

# Laboratorio 1C

Clase 4

Regresiones – Cuadrados mínimos

30/04/22

- Supongamos que queremos medir la velocidad de un cuerpo en MRU.
- En forma **directa**, por ejemplo usando una pistola de velocidad, se obtiene:

$$v = v_0 + \Delta v$$



- En forma **indirecta**, midiendo la posición a dos tiempos distintos, y luego haciendo el cociente entre la distancia recorrida y el tiempo.

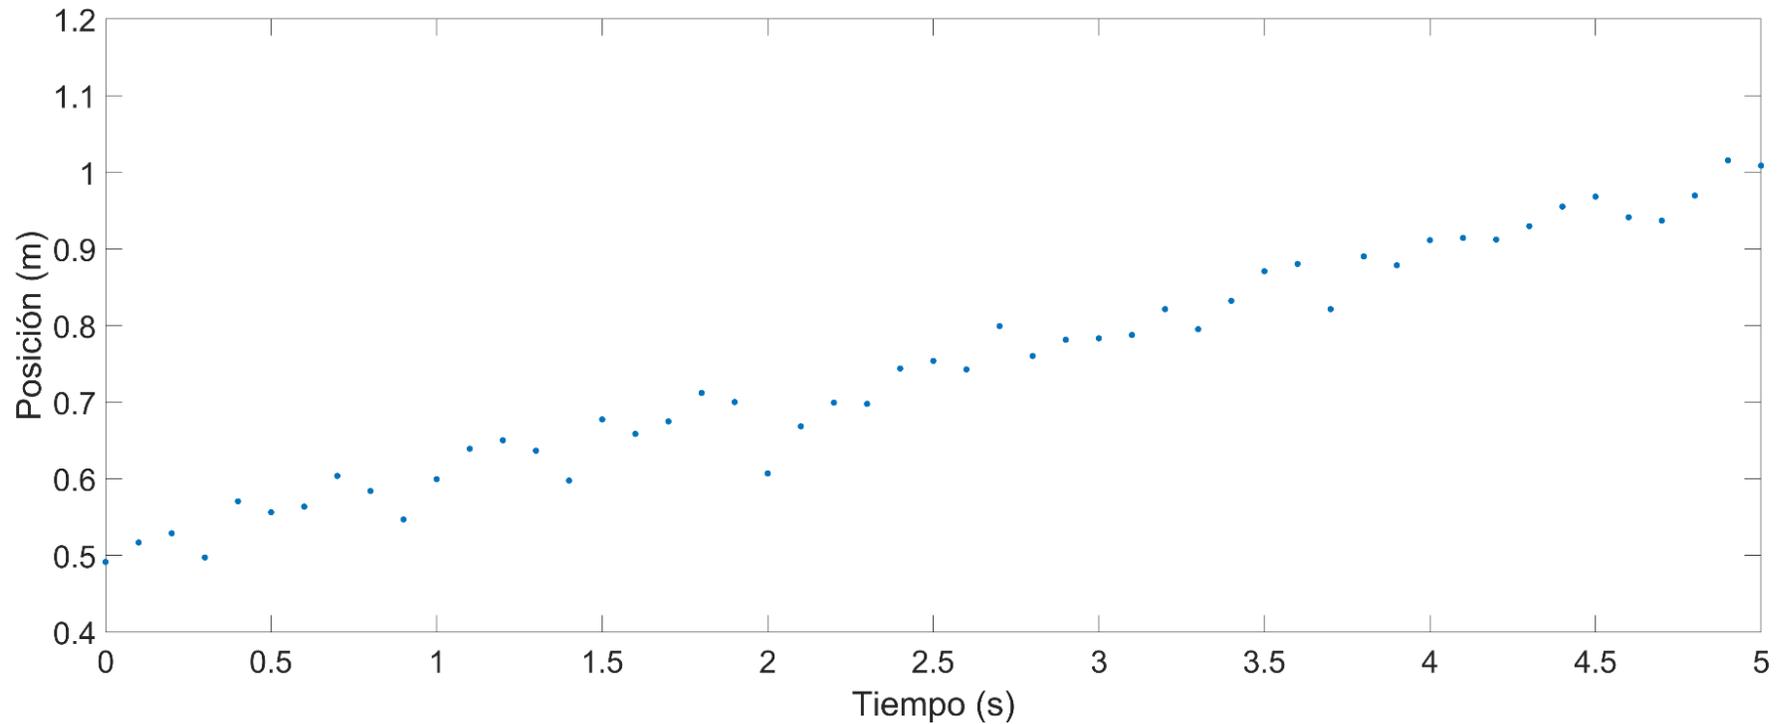
$$v = \frac{x_2 - x_1}{t_2 - t_1}$$

$$\Delta v = \sqrt{\sum_i \left( \frac{\partial v}{\partial q_i} \right)^2 (\Delta q_i)^2}$$

En ambos casos, podríamos medir  $N$  veces, y reportar la media de todas las velocidades obtenidas. El error sería entonces:

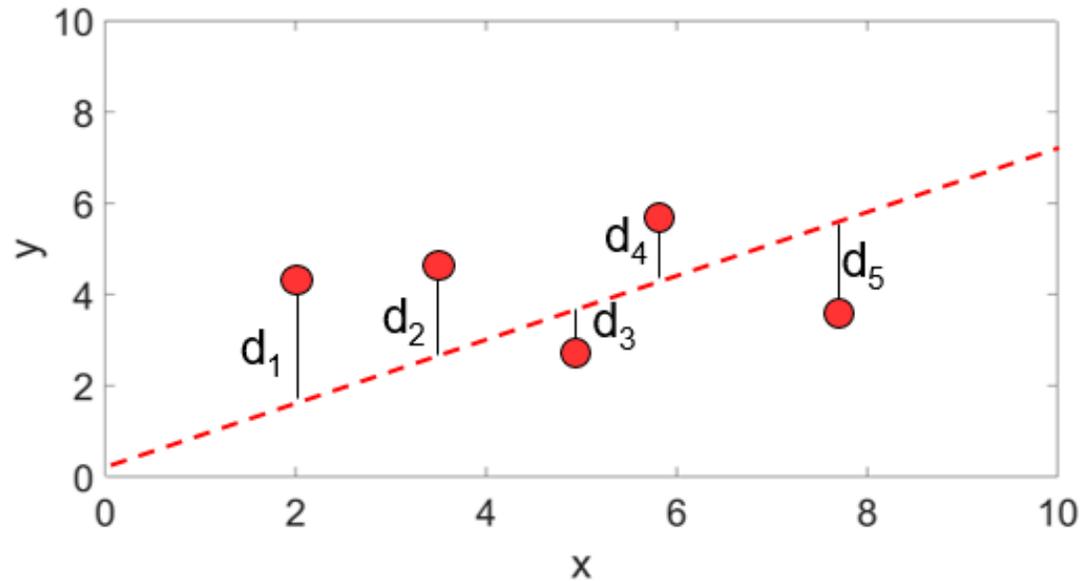
$$\Delta v_C = \sqrt{(\Delta v_A)^2 + (\Delta v_B)^2} = \sqrt{\sum_{i=1}^N \frac{(v_i - \bar{v})^2}{n(n-1)} + (\Delta v_B)^2}$$

- Si medimos la posición en N tiempos, típicamente vamos a ver algo así:



En un MRU:  $x(t) = x_0 + v(t - t_0)$

- ¿Cómo podemos encontrar el  $x$  y  $v$  óptimos?
- Esto es un caso de un problema general: dados puntos  $(x_i, y_i)$  ¿cuál es la recta que está “más cerca” de los puntos?



$$y = f(x) = a + bx$$

Buscamos  $a$  y  $b$ , tales que  $\sum d_i^2$  sea mínima

- Queremos minimizar:

$$\sum d_i^2 = \chi^2 = \sum [y_i - (a + bx_i)]^2$$

- Que es una función de  $a$  y  $b$  (los  $(x_i, y_i)$  son las mediciones!)

$$\frac{\partial \chi^2}{\partial a} = 0 \quad \frac{\partial \chi^2}{\partial b} = 0$$

$$\begin{aligned} \chi^2 &= \sum [y_i - (a + bx_i)]^2 = \sum (y_i - a - bx_i)^2 = \\ &\sum [y_i^2 + a^2 + (bx_i)^2 - 2y_i a - 2y_i bx_i + 2abx_i] = \\ &\sum y_i^2 + Na^2 + b^2 \sum x_i^2 - 2a \sum y_i - 2b \sum x_i y_i + 2ab \sum x_i \end{aligned}$$

$$\chi^2 = \sum y_i^2 + Na^2 + b^2 \sum x_i^2 - 2a \sum y_i - 2b \sum x_i y_i + 2ab \sum x_i$$

$$\frac{\partial \chi^2}{\partial a} = 2Na - 2 \sum y_i + 2b \sum x_i = 0$$

$$\frac{\partial \chi^2}{\partial b} = 2b \sum x_i^2 - 2 \sum x_i y_i + 2a \sum x_i = 0$$

Resolviendo

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

$$b = \frac{1}{\Delta} \left( N \sum x_i y_i - \sum x_i \sum y_i \right)$$

$$\Delta = N \sum x_i^2 - \left( \sum x_i \right)^2$$

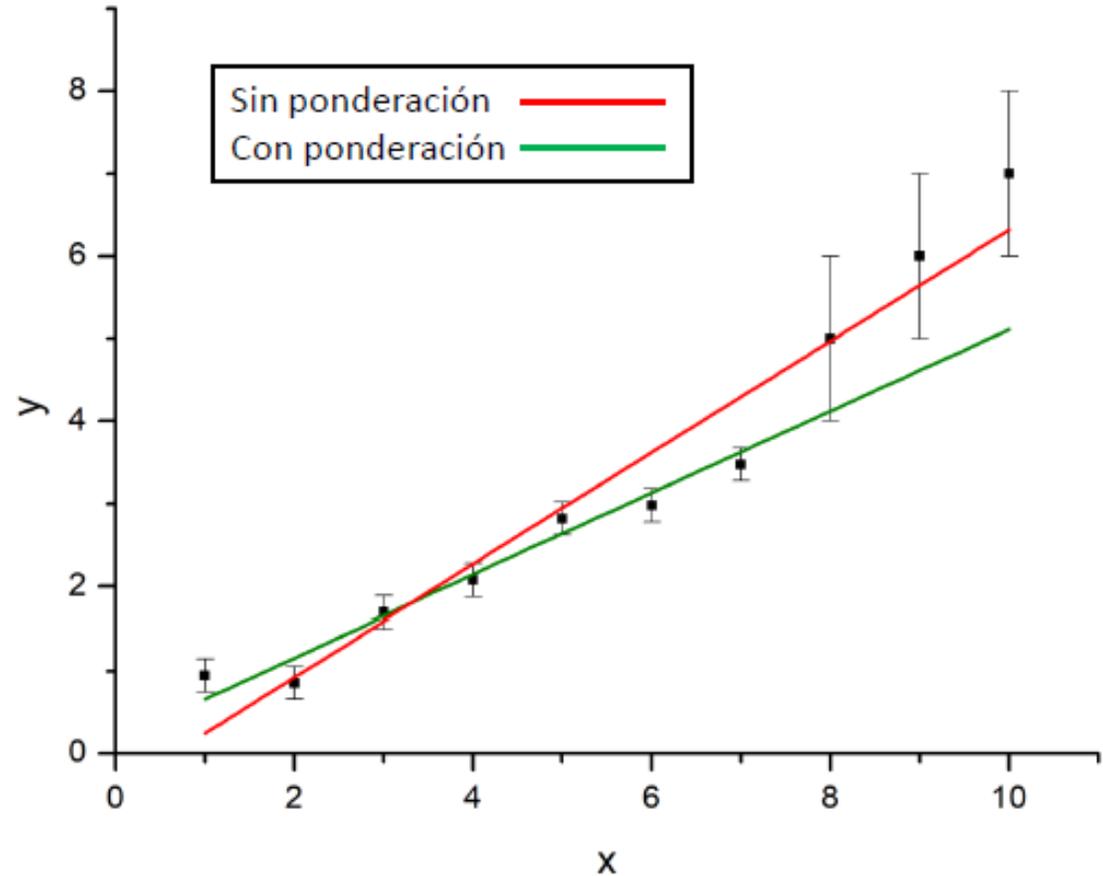
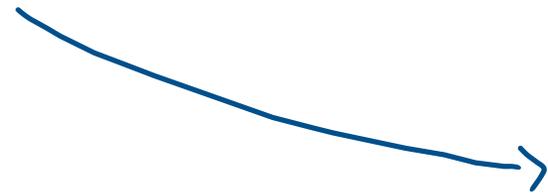
- En un caso un poco más general, consideramos errores en las mediciones de  $y$
- Nos interesa que la recta ajuste mejor a los puntos medidos con mayor precisión.
- Esto se logra definiendo:

$$\chi^2 = \sum \left[ \frac{y_i - (a + bx_i)}{\sigma_i} \right]^2$$

$$a = \frac{1}{\Delta'} \left( \sum \frac{x_i^2}{\sigma_i^2} \sum \frac{y_i}{\sigma_i^2} - \sum \frac{x_i}{\sigma_i^2} \sum \frac{x_i y_i}{\sigma_i^2} \right) \quad \Delta' = \sum \frac{1}{\sigma_i} \sum \frac{x_i^2}{\sigma_i^2} - \left( \sum \frac{x_i}{\sigma_i} \right)^2$$

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

- La ponderación del error mitiga la distorsión que pueden introducir las mediciones poco precisas.
- En un ejemplo donde solo consideramos el error en la variable  $y$



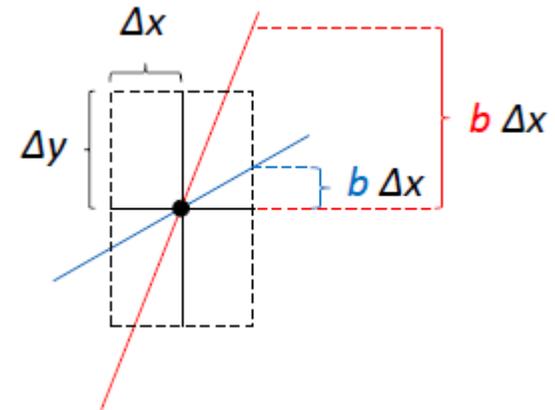
- ¿Y si el error en  $x$  no es despreciable? Hay métodos generales para errores en ambas variables, pero son más complicados.
- Lo habitual es elegir como  $x$  la variable con menor error, y despreciarlo. ¿Qué criterio se puede tomar?

$$\Delta x \leq \Delta y$$

¿Y si  $x$  e  $y$  no son la misma magnitud?

$$\frac{\Delta x}{x} \leq \frac{\Delta y}{y}$$

Mejor ¿pero no depende de más nada?



Lo mejor es elegir  $x$  e  $y$ , aplicar cuadrados mínimos para estimar  $b$ , y chequear que se satisfaga  $b \Delta x \leq \Delta y$

Si no se cumple, podemos invertir

$$x = c + m y$$

Y darlo vuelta de nuevo

$$y = a + b x \quad \Rightarrow \quad b = \frac{1}{m} \quad a = -\frac{c}{m}$$

¿Qué errores tienen  $a$  y  $b$ ? En su determinación están involucradas las  $N$  mediciones de  $(x_i, y_i)$ , así que se estima **propagando** el error de todas ellas.

Suponiendo que las distintas mediciones no están correlacionadas entre sí:

$$\sigma_z^2 = \sum_{i=1}^N \left[ \sigma_i^2 \left( \frac{\partial z}{\partial y_i} \right)^2 \right] \quad z = a, b$$

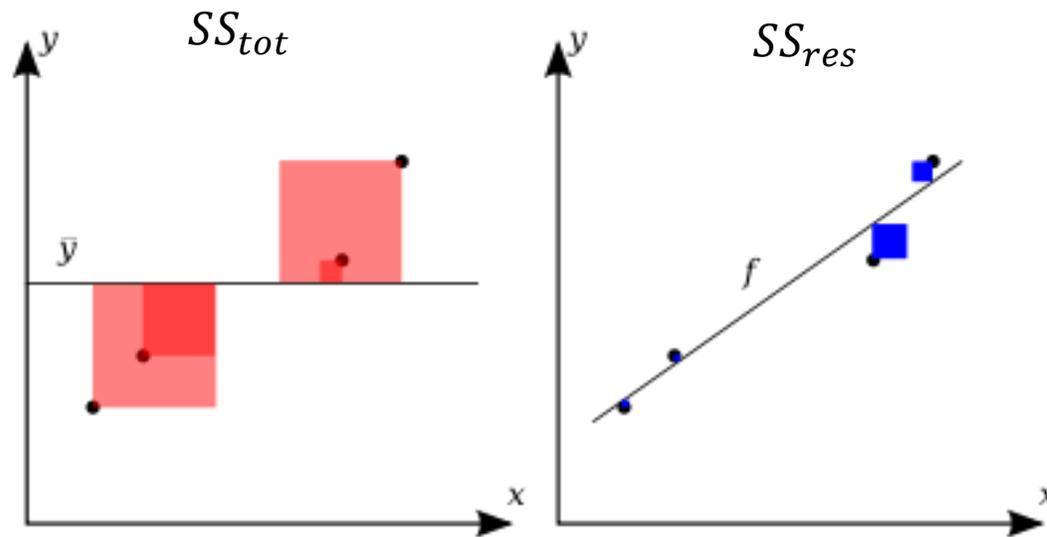
$$\sigma_a^2 = \frac{1}{\Delta'} \sum_{i=1}^N \frac{x_i^2}{\sigma_i^2} \quad \Delta = \sum \frac{1}{\sigma_i^2} \sum \frac{x_i^2}{\sigma_i^2} - \left( \sum \frac{x_i}{\sigma_i^2} \right)^2$$

$$\sigma_b^2 = \frac{1}{\Delta'} \sum_{i=1}^N \frac{1}{\sigma_i^2}$$

**Importante!** Las estimaciones de  $a$  y  $b$  no son independientes! Una fluctuación en  $a$  implica una en  $b$ , y viceversa. Esto es fundamental a la hora de propagar los errores de  $a$  y  $b$  en cálculos que los involucran.

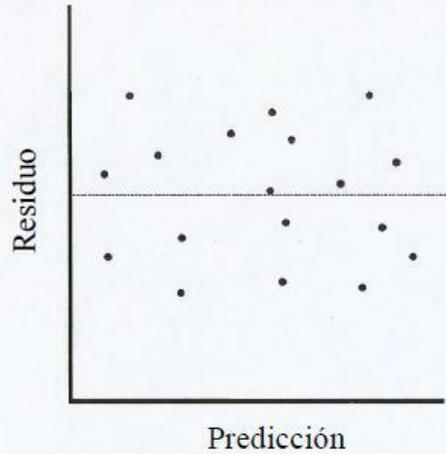
- ¿Cómo evaluamos el ajuste?

$$R^2 = 1 - \frac{\sum_{i=1}^N [y_i - f(x_i)]^2}{\sum_{i=1}^N (y_i - \bar{y})^2} = 1 - \frac{SS_{res}}{SS_{tot}}$$

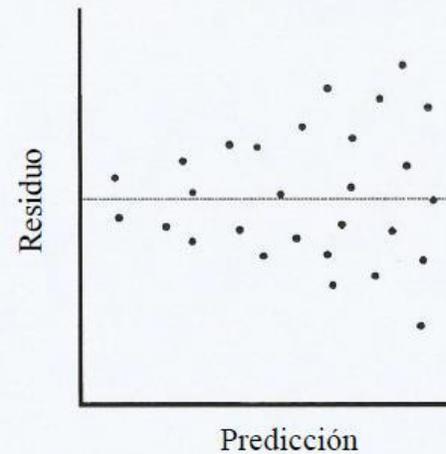


- Análisis de residuos

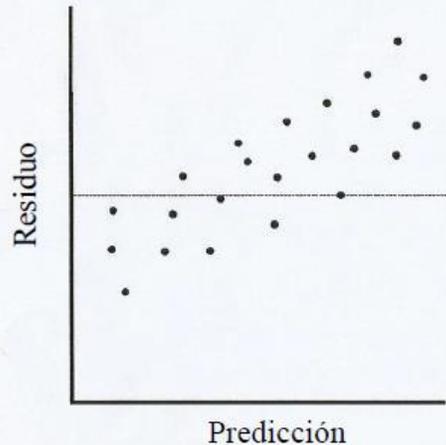
Residuos distribuidos normalmente



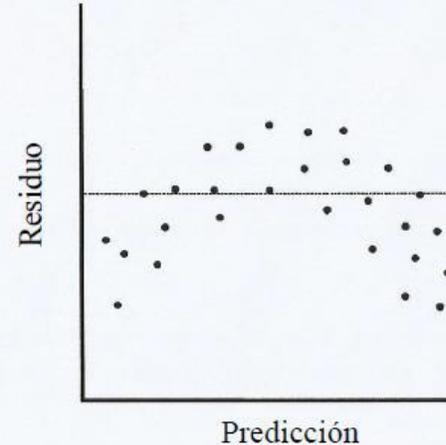
La dispersión del error no es constante



Falta alguna variable en el modelo



El modelo no es el más adecuado



Diferencia entre variable observada y predicha a partir de la regresión:

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

Para regresión lineal, se asume que tiene una **distribución normal**

El concepto de cuadrados mínimos se puede aplicar a todo tipo de funciones, no solamente a rectas. Hay una gran diferencia según si la función es lineal o no lineal en los parámetros que se quieren determinar.

Lineales  $\longrightarrow$   $a + bx + cx^2$ ,  $a \operatorname{sen}(x)$ ,  $a \exp(x)$ ,  $a \log(x)$

Todo lo que vimos sigue valiendo, las ecuaciones normales son diferentes pero siempre tienen solución, y es única.

El concepto de cuadrados mínimos se puede aplicar a todo tipo de funciones, no solamente a rectas. Hay una gran diferencia según si la función es lineal o no lineal en los parámetros que se quieren determinar.

No lineales  $\longrightarrow$   $a + a^2 x$ ,  $\text{sen}(a x)$ ,  $\text{exp}(a x)$ ,  $\text{log}(a x)$

Las ecuaciones normales no siempre tienen solución única, y en general no tienen solución cerrada. La suma de los cuadrados se minimiza **numéricamente** usando algoritmos de optimización.

A veces pueden convertirse en un problema lineal haciendo un cambio de variable

$$y = \text{exp}(a x), \quad u = \ln(y) \quad \Rightarrow \quad u = a x$$

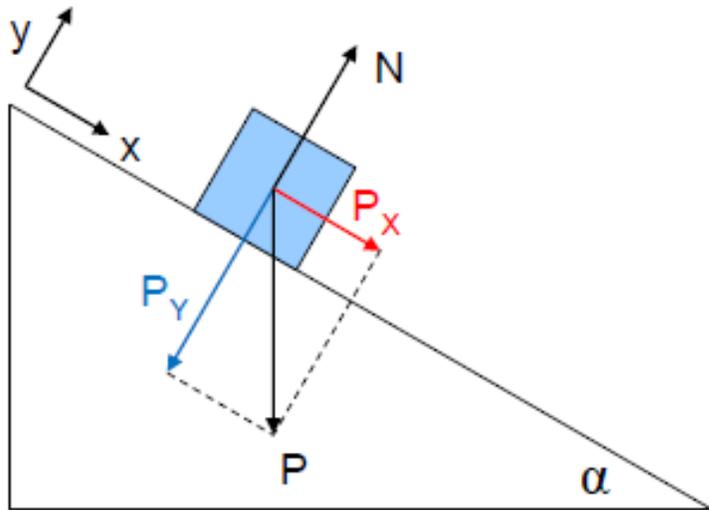
# Experiencia

- Vamos a estudiar el movimiento de un carrito en un plano inclinado
- Medimos posición en función del tiempo
- Determinamos la aceleración para distintas inclinaciones del riel
- A partir de los datos, calculamos la aceleración de la gravedad



# Ecuación horaria

- Vamos a suponer que no hay rozamiento (riel / aire)
- Suponemos movimiento 1D

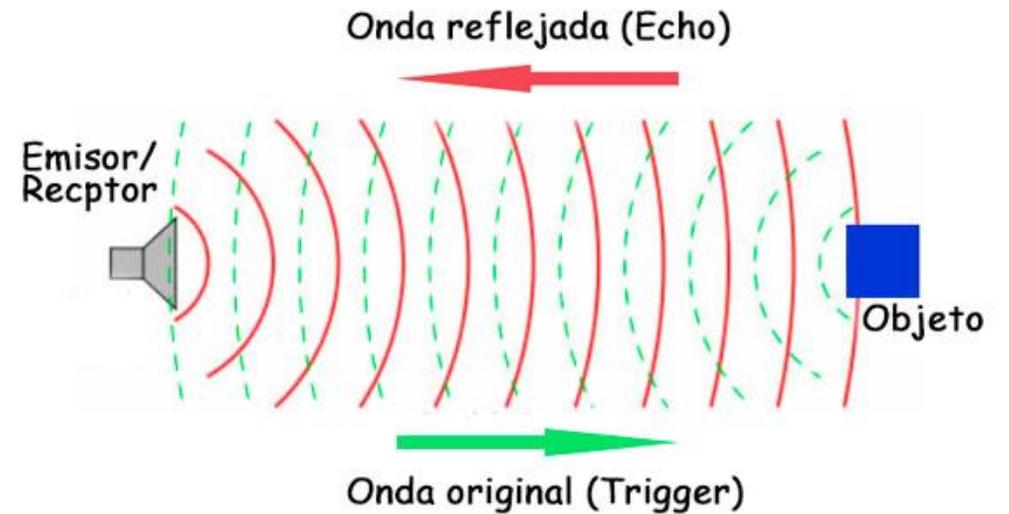


$$\hat{x}) m\ddot{x} = P_x = mg\text{sen}(\alpha)$$

$$\hat{y}) m\ddot{y} = N - P_y = 0$$

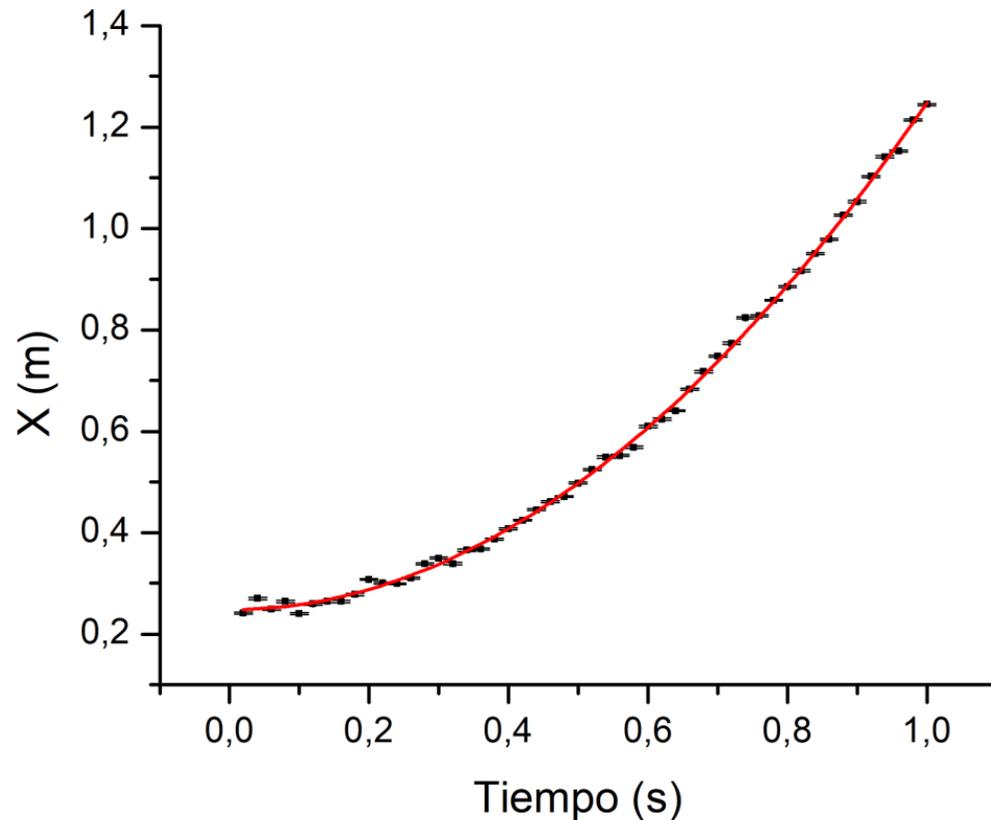
$$\ddot{x} = g\text{sen}(\alpha) \rightarrow x(t) = x_o + v_o(t - t_o) + \frac{1}{2}a(t - t_o)^2$$

# ¿Y cómo medimos la posición?



- Mide distancia según el tiempo de viaje de un pulso de ultrasonido
- Cuidado con el rango, no funciona bien a distancia corta
- Requiere calibración

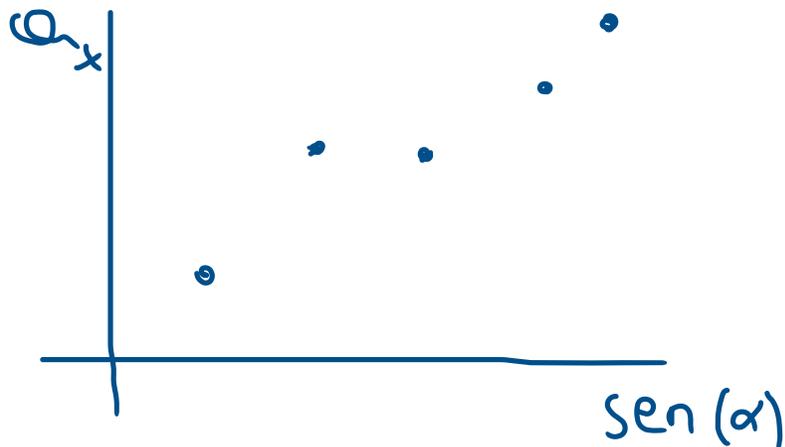
# ¿Cómo se va a ver una medición?



- A tener en cuenta:
  - Estimar errores
  - Hay que medir el ángulo de inclinación de la rampa, ¿ideas?
  - ¿Cómo obtenemos la aceleración?

# Medición de $g$

- Vamos a usar que  $a_x = g \operatorname{sen}(\alpha)$
- Podemos hacer el experiment para varias inclinaciones, calcular  $a_x$  para cada una y luego hacer un ajuste para encontrar  $g$



Atentos con los errores!

# Agenda

Para 5 inclinaciones

- 1) Medir ángulo (con su error!)
- 2) Hacer 5 tiradas del carrito desde el reposo y obtener su aceleración
- 3) Promediar estos valores para tener una medida para cada ángulo (con su error!)
- 4) Obtener  $g$  ajustando la aceleración contra  $\sin$  del ángulo