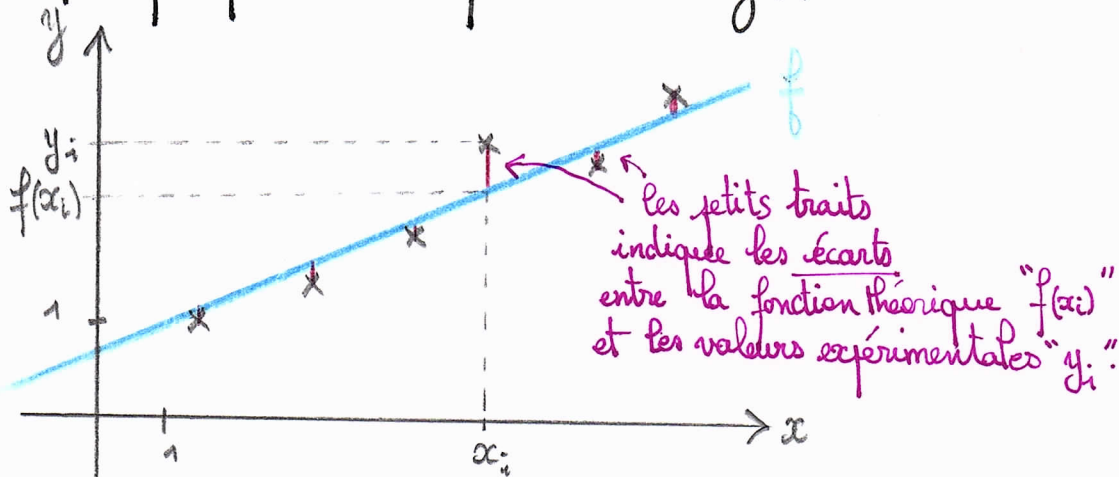


LEÇON 40 : DROITES DE REGRESSION

① Présentation du problème

On a un nuage de points $(x_i; y_i)$ et on cherche une fonction affine ou linéaire $f(x) = mx + p$ dont la courbe représentative passe le plus près possible des points du nuage.



« le plus près possible » signifie qu'on cherche à rendre minimale la somme des carrés des écarts, c'est-à-dire

$$e = \sum (y_i - f(x_i))^2 = \boxed{\sum (y_i - mx_i - p)^2}$$

C'est la méthode « des moindres carrés ».

↪ C'est-à-dire des plus petits carrés.

② Cas où l'on cherche f linéaire

C'est-à-dire on a $p = 0$, et la seule inconnue qui reste est m .

$$e = \sum (y_i - mx_i)^2 = \sum (y_i^2 - 2mx_i y_i + m^2 x_i^2)$$

$$= \left(\sum x_i^2 \right) m^2 - 2 \times \left(\sum x_i y_i \right) m + \left(\sum y_i^2 \right)$$

PROPRIÉTÉ: e est minimale lorsque

$$\boxed{m = \frac{\sum x_i y_i}{\sum x_i^2}}$$


Ex:

x_i	3	4	6	8	8,5
y_i	5	6,5	8	9	10

$$\sum x_i y_i = 3 \times 5 + 4 \times 6,5 + 6 \times 8 + 8 \times 9 + 8,5 \times 10 = 246,8$$

$$\sum x_i^2 = 3^2 + 4^2 + 6^2 + 8^2 + 8,5^2 = 137,5$$

$$m = \frac{\sum x_i y_i}{\sum x_i^2} \approx \boxed{1,247}$$



③ Cas où f est affine

On a alors deux inconnues: m et p . Parmi toutes les fonctions possibles on en cherche une qui passe par le point moyen $G(\bar{x}, \bar{y})$ avec

moyenne des x_i $\bar{x} = \frac{1}{N} \times \sum x_i$ et moyenne des y_i $\bar{y} = \frac{1}{N} \times \sum y_i$.

N est le nombre de points

On a alors $f(x) = m \times x + p = m \times x + (\bar{y} - m \times \bar{x}) = \bar{y} + m \times (x - \bar{x})$.

Alors: $e = \sum (y_i - (m x_i + p))^2 = \sum (y_i - \bar{y} - m(x_i - \bar{x}))^2$

$\uparrow p = \bar{y} - m \bar{x}$ car $f(\bar{x}) = \bar{y}$.

$$= \sum [(y_i - \bar{y})^2 - 2m(x_i - \bar{x})(y_i - \bar{y}) + (x_i - \bar{x})^2 m^2]$$

$$= \left(\sum (x_i - \bar{x})^2 \right) m^2 - 2 \times \left(\sum (x_i - \bar{x})(y_i - \bar{y}) \right) m + \sum (y_i - \bar{y})^2$$

PROPRIÉTÉ: e est minimale lorsque

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

Ex:

x_i	2	4	4,5	7	8	10
y_i	5	3	2,5	2	1	-0,5

$$\bar{x} = \frac{1}{6} \times (2+4+4,5+7+8+10) \approx \underline{5,9}$$

$$\bar{y} = \frac{1}{6} \times (5+3+2,5+2+1-0,5) \approx \underline{2,2}$$

$$\sum (x_i - \bar{x})(y_i - \bar{y}) = \dots \approx -26,7$$

$$\sum (x_i - \bar{x})^2 = \dots \approx 43,2$$

$$m = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sum (x_i - \bar{x})^2} \approx \underline{-0,617...}$$

