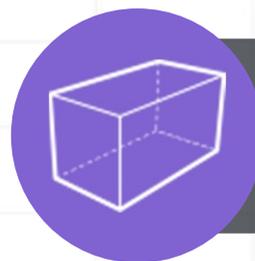
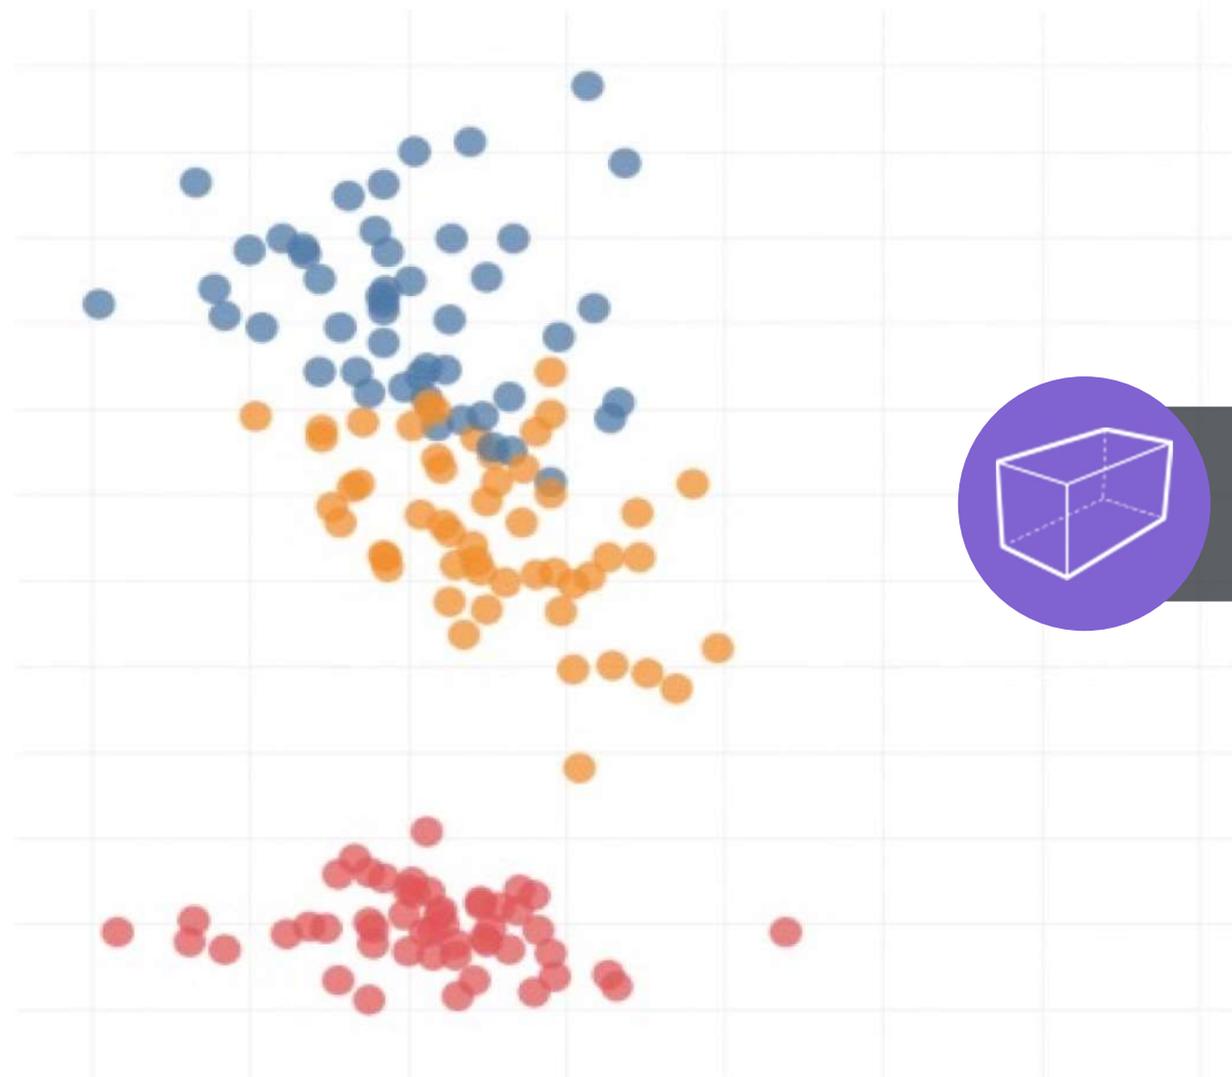


# Mínimos cuadrados 1

Análisis Estadístico y Geoestadístico de Datos

Auxiliar: Fabián Soto F.  
Profesor: Xavier Emery





# Mínimos cuadrados

## Resumen

# Mínimos cuadrados

Se busca ajustar un modelo predictivo a los datos disponibles, minimizando el error

$N$ : número de datos

$\hat{y}_i$  : valor estimado

$y_i$  : valor del dato

$$\chi^2 = \sum_{i=1}^N \varepsilon_i^2$$

$$\varepsilon_i = \hat{y}_i - y_i$$

# Regresión lineal univariante

Se busca ajustar un modelo predictivo a los datos disponibles, minimizando el error

$a$  : intercepto

$$\hat{y}_i = a + bx_i$$

$b$  : pendiente

$\hat{y}_i$  : valor estimado de  $y_i$

$x_i$  : valor del dato de entrada

# Regresión lineal univariante

- Intervalos de confianza para  $a$  y  $b$

$$\hat{y}_i = a + bx_i$$

- Análisis de significancia de los términos de la regresión

- Coeficiente de determinación múltiple: mide cuánto explica la variable y al utilizar el modelo de regresión con las variables  $x$  (cercano a 1 explica mucho, cercano a 0 explica poco).

$$H_0: b = 0$$

$$H_1: b \neq 0$$

- Coeficiente de determinación múltiple ajustado: Permite comparar “justamente” modelos con diferente cantidad de parámetros.

# Test de un modelo lineal sujeto a condiciones

$H_0$ : Modelo reducido es aceptable

$H_1$ : Modelo expandido es aceptable

$$F = \frac{\frac{SE(H_0) - SE(H_1)}{k}}{\frac{SE(H_1)}{N - M}}$$

$k$ : condiciones lineales

$N$ : cantidad de datos

$M$ : coeficientes libres

$SE(H)$  : pendiente suma de cuadrados según la hipótesis  $H$

Se compara el estadístico con un Fisher (valor crítico) de  $k$  y  $N-M$  grados de libertad

# Test de un modelo lineal sujeto a condiciones

$H_0$ : Modelo reducido es aceptable

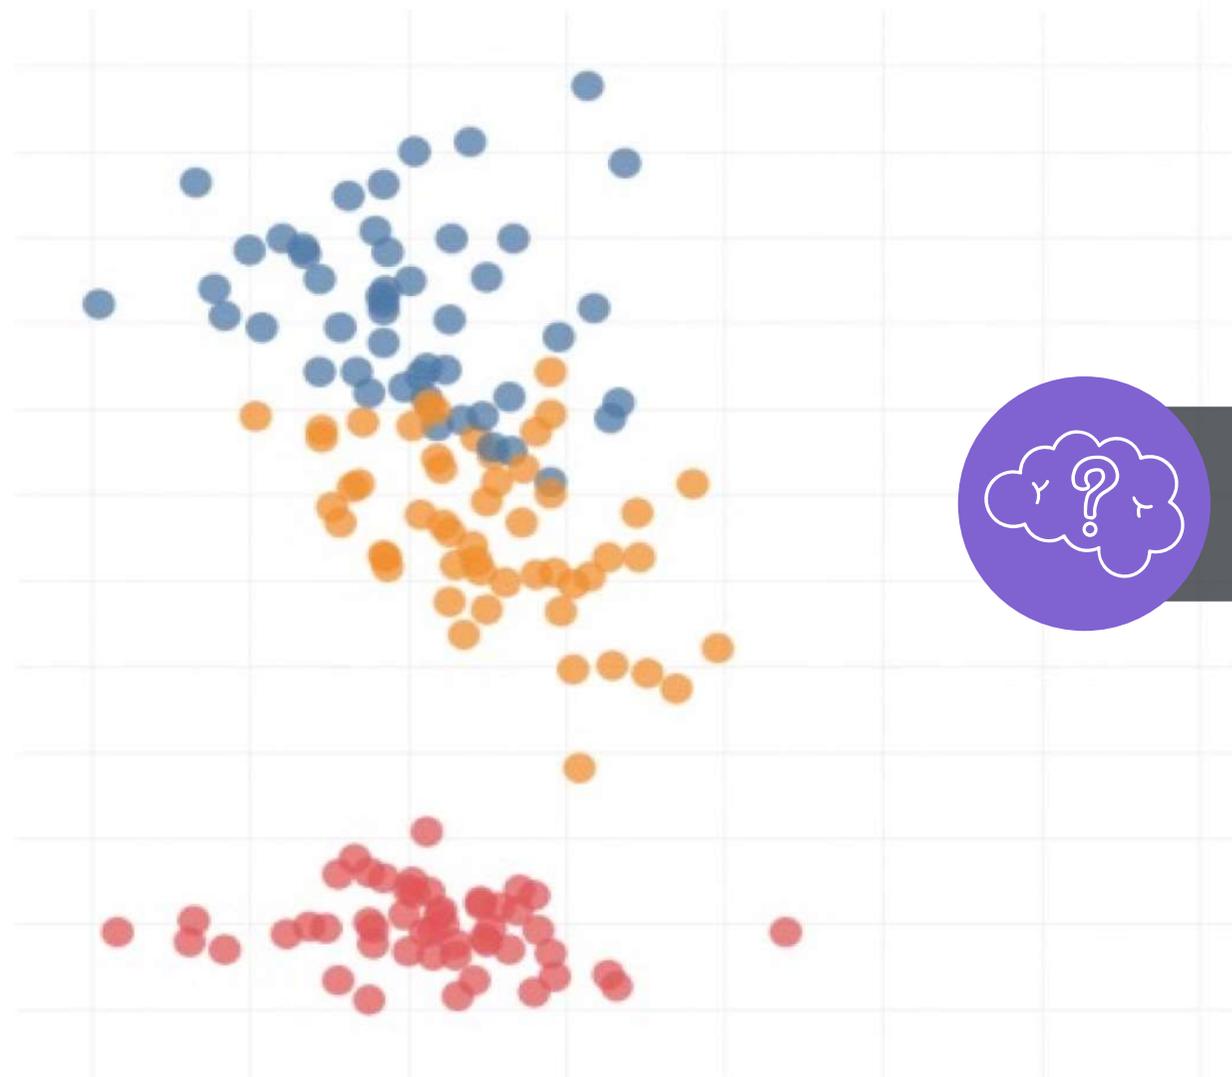
$H_1$ : Modelo expandido es aceptable

- Para el cálculo de la suma de cuadrados ( $SE$ ) se toma el valor predicho según el modelo de la hipótesis  $\mathbf{k}$
- $\hat{y}_{\mathbf{k}, i}$  es el valor predicho para el dato  $i$  según el modelo de la hipótesis  $\mathbf{k}$
- $\varepsilon_i$  representa el error cometido por el modelo en el dato  $i$ -ésimo

$$F = \frac{\frac{SE(H_0) - SE(H_1)}{k}}{\frac{SE(H_1)}{N - M}}$$

$$SE(H_k) = \sum_{i=1}^N \varepsilon_i^2$$

$$\varepsilon_i = \hat{y}_{\mathbf{k}, i} - y_i$$



# Problemas

## Mínimos cuadrados



### Problema 1:

- Modelar la relación entre los datos duplicados que fueron mandados a 2 laboratorios distintos (Archivo *Duplicados.xls*). ¿Es la regresión diferente a la identidad?



### Problema 1:

- Modelar la relación entre los datos duplicados que fueron mandados a 2 laboratorios distintos (Archivo *Duplicados.xls*). ¿Es la regresión diferente a la identidad?



### Problema 2:

- Se tienen valores para 2 variables  $x$  e  $y$ , medidas en 2 condiciones distintas (Pestaña “*Comparación Regresiones*” en el archivo *Regresiones.xls*).
- Se desea saber si las rectas de regresión bajo cada condición son iguales o no.

# Problema 1

Realizaremos la predicción ( $\hat{y}_i$ ) de los análisis del laboratorio B usando los datos obtenidos en el laboratorio A ( $x_i$ )

- Debemos evaluar la significancia de la regresión.

$$H_0: \mathbf{b} = \mathbf{0}$$

$$H_1: \mathbf{b} \neq \mathbf{0}$$

$$\hat{y}_i = \mathbf{a} + \mathbf{b}x_i$$

¿Qué significa que la regresión sea diferente de la identidad?

# Problema 1

Para que la regresión sea igual a la identidad:

Se busca que la regresión  
 $\hat{y}_i = a + bx_i$  sea la identidad



$$a = 0$$
$$b = 1$$

- Este es el modelo reducido  $\hat{y}_i = x_i$
- Se comparará la significancia de este modelo versus el anterior

# Problema 2

Tenemos datos en dos condiciones diferentes (A y B)

Condición A

x	y
0.536	0.54
0.543	0.45
0.377	0.279
0.94	1.176
0.629	0.582
0.826	1.098

Condición B

x	y
0.614	0.876
0.357	0.399
0.556	0.57
1.411	2.025
0.65	1.035
0.864	1.533
0.885	1.266
0.554	0.795

# Problema 2

Tenemos dos modelos en dos condiciones diferentes (A y B)

$$\hat{y}_A = a + bx_A$$
$$\hat{y}_B = a' + b'x_B$$

¿Cómo combinar estos modelos en uno solo?

# Variable indicador

- Es posible usar una variable indicador ( $i$ )
- Este vale 1 si estamos la condición A y vale 0 en caso contrario
- Podemos integrar ambas ecuaciones en una sola

$$\hat{y} = i(\mathbf{a} + \mathbf{b}\mathbf{x}) + (1-i)(\mathbf{a}' + \mathbf{b}'\mathbf{x})$$

Cuando  $i$  vale 1, se obtiene la ecuación para la condición A, y cuando vale 0 se obtiene la ecuación para la condición B.

# Ecuación final

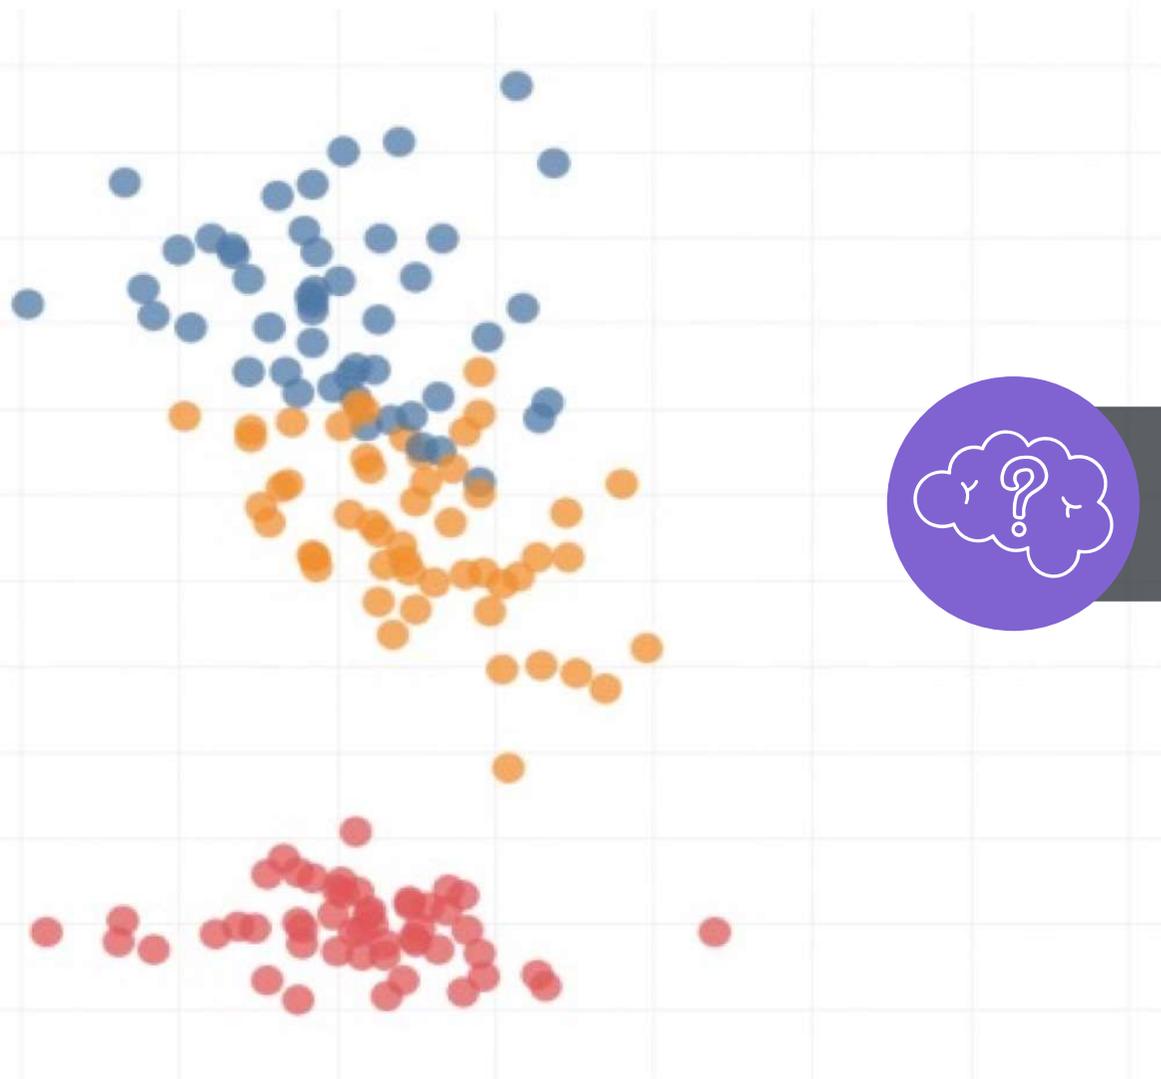
Reordenando la ecuación final obtenemos:

$$\hat{y} = a' + b'x + (a - a')i + (b - b')xi \quad \Leftrightarrow \quad \hat{y} = a' + b'x + ci + dxi$$

Con:

$$c = (a - a')$$

$$d = (b - b')$$



¿Dudas?