

Statistiques à deux variables.

On étudie deux caractères d'une population, X et Y.

Voici par exemple une série chronologique représentant le prix au m² des terrains agricoles dans une certaine région. Le premier caractère est la date (année – 1980) appelé rang , X, le deuxième est le prix au m², Y.

Année	1980	1985	1987	1990	1995	1997	2000	Moyenne	Ecart type	Covariance	0,73
Rang xi	0	5	7	10	15	17	20	10,57	7,14	37,34	59,08
Prix au m ²	58,8	60,9	62,1	67,5	71,7	73	73,8	66,83	6,23	0,84	= ρ

1) Nuage de points.

Chaque couple $(x_i ; y_i)$ est représenté par un point M_i du plan muni d'un repère $(O ; \vec{i} ; \vec{j})$

2) Point Moyen G.

Le point moyen a pour coordonnées $(\bar{X} ; \bar{Y})$, moyenne de X et de Y.

3) Approximation par une droite.

Les points sont presque alignés. On trace une droite d'équation $y = a x + b$ qui passe le plus près possible de ces points.

On peut considérer que X et Y sont liés par la relation $Y \approx a X + b$ et ainsi faire des prévisions.

Le problème est de trouver la droite qui passe le plus près possible. En fait selon les méthodes on trouve différentes droites.

4) Droite de régression linéaire par la méthode des moindres carrés.

C'est la droite d'équation $y = a x + b$ qui minimise les carrés des écarts (et aussi des

distances) entre Y_i et $(a X_i + b)$. C'est à dire la quantité $r = \sum_{i=0}^{i=7} (Y_i - a X_i + b)^2$, r est la somme des résidus.

Les nombres a et b sont donnés par la calculatrice. Cette droite passe par le point moyen G.

5) Quelques notions hors programme.

$$cov(X ; Y) = \frac{1}{8} \sum_{i=0}^{i=7} (X_i - \bar{X})(Y_i - \bar{Y}) = \overline{XY} - \bar{X}\bar{Y} \text{ donne des indications sur les}$$

variations de Y par rapport à X. $cov(X ; Y) > 0$ indique que X et Y varient dans le même sens,

$cov(X ; Y) < 0$ indique que quand X croît Y décroît. $cov(X ; Y)$ proche de 0 indique que les variations de X et Y ne sont pas liées.

Un meilleur indicateur est ρ le coefficient de corrélation linéaire : $\rho = \frac{cov(X ; Y)}{\sigma_x \sigma_y}$

Si ρ est proche de 1 ou de -1, X et Y sont liés "linéairement" : $Y \approx a X + b$.

Pour la droite de régression linéaire par la méthode des moindres carrés :

$$a = \frac{cov(X ; Y)}{V(X)} \text{ et } b = \bar{Y} - a \bar{X}$$