

# FÍSICA 1 (Q): LABORATORIOS

1er cuatrimestre 2020

JTP: Laura Ribba, Diego Shalom, Marcelo Luda

Ay 1ra: Griselda Mingolla, Santiago Estevez Areco

## PRÁCTICA 3: REGRESIÓN LINEAL




# REPASEMOS...

- Definimos un sistema físico a partir de parámetros y variables.  
Medimos de manera sistemática
- Expresamos resultados como un intervalo  $\rightarrow x = (x_0 \mp \Delta x)$
- Utilizamos herramientas e indicadores estadísticos
- $e_{tot}^2 = e_{est}^2 + e_{ins}^2$
- Mediciones indirectas  $\rightarrow y = f(x_i)$
- Propagación de errores:  $\Delta y^2 = \sum \left( \frac{\partial y}{\partial x_i} \right)^2$



# REGRESIÓN LINEAL

- Herramienta que permite contrastar datos **experimentales**  $(x_i, y_i)$  con un **modelo** teórico lineal



$$(x_i, y_i)$$


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

Nos interesa la recta (función lineal) que más «se acerca» a mis datos



# REGRESIÓN LINEAL

- Se busca la función que minimice la suma de las distancias al cuadrado entre la predicción y los datos experimentales



$$S^2 = \sum_i^N \delta_i^2 = \sum_i^N [y_i - f(x_i)]^2$$

$$S^2 = \sum_i^N [y_i - (a.x_i + b)]^2$$

Incógnitas =  $a, b$

# ALGORITMO (SIN ERROR EN Y)

- ¿Cómo cálculo  $a$  y  $b$  en el ajuste?

$$\frac{\partial S^2(a, b)}{\partial a} = 0$$

$$\frac{\partial S^2(a, b)}{\partial b} = 0$$

...

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

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



## OTRO ALGORITMO (CON ERROR EN Y)

- ¿Qué pasa con el error de los datos en el ajuste?

$$S^2 = \sum_i^N \left[ \frac{y_i - f(x_i)}{\sigma_{yi}} \right]^2 = \sum_i^N \frac{[y_i - f(x_i)]^2}{\sigma_{yi}^2}$$

$$\dots \left\{ \begin{aligned} a &= \frac{1}{\Delta} \left[ \sum \frac{1}{\sigma_{yi}^2} \sum \frac{x_i y_i}{\sigma_{yi}^2} - \sum \frac{x_i}{\sigma_{yi}^2} \sum \frac{y_i}{\sigma_{yi}^2} \right] \end{aligned} \right.$$

$$\left\{ \begin{aligned} b &= \frac{1}{\Delta} \left[ \sum \frac{x_i^2}{\sigma_{yi}^2} \sum \frac{y_i}{\sigma_{yi}^2} - \sum \frac{x_i}{\sigma_{yi}^2} \sum \frac{x_i y_i}{\sigma_{yi}^2} \right] \end{aligned} \right.$$

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






**Solo considera errores en Y. Debemos comprobar:**  $\frac{\Delta x}{\bar{x}} \ll \frac{\Delta y}{\bar{y}}$

**Si**  $\frac{\Delta x}{\bar{x}} \gg \frac{\Delta y}{\bar{y}}$  **debemos invertir los ejes y calcular**  $f^{-1}(y)$



# VALIDEZ DE UN AJUSTE

- Coeficiente de correlación de Pearson  $\rho$ :
  - Mide el grado de correlación lineal entre dos variables
  - $-1 < \rho < 1$
  - $\rho = |1|$  indica que los datos están perfectamente alineados
  - $\rho = 0$  indica que no hay correlación lineal entre las variables



# VALIDEZ DE UN AJUSTE

- Coeficiente de determinación  $R^2$  (r-squared)
  - Proporción de la varianza que puede explicar el modelo
  - En regresión lineal es el cuadrado del coeficiente de Pearson
  - $0 < R^2 < 1$
  - Mientras más cercano a 1 mejor es el ajuste

$$R^2 = 1 - \frac{\sum (y_i - f(x_i))^2}{\sum (y_i - \bar{y})^2}$$




# EJEMPLO:

- En un resorte ideal, la relación entre la fuerza y el estiramiento se modela por la ley de Hooke:

$$F = -k \Delta x$$

k: constante del resorte



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

Resultados del ajuste:

$$\left\{ \begin{array}{l} a = -25.09 \mp 1.92 \\ b = 0.113 \mp 0.749 \\ r^2 = 0.977 \end{array} \right.$$

$$a = -k \rightarrow k = (25 \mp 2) \text{ N/m}$$

$$b = ??$$

- Pregunta 1: ¿Qué significado le dan a la ordenada al origen?



# ¿Y SI EL MODELO NO ES LINEAL?

- Muchas veces puede linealizarse la ecuación:

- $y = a \cdot x^3$   Se grafica  $y$  vs  $x^3$

- $y = a \cdot b^x$   $\Delta(x_i^3) = \sqrt{\left(\frac{\partial(x^3)}{\partial x} \Delta x_i\right)^2}$

$$\ln(y) = \ln(a \cdot b^x)$$

$$\ln(y) = \ln(a) + x \cdot \ln(b) \quad \img alt="orange arrow" data-bbox="455 620 555 665"/> \text{ Se grafica } \ln(y) \text{ vs } x$$

- $y(x) = a \cdot x^b$

$$\ln(y) = \ln(a \cdot x^b)$$

$$\ln(y) = \ln(a) + b \cdot \ln(x) \quad \img alt="orange arrow" data-bbox="455 875 555 920"/> \text{ Se grafica } \ln(y) \text{ vs } \ln(x)$$



# LINEALIZAR ECUACIONES: EJEMPLO

## ○ Ley de Beer-Lambert:

- Relaciona la atenuación de la luz con la concentración de determinada especie química

$$T(c) = 10^{-\epsilon lc}$$

$T$  es la transmitancia (se mide),  $l$  la longitud atravesada por el haz de luz,  $\epsilon$  es la absorptividad de la especie y  $c$  es la concentración de la especie

$$\log_{10}(T) = \log_{10}(10^{-\epsilon lc})$$

$$\log_{10}(T) = -\epsilon lc$$



Se grafica  $\log_{10}(T)$  vs  $c$

Antes de hacer el ajuste, debemos propagar el error de las variables!

$$\Delta(\log_{10}T)^2 = \left(\frac{\partial(\log_{10}T)}{\partial T}\Delta T\right)^2 = \dots$$

- La pendiente es igual a  $-\epsilon l$
- Podemos medir  $l$  y despejar  $\epsilon$



## PREGUNTA 2:

- ¿Cómo linealizas la siguiente ecuación?
  - Ley de enfriamiento de Newton:

$$T(t) = T_{amb} + (T_i - T_{amb})e^{-kt}$$



Donde  $T_{amb}$  es la temperatura ambiente y  $T_i$  es la temperatura inicial del objeto.

- ¿Cómo es el error de las nuevas variables?




# PRÁCTICA 3 (PARTE 1)

- Péndulo ideal como caso de estudio
- Medir el período para distintas longitudes (10)
- Utilizar metodología de práctica anterior (10 mediciones de 10 períodos por cada L)
- ¡Graficar con barras de error!



# PRÁCTICA 3 (PARTE 2)



- Linealizar los datos (2 formas)
- Propagar el error
- Ajustar por cuadrados mínimos
- Calcular  $g$
- Reportar datos
- [Aquí está la Guía](#)
- Fecha de entrega: Jueves 14/5

