

# Física Experimental / Laboratorio I

## Clase #3

# Promedios pesados

El problema?: cómo combinar dos mediciones independientes de *la misma* cantidad física:

$$x = x_A \pm \sigma_A$$

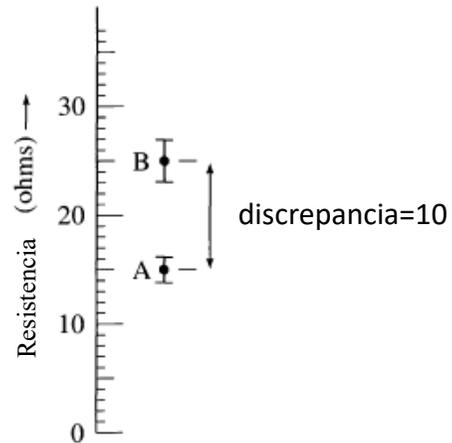
$$x = x_B \pm \sigma_B.$$

# Promedios pesados

El problema?: cómo combinar dos mediciones independientes de *la misma* cantidad física:

$$x = x_A \pm \sigma_A$$

$$x = x_B \pm \sigma_B.$$



Caso #1: Mediciones *inconsistentes*

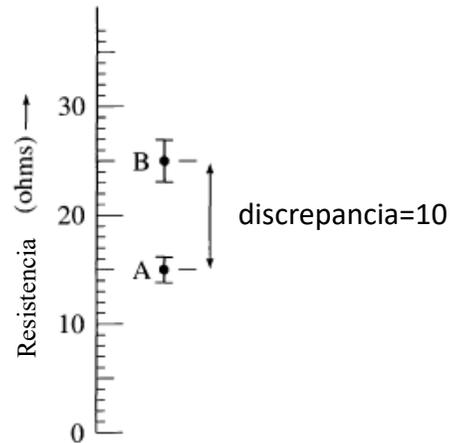
$$|x_A - x_B| \gg \sigma_A, \sigma_B$$

# Promedios pesados

El problema?: cómo combinar dos mediciones independientes de *la misma* cantidad física:

$$x = x_A \pm \sigma_A$$

$$x = x_B \pm \sigma_B$$



Caso #1: Mediciones *inconsistentes*

$$|x_A - x_B| \gg \sigma_A, \sigma_B$$



$$x_{exp} = (x_A + x_B) / 2$$

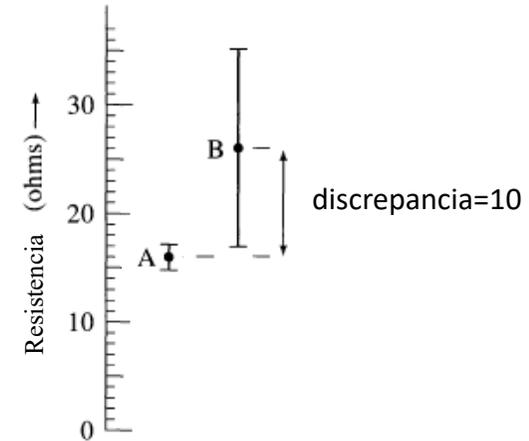
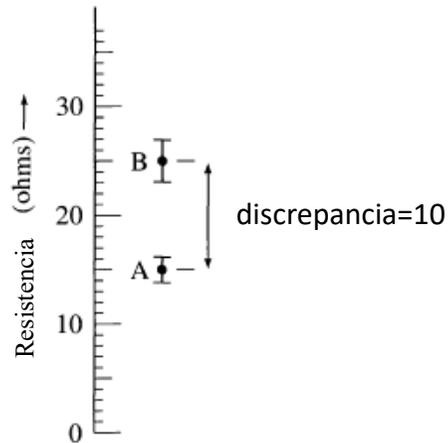
$$\sigma_x = |x_A - x_B| / 2$$

# Promedios pesados

El problema?: cómo combinar dos mediciones independientes de *la misma* cantidad física:

$$x = x_A \pm \sigma_A$$

$$x = x_B \pm \sigma_B$$



Caso #1: Mediciones *inconsistentes*

$$|x_A - x_B| \gg \sigma_A, \sigma_B$$



$$x_{exp} = (x_A + x_B) / 2$$

$$\sigma_x = |x_A - x_B| / 2$$

Caso #2: Mediciones **consistentes**

$$|x_A - x_B| \not\gg \sigma_A, \sigma_B$$

## Promedios pesados

$$Prob(x_A) \propto \frac{1}{\sigma_A} e^{-(x_A - X)^2 / 2\sigma_A^2}$$

$$Prob(x_B) \propto \frac{1}{\sigma_B} e^{-(x_B - X)^2 / 2\sigma_B^2}$$

## Promedios pesados

$$Prob(x_A) \propto \frac{1}{\sigma_A} e^{-(x_A - X)^2 / 2\sigma_A^2}$$

$$Prob(x_B) \propto \frac{1}{\sigma_B} e^{-(x_B - X)^2 / 2\sigma_B^2}$$

Suponiendo que ambos experimentos son independientes,

$$Prob(x_A, x_B) = Prob(x_A) \times Prob(x_B) \propto \frac{1}{\sigma_A \sigma_B} e^{-\chi^2 / 2}$$

donde  $\chi^2 = \left( \frac{x_A - X}{\sigma_A} \right)^2 + \left( \frac{x_B - X}{\sigma_B} \right)^2$

# Promedios pesados

$$Prob(x_A) \propto \frac{1}{\sigma_A} e^{-(x_A - X)^2 / 2\sigma_A^2}$$

$$Prob(x_B) \propto \frac{1}{\sigma_B} e^{-(x_B - X)^2 / 2\sigma_B^2}$$

Suponiendo que ambos experimentos son independientes,

$$Prob(x_A, x_B) = Prob(x_A) \times Prob(x_B) \propto \frac{1}{\sigma_A \sigma_B} e^{-\chi^2 / 2}$$

donde  $\chi^2 = \left( \frac{x_A - X}{\sigma_A} \right)^2 + \left( \frac{x_B - X}{\sigma_B} \right)^2$

Aplicando el principio de máxima verosimilitud, maximizar  $Prob(x_A, x_B)$  es equivalente a *minimizar*  $\chi^2$  (por eso se llama “método de cuadrados mínimos”):

$$\frac{x_A - X}{\sigma_A^2} + \frac{x_B - X}{\sigma_B^2} = 0 \quad \longrightarrow \quad (\text{mejor estimador de } X) = \left( \frac{x_A}{\sigma_A^2} + \frac{x_B}{\sigma_B^2} \right) / \left( \frac{1}{\sigma_A^2} + \frac{1}{\sigma_B^2} \right)$$

# Promedios pesados

$$Prob(x_A) \propto \frac{1}{\sigma_A} e^{-(x_A - X)^2 / 2\sigma_A^2}$$

$$Prob(x_B) \propto \frac{1}{\sigma_B} e^{-(x_B - X)^2 / 2\sigma_B^2}$$

Suponiendo que ambos experimentos son independientes,

$$Prob(x_A, x_B) = Prob(x_A) \times Prob(x_B) \propto \frac{1}{\sigma_A \sigma_B} e^{-\chi^2 / 2}$$

donde 
$$\chi^2 = \left( \frac{x_A - X}{\sigma_A} \right)^2 + \left( \frac{x_B - X}{\sigma_B} \right)^2$$

Aplicando el principio de máxima verosimilitud, maximizar  $Prob(x_A, x_B)$  es equivalente a *minimizar*  $\chi^2$  (por eso se llama "método de cuadrados mínimos"):

$$\frac{x_A - X}{\sigma_A^2} + \frac{x_B - X}{\sigma_B^2} = 0 \quad \longrightarrow \quad (\text{mejor estimador de } X) = \left( \frac{x_A}{\sigma_A^2} + \frac{x_B}{\sigma_B^2} \right) / \left( \frac{1}{\sigma_A^2} + \frac{1}{\sigma_B^2} \right)$$

Si definimos los "pesos"  $w_A = 1/\sigma_A^2$  y  $w_B = 1/\sigma_B^2$ :  $\longrightarrow$  (mejor estimador de  $X$ ) = 
$$\frac{w_A x_A + w_B x_B}{w_A + w_B}$$

En general

$$x_{pp} = \frac{\sum w_i x_i}{\sum w_i}$$

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

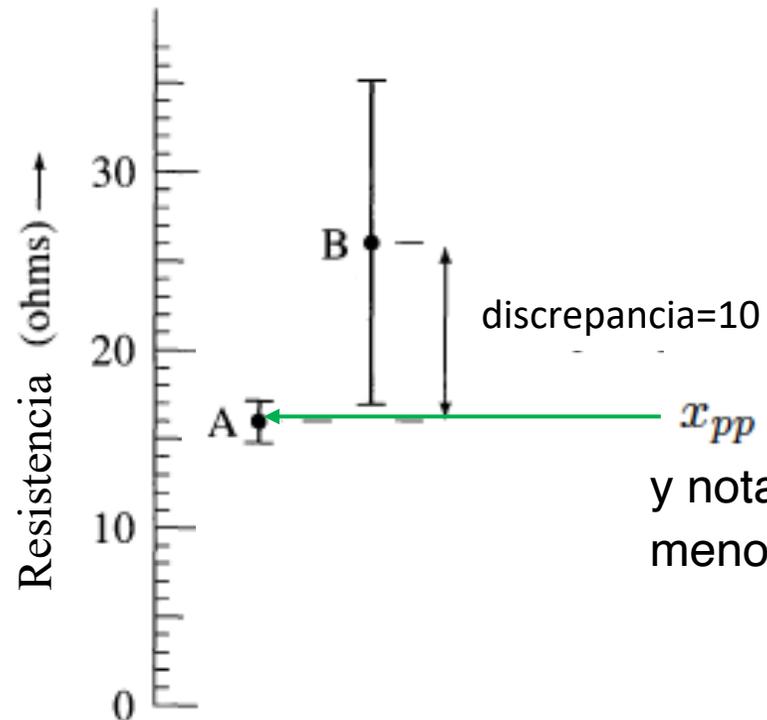
y  $\sigma_{pp} = \frac{1}{\sqrt{\sum w_i}}$

# Promedios pesados

El problema?: cómo combinar dos mediciones independientes de *la misma* cantidad física:

$$x = x_A \pm \sigma_A$$

$$x = x_B \pm \sigma_B$$



y notar que  $\sigma_{pp}$  es menor al menor de los dos,  $\sigma_A$  y  $\sigma_B$

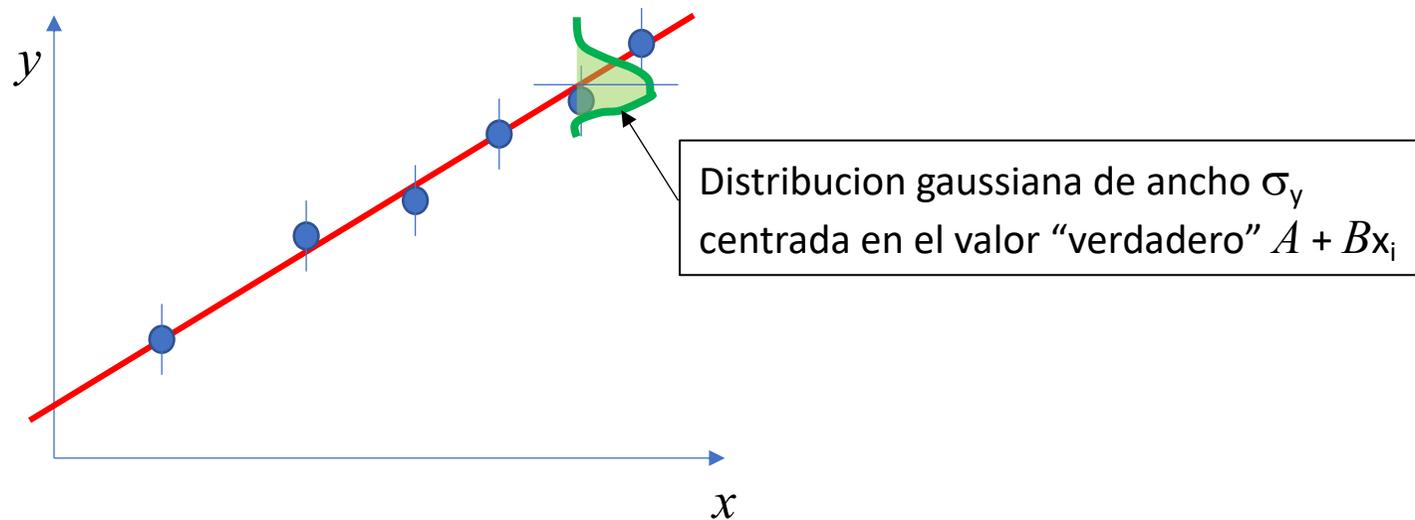
Caso #2: Mediciones **consistentes**

$$|x_A - x_B| \ll \sigma_A, \sigma_B$$

# Ajuste por cuadrados mínimos

Objetivo: encontrar la mejor línea recta  $y = A^* + B^*x$  que ajuste un conjunto de pares de puntos medidos  $(x_1, y_1), \dots, (x_N, y_N)$ .

Para simplificar supondremos que las mediciones de  $y$  están afectadas por incertezas, pero las de  $x$  no. Y supondremos que las incertezas en  $y$  siguen una distribución gaussiana, todas con *el mismo ancho*  $\sigma_y$ .



# Ajuste por cuadrados mínimos

La probabilidad de obtener un dado par de valores  $(x_i, y_i)$  se obtiene como:

$$Prob_{A,B}(y_i) \propto \frac{1}{\sigma_y} e^{-(y_i - A - Bx_i)^2 / 2\sigma_y^2}$$

Entonces la probabilidad de obtener el conjunto completo de mediciones  $y_1, \dots, y_N$ , entendidas como independientes es

$$Prob_{A,B}(y_1, \dots, y_N) \propto \frac{1}{\sigma_y^N} e^{-\chi^2/2} \quad \text{con} \quad \chi^2 = \sum_{i=1}^N \frac{(y_i - A - Bx_i)^2}{\sigma_y^2}$$

## Ajuste por cuadrados mínimos: determinación de $A^*$ y $B^*$ , y de sus incertezas

Los mejores estimadores para  $A$  y  $B$  son aquellos que maximizan esta probabilidad, y por lo tanto minimizan  $\chi^2$ . Para encontrarlos diferenciamos  $\chi^2$  respecto a  $A$  y  $B$ , e igualamos a cero:

$$\frac{\partial \chi^2}{\partial A} = \frac{-2}{\sigma_y^2} \sum_{i=1}^N (y_i - A - Bx_i) = 0 \quad \text{y} \quad \frac{\partial \chi^2}{\partial B} = \frac{-2}{\sigma_y^2} \sum_{i=1}^N x_i (y_i - A - Bx_i) = 0$$

## Ajuste por cuadrados mínimos: determinación de $A^*$ y $B^*$ , y de sus incertezas

Los mejores estimadores para  $A$  y  $B$  son aquellos que maximizan esta probabilidad, y por lo tanto minimizan  $\chi^2$ . Para encontrarlos diferenciamos  $\chi^2$  respecto a  $A$  y  $B$ , e igualamos a cero:

$$\frac{\partial \chi^2}{\partial A} = \frac{-2}{\sigma_y^2} \sum_{i=1}^N (y_i - A - Bx_i) = 0 \quad \text{y} \quad \frac{\partial \chi^2}{\partial B} = \frac{-2}{\sigma_y^2} \sum_{i=1}^N x_i (y_i - A - Bx_i) = 0$$

Estas corresponden a un sistema de dos ecuaciones para las dos incógnitas  $A$  y  $B$ ,

$$AN + B \sum x_i = \sum y_i$$

$$A \sum x_i + B \sum x_i^2 = \sum x_i y_i$$

de donde

$$A^* = \frac{\sum x^2 \sum y - \sum x \sum xy}{\Delta}$$

$$B^* = \frac{N \sum xy - \sum x \sum y}{\Delta}$$

con

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

# Ajuste por cuadrados mínimos: determinación de $A^*$ y $B^*$ , y de sus incertezas

Los mejores estimadores para  $A$  y  $B$  son aquellos que maximizan esta probabilidad, y por lo tanto minimizan  $\chi^2$ . Para encontrarlos diferenciamos  $\chi^2$  respecto a  $A$  y  $B$ , e igualamos a cero:

$$\frac{\partial \chi^2}{\partial A} = \frac{-2}{\sigma_y^2} \sum_{i=1}^N (y_i - A - Bx_i) = 0 \quad \text{y} \quad \frac{\partial \chi^2}{\partial B} = \frac{-2}{\sigma_y^2} \sum_{i=1}^N x_i (y_i - A - Bx_i) = 0$$

Estas corresponden a un sistema de dos ecuaciones para las dos incógnitas  $A$  y  $B$ ,

$$AN + B \sum x_i = \sum y_i$$

$$A \sum x_i + B \sum x_i^2 = \sum x_i y_i$$

de donde

$$A^* = \frac{\sum x^2 \sum y - \sum x \sum xy}{\Delta}$$

$$B^* = \frac{N \sum xy - \sum x \sum y}{\Delta}$$

con

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

Los estimadores de  $A$  y  $B$  resultan ser funciones simples de los  $y_i$ . Sus incertezas pueden entonces encontrarse simplemente propagando errores:

$$\sigma_{A^*} = \sigma_y \sqrt{\frac{\sum x^2}{\Delta}}$$

$$\sigma_{B^*} = \sigma_y \sqrt{\frac{N}{\Delta}}$$

## Ajuste por cuadrados mínimos: determinación de $\sigma_y$

La incerteza en  $y$  podría obtenerse de medir repetidas veces la cantidad  $y_i$  para un dado  $x_i$ . Por otro lado, es intuitivo pensar que lo mismo se puede lograr usando el conjunto ya obtenido de pares  $(x_1, y_1), \dots, (x_N, y_N)$  haciendo:

$$\sigma_y = \sqrt{\frac{1}{N} \sum (y_i - A - Bx_i)^2}$$

Esta expresión puede también encontrarse con el principio de máxima verosimilitud, diferenciando respecto a  $\sigma_y$ .

## Ajuste por cuadrados mínimos: determinación de $\sigma_y$

La incerteza en  $y$  podría obtenerse de medir repetidas veces la cantidad  $y_i$  para un dado  $x_i$ . Por otro lado, es intuitivo pensar que lo mismo se puede lograr usando el conjunto ya obtenido de pares  $(x_1, y_1), \dots, (x_N, y_N)$  haciendo:

$$\sigma_y = \sqrt{\frac{1}{N} \sum (y_i - A - Bx_i)^2}$$

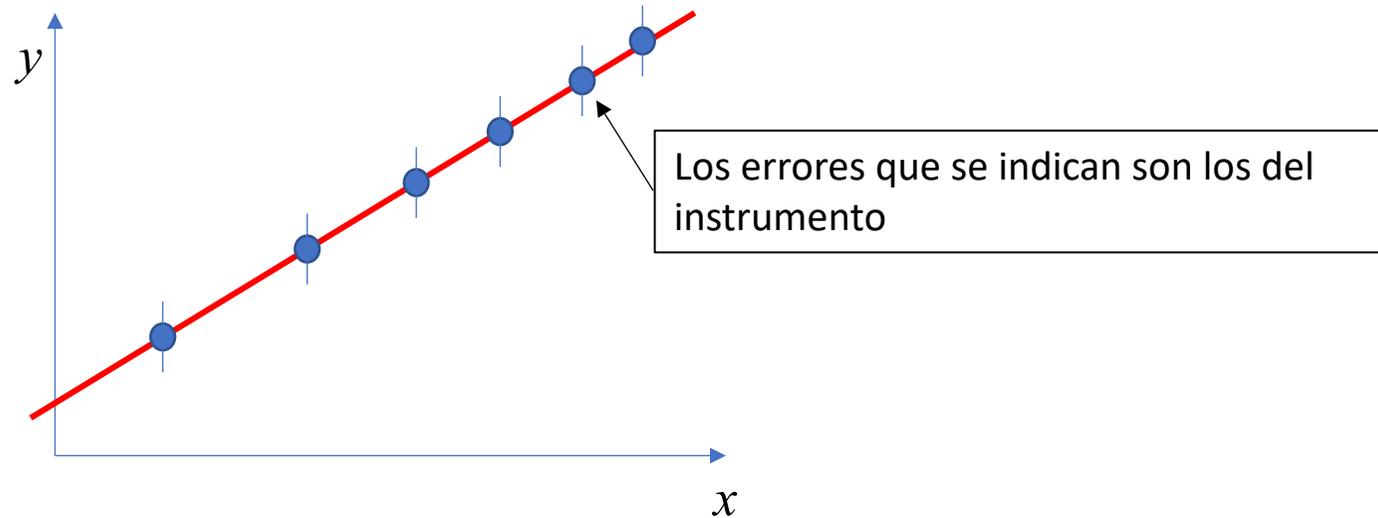
Esta expresión puede también encontrarse con el principio de máxima verosimilitud, diferenciando respecto a  $\sigma_y$ .

El problema igual que antes es que no conocemos a  $A$  y  $B$ , sino a sus estimadores. Se puede demostrar que la expresión correcta cuando se usan los estimadores es:

$$\sigma_y = \sqrt{\frac{1}{N-2} \sum (y_i - A^* - B^*x_i)^2}$$

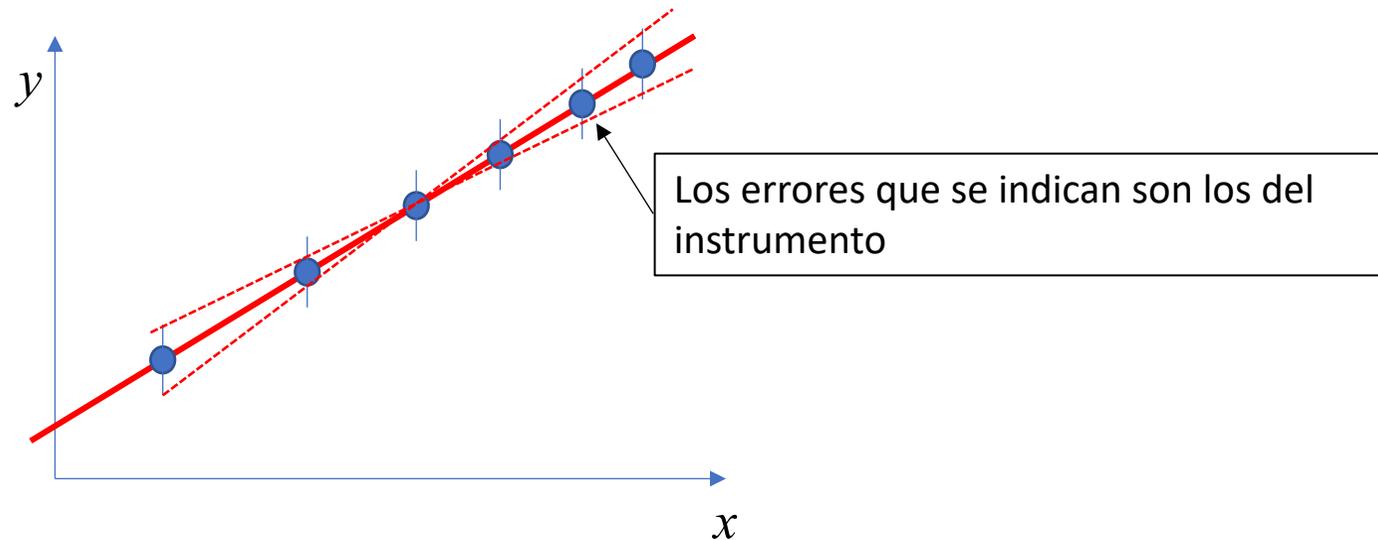
# Cómo tener en cuenta los errores sistemáticos/instrumentales?

Puede ocurrir que los errores del ajuste sean mínimos comparado con los errores sistemáticos:



# Cómo tener en cuenta los errores sistemáticos/instrumentales?

Puede ocurrir que los errores del ajuste sean mínimos comparado con los errores sistemáticos:



Sugerencia 1: estimar la máxima y mínima pendiente posible compatible con esas incertezas

Sugerencia 2: elegir un valor de  $x$  en la mitad de la escala y propagar para ese valor las incertezas de los instrumentos utilizados

$$\frac{\delta B_{inst}}{B} = \sqrt{\left(\frac{\delta y_{inst}}{y}\right)^2 + \left(\frac{\delta x_{inst}}{x}\right)^2}$$

En ambos casos

$$\delta B = \sqrt{(\delta B_{ajuste})^2 + (\delta B_{inst})^2}$$

# Covarianza

Buscamos evaluar  $q(x,y)$

Medimos dos cantidades  $x$  e  $y$ , obteniendo  $N$  pares  $(x_1, y_1), \dots, (x_N, y_N)$ .

De las  $N$  mediciones  $x_1, \dots, x_N$  se puede computar  $\bar{x}$  y  $\sigma_x$ ,

De las mediciones  $y_1, \dots, y_N$  se puede computar  $\bar{y}$  y  $\sigma_y$ .

De manera similar, podemos calcular  $N$  veces  $q_i = q(x_i, y_i)$ , y de ahí  $\bar{q}$  y  $\sigma_q$ .

# Covarianza

Buscamos evaluar  $q(x,y)$

Medimos dos cantidades  $x$  e  $y$ , obteniendo  $N$  pares de  $(x_1, y_1), \dots, (x_N, y_N)$ .

De las  $N$  mediciones  $x_1, \dots, x_N$  se puede computar  $\bar{x}$  y  $\sigma_x$ ,

De las mediciones  $y_1, \dots, y_N$  se puede computar  $\bar{y}$  y  $\sigma_y$ .

De manera similar, podemos calcular  $N$  veces  $q_i = q(x_i, y_i)$ , y de ahí  $\bar{q}$  y  $\sigma_q$ .

Suponemos que las incertezas son pequeñas, y que por lo tanto los  $x_i$  están cerca de  $\bar{x}$  y los  $y_i$  están cerca de  $\bar{y}$ . Entonces:

$$q_i = q(x_i, y_i) \\ \approx q(\bar{x}, \bar{y}) + \frac{\partial q}{\partial x}(x_i - \bar{x}) + \frac{\partial q}{\partial y}(y_i - \bar{y})$$

Las derivadas parciales son evaluadas en  $\bar{x}$  y en  $\bar{y}$ , y por lo tanto son constantes y las mismas para todo  $i$ .

# Covarianza

Buscamos evaluar  $q(x, y)$

Medimos dos cantidades  $x$  e  $y$ , obteniendo  $N$  pares de  $(x_1, y_1), \dots, (x_N, y_N)$ .

De las  $N$  mediciones  $x_1, \dots, x_N$  se puede computar  $\bar{x}$  y  $\sigma_x$ ,

De las mediciones  $y_1, \dots, y_N$  se puede computar  $\bar{y}$  y  $\sigma_y$ .

De manera similar, podemos calcular  $N$  veces  $q_i = q(x_i, y_i)$ , y de ahí  $\bar{q}$  y  $\sigma_q$ .

Suponemos que las incertezas son pequeñas, y que por lo tanto los  $x_i$  están cerca de  $\bar{x}$  y los  $y_i$  están cerca de  $\bar{y}$ . Entonces:

$$\begin{aligned} q_i &= q(x_i, y_i) \\ &\approx q(\bar{x}, \bar{y}) + \frac{\partial q}{\partial x}(x_i - \bar{x}) + \frac{\partial q}{\partial y}(y_i - \bar{y}) \end{aligned}$$

Las derivadas parciales son evaluadas en  $\bar{x}$  y en  $\bar{y}$ , y por lo tanto son constantes y las mismas para todo  $i$ . Entonces

$$\begin{aligned} \bar{q} &= \frac{1}{N} \sum_{i=1}^N q_i \\ &= \frac{1}{N} \sum_{i=1}^N \left[ q(\bar{x}, \bar{y}) + \frac{\partial q}{\partial x}(x_i - \bar{x}) + \frac{\partial q}{\partial y}(y_i - \bar{y}) \right] = q(\bar{x}, \bar{y}) \end{aligned}$$

# Covarianza

La desviación estándar para los  $N$  valores  $q_i$  es entonces

$$\begin{aligned}\sigma_q^2 &= \frac{1}{N-1} \sum (q_i - \bar{q})^2 = \frac{1}{N-1} \sum \left[ \frac{\partial q}{\partial x} (x_i - \bar{x}) + \frac{\partial q}{\partial y} (y_i - \bar{y}) \right]^2 \\ &= \left( \frac{\partial q}{\partial x} \right)^2 \frac{1}{N-1} \sum (x_i - \bar{x})^2 + \left( \frac{\partial q}{\partial y} \right)^2 \frac{1}{N-1} \sum (y_i - \bar{y})^2 \\ &\quad + 2 \frac{\partial q}{\partial x} \frac{\partial q}{\partial y} \frac{1}{N-1} \sum (x_i - \bar{x})(y_i - \bar{y})\end{aligned}$$

# Covarianza

La desviación estándar para los  $N$  valores  $q_i$  es entonces

$$\begin{aligned}\sigma_q^2 &= \frac{1}{N-1} \sum (q_i - \bar{q})^2 = \frac{1}{N-1} \sum \left[ \frac{\partial q}{\partial x} (x_i - \bar{x}) + \frac{\partial q}{\partial y} (y_i - \bar{y}) \right]^2 \\ &= \left( \frac{\partial q}{\partial x} \right)^2 \frac{1}{N-1} \sum (x_i - \bar{x})^2 + \left( \frac{\partial q}{\partial y} \right)^2 \frac{1}{N-1} \sum (y_i - \bar{y})^2 \\ &\quad + 2 \frac{\partial q}{\partial x} \frac{\partial q}{\partial y} \frac{1}{N-1} \sum (x_i - \bar{x})(y_i - \bar{y})\end{aligned}$$

de donde

$$\sigma_q^2 = \left( \frac{\partial q}{\partial x} \right)^2 \sigma_x^2 + \left( \frac{\partial q}{\partial y} \right)^2 \sigma_y^2 + 2 \frac{\partial q}{\partial x} \frac{\partial q}{\partial y} \sigma_{xy}$$

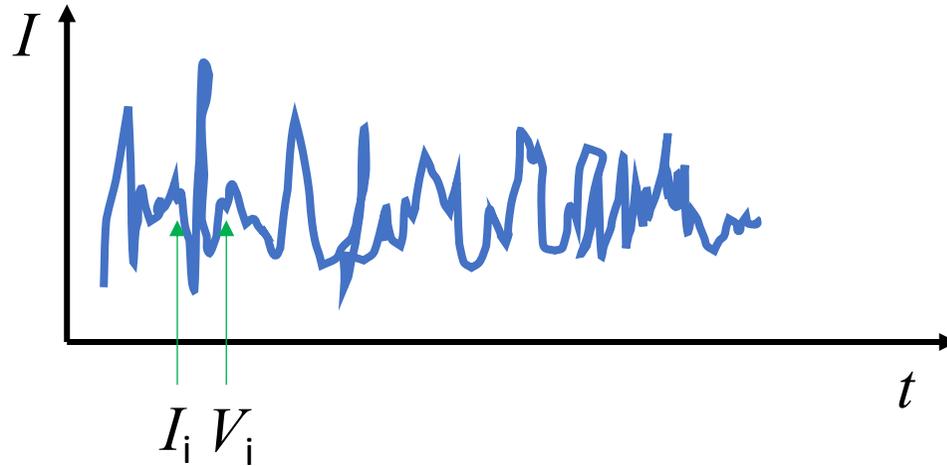
con la “covarianza” definida como

$$\sigma_{xy} = \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})$$

# Ejemplo #1: Resistencia y potencia en el método de 4 puntas

Buscamos medir una resistencia  $R$  como  $R = V/I$ , y la potencia disipada como  $P = V.I$

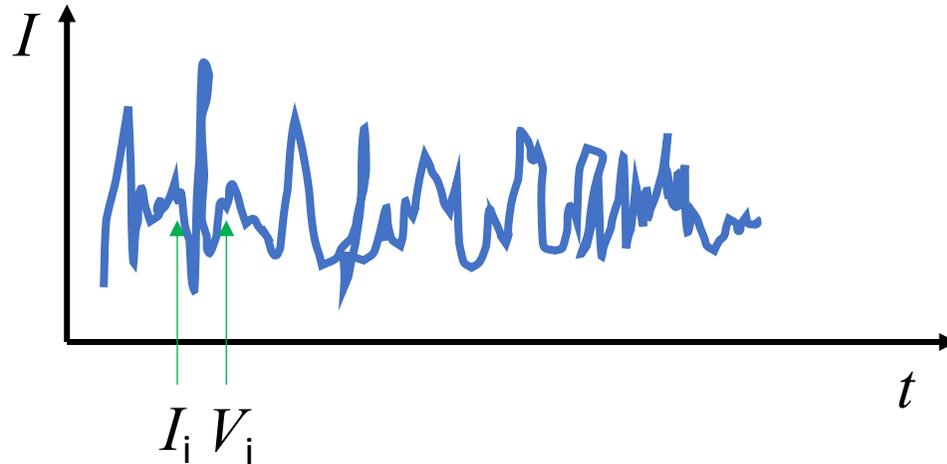
Caso #1: las fluctuaciones en la corriente son tan *rápidas* que al medir la tensión ambas incertezas son ***independientes***



## Ejemplo #1: Resistencia y potencia en el método de 4 puntas

Buscamos medir una resistencia  $R$  como  $R = V/I$ , y la potencia disipada como  $P = V.I$

Caso #1: las fluctuaciones en la corriente son tan *rápidas* que al medir la tensión ambas incertezas son ***independientes***



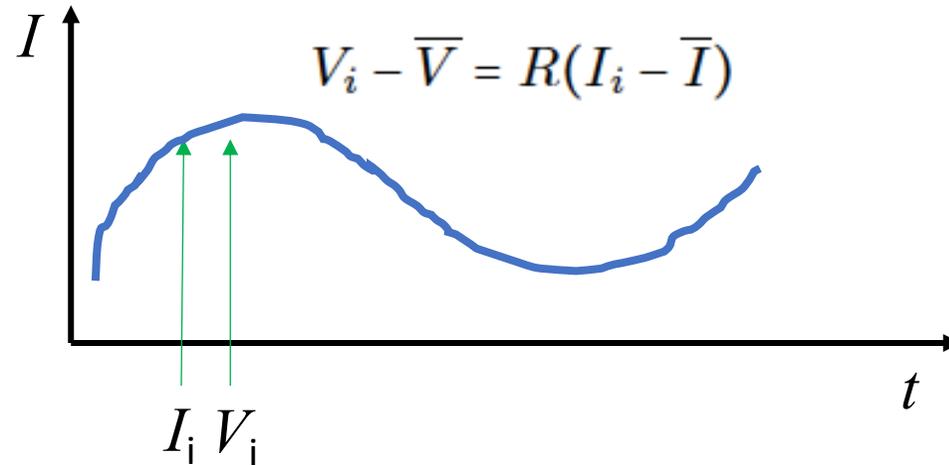
$$(\delta R)^2 = \frac{1}{I^2} \delta V^2 + \left( \frac{V}{I^2} \right)^2 \delta I^2 = \frac{1}{I^2} (\delta V^2 + R^2 \delta I^2)$$

$$(\delta P)^2 = I^2 \delta V^2 + V^2 \delta I^2 = I^2 (\delta V^2 + R^2 \delta I^2)$$

# Ejemplo #1: Resistencia y potencia en el método de 4 puntas

Buscamos medir una resistencia  $R$  como  $R = V/I$ , y la potencia disipada como  $P = V.I$

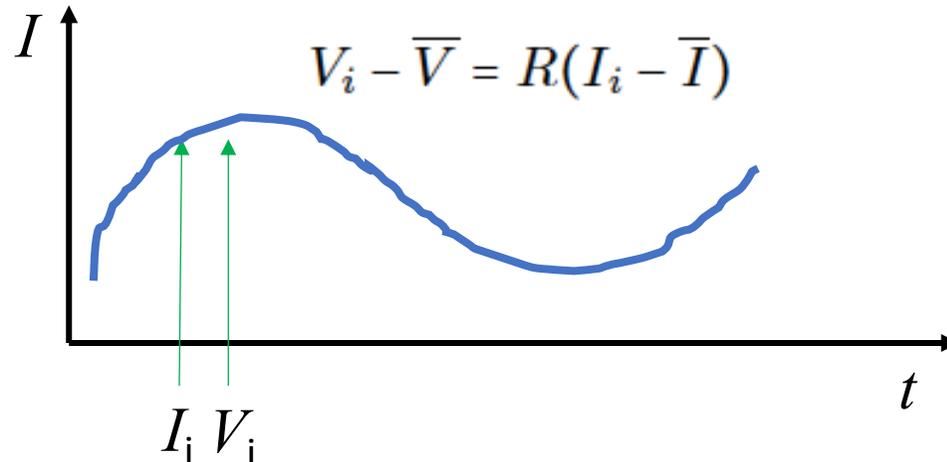
Caso #2: las fluctuaciones en la corriente son tan *lentas* que al medir la tensión ambas incertezas son **dependientes**



## Ejemplo #1: Resistencia y potencia en el método de 4 puntas

Buscamos medir una resistencia  $R$  como  $R = V/I$ , y la potencia disipada como  $P = V.I$

Caso #2: las fluctuaciones en la corriente son tan *lentas* que al medir la tensión ambas incertezas son **dependientes**

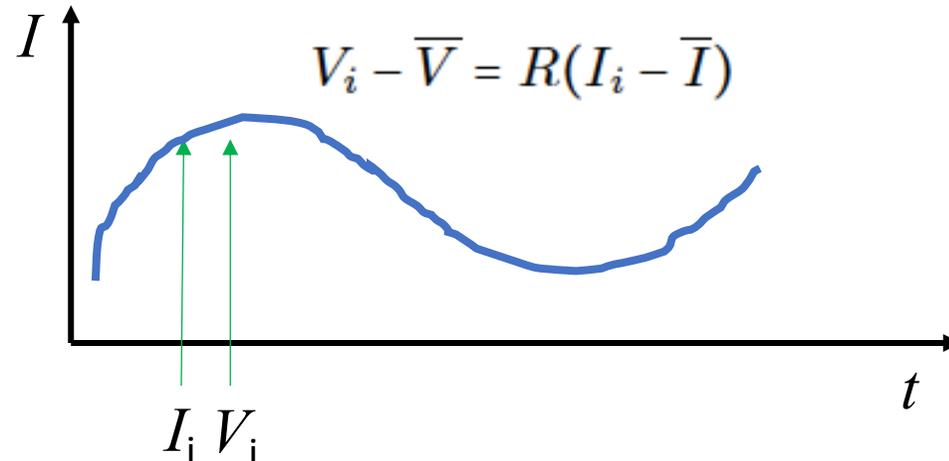


En este caso entonces  $\sigma_{VI}^2 = \frac{1}{N-1} \sum (V_i - \bar{V})(I_i - \bar{I}) = R\sigma_I^2$

## Ejemplo #1: Resistencia y potencia en el método de 4 puntas

Buscamos medir una resistencia  $R$  como  $R = V/I$ , y la potencia disipada como  $P = V.I$

Caso #2: las fluctuaciones en la corriente son tan *lentas* que al medir la tensión ambas incertezas son **dependientes**



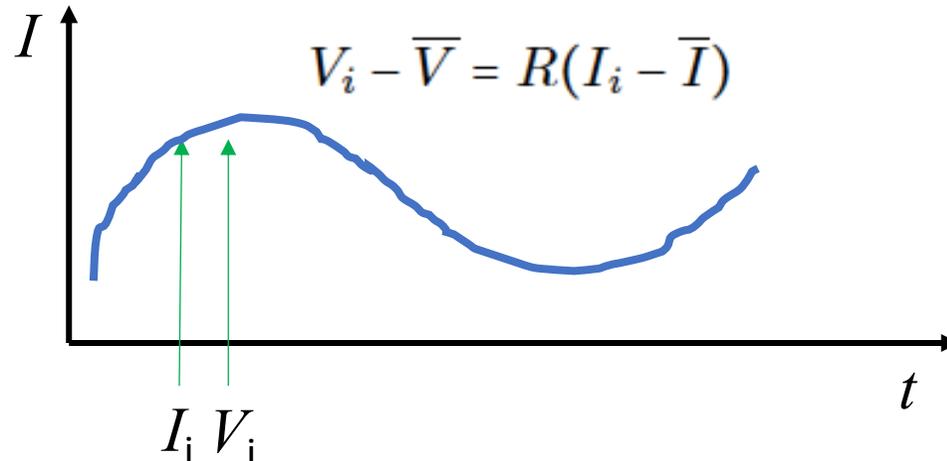
En este caso entonces  $\sigma_{VI}^2 = \frac{1}{N-1} \sum (V_i - \bar{V})(I_i - \bar{I}) = R\sigma_I^2$

$$\begin{aligned}(\delta R)^2 &= \frac{1}{I^2} (\delta V^2 + R^2 \delta I^2) + 2 \frac{1}{I} \left( -\frac{V}{I^2} \right) R \delta I^2 \\ &= \frac{R^2}{I^2} (2\delta I^2) - 2 \frac{VR}{I^3} \delta I^2 \\ &= \frac{R^2}{I^2} (2\delta I^2) - \frac{R^2}{I^2} (2\delta I^2) = 0!!\end{aligned}$$

## Ejemplo #1: Resistencia y potencia en el método de 4 puntas

Buscamos medir una resistencia  $R$  como  $R = V/I$ , y la potencia disipada como  $P = V.I$

Caso #2: las fluctuaciones en la corriente son tan *lentas* que al medir la tensión ambas incertezas son **dependientes**



En este caso entonces  $\sigma_{VI}^2 = \frac{1}{N-1} \sum (V_i - \bar{V})(I_i - \bar{I}) = R\sigma_I^2$

Mientras que

$$(\delta P)^2 = I^2 R^2 (2\delta I)^2 + 2VIR\delta I^2 = 4I^2 R^2 \delta I^2 \neq 0$$

Recordar que el caso no correlacionado era

$$(\delta P)^2 = I^2 \delta V^2 + V^2 \delta I^2 = I^2 (\delta V^2 + R^2 \delta I^2)$$

## Ejemplo #2: Correlaciones en el ajuste lineal

Consideremos un ajuste lineal por cuadrados mínimos  $y = a + bx$ , que resulta en los mejores estimadores

$$a^* = \frac{\sum x^2 \sum y - \sum x \sum xy}{N \sum x^2 - (\sum x)^2}$$

$$b^* = \frac{N \sum xy - \sum x \sum y}{N \sum x^2 - (\sum x)^2}$$

## Ejemplo #2: Correlaciones en el ajuste lineal

Consideremos un ajuste lineal por cuadrados mínimos  $y = a + bx$ , que resulta en los mejores estimadores

$$a^* = \frac{\sum x^2 \sum y - \sum x \sum xy}{N \sum x^2 - (\sum x)^2} \quad b^* = \frac{N \sum xy - \sum x \sum y}{N \sum x^2 - (\sum x)^2}$$

Consideremos el punto  $\bar{x} = \frac{\sum x}{N}$  y  $\bar{y} = \frac{\sum y}{N}$ . Entonces:

$$\begin{aligned} a^* + b^* \bar{x} &= \frac{\sum x^2 \sum y - \sum x \sum xy + \left[ \sum xy \sum x - (\sum x)^2 \frac{\sum y}{N} \right]}{N \sum x^2 - (\sum x)^2} \\ &= \frac{\sum y}{N} \left[ \frac{N \sum x^2 - (\sum x)^2}{N \sum x^2 - (\sum x)^2} \right] \\ &= \bar{y} \end{aligned}$$

## Ejemplo #2: Correlaciones en el ajuste lineal

Consideremos un ajuste lineal por cuadrados mínimos  $y = a + bx$ , que resulta en los mejores estimadores

$$a^* = \frac{\sum x^2 \sum y - \sum x \sum xy}{N \sum x^2 - (\sum x)^2} \quad b^* = \frac{N \sum xy - \sum x \sum y}{N \sum x^2 - (\sum x)^2}$$

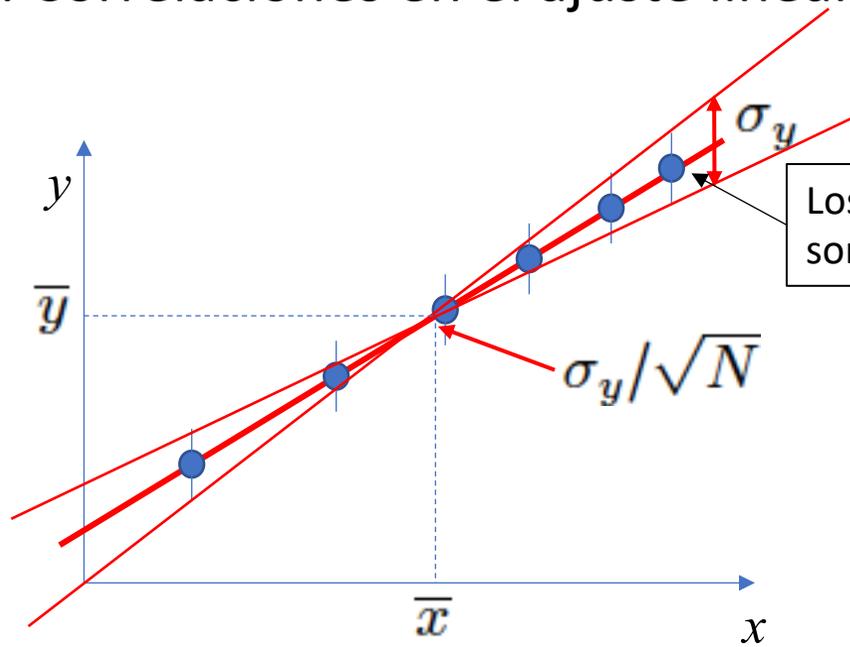
Consideremos el punto  $\bar{x} = \frac{\sum x}{N}$  y  $\bar{y} = \frac{\sum y}{N}$ . Entonces:

$$\begin{aligned} a^* + b^* \bar{x} &= \frac{\sum x^2 \sum y - \sum x \sum xy + \left[ \sum xy \sum x - (\sum x)^2 \frac{\sum y}{N} \right]}{N \sum x^2 - (\sum x)^2} \\ &= \frac{\sum y}{N} \left[ \frac{N \sum x^2 - (\sum x)^2}{N \sum x^2 - (\sum x)^2} \right] \\ &= \bar{y} \end{aligned}$$

Es decir: el punto  $(\bar{x}, \bar{y})$  es solución de la ecuación lineal ajustada.

Notar que sus fluctuaciones son del orden de  $\sigma_y / \sqrt{N}$ , mientras que las fluctuaciones de los puntos individuales son del orden de  $\sigma_y$ .

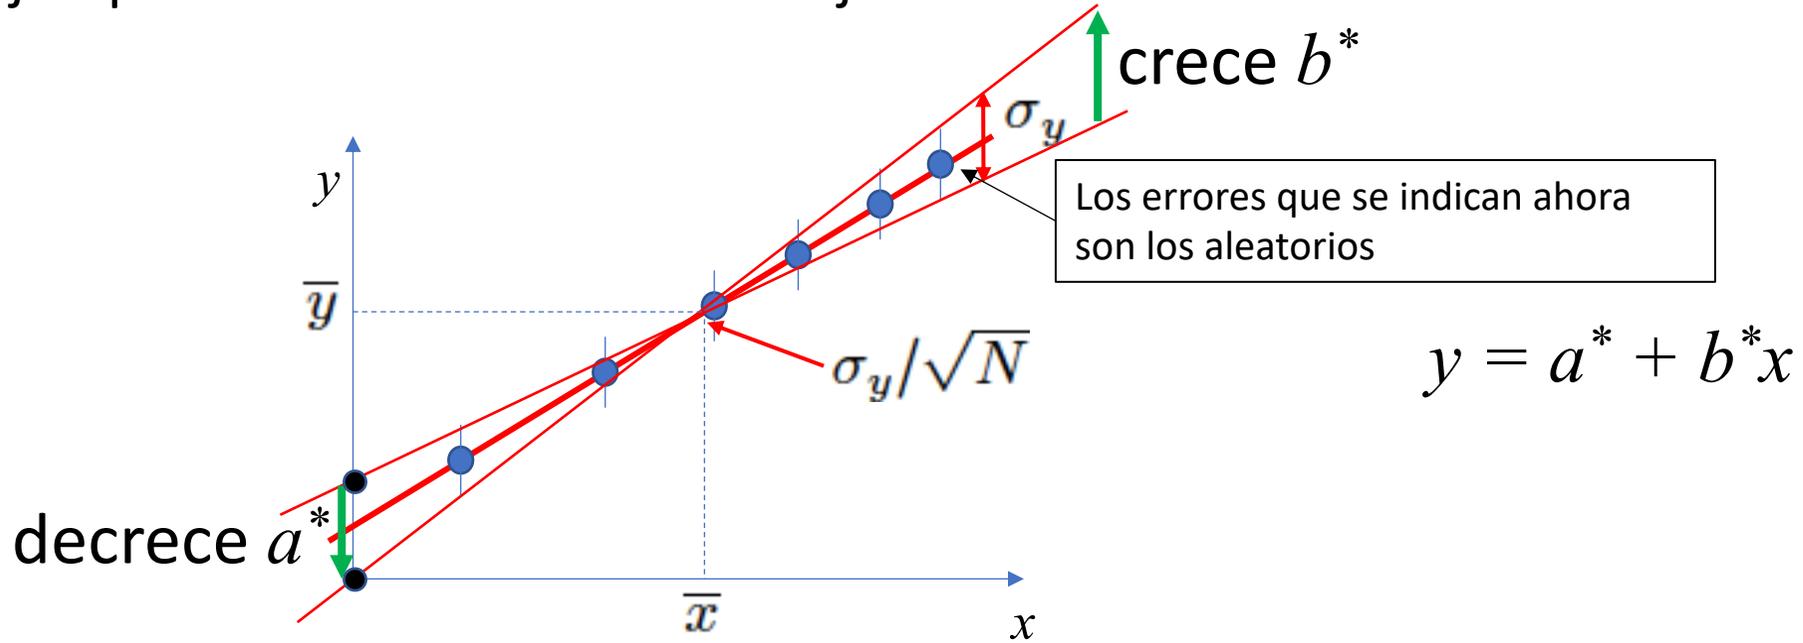
## Ejemplo #2: Correlaciones en el ajuste lineal



Los errores que se indican ahora son los aleatorios

$$y = a^* + b^*x$$

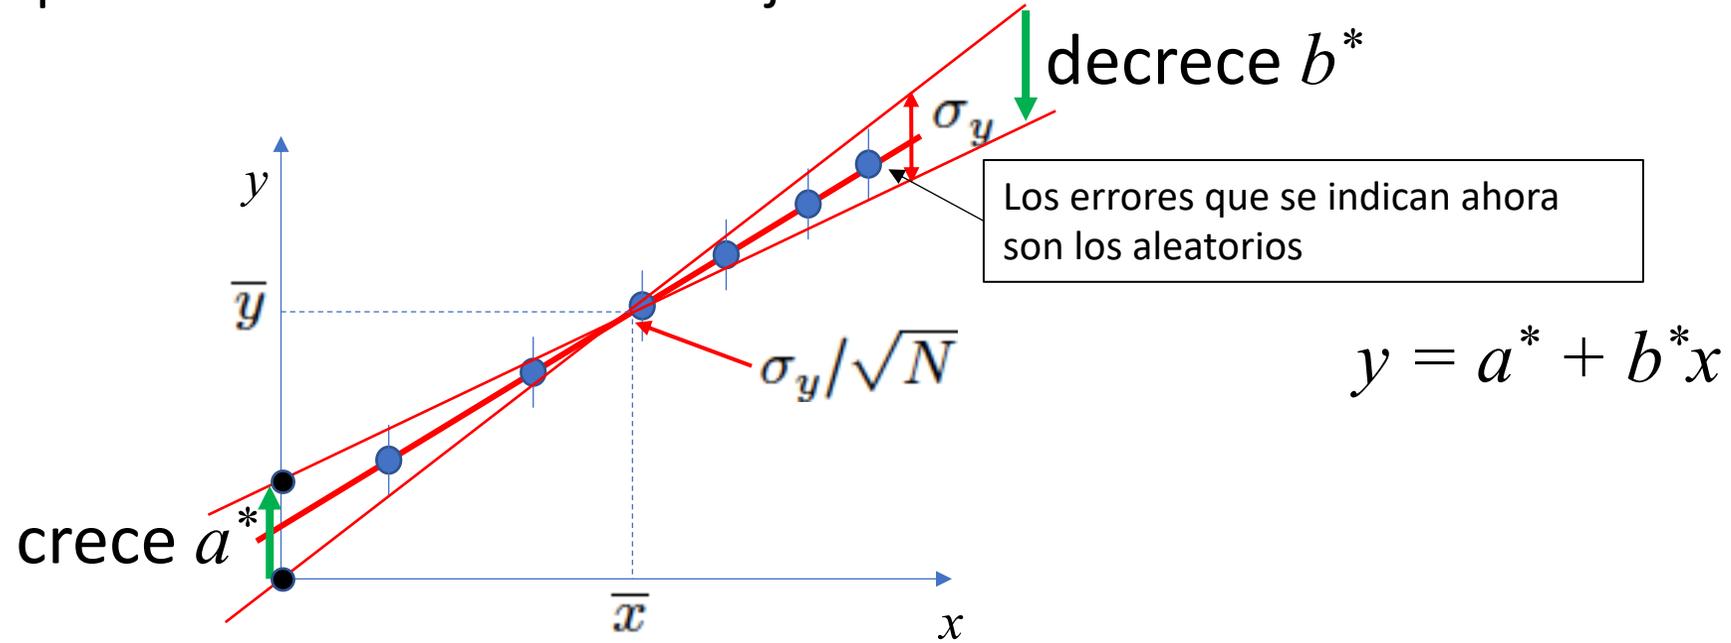
# Ejemplo #2: Correlaciones en el ajuste lineal



Los errores que se indican ahora son los aleatorios

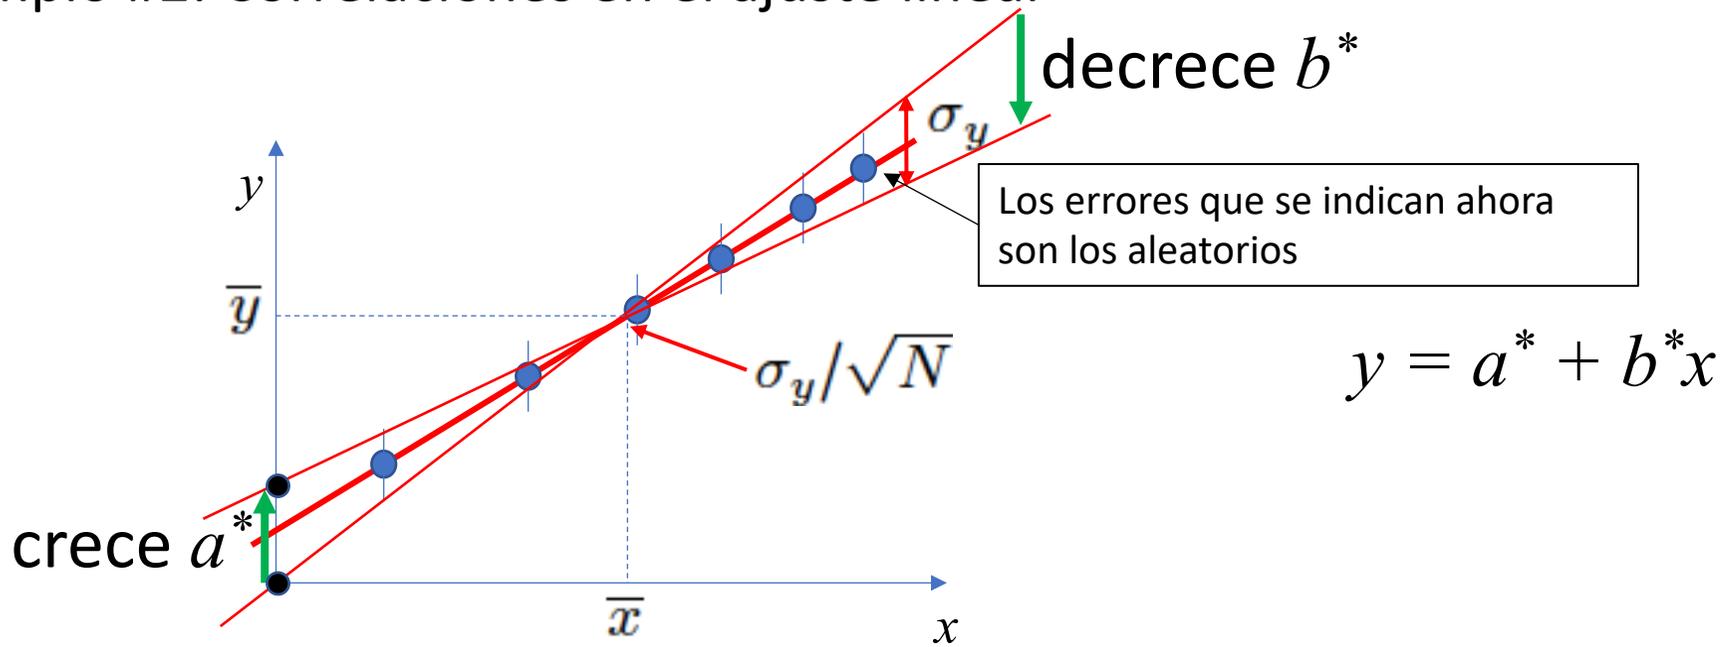
$$y = a^* + b^*x$$

# Ejemplo #2: Correlaciones en el ajuste lineal



Es decir que  $a^*$  y  $b^*$  están fuertemente correlacionados.

## Ejemplo #2: Correlaciones en el ajuste lineal



Es decir que  $a^*$  y  $b^*$  están fuertemente correlacionados.

La pregunta es entonces cuánto vale

$$\sigma_{ab} = \frac{1}{M-1} \sum_{R=1}^M (a_R - \bar{a})(b_R - \bar{b})$$

## Ejemplo #2: Correlaciones en el ajuste lineal

La filosofía de esto es realizar una serie de ajustes del tipo

$$\begin{array}{c} (x_1, y_1^1)(x_2, y_2^1)\dots\dots(x_N, y_N^1) \rightarrow a_1, b_1 \\ (x_1, y_1^2)(x_2, y_2^2)\dots\dots(x_N, y_N^2) \rightarrow a_2, b_2 \\ \vdots \\ (x_1, y_1^R)(x_2, y_2^R)\dots\dots(x_N, y_N^R) \rightarrow a_R, b_R \\ \vdots \\ (x_1, y_1^M)(x_2, y_2^M)\dots\dots(x_N, y_N^M) \rightarrow a_M, b_M \end{array}$$

## Ejemplo #2: Correlaciones en el ajuste lineal

La filosofía de esto es realizar una serie de ajustes del tipo

$$\begin{array}{c} (x_1, y_1^1)(x_2, y_2^1)\dots\dots(x_N, y_N^1) \rightarrow a_1, b_1 \\ (x_1, y_1^2)(x_2, y_2^2)\dots\dots(x_N, y_N^2) \rightarrow a_2, b_2 \\ \vdots \\ (x_1, y_1^R)(x_2, y_2^R)\dots\dots(x_N, y_N^R) \rightarrow a_R, b_R \\ \vdots \\ (x_1, y_1^M)(x_2, y_2^M)\dots\dots(x_N, y_N^M) \rightarrow a_M, b_M \end{array}$$

de donde obtenemos

$$(x_1, \bar{y}_1)(x_2, \bar{y}_2)\dots\dots(x_N, \bar{y}_N) \rightarrow \bar{a}, \bar{b}$$

## Ejemplo #2: Correlaciones en el ajuste lineal

Desarrollando  $a_R$  y  $b_R$  alrededor de sus valores medios tenemos que

$$a_R = \bar{a} + \sum_{i=1}^N \frac{\partial a}{\partial y_i} (y_i^R - \bar{y}_i)$$

$$b_R = \bar{b} + \sum_{j=1}^N \frac{\partial b}{\partial y_j} (y_j^R - \bar{y}_j)$$

de donde

$$\begin{aligned} \sigma_{ab} &= \frac{1}{M-1} \sum_{R=1}^M \left[ \sum_{i=1}^N \frac{\partial a}{\partial y_i} (y_i^R - \bar{y}_i) \sum_{j=1}^N \frac{\partial b}{\partial y_j} (y_j^R - \bar{y}_j) \right] \\ &= \sum_{i=1}^N \sum_{j=1}^N \frac{\partial a}{\partial y_i} \frac{\partial b}{\partial y_j} \left[ \frac{1}{M-1} \sum_{R=1}^M (y_i^R - \bar{y}_i)(y_j^R - \bar{y}_j) \right] \end{aligned}$$

## Ejemplo #2: Correlaciones en el ajuste lineal

Desarrollando  $a_R$  y  $b_R$  alrededor de sus valores medios tenemos que

$$a_R = \bar{a} + \sum_{i=1}^N \frac{\partial a}{\partial y_i} (y_i^R - \bar{y}_i)$$

$$b_R = \bar{b} + \sum_{j=1}^N \frac{\partial b}{\partial y_j} (y_j^R - \bar{y}_j)$$

de donde

$$\begin{aligned} \sigma_{ab} &= \frac{1}{M-1} \sum_{R=1}^M \left[ \sum_{i=1}^N \frac{\partial a}{\partial y_i} (y_i^R - \bar{y}_i) \sum_{j=1}^N \frac{\partial b}{\partial y_j} (y_j^R - \bar{y}_j) \right] \\ &= \sum_{i=1}^N \sum_{j=1}^N \frac{\partial a}{\partial y_i} \frac{\partial b}{\partial y_j} \left[ \frac{1}{M-1} \sum_{R=1}^M (y_i^R - \bar{y}_i)(y_j^R - \bar{y}_j) \right] \end{aligned}$$

Podemos ver entonces que si todos los  $y_i$  son independientes, el producto

$$\frac{1}{M-1} \sum_{R=1}^M (y_i^R - \bar{y}_i)(y_j^R - \bar{y}_j) = \delta_{ij} \sigma_y^2$$

es decir,

$$\sigma_{ab} = \sum_{i=1}^N \frac{\partial a}{\partial y_i} \frac{\partial b}{\partial y_i} \sigma_y^2$$

## Ejemplo #2: Correlaciones en el ajuste lineal

$$\sigma_{ab} = \sum_{i=1}^N \frac{\partial a}{\partial y_i} \frac{\partial b}{\partial y_i} \sigma_y^2$$

$$a^* = \frac{\sum x^2 \sum y - \sum x \sum xy}{N \sum x^2 - (\sum x)^2}$$

$$b^* = \frac{N \sum xy - \sum x \sum y}{N \sum x^2 - (\sum x)^2}$$

Es fácil ver que

$$\frac{\partial a}{\partial y_i} = \frac{\sum x^2 - x_i \sum x}{\Delta}$$

$$\frac{\partial b}{\partial y_i} = \frac{N x_i - \sum x}{\Delta}$$

## Ejemplo #2: Correlaciones en el ajuste lineal

$$\sigma_{ab} = \sum_{i=1}^N \frac{\partial a}{\partial y_i} \frac{\partial b}{\partial y_i} \sigma_y^2$$

$$a^* = \frac{\sum x^2 \sum y - \sum x \sum xy}{N \sum x^2 - (\sum x)^2}$$

$$b^* = \frac{N \sum xy - \sum x \sum y}{N \sum x^2 - (\sum x)^2}$$

Es fácil ver que

$$\frac{\partial a}{\partial y_i} = \frac{\sum x^2 - x_i \sum x}{\Delta}$$

$$\frac{\partial b}{\partial y_i} = \frac{N x_i - \sum x}{\Delta}$$

y por lo tanto

$$\sum_{i=1}^N \frac{\partial a}{\partial y_i} \frac{\partial b}{\partial y_i} = -\frac{\sum x}{\Delta}$$

Finalmente entonces,

$$\sigma_{ab} = -\frac{\sum x}{\Delta} \sigma_y^2$$

Esto implica que uno puede calcular la covarianza  $\sigma_{ab}$  con una *única* medición y por lo tanto una única determinación de a y b.

## Ejemplo #2: Correlaciones en el ajuste lineal

Cuál es la relevancia de este resultado?.

Supongamos tener un ajuste lineal de la forma  $y = a + bx$ , y con esto queremos inter o extrapolar el valor  $y_0 = a + bx_0$ . La pregunta es cuánto vale la incerteza de  $y_0$ ?

y la respuesta es

$$\sigma_{y_0}^2 = \sigma_a^2 + x_0^2 \sigma_b^2 + 2x_0 \sigma_{ab}$$

con

$$\sigma_{ab} = -\frac{\sum x}{\Delta} \sigma_y^2$$