

Clase 2

Comparación de datos con modelos (cuadrados mínimos)

<https://asignaturas.df.uba.ar/myt-wisniacki/laboratorio/>

Comparación de datos y modelos

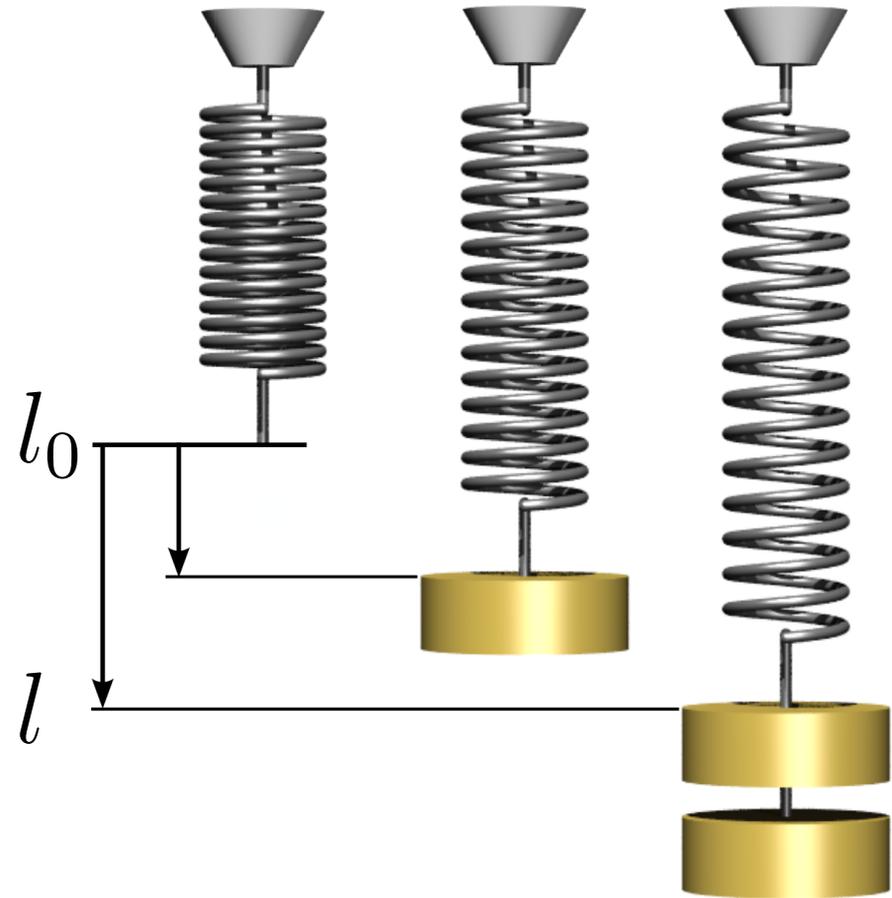
Ejemplo de modelo: Ley de Hook

Relación funcional entre posición y fuerza: Lineal

$$F = -k \cdot (l - l_0)$$

$$F = l \cdot (-k) + (k \cdot l_0)$$

$$y = x \cdot a + b$$



Cuadrados mínimos

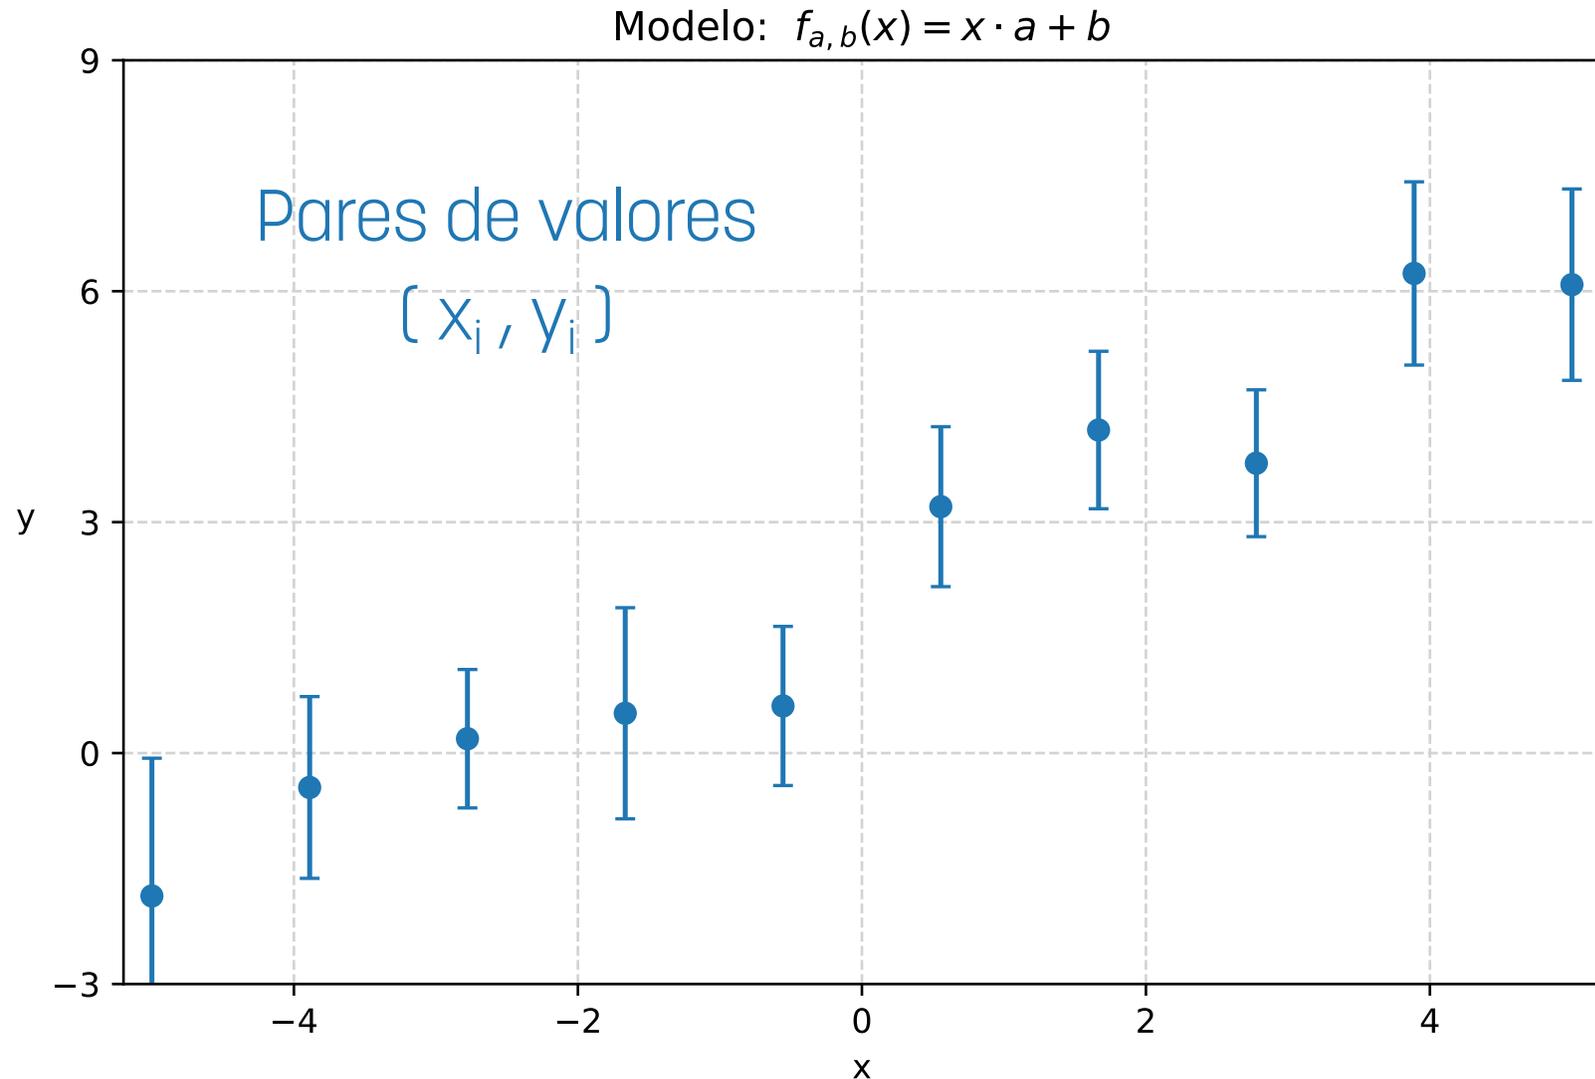
Conjunto de datos medidos (con sus errores)

Modelo Lineal

parámetros

$$f(x) = x \cdot a + b$$

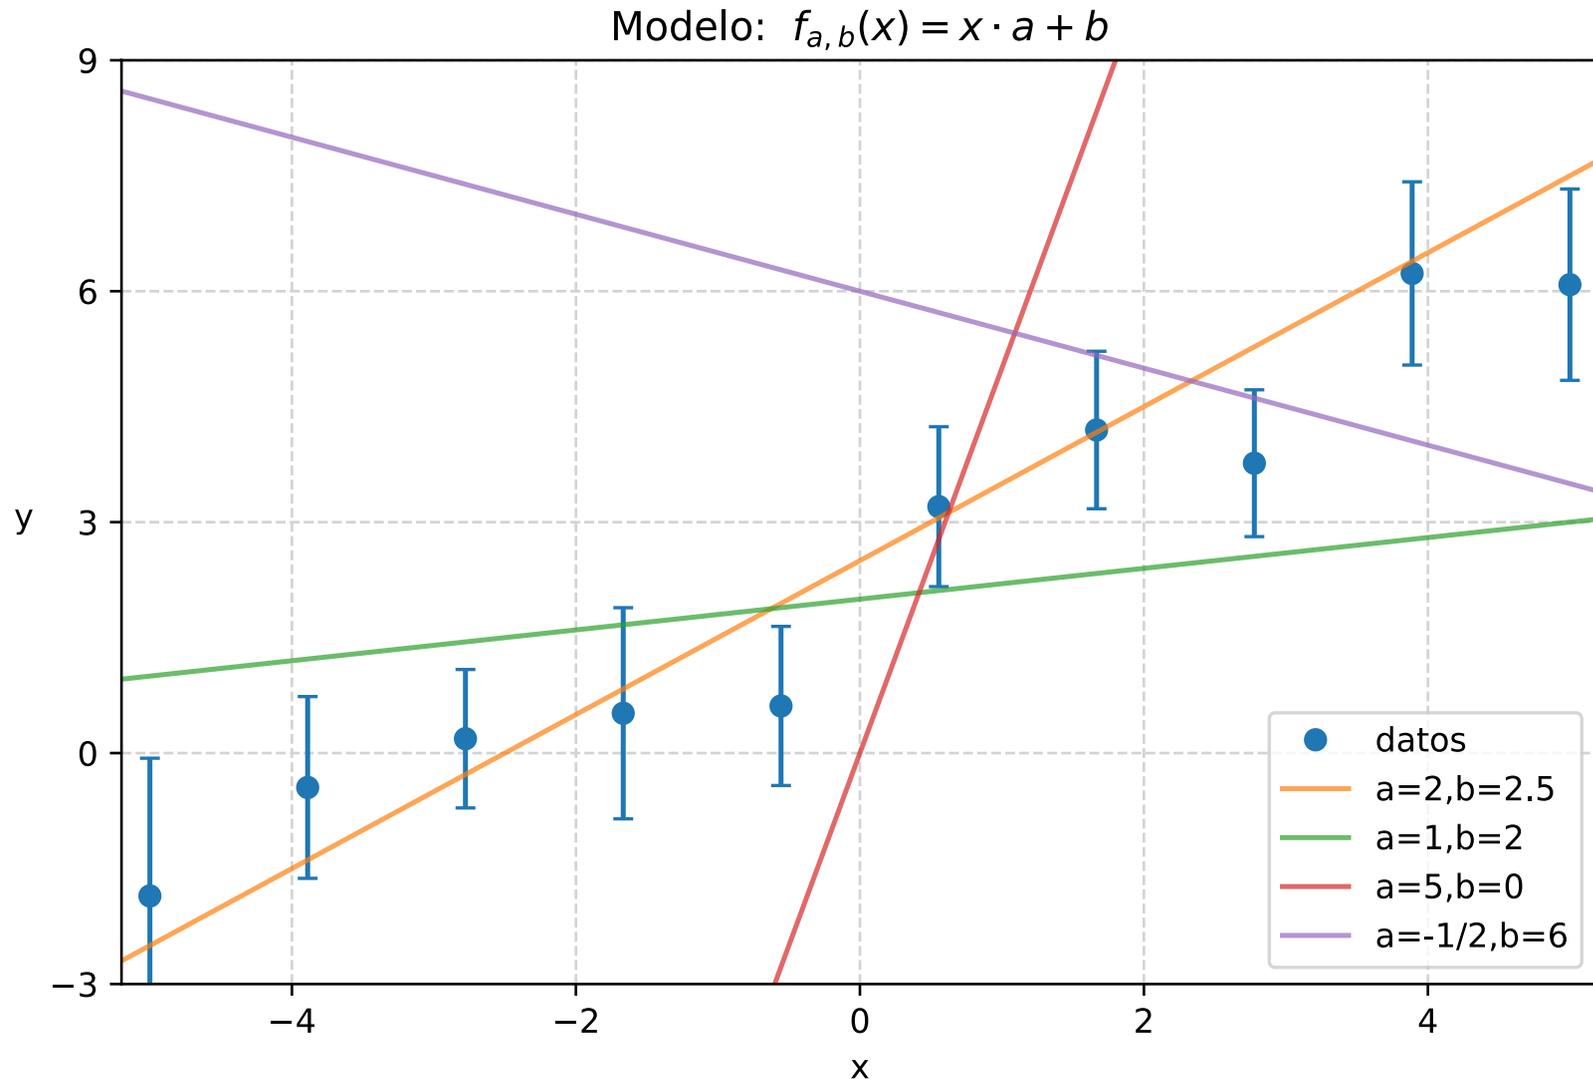
¿Responden
los datos al
modelo?



Cuadrados mínimos

Modelo para diferentes parámetros

¿Con que parámetros el modelo "se parece" más a los datos?

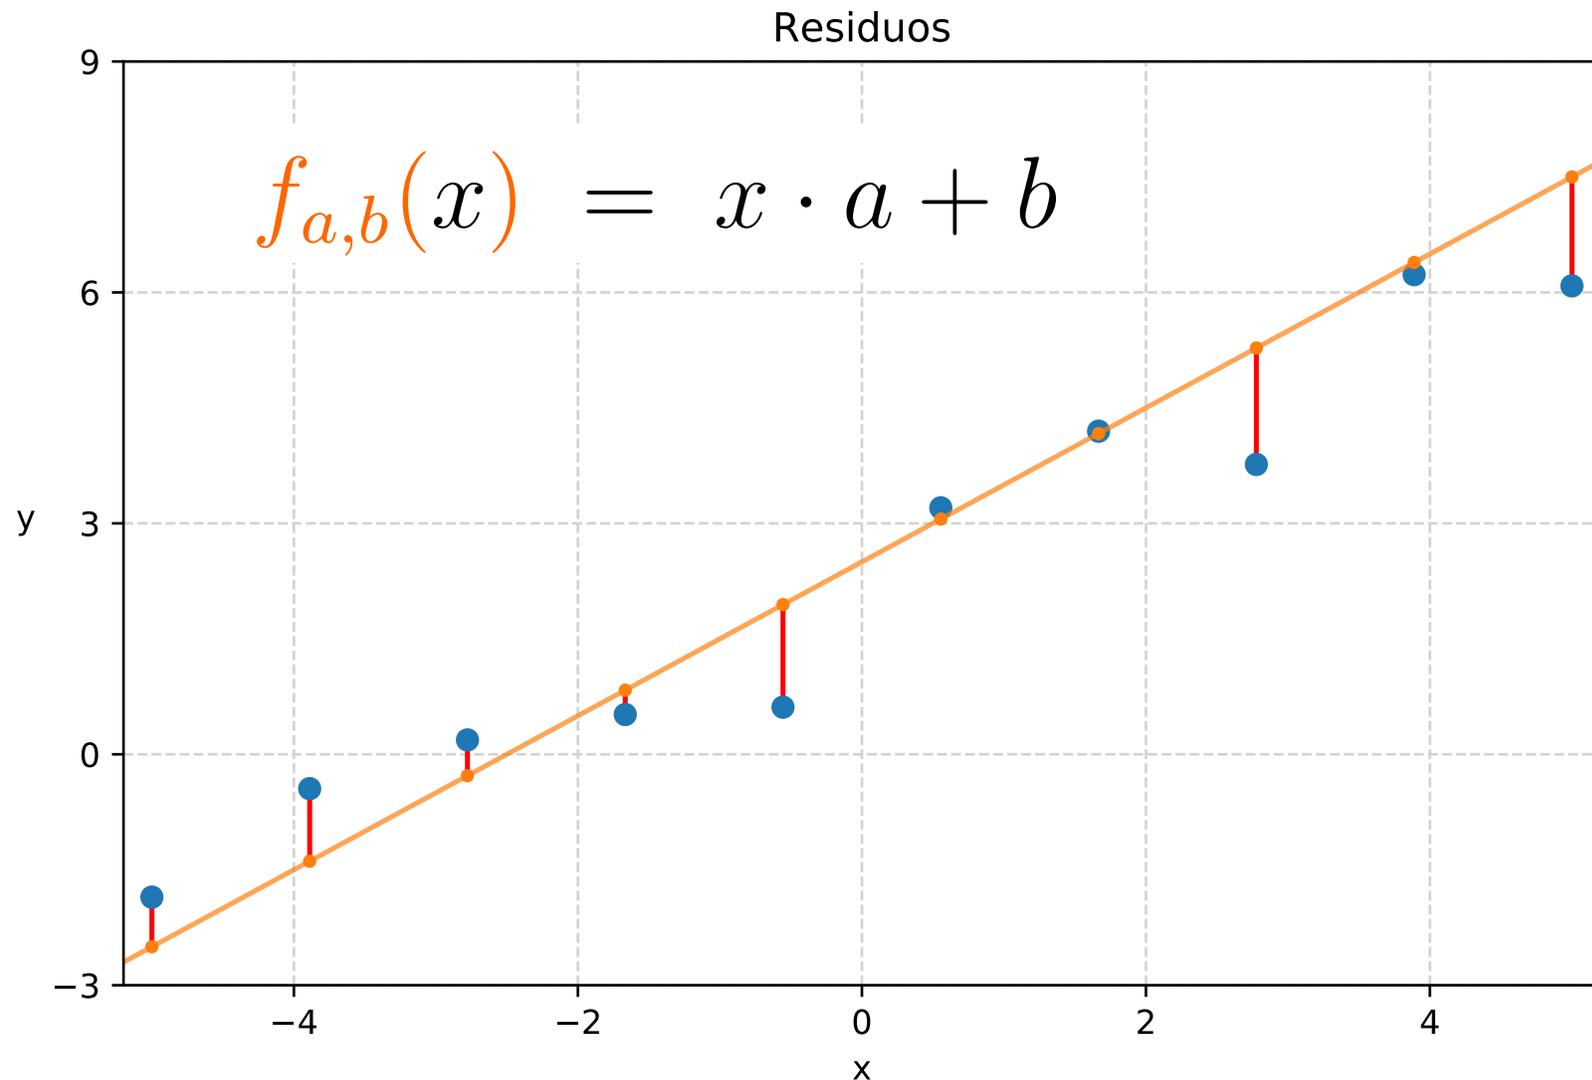


Cuadrados mínimos

$$\text{res}_i = y_i - f_{a,b}(x_i)$$

$$(x_i, y_i)$$

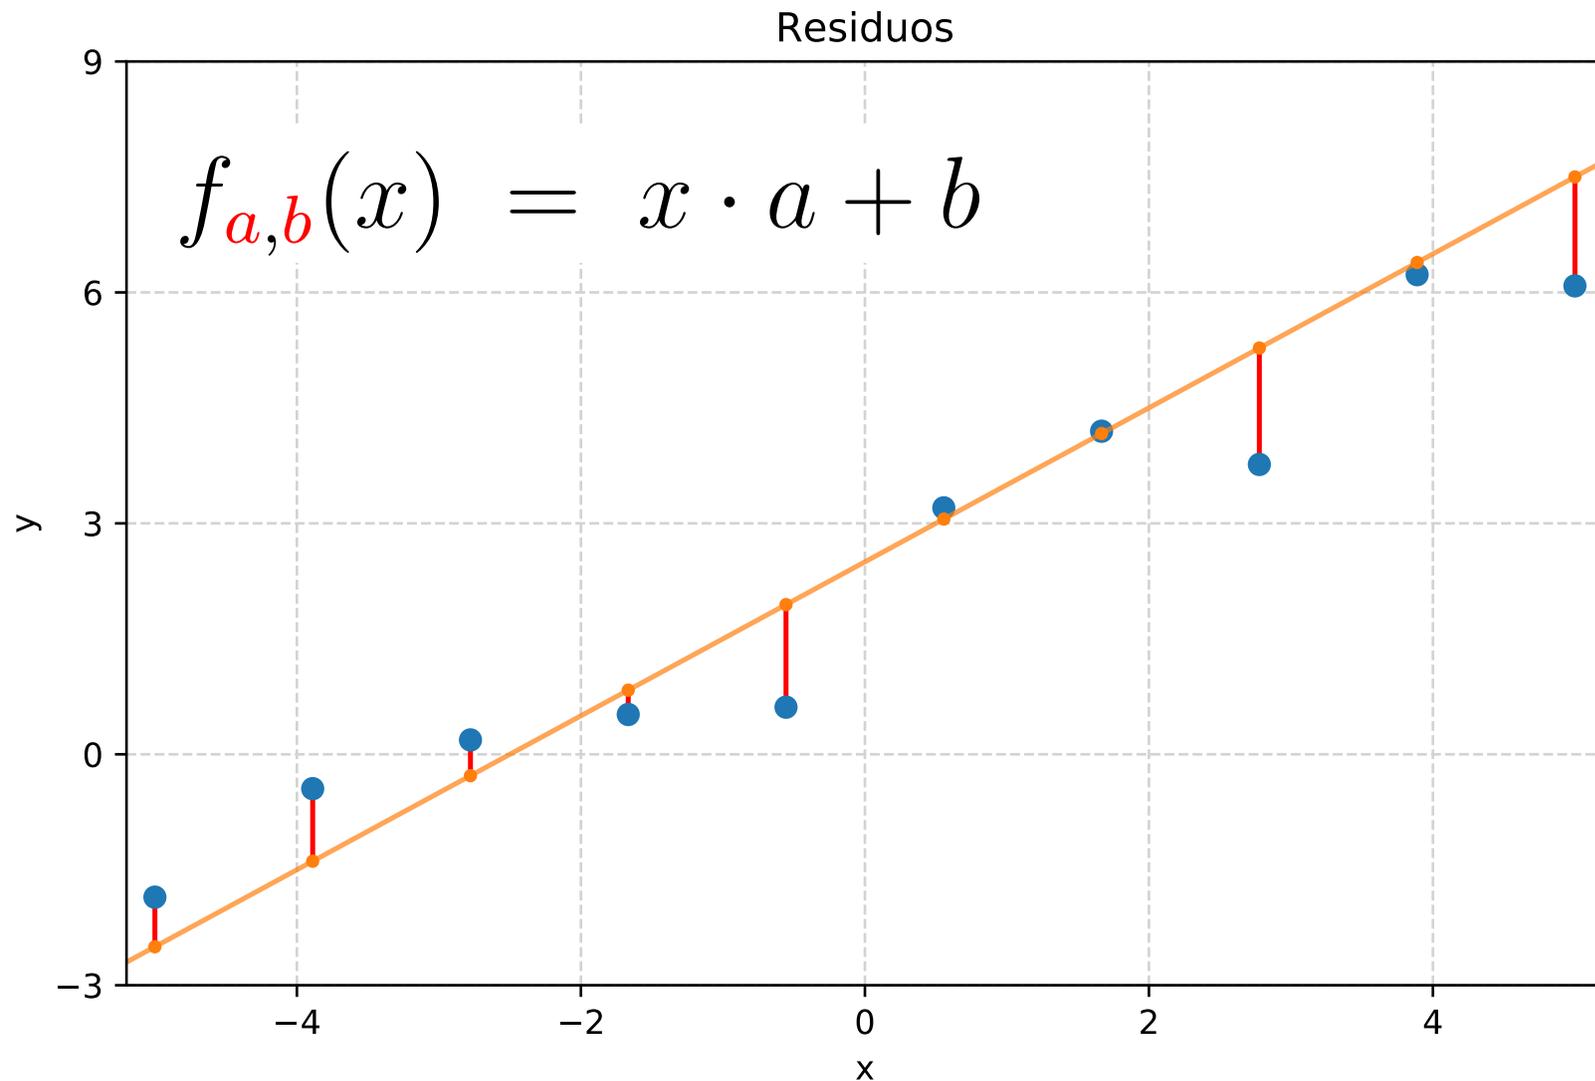
Fabricar una
"medida de
distancia"
entre las
predicciones
del modelo y
los datos
medidos



Cuadrados mínimos

$$S^2(a, b) = \sum_{i=1}^N [y_i - f_{a,b}(x_i)]^2 = \sum_{i=1}^N [y_i - x_i \cdot a - b]^2$$

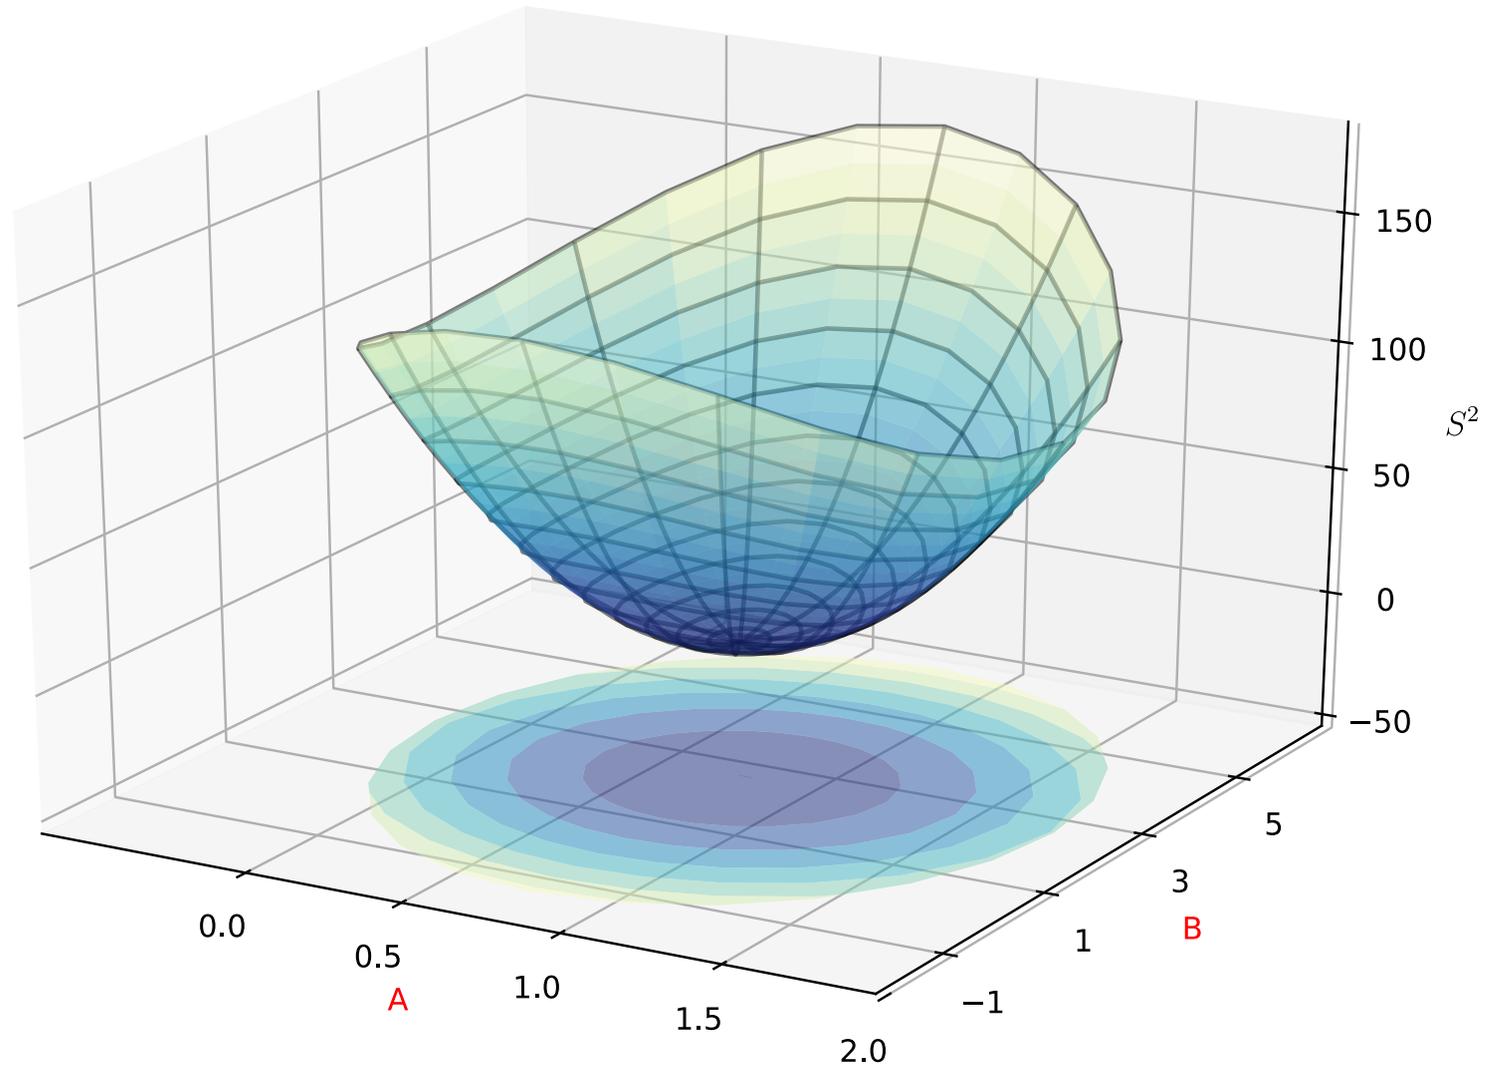
(x_i, y_i)



Cuadrados mínimos

$$S^2(a, b) = \sum_{i=1}^N [y_i - f_{a,b}(x_i)]^2 = \sum_{i=1}^N [y_i - x_i \cdot a - b]^2$$

Superficie que
representa a S^2

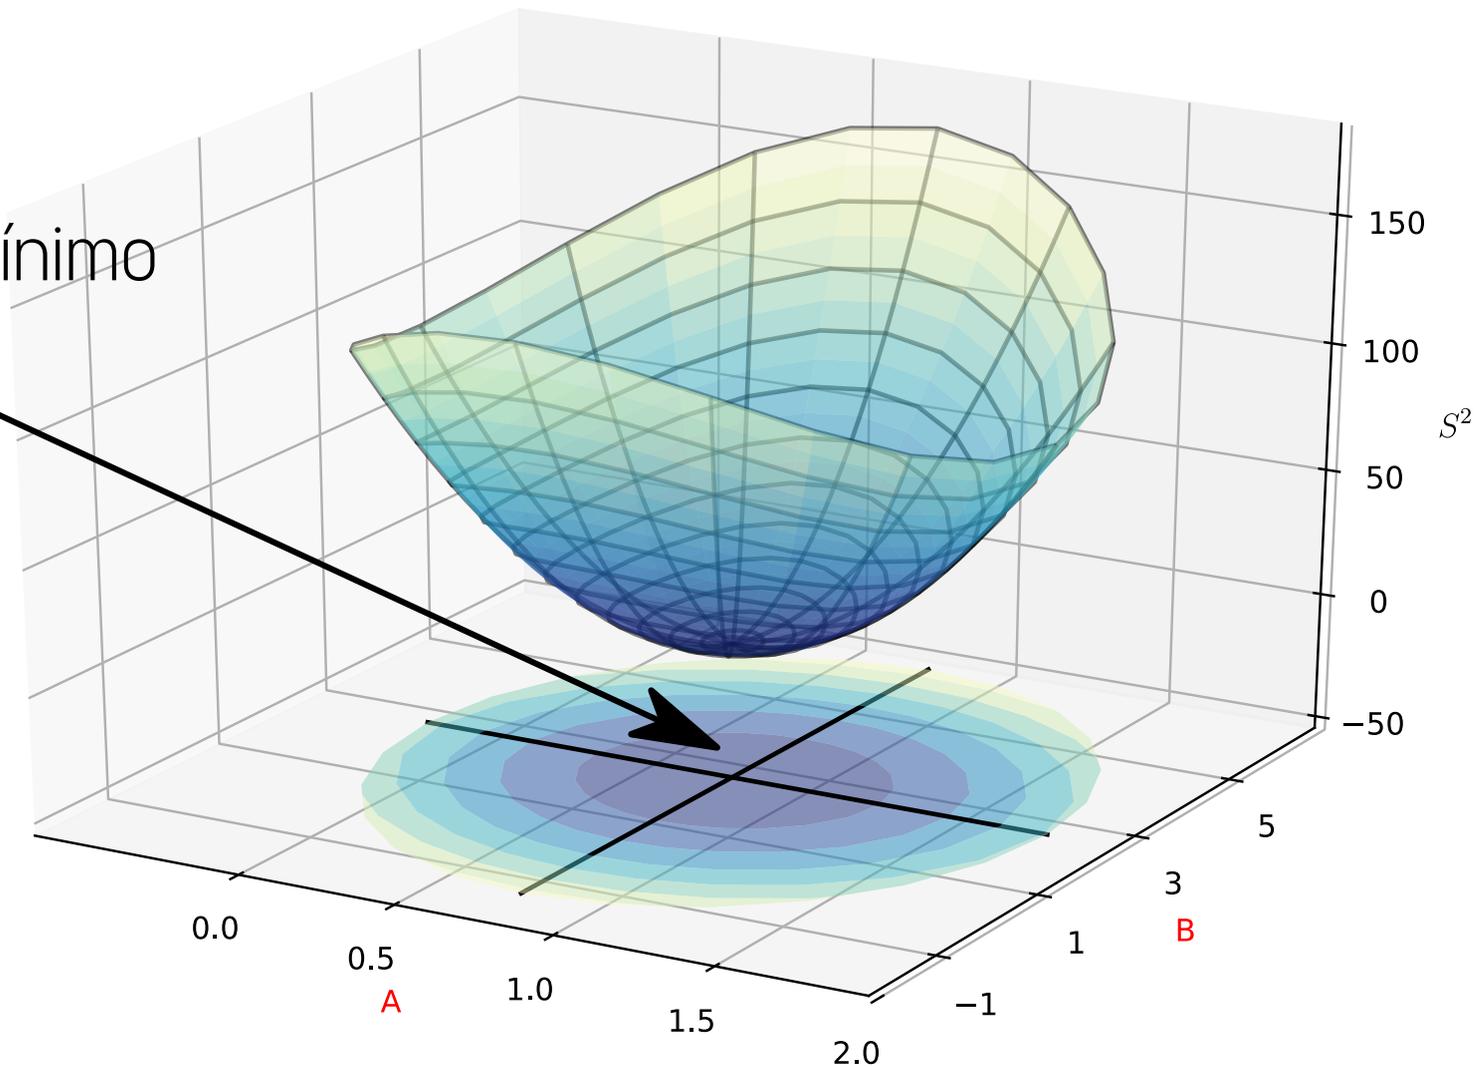


Cuadrados mínimos

$$S^2(a, b) = \sum_{i=1}^N [y_i - f_{a,b}(x_i)]^2 = \sum_{i=1}^N [y_i - x_i \cdot a - b]^2$$

Búsqueda del mínimo

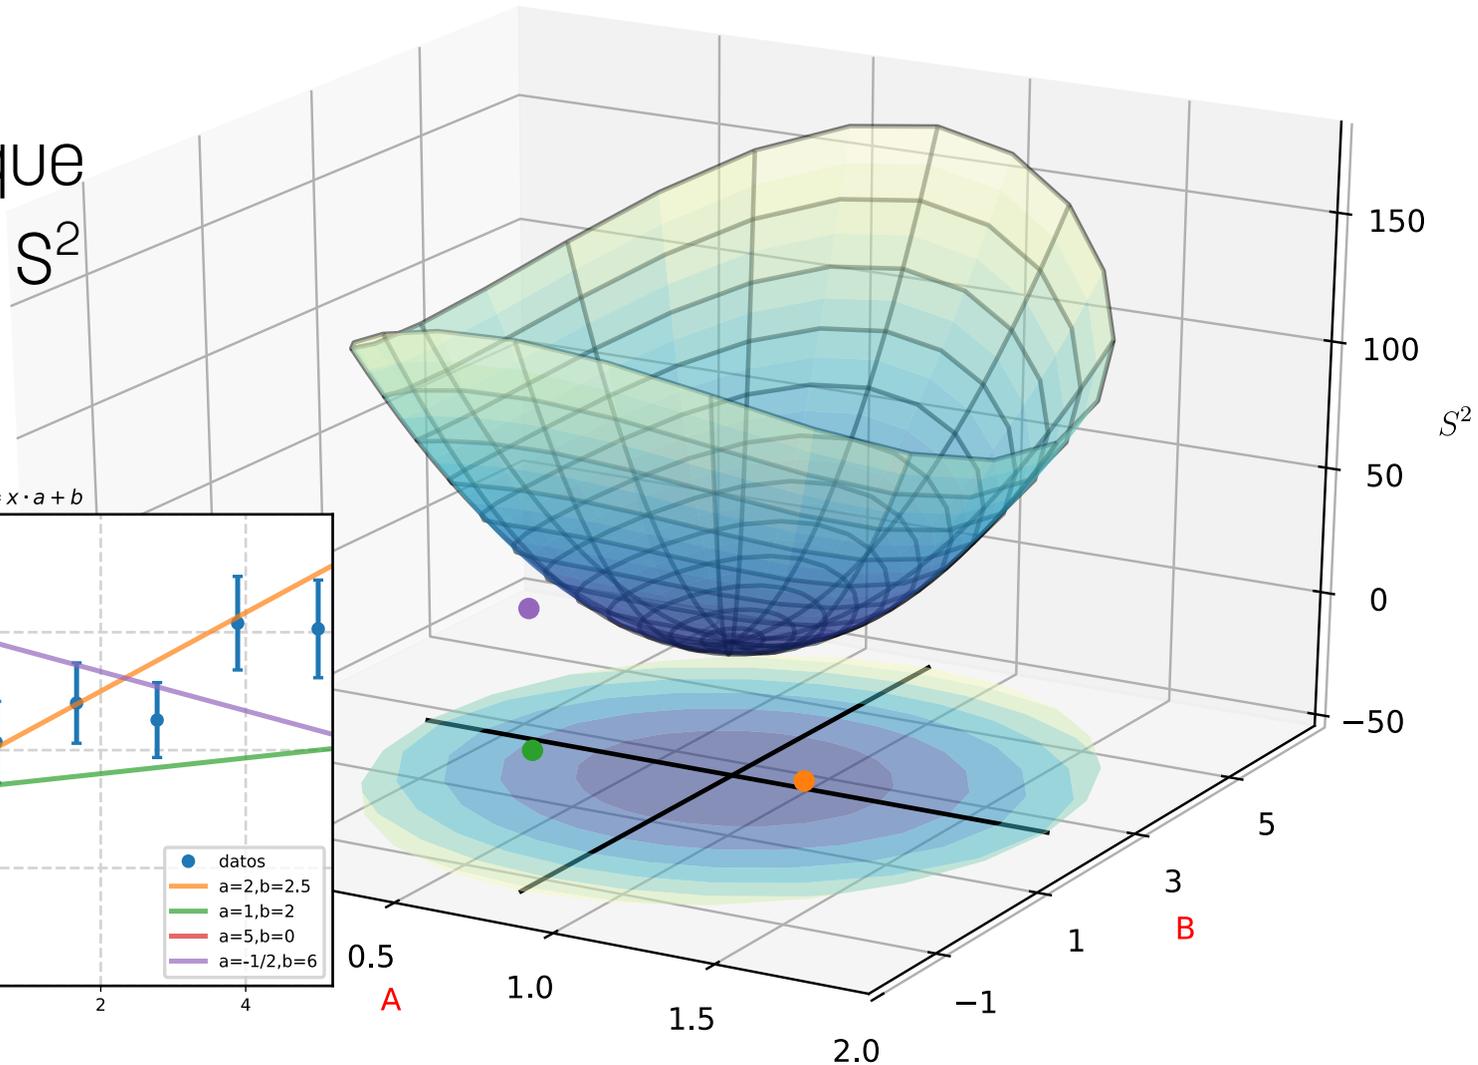
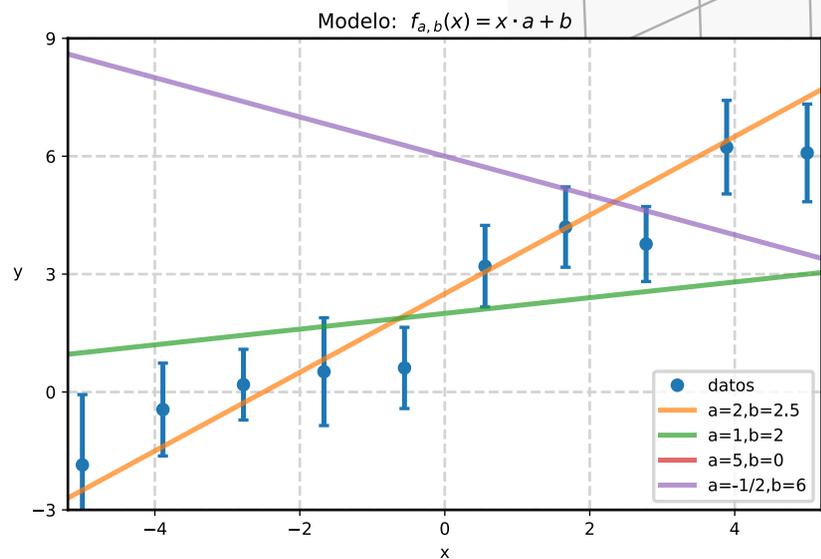
Algoritmo



Cuadrados mínimos

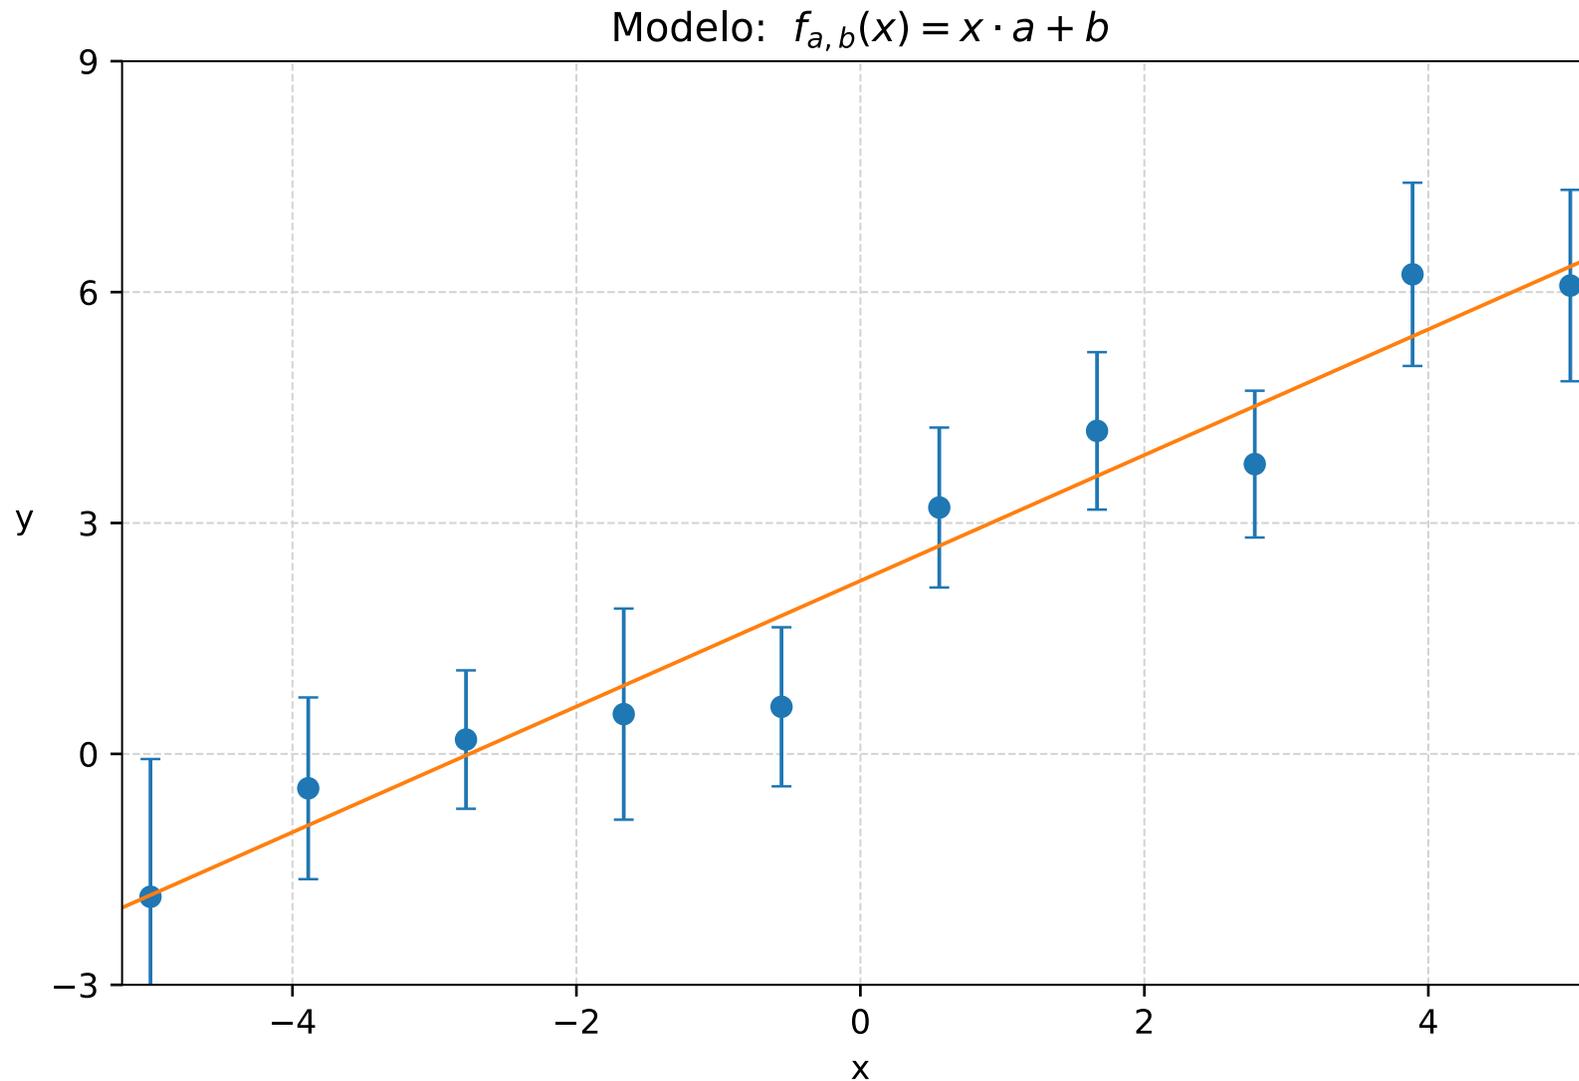
$$S^2(a, b) = \sum_{i=1}^N [y_i - f_{a,b}(x_i)]^2 = \sum_{i=1}^N [y_i - x_i \cdot a - b]^2$$

Ejemplos de
parámetros que
no minimizan S^2



Cuadrados mínimos

Con los parámetros que minimizan S^2
obtenemos el modelo ajustado



Cuadrados mínimos

Algoritmo para modelo lineal (sin incertezas en y)

$$S^2(a, b) = \sum_{i=1}^N [y_i - x_i \cdot a - b]^2$$

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

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

Cuadrados mínimos

Algoritmo para modelo lineal (con incertezas en y)

$$S_w^2(a, b) = \sum_{i=1}^N \left[\frac{y_i - f_{a,b}(x_i)}{\sigma_{y_i}} \right]^2 = \frac{[y_i - f_{a,b}(x_i)]^2}{\sigma_{y_i}^2}$$

$$a = \frac{1}{\Delta} \left[\sum \frac{1}{\sigma_{y_i}^2} \sum \frac{x_i y_i}{\sigma_{y_i}^2} - \sum \frac{x_i}{\sigma_{y_i}^2} \cdot \sum \frac{y_i}{\sigma_{y_i}^2} \right]$$

$$b = \frac{1}{\Delta} \left[\sum \frac{x_i^2}{\sigma_{y_i}^2} \sum \frac{y_i}{\sigma_{y_i}^2} - \sum \frac{x_i}{\sigma_{y_i}^2} \sum \frac{x_i y_i}{\sigma_{y_i}^2} \right]$$

$$\Delta = \sum \frac{1}{\sigma_{y_i}^2} \sum \frac{x_i^2}{\sigma_{y_i}^2} - \left(\sum \frac{x_i}{\sigma_{y_i}^2} \right)^2$$

Estimadores de bondad de ajuste

→ **Coefficiente de determinación, R^2 , r-squared**

→ Porcentaje de la varianza que puede explicar el modelo

→ $0 < R^2 < 1$

→ Ej: si $R^2=0.85$, puedo decir que el modelo explica el 85% de la varianza de mis datos

→ Mientras más cercano a 1, mejor es el ajuste

$$R^2 = 1 - \frac{\text{RSS}}{\text{SST}}$$

$$\text{RSS} \equiv S^2 = \sum_i \text{res}_i^2$$

$$\text{SST} \equiv \sum_i (y_i - \langle y \rangle)^2$$

$$R_{adj}^2 = 1 - \frac{\text{RSS}}{\text{SST}} \cdot \frac{N - 1}{N - P - 1}$$

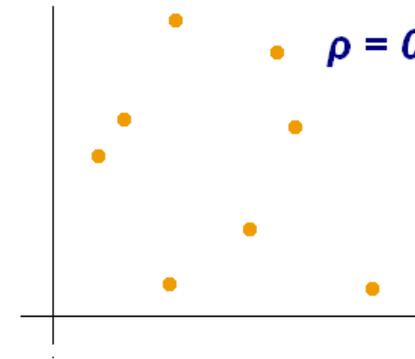
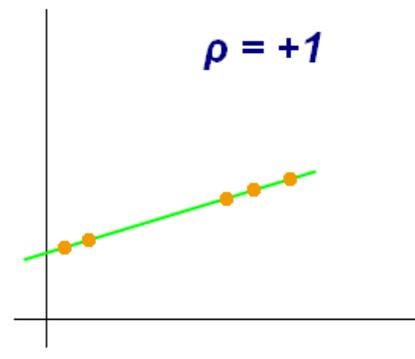
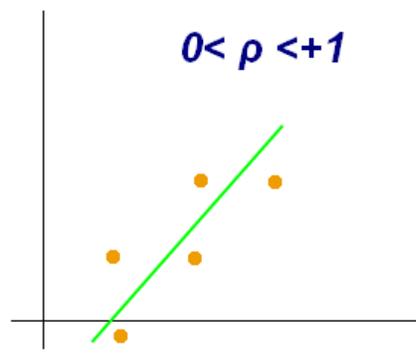
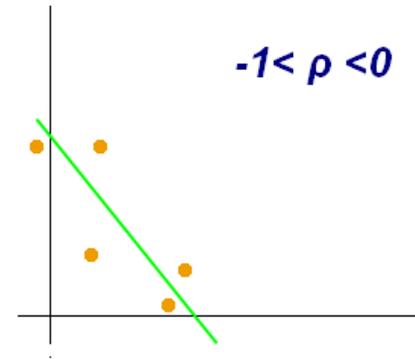
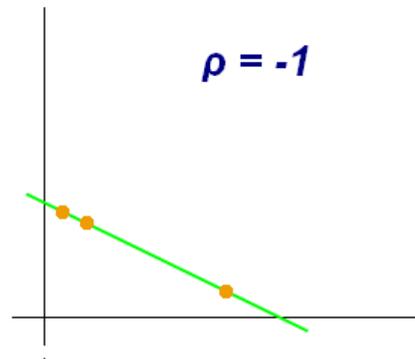
Estimadores de bondad de ajuste

→ **Coefficiente de Correlación de Pearson, r , r -pear, ρ**

→ "Cuando una variable sube la otra también" o al revez

→ $-1 < \rho < 1$

→ $|\rho| = 1$ significa que los datos están perfectamente alineados



Cuarteto de Anscombe

$$\bar{x} = 9$$

$$\text{std}(x)^2 = 11$$

$$\bar{y} = 7.50$$

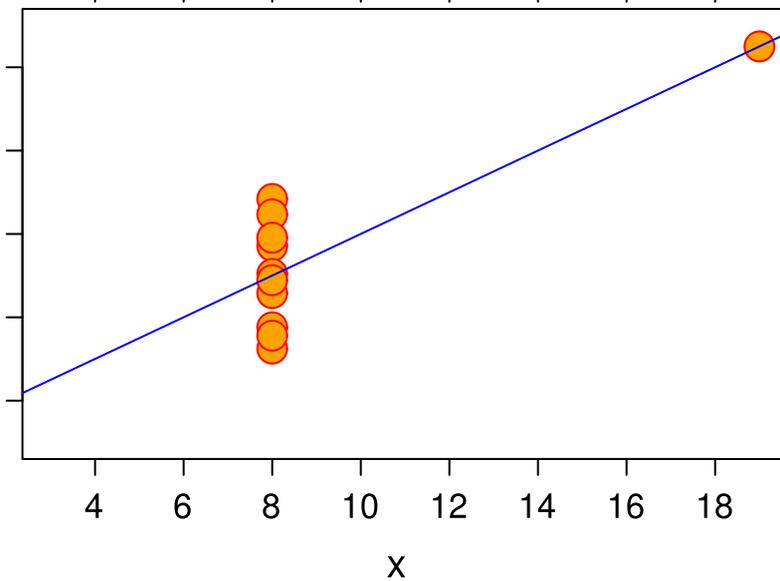
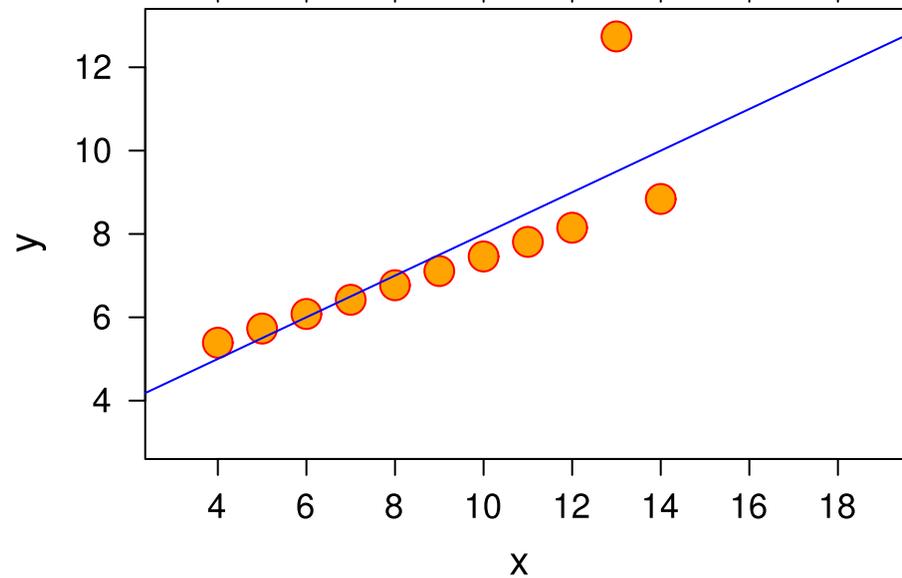
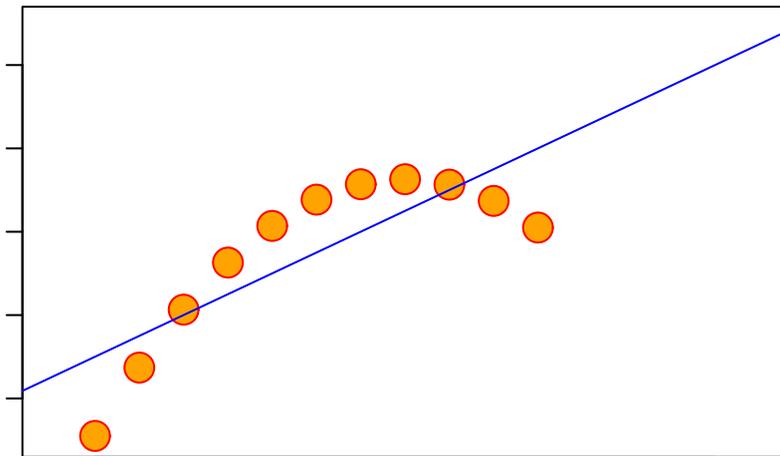
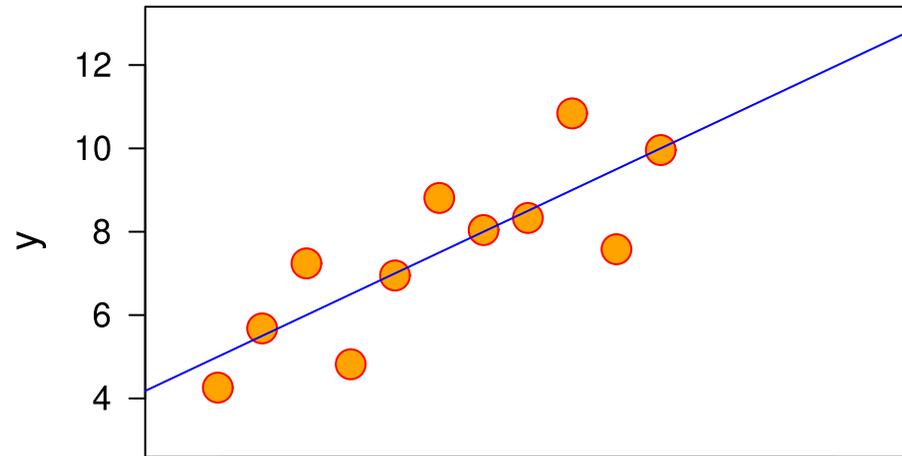
$$\text{std}(y)^2 = 4.125$$

$$\text{cor}(x, y) = 0.816$$

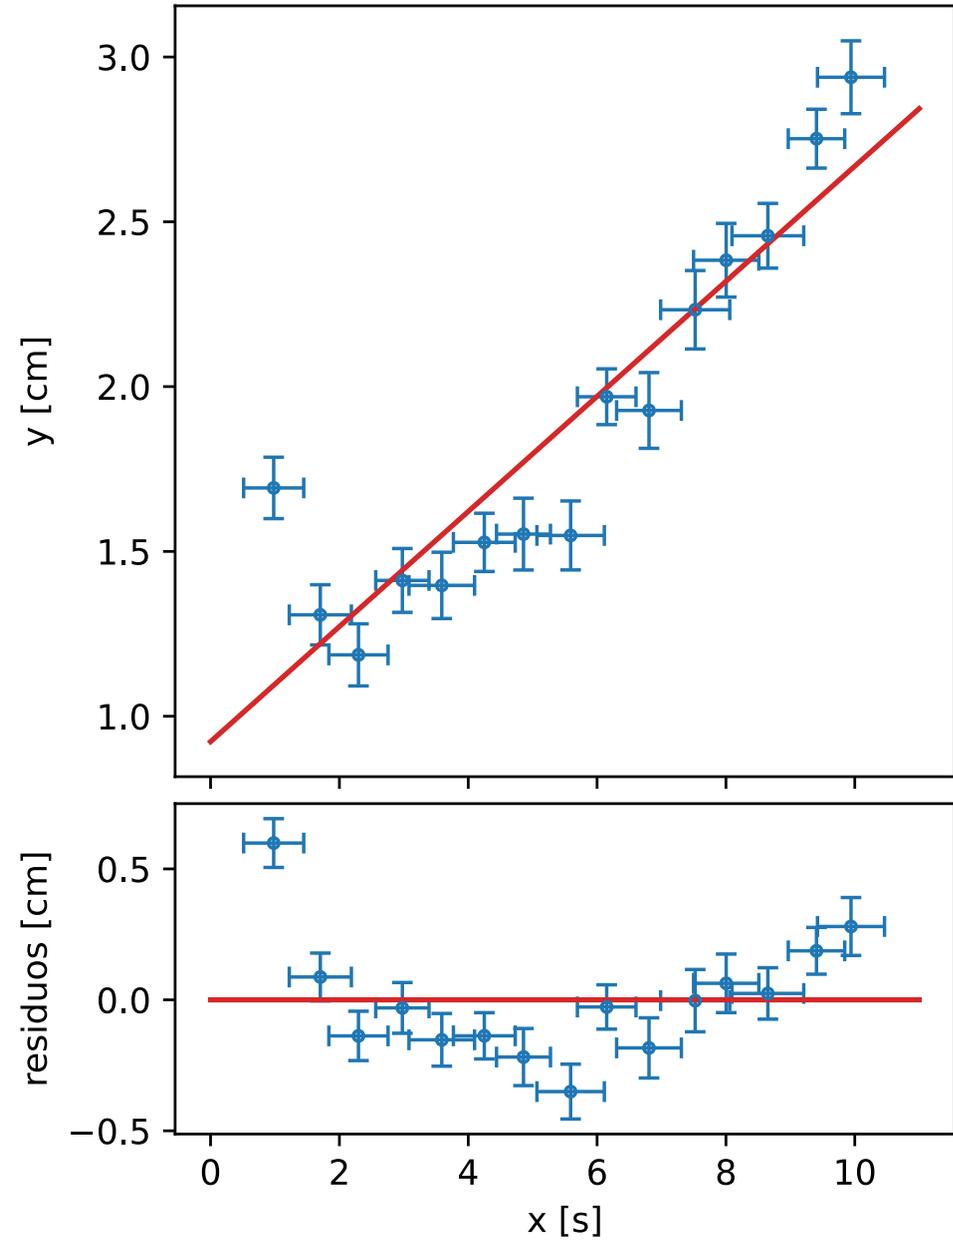
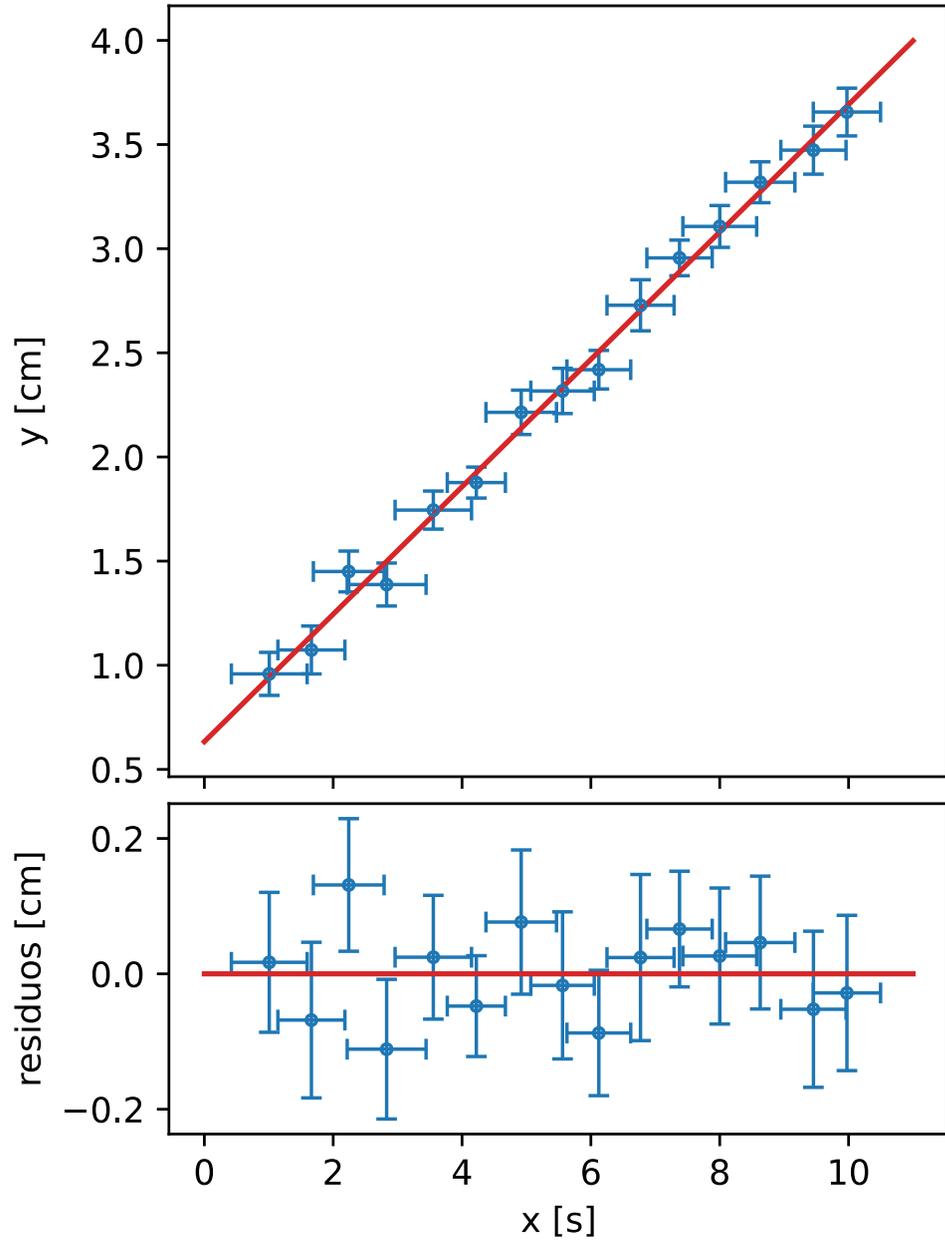
$$R^2 = 0.67$$

linear fit

$$y = 3.00 + 5.000 \cdot x$$



Residuos



¿...y si el modelo no es lineal?

→ **Usar cantidades que sí tengan relación lineal**

Ej: Caída libre por aceleración de la gravedad

$$y(t) = y_0 + t \cdot v_i + t^2 \cdot \frac{1}{2}g$$

$$y(t) = t^2 \cdot \left(\frac{1}{2}g\right)$$

$Y = X \cdot a$

$a \equiv \frac{1}{2}g$

$X \equiv t^2$

¿...y si el modelo no es lineal?

→ Usar cantidades transformadas (ej: aplicar logaritmo)

$$y(t) = t^2 \cdot \left(\frac{1}{2}g\right)$$

$$\log(y) = \log\left(t^2 \cdot \frac{1}{2}g\right)$$

$$\log(y) = 2 \cdot \log(t) + \log\left(\frac{1}{2}g\right)$$

$$Y = a \cdot X + b$$

$$\begin{aligned} a &\equiv 2 \\ b &\equiv \log\left(\frac{1}{2}g\right) \\ X &\equiv \log(t) \\ Y &\equiv \log(y) \end{aligned}$$

¿...y si el modelo no es lineal?

→ Usar cantidades transformadas (ej: aplicar logaritmo)

$$y(t) = t^2 \cdot \left(\frac{1}{2}g\right)$$

$$\log(y) = \log\left(t^2 \cdot \frac{1}{2}g\right)$$

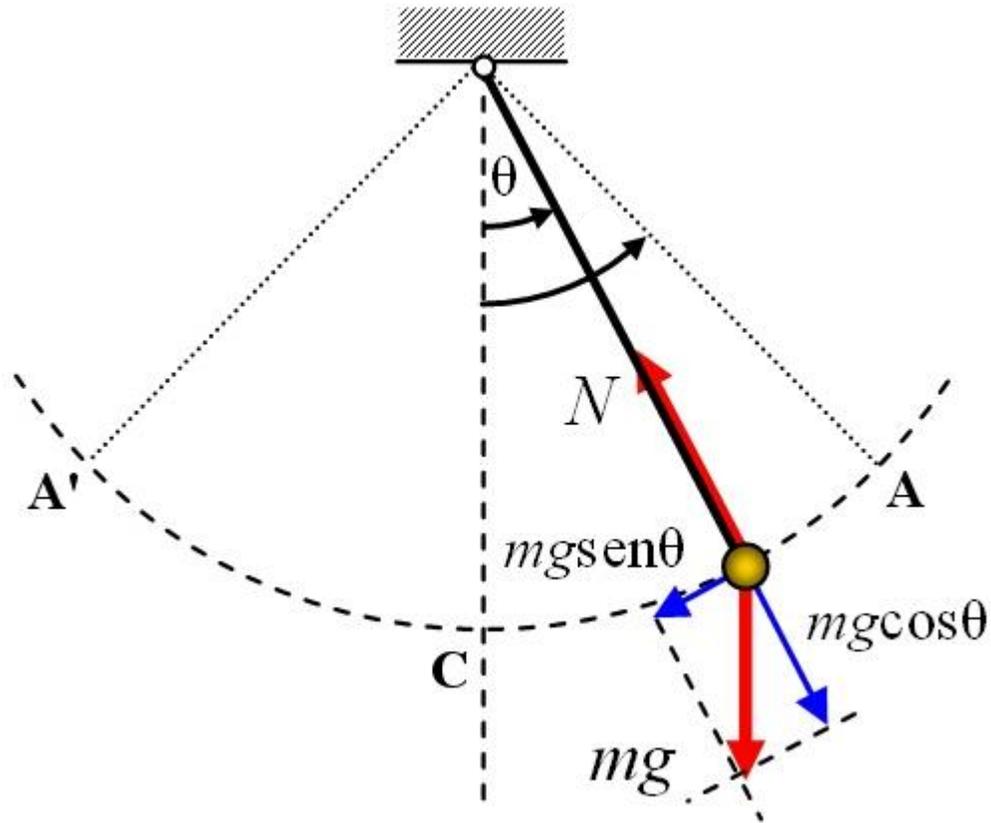
$$\log(y) = 2 \cdot \log(t) + \log\left(\frac{1}{2}g\right)$$

$$Y = a \cdot X + b$$

$$\begin{aligned} a &\equiv 2 \\ b &\equiv \log\left(\frac{1}{2}g\right) \\ X &\equiv \log(t) \\ Y &\equiv \log(y) \end{aligned}$$

Actividad: validar modelo péndulo

Dinámica de un péndulo



Dinámica:

$$F_t = -m \cdot g \cdot \sin(\theta) = m \cdot L \cdot \ddot{\theta}$$

Ecuación diferencial:

$$L \cdot \ddot{\theta} + g \cdot \sin(\theta) = 0$$

Aproximación: $\sin(\theta) \sim \theta$ $\theta \ll 1$

$$L \cdot \ddot{\theta} + g \cdot \theta = 0$$

Solución:

$$\theta(t) = A \cdot \sin(\omega t + \phi)$$

$$\omega = \frac{2\pi}{T} = \sqrt{\frac{g}{L}}$$

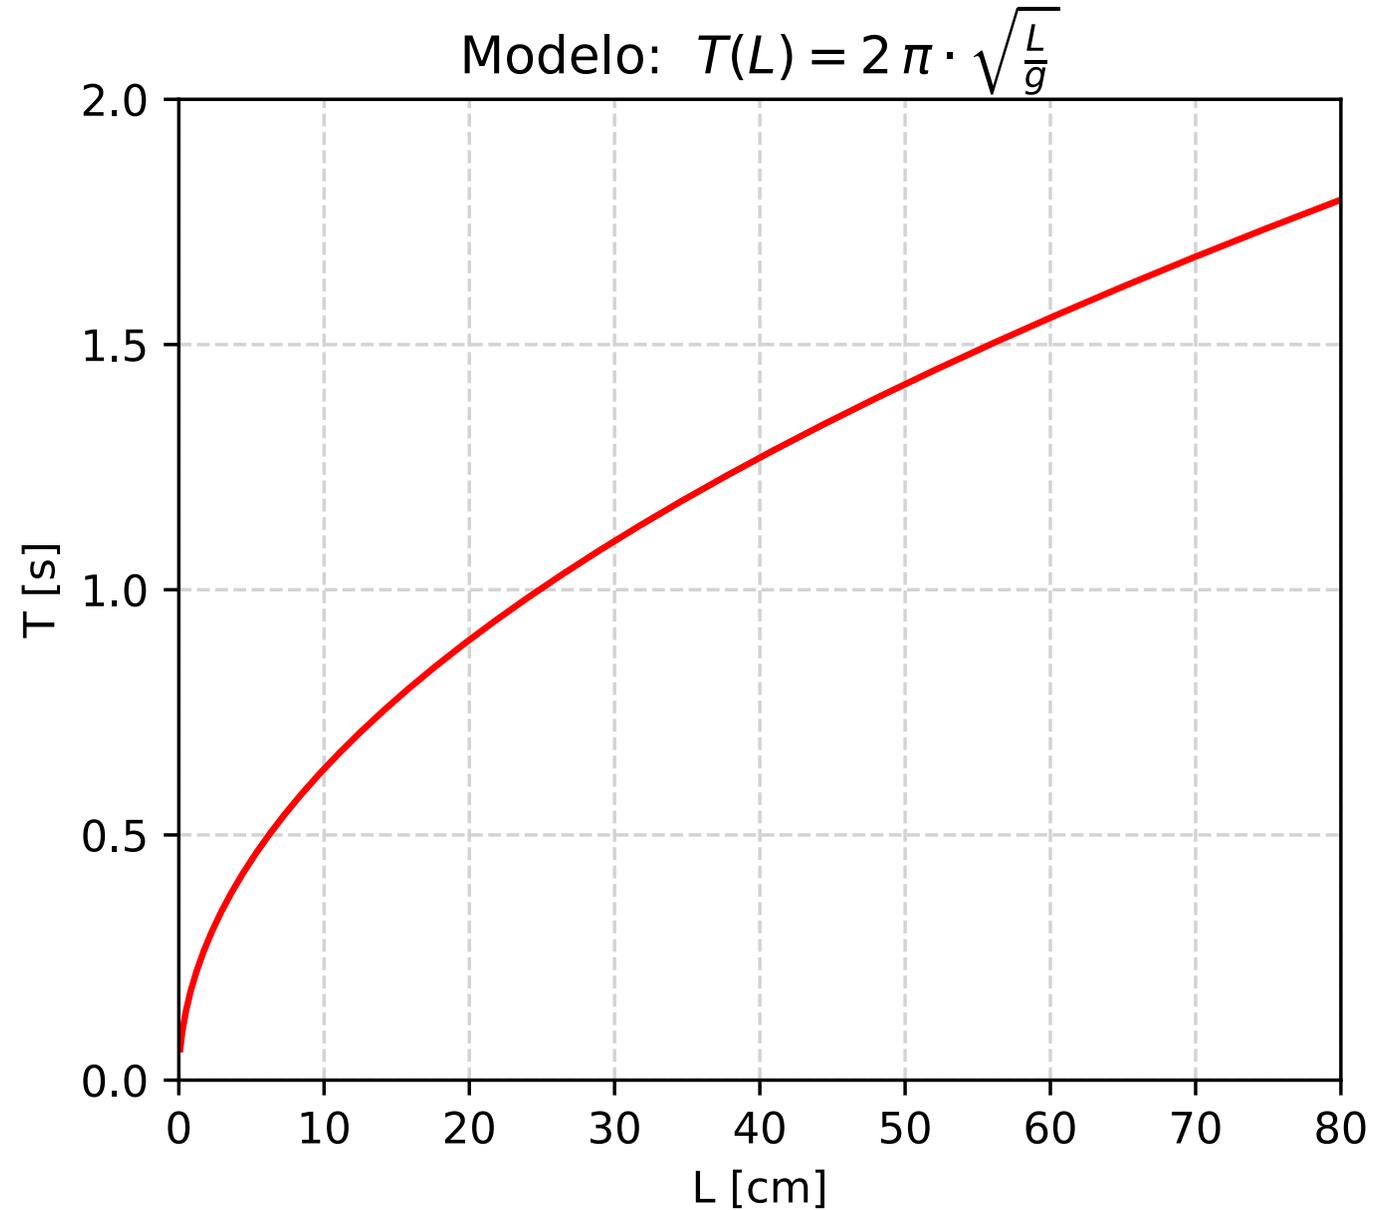
Modelo a validar:

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

Actividad: validar modelo péndulo

Modelo de péndulo

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



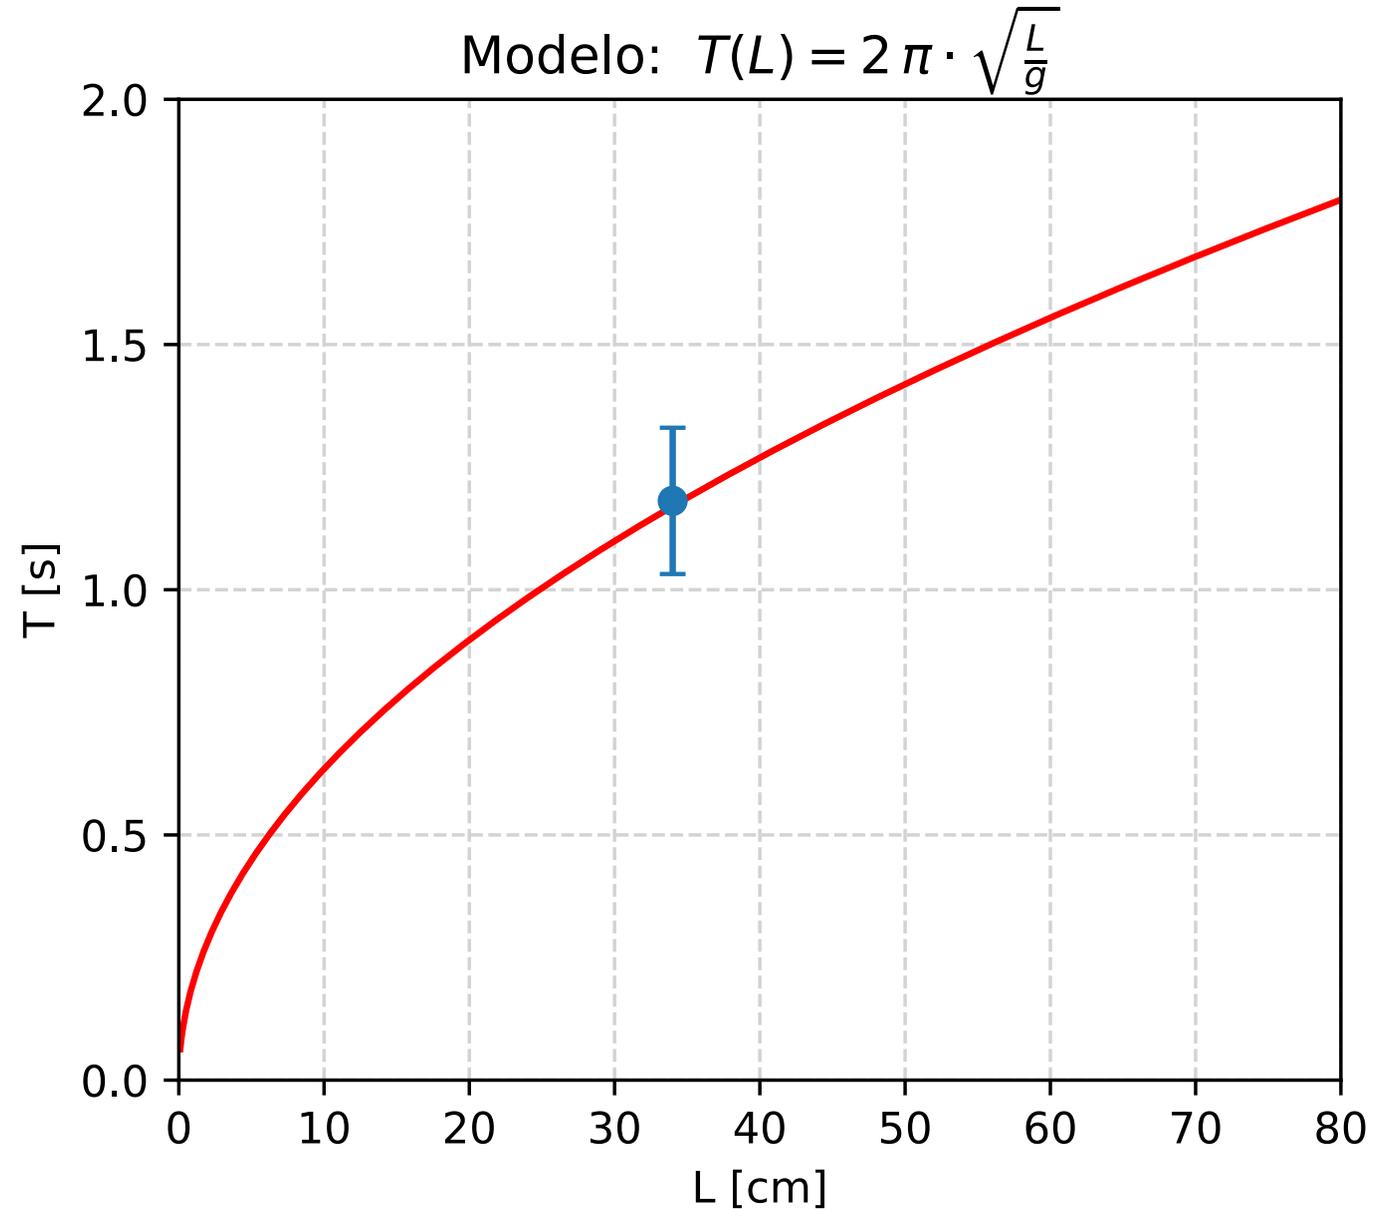
Actividad: validar modelo péndulo

Modelo de péndulo

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

La vez
pasada
tomamos
un dato

(T, L)



Actividad: validar modelo péndulo

Modelo de péndulo

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

Necesitamos
más pares
ordenados

$$(T_i, L_i)$$

