

Física 1 (Química) Laboratorio

Verano 2021

JTP Nicolás Torasso

Ay 1^{ra} Magalí Xaubet

Ay 2^{da} Adán Garros

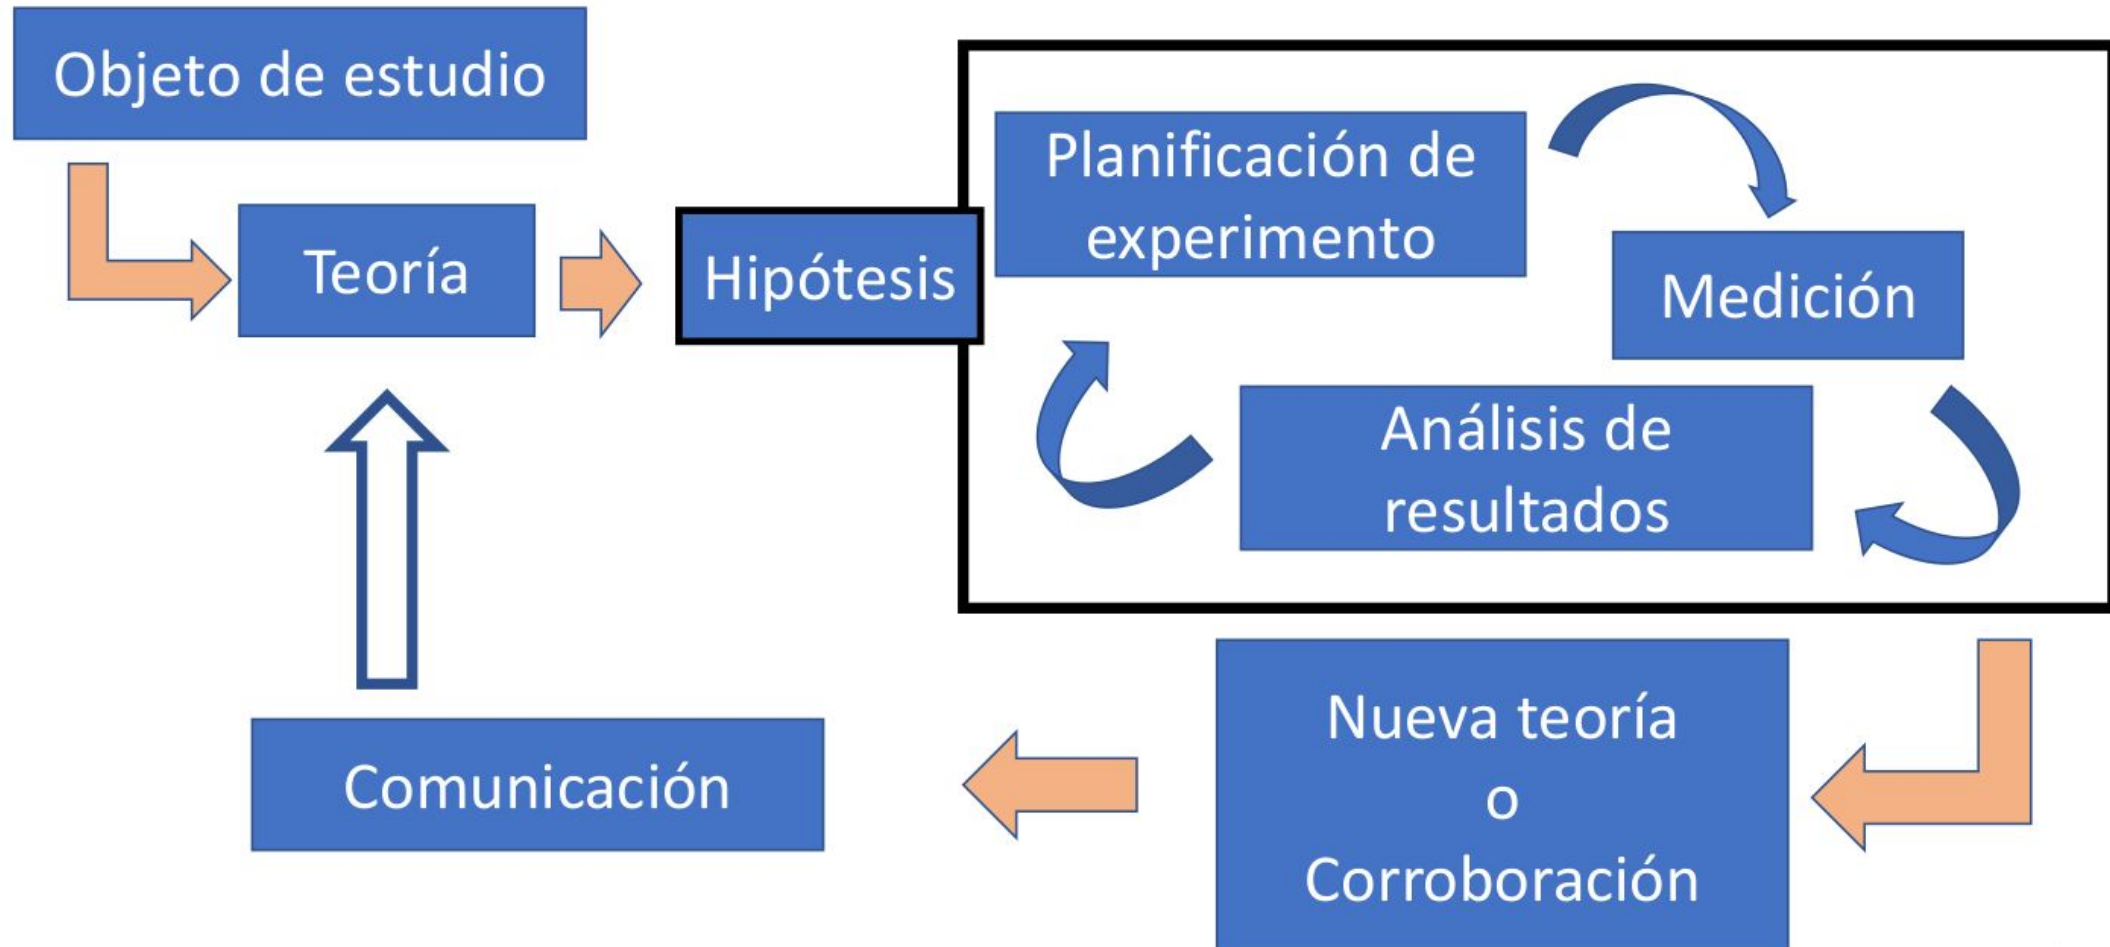
Lunes y Miércoles 14:30-18:30 hs

Prof. Gustavo Lozano

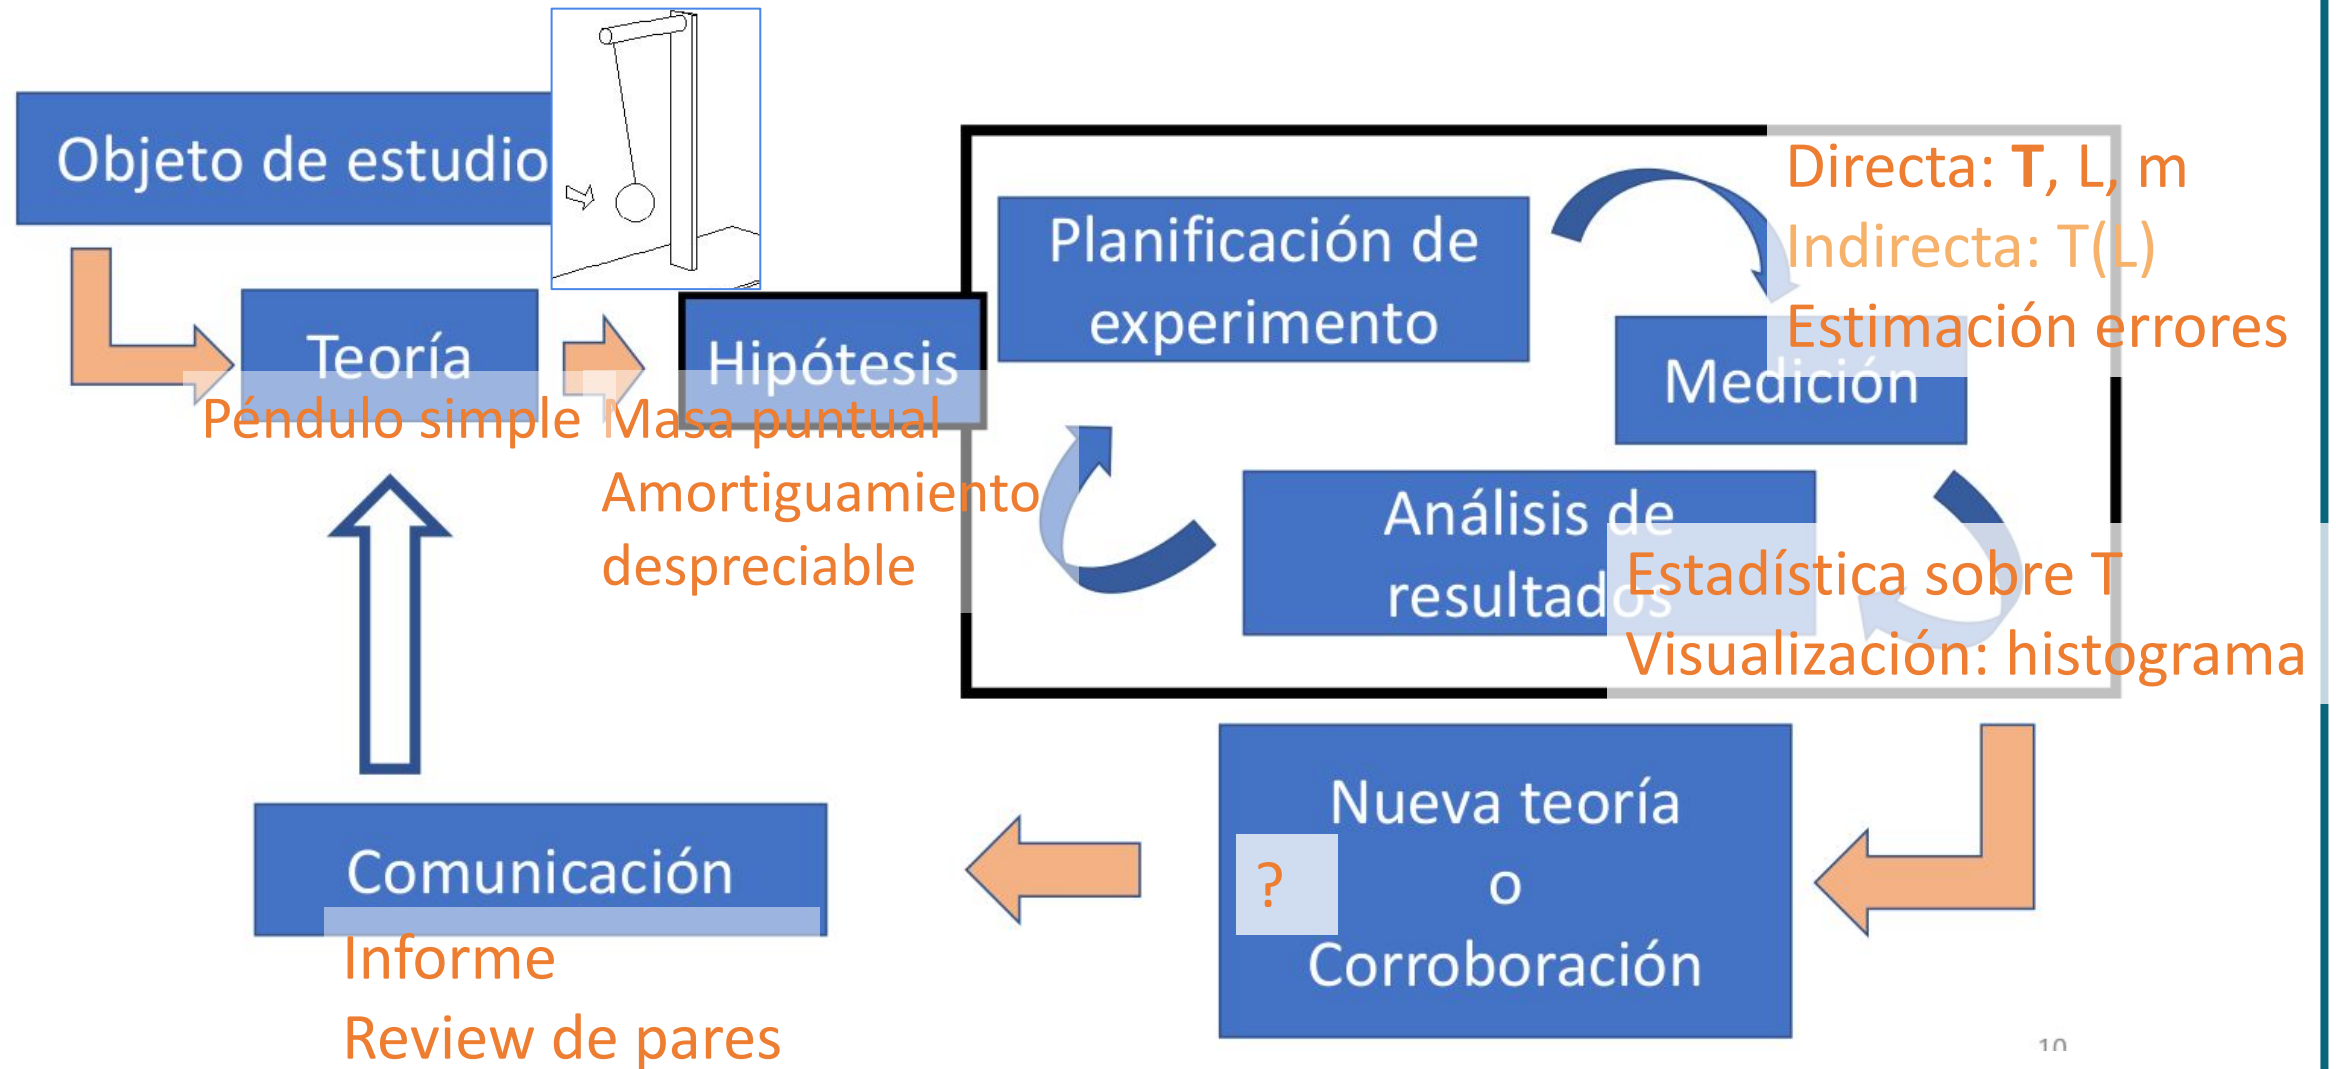
Hoy

- Repaso breve.
- Testeo de un modelo mediante gráficos tipo “scatter”
- Testeo de modelo lineal o linealizado: Ajuste lineal - cuadrados mínimos (ponderados - no ponderados)
- Coeficientes r , R^2 : estimadores de validez del modelo
- Cuadrados mínimos vs cálculo punto a punto
- Planificación del Experimento 4: determinación de g

El trabajo experimental: repaso



El trabajo experimental: repaso



Análisis y testeo de un modelo

- Para testear un modelo podemos calcular los valores que predice y comparar con el valor que medimos en nuestro experimento.
- Otra alternativa es graficar pares de variables en ejes cartesianos y comparar con el tipo de dependencia (función matemática) que indica el modelo.
- Una visualización apropiada nos permite:
 - analizar los resultados del experimento y extraer información novedosa
 - simplificar la comunicación de los resultados a la comunidad


Análisis y testeo de un modelo

- A la hora de testear un modelo:
 - liberarnos de preconceptos. ej: el modelo es correcto. el modelo es incorrecto.
 - la naturaleza se manifestó frente nuestro: ser objetivos y reportar con fidelidad, sin descartar observaciones o alterar resultados

Testeo mediante gráficos tipo scatter

- Podemos graficar dos parámetros físicos medidos y visualizar su tipo de relación
- Podemos graficar los parámetros en forma **linealizada**. Para ello necesitamos conocer de antemano el modelo a testear. Ej:

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




Testeo mediante gráficos tipo scatter

- Podemos graficar dos parámetros físicos medidos y visualizar su tipo de relación
- Podemos graficar los parámetros en forma **linealizada**. Para ello necesitamos conocer de antemano el modelo a testear. Ej:


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

Opciones: T vs. \sqrt{L}
 T² vs. L




Testeo de relación lineal

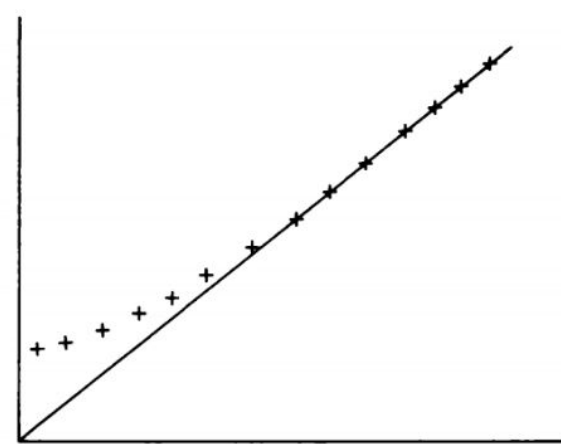
entre dos parámetros o dos parámetros linealizados. Puede pasar:




(a)




(b)




(c)




(d)



(e)



(f)



(g)

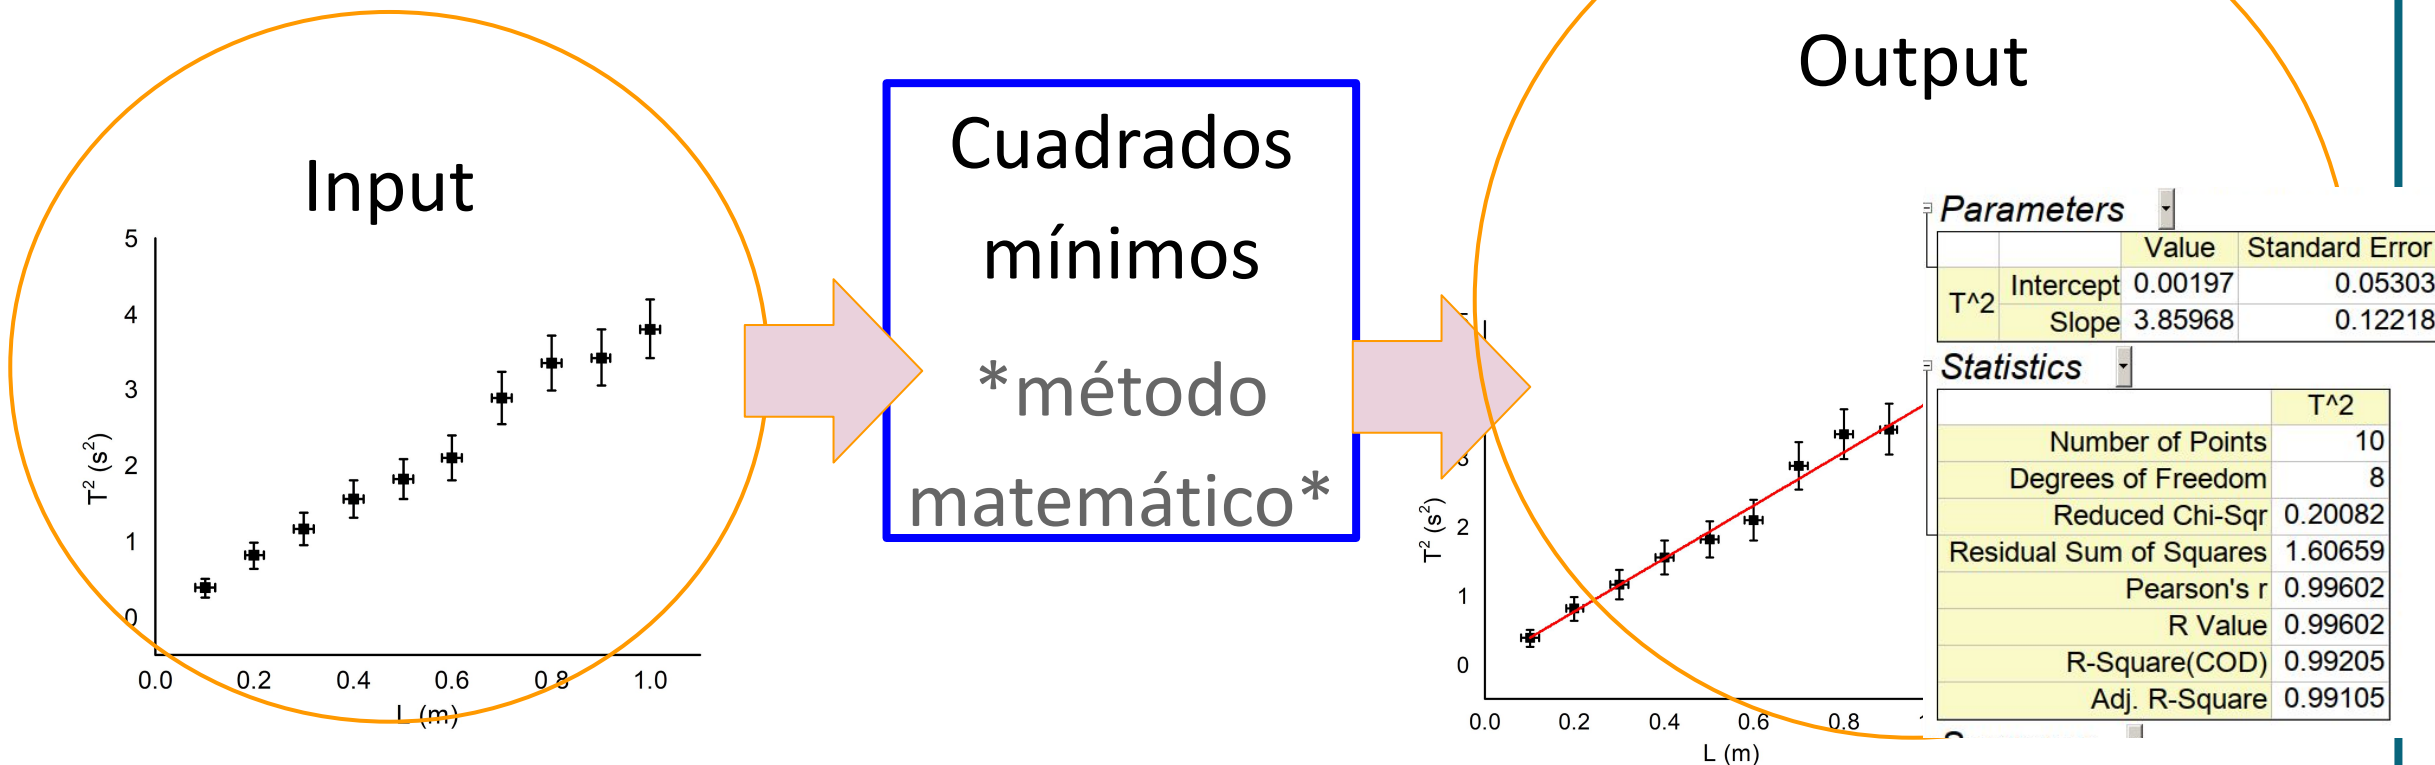
Regresión lineal - cuadrados mínimos

- Método matemático para obtener la recta que “mejor ajusta” la nube de puntos. $f(x) = \mathbf{a} x + \mathbf{b}$
- Obtenemos como resultado los parámetros **a** y **b** de la “recta que mejor ajusta” (y sus errores)
- Optativo: calcular estimadores de la validez del ajuste: r , R^2 , χ^2
- Nota: el método de cuadrados mínimos no-lineal sirve para testear cualquier otro tipo de relaciones funcionales: cuadráticas, polinomiales, gaussianas, etc etc. $f(x) = ax^2 + bx + c$

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}$$

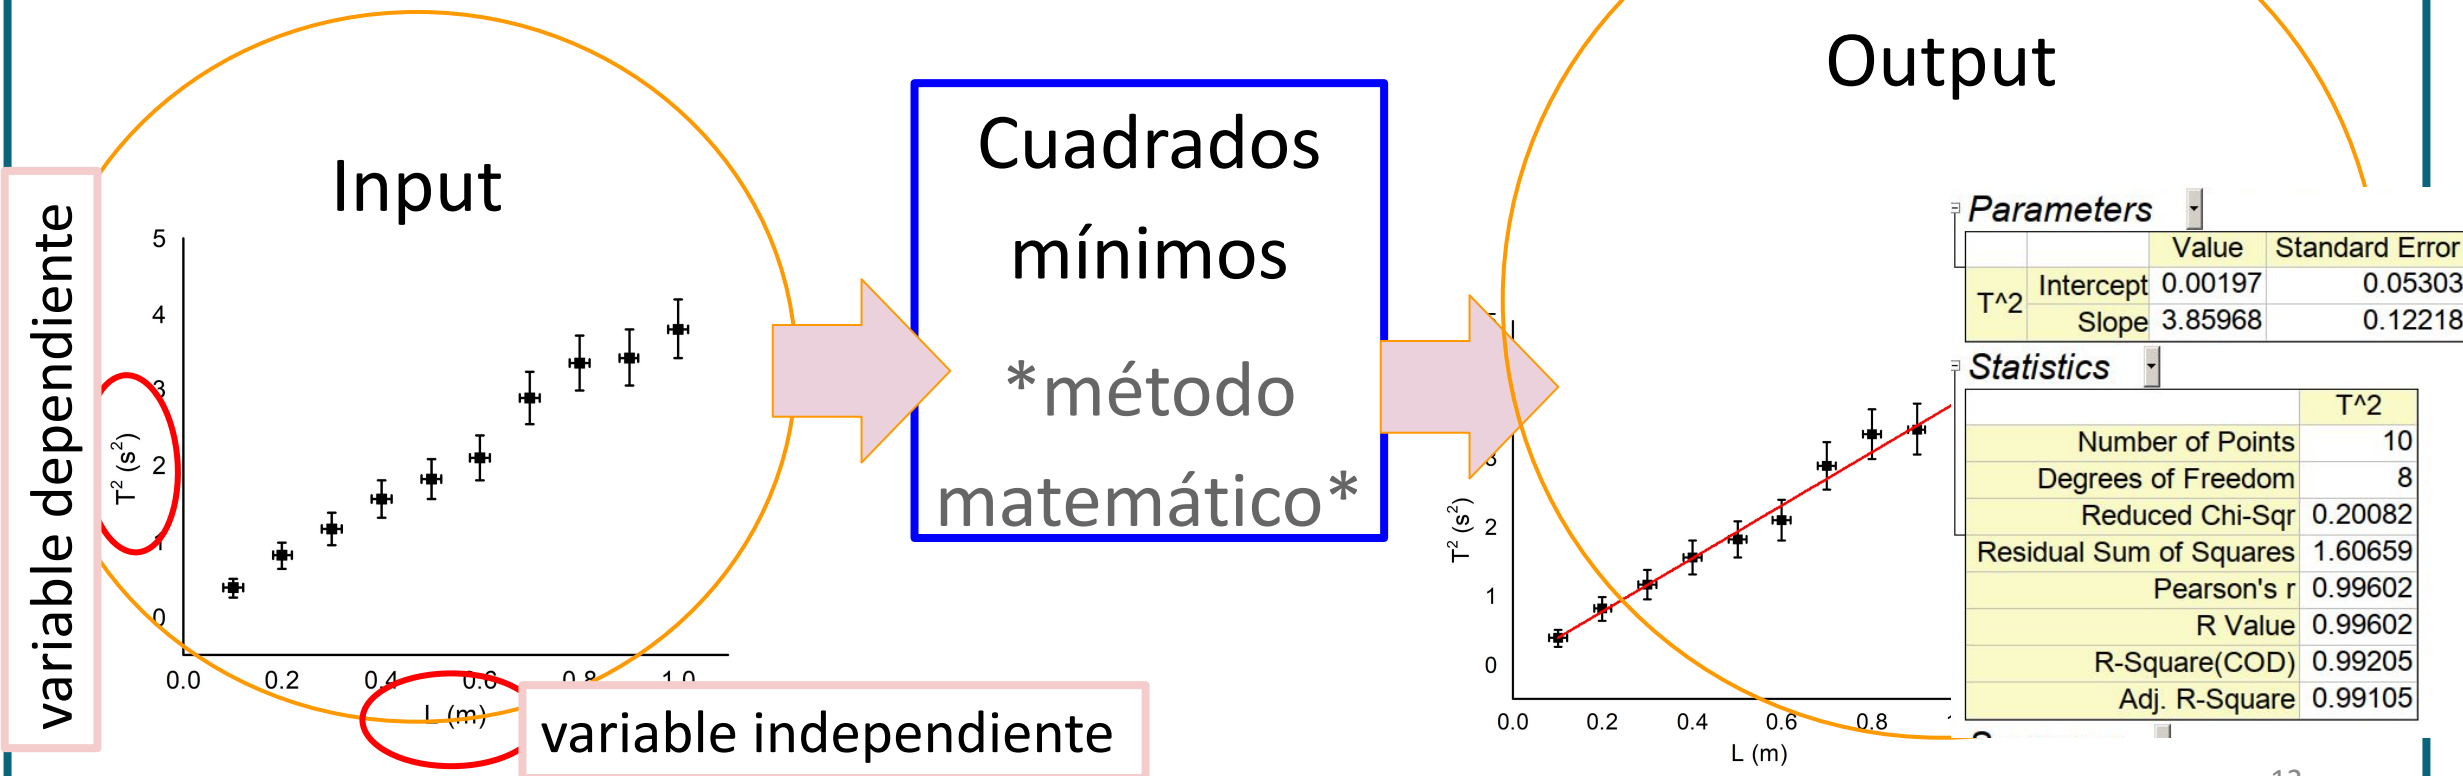
Regresión lineal - cuadrados mínimos

- Método matemático para obtener la recta que “mejor ajusta” la nube de puntos. $f(x) = a x + b$




Regresión lineal - cuadrados mínimos

- Método matemático para obtener la recta que “mejor ajusta” la nube de puntos. $f(x) = a x + b$



Regresión lineal - cuadrados mínimos

- Método matemático para obtener la recta que “mejor ajusta” la nube de puntos. $f(x) = a x + b$



Parameters			
		Value	Standard Error
T ²	Intercept	0.00197	0.05303
	Slope	3.85968	0.12218


Statistics	
	T ²
Number of Points	10
Degrees of Freedom	8
Reduced Chi-Sqr	0.20082
Residual Sum of Squares	1.60659
Pearson's r	0.99602
R Value	0.99602
R-Square(COD)	0.99205
Adj. R-Square	0.99105

a y b:
valor central y error
(sin unidades, sin
redondear)

r, R², χ²
calidad del ajuste


Regresión lineal - cuadrados mínimos

- Método matemático para obtener la recta que “mejor ajusta” la nube de puntos. $f(x) = a x + b$




más info sobre calidad del ajuste:

residuos: distancia entre cada punto y la recta



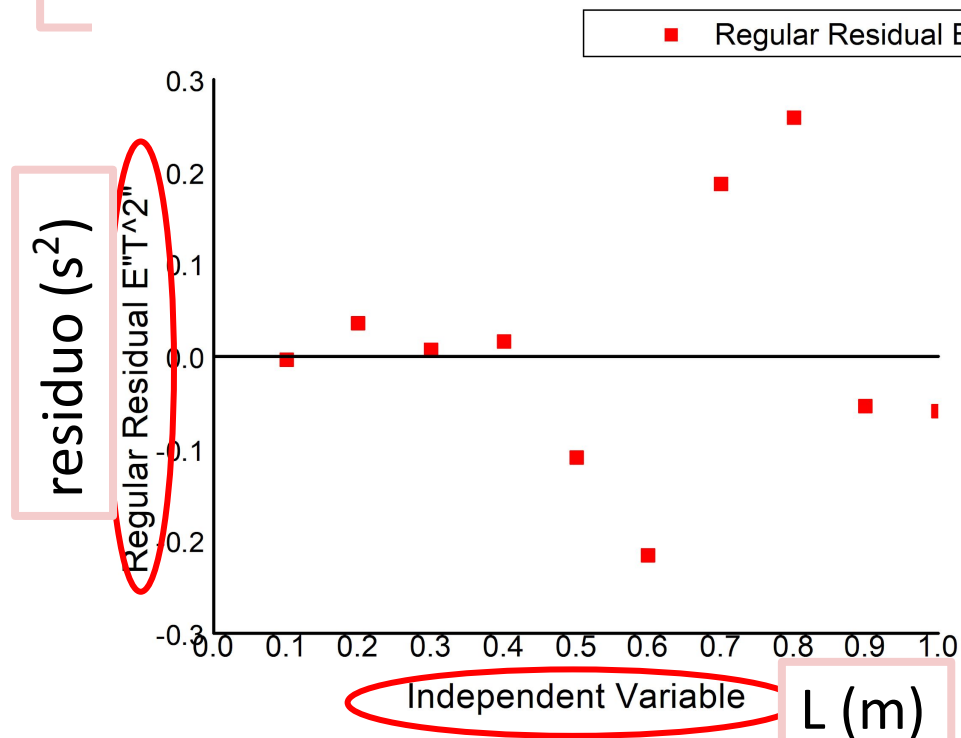
Regresión lineal - cuadrados mínimos

- Método matemático para obtener la recta que “mejor ajusta” la nube de puntos. $f(x) = a x + b$



más info sobre calidad del ajuste:

residuos: distancia entre cada punto y la recta



Ajuste por cuadrados mínimos

- El método de ajuste por cuadrados mínimos **busca los parámetros** del modelo propuesto que **minimizan la sumatoria de residuos**.
- Cuando la regresión es **lineal**, existe un cálculo analítico para calcular los coeficientes **a** y **b** y sus errores. (ver siguientes diapos)
- Si la regresión es no-lineal (cuadrática, gaussiana, etc) se usa un algoritmo iterativo (=método numérico) que repite unas operaciones hasta obtener los parámetros que minimizan la suma de residuos.

Hipótesis del modelo de regresión lineal simple

*Diapos adaptadas de presentaciones de:

Dra. Silvia Goyanes

Dra. Adriana Márquez


Lic. Santiago Estévez Areco

Independencia

- Los datos deben ser independientes.
- Una observación no debe dar información sobre las demás.

Normalidad

- Se asume que los datos son normales a priori.




Estimadores de mínimos cuadrados

Gauss propuso en 1809 el **método de mínimos cuadrados** para obtener los valores **a** y **b** que mejor se ajustan a los datos:

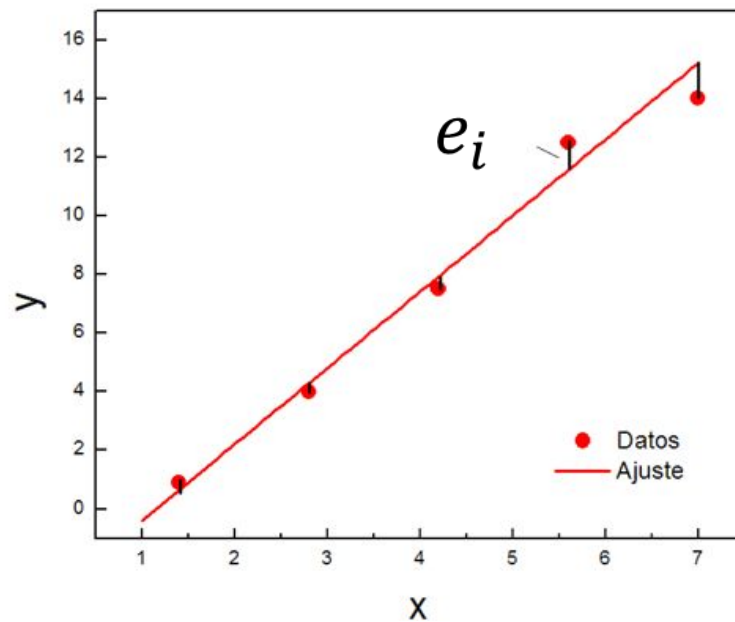
$$\hat{y}_i = a x_i + b$$

El método consiste en **minimizar la suma de los residuos al cuadrado (S^2)**:

$$S^2 = \sum_i^N e_i^2 = \sum_i^N (y_i - \hat{y}_i)^2 = \sum_i^N [y_i - (a x_i + b)]^2$$



Es decir, minimizar la suma de los cuadrados de las diferencias entre los valores reales observados (y_i) y los valores estimados (\hat{y}_i)



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

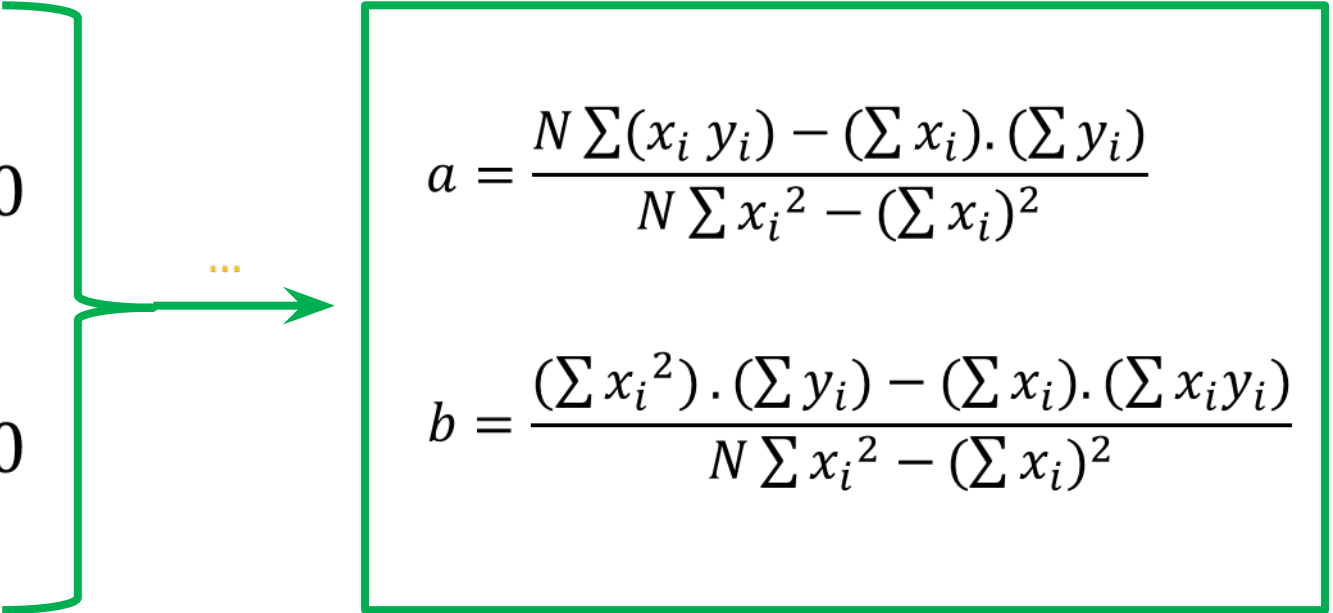
Busco minimizar $S^2(a, b)$

Incógnitas: a y b

¿Cómo cálculo a y b en el ajuste?
Minimizo S^2

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

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


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

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

¿Cuáles son los errores de los parámetros obtenidos a y b?

Propagamos errores:

$$\sigma_a^2 = \sum \left(\frac{\partial a}{\partial y_i} \sigma_y \right)^2 \quad \sigma_b^2 = \sum \left(\frac{\partial b}{\partial y_i} \sigma_y \right)^2$$

Si $\sigma_{y_1} = \sigma_{y_2} = \dots = \sigma_{y_N} = \sigma_y$

$$\sigma_A = \sigma_y \sqrt{\frac{\sum x^2}{\Delta}}$$

$$\sigma_B = \sigma_y \sqrt{\frac{N}{\Delta}}$$

Donde:

$$\Delta = N \sum x^2 - (\sum x)^2$$

Cuadrados mínimos solo considera errores en eje Y

- Se debe cumplir que:

$$\Delta x \frac{dy}{dx} \ll \Delta y$$

En caso contrario, **invertir los ejes**.


- Si aproximamos por una recta y **pasa por el origen**, entonces el criterio se puede expresar como:

$$\varepsilon_x \ll \varepsilon_y$$

- Si los errores en x e y son del **mismo orden**, podemos “trasladar” el error en x al error en y:

$$\Delta y_{\text{nuevo}}^2 = \left(\Delta x \frac{dy}{dx} \right)^2 + \Delta y_{\text{original}}^2$$

Hasta acá no tuvimos en cuenta el error de los datos. Algunos datos podrían ser más confiables que otros, y queremos que “pesen” más.

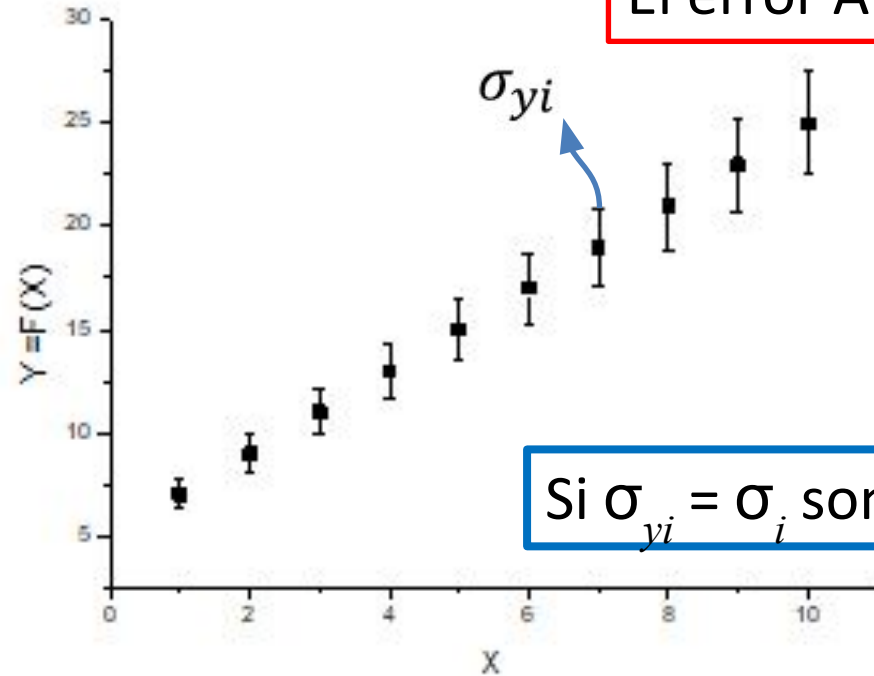


Si $\sigma_{y_i} = \sigma_i$ son distintos:

Peso

$$w_i = \frac{1}{\sigma_i^2}$$

Ajuste de cuadrados mínimos pesado
con la incertidumbre



El error Absoluto cambia de dato a dato

¿Cómo tengo en cuenta eso?

Si $\sigma_{yi} = \sigma_i$ son distintos

CM PONDERADOS

$$w_i = \frac{1}{\sigma_i^2}$$

CM sin ponderar

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

CM PONDERADOS

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

$$\begin{aligned}
 S^2 &= \sum_i^N \left[\frac{y_i - f(x_i)}{\sigma_{yi}} \right]^2 \\
 &= \sum_i^N \frac{[y_i - f(x_i)]^2}{\sigma_{yi}^2}
 \end{aligned}
 \left[\begin{aligned}
 a &= \frac{1}{\Delta} \left[\sum \frac{1}{\sigma_{yi}^2} \sum \frac{x_i y_i}{\sigma_{yi}^2} - \sum \frac{x_i}{\sigma_{yi}^2} \sum \frac{y_i}{\sigma_{yi}^2} \right] \\
 b &= \frac{1}{\Delta} \left[\sum \frac{x_i^2}{\sigma_{yi}^2} \sum \frac{y_i}{\sigma_{yi}^2} - \sum \frac{x_i}{\sigma_{yi}^2} \sum \frac{x_i y_i}{\sigma_{yi}^2} \right] \\
 \Delta &= \sum \frac{1}{\sigma_{yi}^2} \sum \frac{x_i^2}{\sigma_{yi}^2} - \left(\sum \frac{x_i}{\sigma_{yi}^2} \right)^2
 \end{aligned} \right.$$

Ajuste de cuadrados mínimos pesado con la incertidumbre

Si $\sigma_{y_i} = \sigma_i$ son distintos

$$w_i = \frac{1}{\sigma_i^2}$$

$$\Delta = \sum w \sum wx^2 - (\sum wx)^2$$

$$\Delta = N \sum x^2 - (\sum x)^2$$

$$\sigma_A = \sigma_y \sqrt{\frac{\sum x^2}{\Delta}}$$

$$\sigma_B = \sigma_y \sqrt{\frac{N}{\Delta}}$$

$$\sigma_A = \sigma_y \sqrt{\frac{\sum wx^2}{\Delta}}$$

$$\sigma_B = \sigma_y \sqrt{\frac{\sum w}{\Delta}}$$

Estimadores de la validez del modelo

- r : permite evaluar el grado de correlación lineal entre las dos variables
- R^2 : permite evaluar la validez de determinada dependencia funcional (=del ajuste que hicimos) entre las variables
- χ^2 reducido: mide la suma cuadrática de residuos. permite comparar dos ajustes distintos realizados sobre el mismo set de datos.

Coeficiente r de correlación lineal de Pearson

- Covarianza: cuantificación de la varianza conjunta de dos variables

$$\bar{x} = \frac{\sum_{i=1}^n x_i}{n}, \quad \bar{y} = \frac{\sum_{i=1}^n y_i}{n}, \quad S_X^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n}, \quad S_Y^2 = \frac{\sum_{i=1}^n (y_i - \bar{y})^2}{n}, \quad S_{XY} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{n}.$$

Promedio en x

Promedio en y

Varianza en x (SD²)

Varianza en y

Covarianza: ⁿ aumenta cuando la dispersión “va de la mano” en ambas variables

Coeficiente r de correlación lineal de Pearson

- Covarianza: cuantificación de la varianza conjunta de dos variables

$$\bar{x} = \frac{\sum_{i=1}^n x_i}{n}, \quad \bar{y} = \frac{\sum_{i=1}^n y_i}{n}, \quad S_X^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n}, \quad S_Y^2 = \frac{\sum_{i=1}^n (y_i - \bar{y})^2}{n}, \quad S_{XY} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{n}.$$

Promedio en x

Promedio en y

Varianza en x (SD²)

Varianza en y

Covarianza: ⁿ aumenta cuando la dispersión “va de la mano” en ambas variables

$$r = \frac{S_{XY}}{S_X S_Y},$$

Coeficiente r de correlación lineal de Pearson

- Covarianza: cuantificación de la varianza conjunta de dos variables

$$\bar{x} = \frac{\sum_{i=1}^n x_i}{n}, \quad \bar{y} = \frac{\sum_{i=1}^n y_i}{n}, \quad S_X^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n}, \quad S_Y^2 = \frac{\sum_{i=1}^n (y_i - \bar{y})^2}{n}, \quad S_{XY} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{n}.$$

Promedio en x

Promedio en y

Varianza en x (SD²)

Varianza en y

Covarianza: aumenta cuando la dispersión “va de la mano” en ambas variables






$$r = \frac{S_{XY}}{S_X S_Y}$$

- No tiene dimensión, y siempre toma valores en [-1,1].
- Si r=1 o r=-1 la relación es perfectamente lineal
- Si las variables son independientes, entonces r=0, pero el inverso no tiene por qué ser cierto.
- Si r > 0, esto indica una relación directa entre las variables (si aumenta X, también aumenta Y).
- Si r < 0, la correlación entre las variables es inversa (si aumenta una, la otra disminuye).

Coeficiente r de correlación lineal de Pearson

$$r = \frac{S_{XY}}{S_X S_Y},$$

$$r = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2 \sum (y_i - \bar{y})^2}}.$$




R² (R-square): Coeficiente de determinación

$$SS_{\text{tot}} = \sum_i (y_i - \bar{y})^2 \quad SS_{\text{res}} = \sum_i (y_i - f_i)^2 = \sum_i e_i^2$$

Varianza en y (sin N) Suma cuadrática de los residuos

$$R^2 = 1 - \frac{SS_{\text{res}}}{SS_{\text{tot}}}$$



Mide si pesa más la correlación entre los puntos o su dispersión

Mientras más cercano a 1 mejor es el ajuste
 En una regresión lineal $R^2 = r^2$

χ_v^2 (reduced chi-square)

$$\chi_v^2 = \frac{1}{\nu} \sum_i \frac{(y_i - f_i)^2}{\sigma_{y_i}^2}$$


Equivale a la suma cuadrática de residuos ponderada por la incerteza en y de cada punto y dividido el número de grados de libertad (ν)

$\nu =$ número de mediciones (N) - número de parámetros

Los métodos de regresión no-lineal buscan minimizar esa cantidad

Retomando el ejemplo:

- Aplicamos una regresión lineal por cuadrados mínimos y obtuvimos: $f(x)=a.x+b$



Parameters			
		Value	Standard Error
T ²	Intercept	0.00197	0.05303
	Slope	3.85968	0.12218

Statistics	
	T ²
Number of Points	10
Degrees of Freedom	8
Reduced Chi-Sqr	0.20082
Residual Sum of Squares	1.60659
Pearson's r	0.99602
R Value	0.99602
R-Square(COD)	0.99205
Adj. R-Square	0.99105

$$a = (3.86 \pm 0.12)$$

$$b = (0.002 \pm 0.053)$$


pregunta: ¿unidad?

$$r = 0.99602$$

$$R^2 = 0.99205$$


Retomando el ejemplo:

- Aplicamos una regresión lineal por cuadrados obtuvimos: $f(x)=a.x+b$



Parameters		Value
T ²	Intercept	0.0019
	Slope	3.8596

Statistics		T ²
Number of Points		10
Degrees of Freedom		8
Reduced Chi-Sqr		0.20082
Residual Sum of Squares		1.60659
Pearson's r		0.99602
R Value		0.99602
R-Square(COD)		0.99205
Adj. R-Square		0.99105



pregunta:¿unidad?

r= 0.99602
R²= 0.99205

Retomando el ejemplo:

$$a = (3.86 \pm 0.12) \text{ s}^2/\text{m}$$

$$b = (0.002 \pm 0.053) \text{ s}^2$$

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

- ¿Cómo obtener **g** a partir de la pendiente? Valor central y prop. de errores
- ¿Qué rol cumplen **a** y **b** en el modelo de péndulo simple? $T^2 = \frac{4\pi^2}{g} L$

- Cálculo **g**: $g(a) = \frac{4\pi^2}{a}$

- Propagación de errores: $\Delta g = \left| \frac{dg(a)}{da} \right| \Delta a$

$$\Delta g = \frac{4\pi^2}{a^2} \Delta a$$

Retomando el ejemplo:

$$a = (3.86 \pm 0.12) \text{ s}^2/\text{m}$$

$$b = (0.002 \pm 0.053) \text{ s}^2$$

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

- ¿Cómo obtener **g** a partir de la pendiente? Valor central y prop. de errores
- ¿Qué rol cumplen **a** y **b** en el modelo de péndulo simple? $T^2 = \frac{4\pi^2}{g} L$

- Cálculo **g**:

$$g(a) = \frac{4\pi^2}{a}$$

- Propagación de errores:

$$\Delta g = \left| \frac{dg(a)}{da} \right| \Delta a$$

$$\Delta g = \frac{4\pi^2}{a^2} \Delta a$$

El parámetro **b** no interviene en el cálculo.

De todos modos da información sobre la validez del modelo.

Comparación entre regresión lineal y cálculo dato a dato:

- Opción 1: calcular g para cada una de las N mediciones. Promediar y calcular SD.

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

$$g(L, T) = \frac{4\pi^2}{T^2} L$$

$$\Delta g_{\text{inst}} = \sqrt{\left(\frac{dg(L, T)}{dL} \Delta L\right)^2 + \left(\frac{dg(L, T)}{dT} \Delta T\right)^2}$$

$$\Delta g_{\text{inst}} = \sqrt{\left(\frac{4\pi^2}{T^2} \Delta L\right)^2 + \left(2\frac{4\pi^2}{T^3} L \Delta T\right)^2}$$

$$\Delta g_{\text{inst}} = \sqrt{\left(\frac{4\pi^2}{T^2} \Delta L\right)^2 + \left(2\frac{g}{T} \Delta T\right)^2}$$

$$\Delta g = \sqrt{\Delta g_{\text{inst}}^2 + \left(\frac{\sigma}{\sqrt{N}}\right)^2}$$

- Nota: calcular g con una única medición de T y L ofrece con poca exactitud. No tiene en cuenta la fluctuación estadística.
- Opción 2: obtenerlo a partir de la regresión lineal.

Experimento 4: Determinación de g

- Leemos guía
- Debate:
 - Criterios para medir T y L
 - Incertezas de T y L
 - ¿Cuántas configuraciones distintas tomar para L ?