

# Modelo lineal y método de cuadrados mínimos

Laboratorio 1B – 2do Cuatrimestre 2024

Federico Trupp

(basado en presentaciones Lucía Famá)

# MODELADO POR EL MÉTODO DE CUADRADOS MÍNIMOS

## Relación entre dos medidas:

Empleo un **modelo** que mejor relacione las variables  
(que **mejor aproxime a mis datos experimentales**)

### Caso más sencillo



Modelo Lineal

## ¿Por qué modelar?

- Se puede observar la relación entre las variables.
- El resultado es más representativo del sistema que tomar un único caso.
- Reducimos posibles fuentes de errores.
- Permite verificar la teoría.
- Se pueden realizar predicciones para la magnitud física fuera del rango de medición.


# Caso más sencillo

## Modelo Lineal

Tomamos una serie de medidas  $(x_i, y_i)$

Partamos asumiendo que la relación es:

$$y = mx + b$$




Caso aún más sencillo: Considerando la **Distancia en "y"**

Buscamos encontrar los parámetros  **$m$**  y  **$b$**  que minimicen la distancia de los datos al modelo en el eje "y"

Buscamos encontrar los parámetros  $m$  y  $b$  que minimicen la distancia de los datos al modelo


Considerando la **Distancia en "y"**



# Caso A

## Cuadrados mínimos NO Ponderados

Cuando todos los datos en "y" tienen igual incerteza



Minimizar la Suma de los Cuadrados de los Residuos

# ¿Cómo encontramos los parámetros $m$ y $b$ ?

Minimizar la Suma de los Cuadrados de los Residuos

$$M(m, b) = \sum_i y_i^2 + m^2 \sum_i x_i^2 + Nb^2 + 2mb \sum_i x_i - 2m \sum_i x_i y_i - 2b \sum_i y_i$$

$$\left\{ \begin{array}{l} \frac{\partial M}{\partial m} = 0 \longrightarrow 2m \sum_i x_i^2 + 2b \sum_i x_i - 2 \sum_i x_i y_i = 0 \\ \frac{\partial M}{\partial b} = 0 \longrightarrow 2Nb + 2m \sum_i x_i - 2 \sum_i y_i = 0 \end{array} \right. \quad \begin{array}{l} 2 \text{ ecuaciones y} \\ 2 \text{ incógnitas} \end{array}$$

$$m = \frac{N \sum x_i y_i - \sum x_i \sum y_i}{N \sum x_i^2 - (\sum x_i)^2}$$

$$b = \frac{\sum x_i^2 \sum y_i - \sum x_i \sum x_i y_i}{N \sum x_i^2 - (\sum x_i)^2}$$

## ¿Cómo encontramos $S_m$ y $S_b$ ?


$$m = \frac{N\sum x_i y_i - \sum x_i \sum y_i}{N\sum x_i^2 - (\sum x_i)^2}$$

$$b = \frac{\sum x_i^2 \sum y_i - \sum x_i \sum x_i y_i}{N\sum x_i^2 - (\sum x_i)^2}$$

Propagación de errores!!



D. C. Baird. Prentice Hall  
(1991). Apéndice 2



Estamos evaluando la incerteza en el eje y

→ Hipótesis: Consideremos a la incerteza como  $\delta_i$

$$S_m = S_y \sqrt{\frac{N}{N\sum x_i^2 - (\sum x_i)^2}}$$

$$S_b = S_y \sqrt{\frac{\sum x_i}{N\sum x_i^2 - (\sum x_i)^2}}$$

$$\dots \rightarrow S_y = \sqrt{\frac{\sum \delta_i^2}{N-2}}$$


⇒ Calculamos las incertezas de forma exacta

**Válido cuando todas las medidas de y tienen igual precisión**



Cuando todos los datos en "y" tienen diferente incerteza

$$y = f(x) = mx + b$$



**Hipótesis:** Considera a las medidas más precisas como las más relevantes

Chi cuadrado

$$\chi^2 = \sum_1^N \left[ \frac{y_i - (mx_i + b)}{\Delta y_i} \right]^2$$

Minimizar la Suma de los Cuadrados de los Residuos Normalizados al error de cada medida

Si confiamos más en algunos puntos que en otros

## Cuadrados mínimos ponderados

Obtengo  $m$  y  $b$  despejando (2 ecuaciones y 2 incógnitas):

$$b = \frac{\sum \frac{1}{(S_{yi})^2} y_i \sum \frac{1}{(S_{yi})^2} x_i^2 - \sum \frac{1}{(S_{yi})^2} x_i \sum \frac{1}{(S_{yi})^2} x_i y_i}{\sum \frac{1}{(S_{yi})^2} \sum \frac{1}{(S_{yi})^2} x_i^2 - \left( \sum \frac{1}{(S_{yi})^2} x_i \right)^2}$$

$$m = \frac{\sum \frac{1}{(S_{yi})^2} \sum \frac{1}{(S_{yi})^2} (x_i y_i) - \sum \frac{1}{(S_{yi})^2} x_i \sum \frac{1}{(S_{yi})^2} y_i}{\sum \frac{1}{(S_{yi})^2} \sum \frac{1}{(S_{yi})^2} x_i^2 - \left( \sum \frac{1}{(S_{yi})^2} x_i \right)^2}$$


$$S_m^2 = \frac{\sum \frac{1}{(S_{yi})^2}}{\sum \frac{1}{(S_{yi})^2} \sum \frac{x_i^2}{(S_{yi})^2} - \left( \sum \frac{x_i}{(S_{yi})^2} \right)^2}$$

$$S_b^2 = \frac{\sum \frac{x_i y_i}{(S_{yi})^2}}{\sum \frac{1}{(S_{yi})^2} \sum \frac{x_i^2}{(S_{yi})^2} - \left( \sum \frac{x_i}{(S_{yi})^2} \right)^2}$$

Lo importante es que  
puedo calcular estos  
valores de manera  
**EXACTA**

# SIN Ponderación vs CON Ponderación

Se pondera cuando las incertezas absolutas de la MF que se asigna al eje "y" tienen diferente precisión



Residuos ( $\delta_i$ )  $\rightarrow \delta_i = y_i - y_r$

SIN

$$M = \sum_1^N [y_i - (mx_i + b)]^2$$

CON

$$\chi^2 = \sum_1^N \left[ \frac{y_i - (mx_i + b)}{\Delta y_i} \right]^2$$

Al ponderar, considera más relevantes a las medidas más precisas

¿Cómo determinamos si el ajuste es “bueno”?  
¿Qué medidas podemos evaluar y comparar?

## Parámetros de BONDAD

*Los Parámetros de Bondad pueden darnos una idea de la **discrepancia entre los valores observados (datos experimentales) y los esperados según el modelo de estudio***

## Coeficiente de Correlación de Pearson ( $r$ )

*Indica cuán fuerte es la correlación entre las variables  $X$  e  $Y$*   
*¿Existe algún patrón entre ellas?*

$$r = \frac{\text{Cov}(x, y)}{\sqrt{\text{Var}(x)\text{Var}(y)}} = \frac{S_{xy}}{S_x S_y}$$

$$-1 \leq r \leq 1$$

Se espera que  $|r| \sim 1$

$$\text{Var}(x) = S_x^2 = \frac{1}{N} \sum (x_i - \bar{x})^2$$

$$\text{Var}(y) = S_y^2 = \frac{1}{N} \sum (y_i - \bar{y})^2$$


$$\text{Cov}(x, y) = S_{xy} = \frac{1}{N} \sum (x_i - \bar{x})(y_i - \bar{y})$$

Cálculo del Correlación de Pearson en Python: **corrcoef()**



# Parámetros de BONDAD

## Coeficiente de Correlación de Pearson ( $r$ )



- **Si  $r = 1$ :** Correlación positiva perfecta. El índice refleja la dependencia total entre ambas variables, la que se denomina relación directa: cuando una de las variables aumenta, la otra variable aumenta en proporción constante.

- **Si  $0 < r < 1$ :** Refleja que se da una correlación positiva.

- **Si  $r = 0$ :** En este caso no hay una relación lineal. Aunque no significa que las variables sean independientes, puede haber relaciones no lineales entre ambas.

- **Si  $-1 < r < 0$ :** Indica que existe una correlación negativa.

- **Si  $r = -1$ :** Indica una **correlación negativa perfecta** y una dependencia total entre ambas variables lo que se conoce como "**relación inversa**", que es cuando una de las variables aumenta, la otra variable disminuye en proporción constante.

## Vamos a usar el coeficiente de determinación $R^2$

En el caso de los modelos lineales, es igual al coeficiente de Pearson al cuadrado

$$R^2 = \frac{\sigma_{XY}^2}{\sigma_X^2 \sigma_Y^2} = \rho^2$$

$$\rho^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} = 1 - \frac{\sigma_r^2}{\sigma_y^2}$$

Donde:

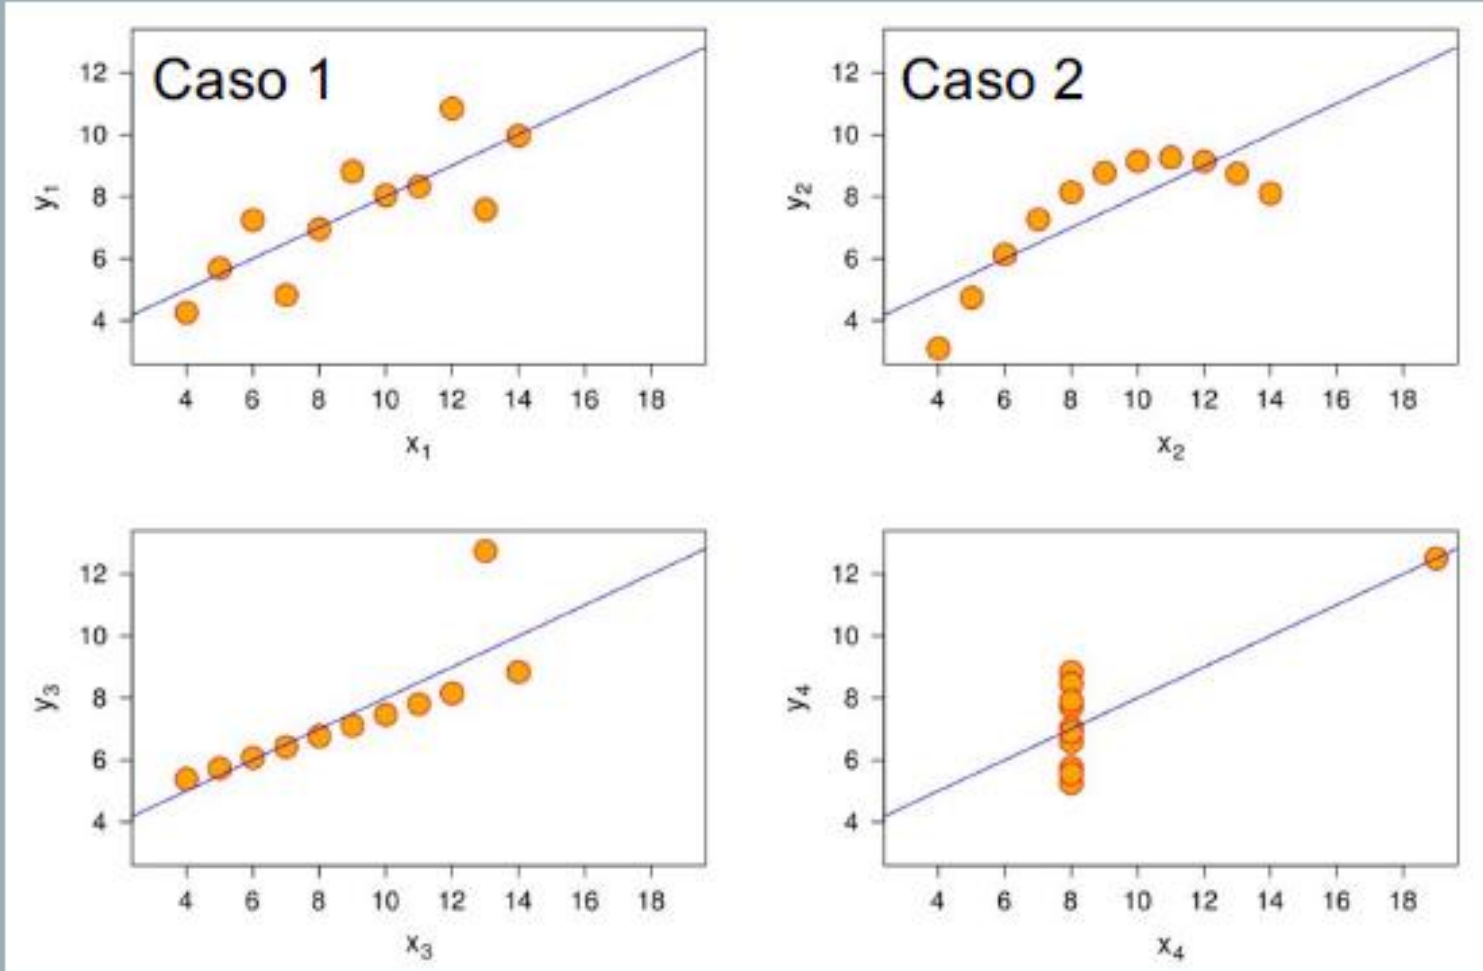
- $\sigma_{XY}$  es la **covarianza** de  $(X, Y)$
- $\sigma_X^2$  es la **varianza** de la variable  $X$
- $\sigma_Y^2$  es la **varianza** de la variable  $Y$

$R^2$  está entre 0 y 1  
Cuanto más cerca de 1,  
mayor es la correlación

Pero ojo! el  $R^2$  solo no alcanza para determinar la bondad de un ajuste

### Bondad del ajuste

El cuarteto de Anscombe (  $R^2 = 0.666$  )


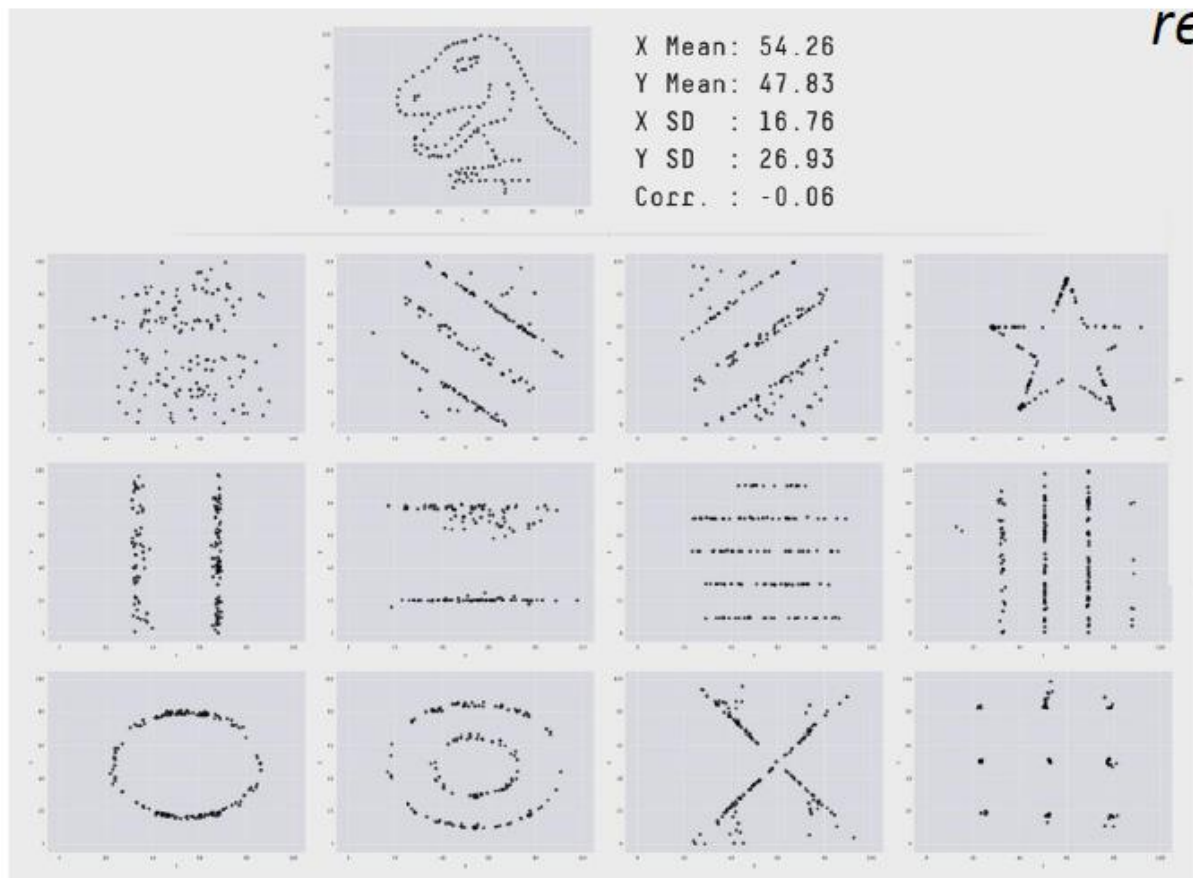




# Estos casos tienen los MISMOS Parámetros Estadísticos!!!

## Datasaurus dozen

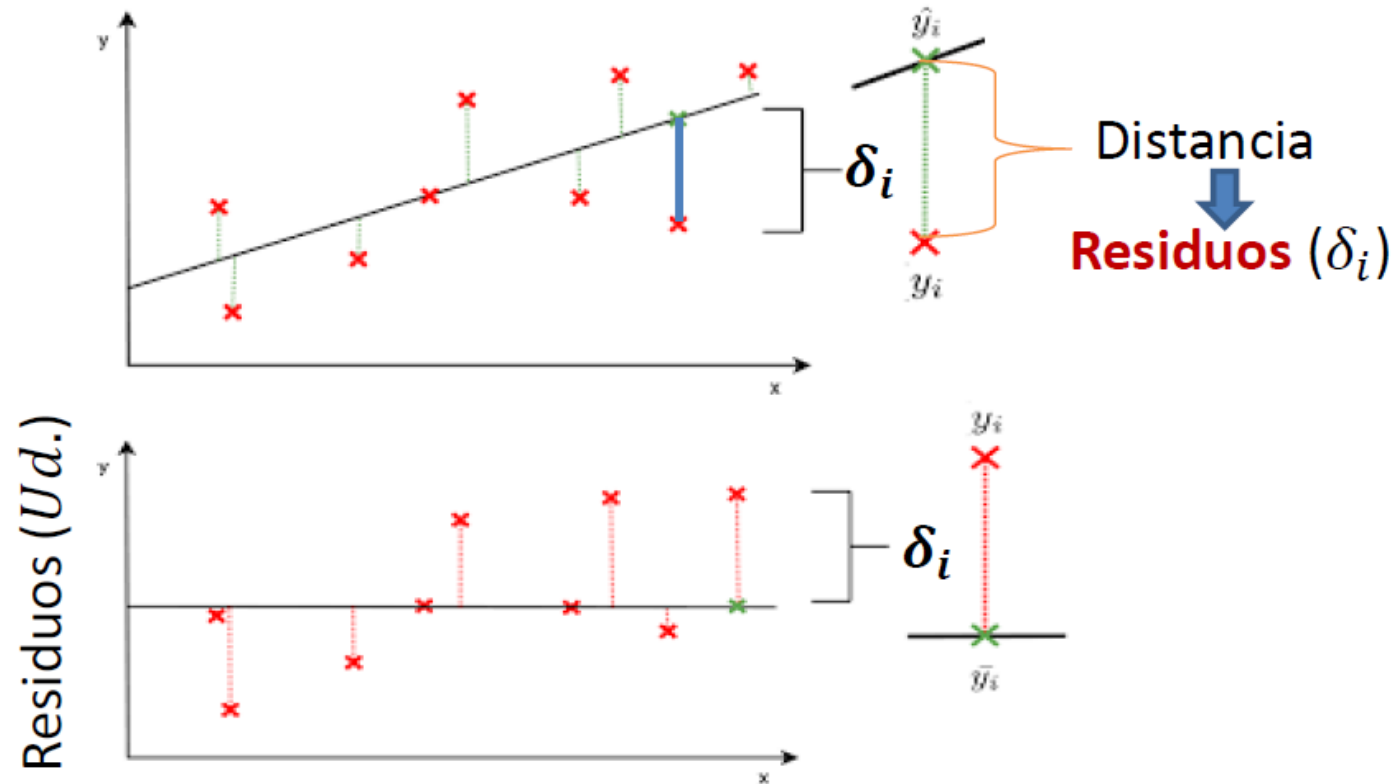
... pero que producen gráficos diferentes  
Por eso la **IMPORTANCIA** de las  
representaciones gráficas



# Parámetros de BONDAD

## Gráfico de Residuos

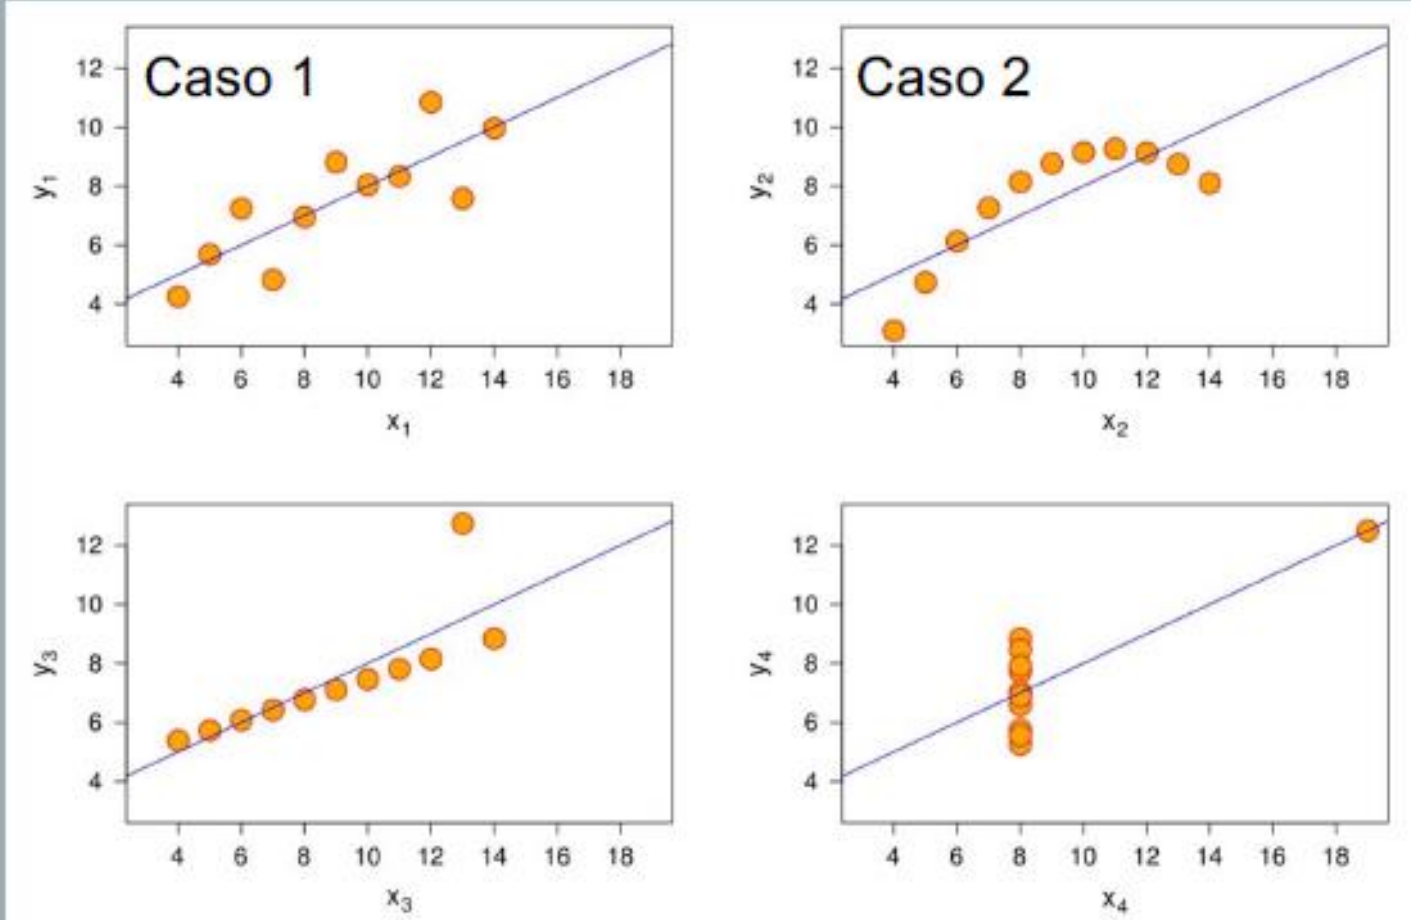
Distancia de los puntos experimentales a la recta, en "y"




**Los residuos deben ser datos distribuidos en forma aleatoria  
alrededor del cero.  
NO DEBEN tener ESTRUCTURA**

También tenemos que observar el gráfico de residuos y ver si tienen estructura


El cuarteto de Anscombe ( $R^2 = 0.666$ )



Caso 1



Caso 2



En los **casos 2, 3 y 4** la distribución de los datos alrededor de la recta no es normal. **Los residuos tienen estructura**

Por último, necesitamos una medida que nos dé información sobre nuestra estimación de incertezas:  $\chi^2_v$  (chi cuadrado reducido)



*Dimensiona cuánto difieren los datos experimentales de los del modelo. Pesa fuertemente la incerteza  $\Delta y$*

$$\chi^2 = \sum_1^N \left[ \frac{y_i - (mx_i + b)}{\Delta y_i} \right]^2$$

**Caso lineal:**




**$N$  = número de datos**

**2: los grado de libertad**

Chi cuadrado  
reducido

→  $\chi^2_v = \frac{\chi^2}{N - 2}$

Se espera que  $\chi^2_v$

- $\chi^2_v \sim 1$  
- $\chi^2_v \ll 1$  
- $\chi^2_v \gg 1$  



# Parámetros de BONDAD

¿Qué esperamos?

Parámetros de BONDAD que nos servirán de ayuda:

Coeficiente de  
Determinación

$R^2 \rightarrow$


$$R^2 \sim 1$$

Chi-cuadrado reducido

$\chi_v^2 \rightarrow$

$$\chi_v^2 \sim 1$$

Residuos  
Sin ESTRUCTURA



## Objetivo de la práctica de hoy

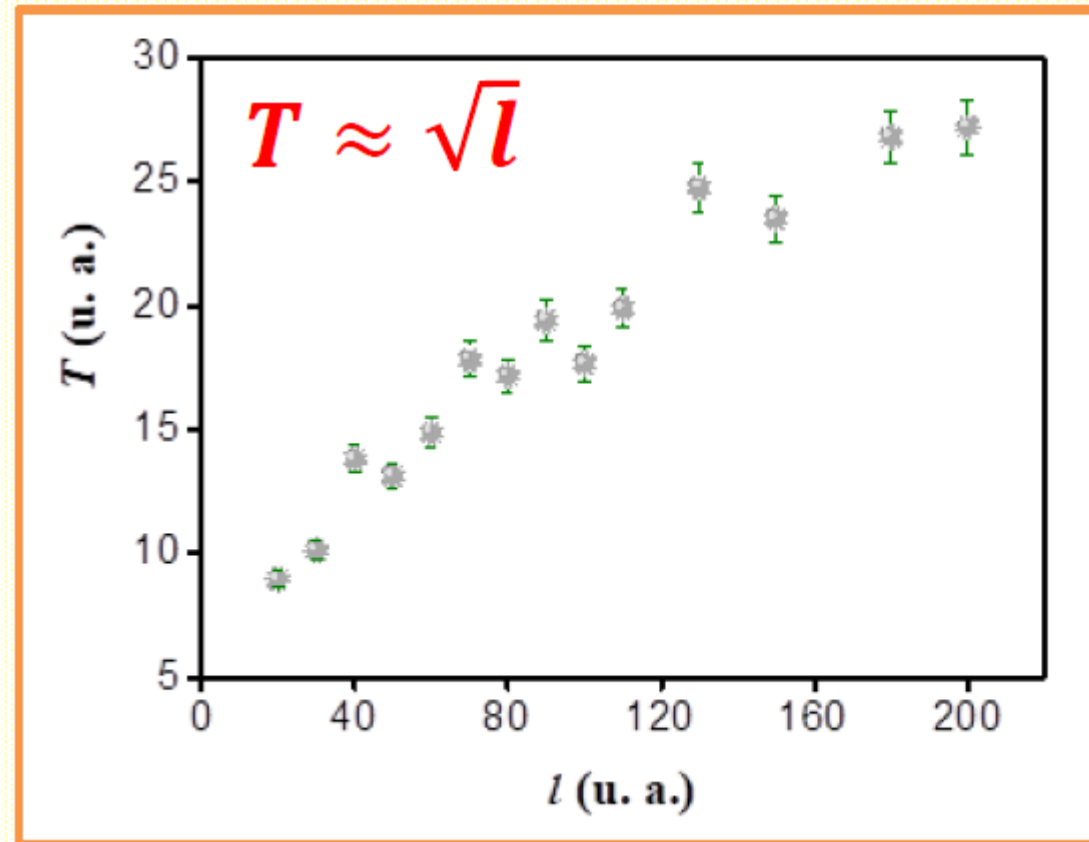
Determinar la aceleración de la gravedad  $g$   
a partir de los datos del Período de un  
Péndulo  $T$  y su Longitudes  $l$

$$g = (\bar{g} \pm \Delta g) \text{ Ud.}$$

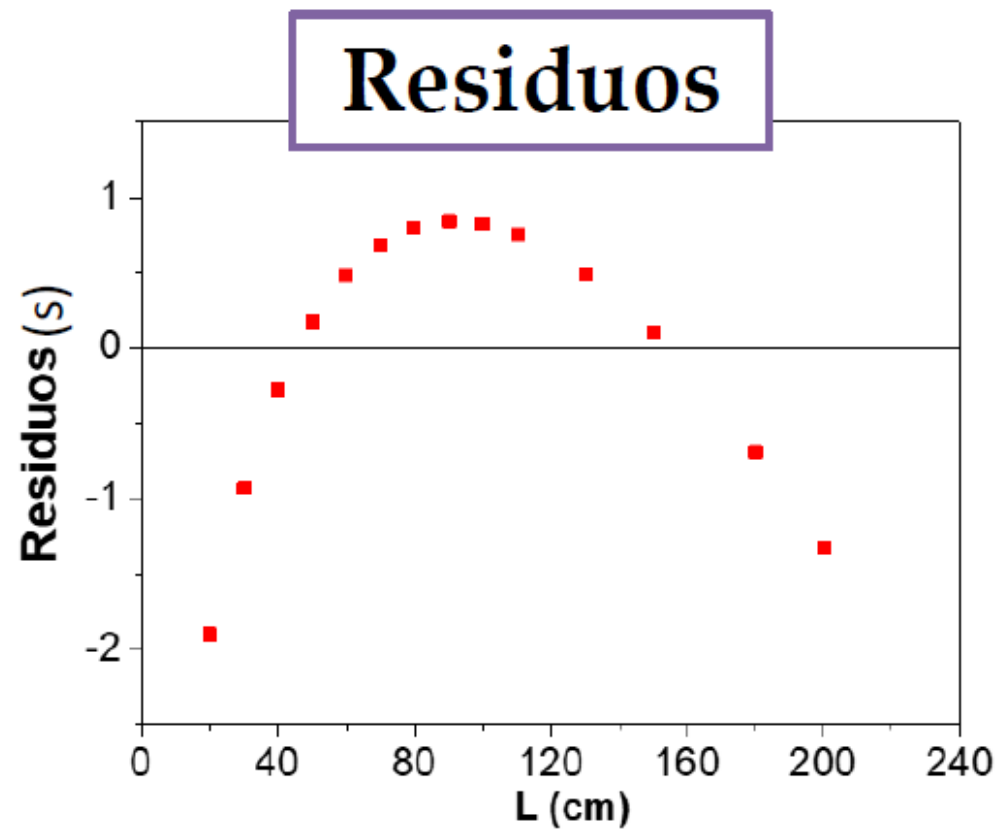

# Determinar la aceleración de la gravedad $g$ a partir de $T$ y $l$ de DIFERENTES Péndulos y un MODELO LINEAL DEL MÉTODO DE CUADRADOS MÍNIMOS

PERO  $T$  y  $l$  SE  
RELACIONAN  
LINEALMENTE??

$$T = 2\pi \sqrt{\frac{l}{g}}$$



*Está bien usar el modelo lineal en este caso?*



**NOOOOOO es lineal!!**




# ¿Cómo utilizo el modelo lineal en una relación NO lineal?

$$T = 2\pi \sqrt{\frac{l}{g}}$$

Diagram illustrating the linearization of the period  $T$  of a simple pendulum:

- The original equation is  $T = 2\pi \sqrt{\frac{l}{g}}$ .
- Two paths are shown from the original equation:
  - Upward arrow:  $T = \frac{2\pi}{\sqrt{g}} \sqrt{l}$ . Here,  $T$  and  $\sqrt{l}$  are circled in red, and  $\frac{2\pi}{\sqrt{g}}$  is the slope.
  - Downward arrow:  $T^2 = \frac{4\pi^2}{g} l$ . Here,  $T^2$  and  $l$  are circled in red,  $\frac{4\pi^2}{g}$  is circled in blue, and labeled "Pendiente" (Slope).



$$\checkmark y = mx + b$$

Queremos obtener:

$$g = (\bar{g} \pm \Delta g) Ud.$$

Uno de los dos casos:

$$T^2 = \frac{4\pi^2}{g} l$$

Diagram showing the equation  $T^2 = \frac{4\pi^2}{g} l$  with annotations:  $T^2$  is circled in red with an arrow pointing to  $y$ ;  $l$  is circled in red with an arrow pointing to  $x$ ;  $g$  is circled in blue with an arrow pointing to  $m$ .

Pendiente  $m = \bar{m} + \Delta m$

$$m = \frac{4\pi^2}{g} \rightarrow g = \frac{4\pi^2}{m}$$

$$\bar{g} = \frac{4\pi^2}{\bar{m}}$$

¿ $\Delta g$ ?

Propago!!

$$\Delta y = \sqrt{\left(\left.\frac{\partial f}{\partial p}\right|_{y_0} \Delta p\right)^2 + \left(\left.\frac{\partial f}{\partial q}\right|_{y_0} \Delta q\right)^2 + \left(\left.\frac{\partial f}{\partial r}\right|_{y_0} \Delta r\right)^2 + \dots}$$

Son productos y divisiones

$$y = \frac{p}{q}$$

$$y = p \cdot q$$

$$\frac{\Delta y}{y_0} = \sqrt{\frac{(\Delta q)^2}{q_0^2} + \frac{(\Delta p)^2}{p_0^2}}$$

$$\frac{\Delta y}{y_0} = \sqrt{\frac{(\Delta q)^2}{q_0^2} + \frac{(\Delta p)^2}{p_0^2}}$$

Para la próxima clase, se entrega el cuaderno con:

- 1. PRÁCTICA 2 - ACTIVIDAD 2: DETERMINACIÓN DE G A PARTIR DE LA MEDICIÓN DEL PERÍODO DE UN PÉNDULO (con los datos del TP1)**
- 2. PRÁCTICA 3 - ACTIVIDAD 1: DETERMINACIÓN DE G A PARTIR DE LA MEDICIÓN DEL PERÍODO DE UN PÉNDULO (actividad de hoy)**

Como siempre: antes de las 13 hs del miércoles que viene en el mismo link.