= a \sum_{i=1}^N x_i^2 + b \sum_{i=1}^N x_i^3 + c \sum_{i=1}^N x_i^4 \end{aligned} \right\}$$

Para medir la bondad del ajuste se utilizará el coeficiente de determinación

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

# Regresión Lineal Múltiple

# Regresión Lineal Múltiple

## Aplicaciones de la Regresión

- **Explicativo**. Determinar que variables explican una variable dada.
- **Predictivo**. Predecir valores de una variable a partir de valores conocidos de otras.

# Regresión Lineal Múltiple

## Aplicaciones de la Regresión

- **Explicativo**. Determinar que variables explican una variable dada.
- **Predictivo**. Predecir valores de una variable a partir de valores conocidos de otras.

# Regresión Lineal Múltiple

## Ajuste a un Hiperplano por Mínimos Cuadrados

Dando valores a la ecuación del hiperplano tenemos:

$$\left. \begin{aligned} y_1^* &= b_0 + b_1x_{11} + b_2x_{21} + \cdots + b_kx_{k1} \\ y_2^* &= b_0 + b_1x_{12} + b_2x_{22} + \cdots + b_kx_{k2} \\ &\vdots \\ y_n^* &= b_0 + b_1x_{1n} + b_2x_{2n} + \cdots + b_kx_{kn} \end{aligned} \right\}$$

Matricialmente sería  $Y^* = XB$  donde

$$Y^* = \begin{pmatrix} y_1^* \\ y_2^* \\ \vdots \\ y_n^* \end{pmatrix} \quad X = \begin{pmatrix} 1 & x_{11} & x_{21} & \cdots & x_{k1} \\ 1 & x_{12} & x_{22} & \cdots & x_{k2} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & x_{1n} & x_{2n} & \cdots & x_{kn} \end{pmatrix} \quad B = \begin{pmatrix} b_0 \\ b_1 \\ b_2 \\ \vdots \\ b_k \end{pmatrix}$$

# Regresión Lineal Múltiple

## Ajuste a un Hiperplano por Mínimos Cuadrados

Dando valores a la ecuación del hiperplano tenemos:

$$\left. \begin{aligned} y_1^* &= b_0 + b_1x_{11} + b_2x_{21} + \cdots + b_kx_{k1} \\ y_2^* &= b_0 + b_1x_{12} + b_2x_{22} + \cdots + b_kx_{k2} \\ &\vdots \\ y_n^* &= b_0 + b_1x_{1n} + b_2x_{2n} + \cdots + b_kx_{kn} \end{aligned} \right\}$$

Matricialmente sería  $Y^* = XB$  donde

$$Y^* = \begin{pmatrix} y_1^* \\ y_2^* \\ \vdots \\ y_n^* \end{pmatrix} \quad X = \begin{pmatrix} 1 & x_{11} & x_{21} & \cdots & x_{k1} \\ 1 & x_{12} & x_{22} & \cdots & x_{k2} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & x_{1n} & x_{2n} & \cdots & x_{kn} \end{pmatrix} \quad B = \begin{pmatrix} b_0 \\ b_1 \\ b_2 \\ \vdots \\ b_k \end{pmatrix}$$

# Regresión Lineal Múltiple

## Ajuste a un Hiperplano por Mínimos Cuadrados

Si  $A$  es una matriz denotaremos por  $A^t$  la **matriz traspuesta** de  $A$ .  
La matriz de errores será:

$$E = Y - Y^* = \begin{pmatrix} e_1 = y_1 - y_1^* \\ e_2 = y_2 - y_2^* \\ \vdots \\ e_n = y_n - y_n^* \end{pmatrix}$$

De nuevo nuestro objetivo es minimizar

$$\sum_{i=1}^n e_i^2 = \sum_{i=1}^n (y_i - y_i^*)^2 = E^t E$$

# Regresión Lineal Múltiple

## Ajuste a un Hiperplano por Mínimos Cuadrados

Si  $A$  es una matriz denotaremos por  $A^t$  la **matriz traspuesta** de  $A$ .  
La matriz de errores será:

$$E = Y - Y^* = \begin{pmatrix} e_1 = y_1 - y_1^* \\ e_2 = y_2 - y_2^* \\ \vdots \\ e_n = y_n - y_n^* \end{pmatrix}$$

De nuevo nuestro objetivo es minimizar

$$\sum_{i=1}^n e_i^2 = \sum_{i=1}^n (y_i - y_i^*)^2 = E^t E$$

# Regresión Lineal Múltiple

## Ajuste a un Hiperplano por Mínimos Cuadrados

Por otro lado

$$E = Y - XB$$

luego tenemos que minimizar

$$E^t E = (Y - XB)^t (Y - XB) = Y^t Y - 2Y^t X B + B^t X^t X B$$

y derivando e igualando a cero tenemos:

$$\frac{\partial E^t E}{\partial B} = -2X^t Y + 2X^t X B = 0$$

de donde deducimos que

$$X^t X B = X^t Y$$

# Regresión Lineal Múltiple

## Ajuste a un Hiperplano por Mínimos Cuadrados

Por otro lado

$$E = Y - XB$$

luego tenemos que minimizar

$$E^t E = (Y - XB)^t (Y - XB) = Y^t Y - 2Y^t X B + B^t X^t X B$$

y derivando e igualando a cero tenemos:

$$\frac{\partial E^t E}{\partial B} = -2X^t Y + 2X^t X B = 0$$

de donde deducimos que

$$X^t X B = X^t Y$$

# Regresión Lineal Múltiple

## Ajuste a un Hiperplano por Mínimos Cuadrados

Por tanto si existe la matriz inversa de  $X^tX$  tenemos que:

$$B = (X^tX)^{-1}X^tY$$

# Regresión Lineal Múltiple

## Ajuste a un Hiperplano por Mínimos Cuadrados

Por tanto si existe la matriz inversa de  $X^tX$  tenemos que:

$$B = (X^tX)^{-1}X^tY$$

# Coeficiente de Correlación Múltiple

# Regresión Lineal Múltiple

## Coeficiente de Correlación Múltiple

Con la misma filosofía que en el caso de la regresión lineal definimos el **coeficiente de correlación múltiple** como:

$$R^2_{y,12\dots k} = \frac{s_{y^*}^2}{s_y^2} = 1 - \frac{s_e^2}{s_y^2}$$

además se verifica que

$$0 \leq R^2_{y,12\dots k} \leq 1$$

siendo mejor el ajuste cuando mas cercano esté a 1.

# Regresión Lineal Múltiple

## Coeficiente de Correlación Múltiple

Con la misma filosofía que en el caso de la regresión lineal definimos el **coeficiente de correlación múltiple** como:

$$R^2_{y,12\dots k} = \frac{s_{y^*}^2}{s_y^2} = 1 - \frac{s_e^2}{s_y^2}$$

además se verifica que

$$0 \leq R^2_{y,12\dots k} \leq 1$$

siendo mejor el ajuste cuando mas cercano esté a 1.

# Regresión Lineal Múltiple

## Coeficiente de Correlación Múltiple en Forma Matricial

Como  $E = Y - XB$  y  $B = (X^t X)^{-1} X^t Y$  tenemos que

$$s_e^2 = \frac{1}{n} (Y^t Y - B^t X^t Y)$$

$$\left( \begin{array}{l} \text{Dem: } ns_e^2 = E^t E = (Y - XB)^t (Y - XB) = Y^t Y - B^t X^t Y - Y^t X B + B^t X^t X B = \\ = Y^t Y - B^t X^t Y - Y^t X B + (X^t X)^{-1} X^t Y^t X^t X B = \\ = Y^t Y - B^t X^t Y - Y^t X B + Y^t X B = Y^t Y - B^t X^t Y. \end{array} \right)$$

Como también  $\bar{y} = \bar{y}^*$  tenemos que

$$s_{y^*}^2 = \frac{1}{n} B^t X^t Y - \bar{y}^2$$

$$\left( \begin{array}{l} \text{Dem: } ns_{y^*}^2 = \sum_{i=1}^n (y_i^* - \bar{y}^*)^2 = \sum_{i=1}^n y_i^{*2} - n\bar{y}^2 = Y^{*t} Y^* - n\bar{y}^2 = (XB)^t (XB) - n\bar{y}^2 = \\ B^t X^t X B - n\bar{y}^2 = B^t X^t X (X^t X)^{-1} X^t Y - n\bar{y}^2 = B^t X^t Y - n\bar{y}^2. \end{array} \right)$$

# Regresión Lineal Múltiple

## Coeficiente de Correlación Múltiple en Forma Matricial

Como  $E = Y - XB$  y  $B = (X^t X)^{-1} X^t Y$  tenemos que

$$s_e^2 = \frac{1}{n} (Y^t Y - B^t X^t Y)$$

$$\left( \begin{array}{l} \text{Dem: } ns_e^2 = E^t E = (Y - XB)^t (Y - XB) = Y^t Y - B^t X^t Y - Y^t X B + B^t X^t X B = \\ = Y^t Y - B^t X^t Y - Y^t X B + (X^t X)^{-1} X^t Y^t X^t X B = \\ = Y^t Y - B^t X^t Y - Y^t X B + Y^t X B = Y^t Y - B^t X^t Y. \end{array} \right)$$

Como también  $\bar{y} = \bar{y}^*$  tenemos que

$$s_{y^*}^2 = \frac{1}{n} B^t X^t Y - \bar{y}^2$$

$$\left( \begin{array}{l} \text{Dem: } ns_{y^*}^2 = \sum_{i=1}^n (y_i^* - \bar{y}^*)^2 = \sum_{i=1}^n y_i^{*2} - n\bar{y}^2 = Y^{*t} Y^* - n\bar{y}^2 = (XB)^t (XB) - n\bar{y}^2 = \\ B^t X^t X B - n\bar{y}^2 = B^t X^t X (X^t X)^{-1} X^t Y - n\bar{y}^2 = B^t X^t Y - n\bar{y}^2. \end{array} \right)$$

# Regresión Lineal Múltiple

## Coeficiente de Correlación Múltiple en Forma Matricial

Además

$$s_y^2 = \frac{1}{n} Y^t Y - \bar{y}^2$$

( Dem:  $ns_y^2 = \sum_{i=1}^n (y_i - \bar{y})^2 = \sum_{i=1}^n y_i^2 - n\bar{y}^2 = Y^t Y - n\bar{y}^2.$  )

Luego

$$R^2 = 1 - \frac{s_e^2}{s_y^2} = 1 - \frac{Y^t Y - B^t X^t Y}{Y^t Y - n\bar{y}^2} = \frac{B^t X^t Y - n\bar{y}^2}{Y^t Y - n\bar{y}^2}.$$

# Regresión Lineal Múltiple

## Coeficiente de Correlación Múltiple en Forma Matricial

Además

$$s_y^2 = \frac{1}{n} Y^t Y - \bar{y}^2$$

( Dem:  $ns_y^2 = \sum_{i=1}^n (y_i - \bar{y})^2 = \sum_{i=1}^n y_i^2 - n\bar{y}^2 = Y^t Y - n\bar{y}^2.$  )

Luego

$$R^2 = 1 - \frac{s_e^2}{s_y^2} = 1 - \frac{Y^t Y - B^t X^t Y}{Y^t Y - n\bar{y}^2} = \frac{B^t X^t Y - n\bar{y}^2}{Y^t Y - n\bar{y}^2}.$$

# Coeficiente de Correlación Parcial

# Regresión Lineal Múltiple

## Coeficiente de Correlación Parcial

### Problema

Estudiar el grado de asociación lineal entre las variables  $Y$  y  $X_i$ .

### Solución 1

Una posible solución sería calculando el coeficiente de correlación lineal

$$r = \frac{S_{YX_i}}{s_y s_{X_i}}$$

Pero de esta manera no se tiene en cuenta que el grado de **correlación** obtenido pueda ser **fruto** de la influencia que ejercen el **resto de variables**  $X_1, X_2, \dots, X_{i-1}, X_{i+1}, \dots, X_k$

# Regresión Lineal Múltiple

## Coeficiente de Correlación Parcial

### Problema

Estudiar el grado de asociación lineal entre las variables  $Y$  y  $X_i$ .

### Solución 1

Una posible solución sería calculando el coeficiente de correlación lineal

$$r = \frac{S_{YX_i}}{s_y s_{X_i}}$$

Pero de esta manera no se tiene en cuenta que el grado de **correlación** obtenido pueda ser **fruto** de la influencia que ejercen el **resto de variables**  $X_1, X_2, \dots, X_{i-1}, X_{i+1}, \dots, X_k$

# Regresión Lineal Múltiple

## Coeficiente de Correlación Parcial

### Solución 2

Eliminar la influencia de  $X_1, X_2, \dots, X_{i-1}, X_{i+1}, \dots, X_k$

¿Cómo?

En tres pasos.

1.- Obteniendo los hiperplanos de regresión:

$$\left. \begin{aligned} \hat{Y} &= c_0 + c_1 X_1 + c_2 X_2 + \dots + c_{i-1} X_{i-1} + c_{i+1} X_{i+1} + \dots + c_k X_k \\ \hat{X}_i &= d_0 + d_1 X_1 + d_2 X_2 + \dots + d_{i-1} X_{i-1} + d_{i+1} X_{i+1} + \dots + d_k X_k \end{aligned} \right\}$$

que resumen la influencia que ejercen las variables  $X_1, X_2, \dots, X_{i-1}, X_{i+1}, \dots, X_k$  sobre  $Y$  y  $X_i$  respectivamente.

# Regresión Lineal Múltiple

## Coeficiente de Correlación Parcial

### Solución 2

Eliminar la influencia de  $X_1, X_2, \dots, X_{i-1}, X_{i+1}, \dots, X_k$

¿Cómo?

En tres pasos.

1.- Obteniendo los hiperplanos de regresión:

$$\left. \begin{aligned} \hat{Y} &= c_0 + c_1 X_1 + c_2 X_2 + \dots + c_{i-1} X_{i-1} + c_{i+1} X_{i+1} + \dots + c_k X_k \\ \hat{X}_i &= d_0 + d_1 X_1 + d_2 X_2 + \dots + d_{i-1} X_{i-1} + d_{i+1} X_{i+1} + \dots + d_k X_k \end{aligned} \right\}$$

que resumen la influencia que ejercen las variables  $X_1, X_2, \dots, X_{i-1}, X_{i+1}, \dots, X_k$  sobre  $Y$  y  $X_i$  respectivamente.

# Regresión Lineal Múltiple

## Coeficiente de Correlación Parcial

2.- Se definen las variables:

$$\left. \begin{aligned} U &= Y - \hat{Y} \\ V &= X_i - \hat{X}_i \end{aligned} \right\}$$

que incorporan aquella parte de  $Y$  y  $X_i$  respectivamente, que queda libre de la influencia de  $X_1, X_2, \dots, X_{i-1}, X_{i+1}, \dots, X_k$

3.- Se define el **coeficiente de correlación parcial** entre  $Y$  y  $X_i$  como la correlación simple entre  $U$  y  $V$ :

$$r_{Y_i \cdot 12 \dots i-1 i+1 \dots k} = \frac{S_{UV}}{S_U S_V}$$

# Regresión Lineal Múltiple

## Coeficiente de Correlación Parcial

2.- Se definen las variables:

$$\left. \begin{aligned} U &= Y - \hat{Y} \\ V &= X_i - \hat{X}_i \end{aligned} \right\}$$

que incorporan aquella parte de  $Y$  y  $X_i$  respectivamente, que queda libre de la influencia de  $X_1, X_2, \dots, X_{i-1}, X_{i+1}, \dots, X_k$

3.- Se define el **coeficiente de correlación parcial** entre  $Y$  y  $X_i$  como la correlación simple entre  $U$  y  $V$ :

$$r_{Y_i \cdot 12 \dots i-1 i+1 \dots k} = \frac{S_{UV}}{S_U S_V}$$

# El Problema de la Multicolinealidad

# Regresión Lineal Múltiple

## El Problema de la Multicolinealidad

La multicolinealidad ocurre cuando **existe** una **correlación** entre dos o más **variables** explicativas.

Ésto implica que en la matriz  $X$  existen columnas que son combinación lineal de otras.

Por esta razón la matriz  $(X^t X)$  **no será invertible** y por tanto el vector de coeficientes  $B = (X^t X)^{-1} X^t Y$  **no se puede determinar**.

# Regresión Lineal Múltiple

## El Problema de la Multicolinealidad

La multicolinealidad ocurre cuando **existe** una **correlación** entre dos o más **variables** explicativas.

Ésto implica que en la matriz  $X$  existen columnas que son combinación lineal de otras.

Por esta razón la matriz  $(X^t X)$  **no será invertible** y por tanto el vector de coeficientes  $B = (X^t X)^{-1} X^t Y$  **no se puede determinar**.

# Bibliografía

## Bibliografía

- GARCÍA CÓRDOBA J. A. , LÓPEZ HERNÁNDEZ F. A., PALACIOS SÁNCHEZ M<sup>a</sup> Á. y RUIZ MARÍN, M. (2000), *Introducción a la Estadística para la Empresa*. Horacio Escarabajal Editores, pp 95–124.
- MARTÍN PLIEGO LÓPEZ, F.J. (2004), *Introducción a la Estadística Económica Y Empresarial*. Ed. Prentice Hall. pp. 235–372.
- MONTIEL A.M., RIUS F. y BARÓN F.J., (1997), *Elementos Básicos De Estadística Económica Y Empresarial*. Ed. Prentice Hall. pp. 147–186.
- NOVALES, A., (1996), *Estadística y Econometría*, Madrid: Mc Graw-Hill, pp.475-516.
- SANZ J.A.; BEDATE, A.; RIVAS, A. y GONZÁLEZ, J., (1996), *Problemas De Estadística Descriptiva Empresarial*. Ed. Ariel Economía., pp. 131–284.