

Cuadrados mínimos

Cuadrados mínimos

¿Qué vamos a ver?

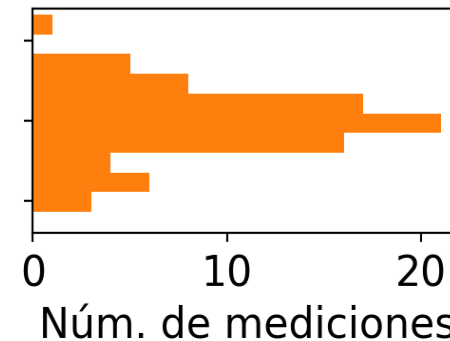

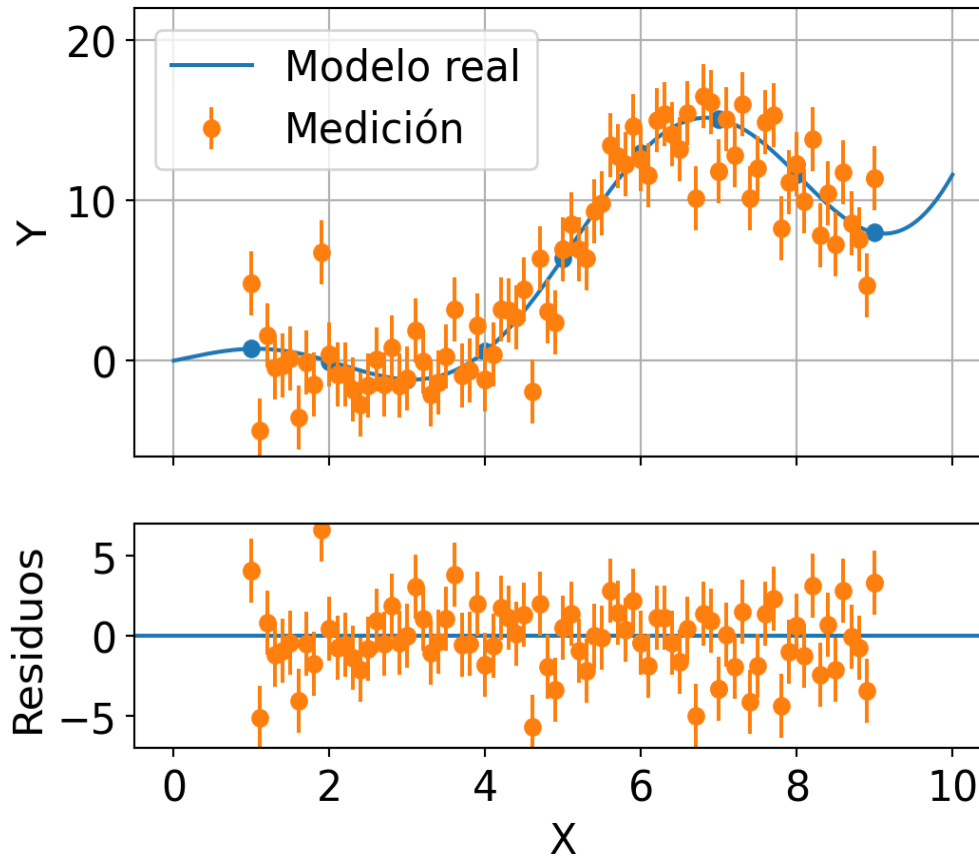
- Evaluación de modelos
 - Residuos, χ^2 , y R^2
 - Ejemplos
- Minimización de χ^2
 - Lineal vs no lineal
 - Caso función constante
- ¿Por qué usamos cuadrados mínimos?
 - Extensión del promedio
 - Descubrir y eliminar errores sistemáticos
- Ejemplos

Evaluando un modelo (con datos)

Vimos dos medidas:

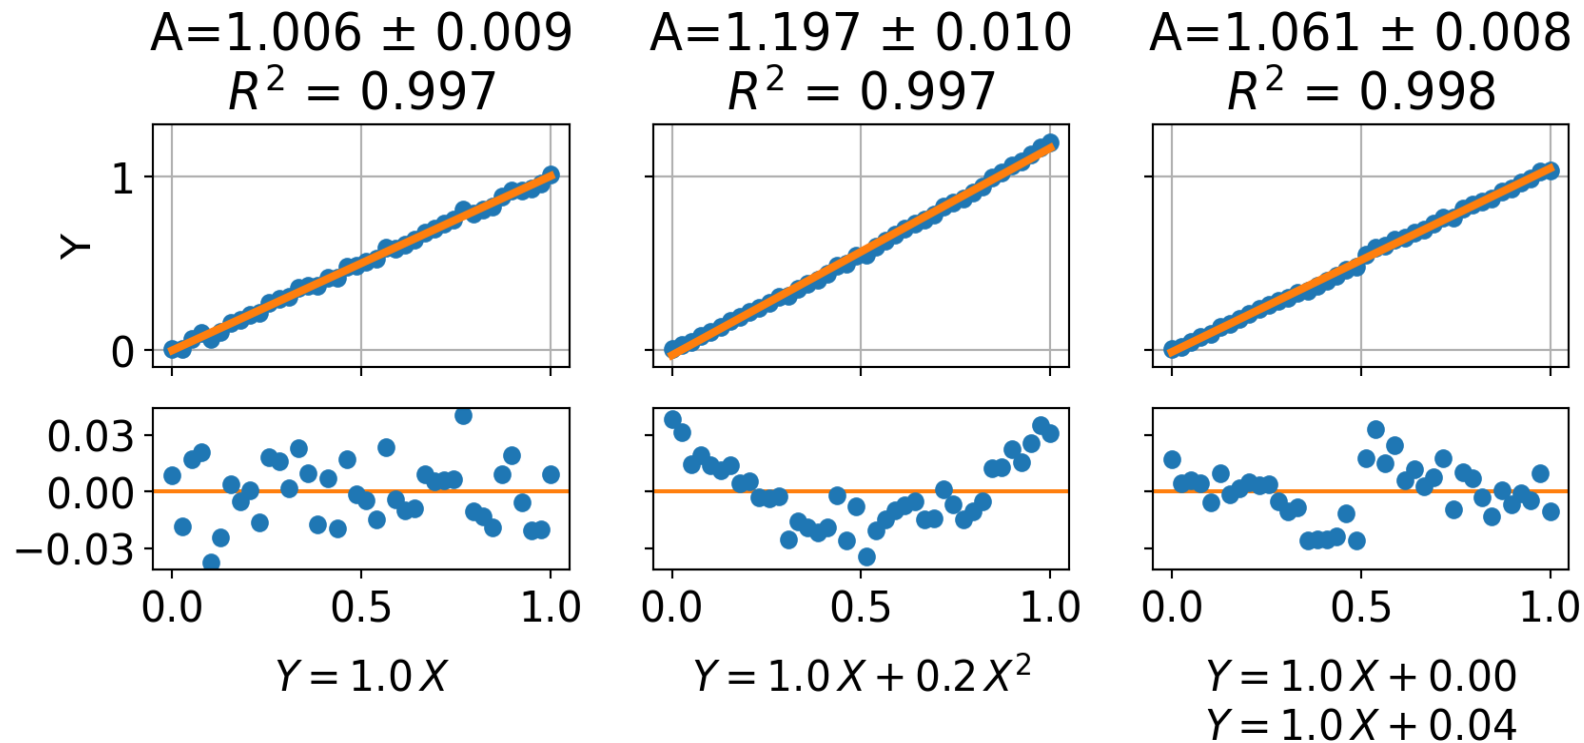
$$R^2 = 1 - \frac{\sigma_r^2}{\sigma_y^2}$$

$$\chi^2 = \sum \left[\frac{y_i - f(x_i)}{\sigma_{y_i}} \right]^2$$



Ejemplo: usando R^2

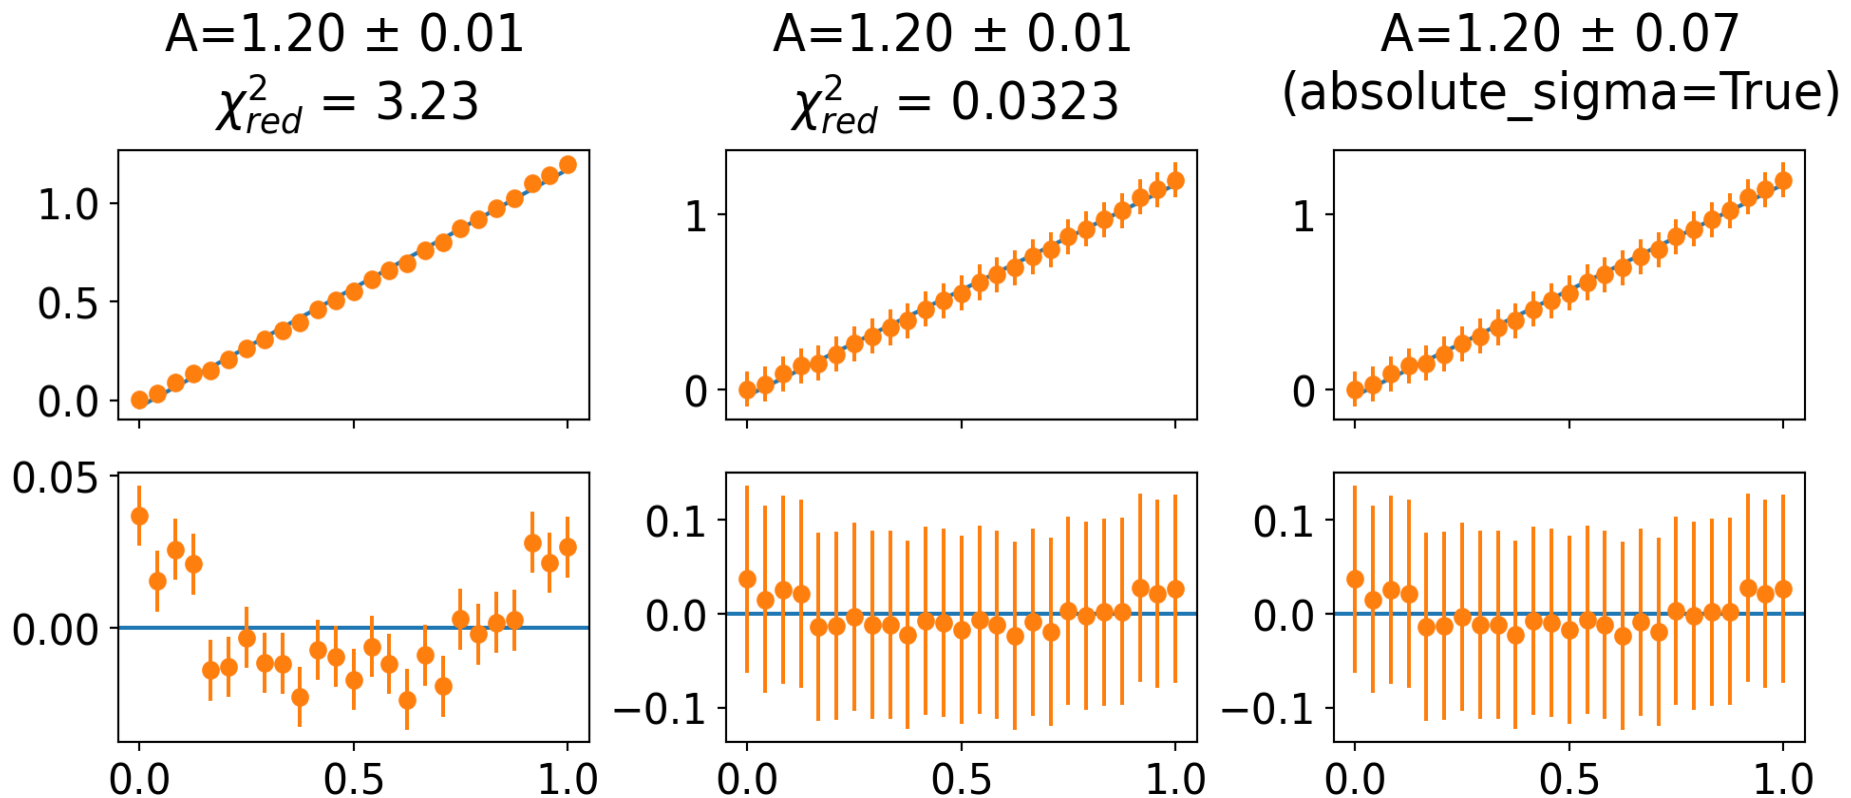
Tengo 3 conjuntos de mediciones y ajusto por $y = Ax + B$



- R^2 no dice si ajustó bien.
- Residuos mal \rightarrow parámetro mal.

Ejemplo: χ^2

Tengo un conjunto de datos $y = 1.0 x + 0.2 x^2$ y le ajusto $y = Ax + B$



χ^2 falla si tenemos mal los errores

En resumen

Para evaluar un ajuste, mirar **los residuos**:

- la **aleatoriedad** es lo más seguro.
- la **distancia** (χ^2) también sirve, pero puede fallar.

Cuadrados mínimos

¿Cómo y por qué lo usamos?

Minimización de χ^2

Dada una función $f(x, p_0, \dots, p_k)$, buscamos los parámetros p que minimicen:

$$\chi^2 = \sum_i \left[\frac{y_i - f(x_i, p_0, \dots, p_k)}{\sigma_i} \right]^2 = \sum_i \left[\frac{r_i}{\sigma_i} \right]^2$$

Para ello, derivamos e igualamos a 0:

$$0 = \frac{\partial \chi^2}{\partial p_0} = \dots = \frac{\partial \chi^2}{\partial p_k}$$

Hay dos casos, según si f es **lineal en los parámetros**.

En el caso no lineal, tenemos que ayudar al algoritmo con **parámetros iniciales**.

No lineal:

$$f(x, A, \varphi) = A \cos(x + \varphi)$$

Lineal:

$$f(x, A, B) = A \cos(x) + B \sin(x)$$

Función constante

Supongamos que tenemos:

- modelo constante $f(x) = A$, que no depende de x ,
- errores iguales $\sigma_i = \sigma$ para todo i

$$\chi^2 = \sum_i \left[\frac{y_i - f(x_i, p_0, \dots, p_k)}{\sigma_i} \right]^2 = \frac{1}{\sigma^2} \sum_i [y_i - A]^2$$

Si minimizamos

$$\frac{\partial \chi^2}{\partial A} = 0$$

obtenemos

$$A = \frac{1}{N} \sum_{i=1}^N y_i = \bar{y}$$

¡El promedio!

Si los σ_i son distintos,
obtenemos el promedio pesado.

Extensión del promedio

Supongamos que el modelo es $f(x) = Ax$.

x	y	Δy	¿Cómo calculamos A?	$A = y/x$	ΔA	¿Cómo juntamos esos valores de A?
1	2	1	Opción: despejando.	2	1	
2	4	1		2	1/2	
3	6	1		2	1/3	
...	
N	2N	1		2	1/N	

Opción 1:

Promedio

$$\frac{A_1 + A_2 + \dots}{N}$$

Opción 2:

Promedio pesado

$$\frac{w_1 A_1 + w_2 A_2 + \dots}{N}$$

Opción 3:

cuadrados mínimos

$$\chi^2 = \dots$$


Cuadrados mínimos va hacer “un promedio ponderado”.

Errores sistemáticos

Supongamos que el modelo es $f(x) = Ax$.

Pero, cuando medimos:

x	y	A = y/x
1	2	2.00
2	3	1.50
3	4	1.33
4	5	1.25
5	6	1.20
...
9	10	1.11



Podemos descubrir y corregir errores sistemáticos.

Complejizando el modelo

Entonces, si la teoría era $y = Ax$, ¿ajustamos $y = Ax + B$ por las dudas?

- **Opción 1:** Agregó B siempre, y veo si $B = 0$ (con su error ΔB).
- **Opción 2:** Agregó B solo si da mal el ajuste (residuos).

¿Por qué la opción 2 es mejor?


Agregar más parámetros, aumenta el error de los parámetros.

Si preferimos la opción 1, ¿por qué no agregar un término cuadrático?

$$y = Ax + B + Cx^2$$

Empezar por lo más simple → complejizar cuando haga falta.

Ejemplo: aceleración del carrito



¿Necesitamos conocer t_0 e y_0 ?

Podemos ajustar el modelo completo:

$$y = A(t - t_0)^2 + y_0$$

y que lo estime a partir de los datos.

Si expandimos el cuadrado:

$$y = A t^2 + (-2At_0) t + (At_0^2 + y_0)$$

podemos ajustar:

$$y = A t^2 + B t + C$$

Ejemplo: péndulo

$$T^2 = \frac{(2\pi)^2}{g}L = AL$$

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

Si tenemos un error sistemático L_0 constante en L

$$T^2 = \frac{(2\pi)^2}{g}(L - L_0)$$

$$T = \frac{2\pi}{\sqrt{g}}\sqrt{L - L_0}$$

Es equivalente a:

$$T^2 = AL + B$$

NO es equivalente a:

$$T = A\sqrt{L} + B$$

¡Hay que modelar el experimento!

Resumen

- Cuadrados mínimos: “extensión del promedio”
- Modelo a ajustar:
 - Lineal (en los parámetros) → solución única
 - No lineal → parámetros iniciales
- Elección del modelo:
 - Simple → complejo
 - Hay que pensar en el experimento
- Evaluación del ajuste:
 - Aleatoriedad de residuos
 - Distancia de residuos (χ^2)

Si el modelo ajusta mal, los parámetros están mal.

Ejemplo: aceleración del carrito

¿Podemos estimar t_0 directamente como una de las mediciones?

