

A présent on se pose la question: quelle sera la formule de la liaison entre x_1 et y_1 , entre x_2 et y_2 , entre x_3 et y_3 . . . entre x_i et y_i , etc. si

1-0 — cette liaison (dépendance) peut s'exprimer par toute une fonction rationnelle du premier degré (fonction linéaire).

2-0 — cette fonction reste la même pour toutes les N couples de termes des deux séries, et

3-0 — à notre cas peut s'appliquer la méthode dite „des moindres carrés“.

Autrement dit, on suppose que la liaison entre le terme arbitraire, d'ordre i , de la première série x_i et le terme correspondant de la seconde série y_i (i pouvant être égal à 1, 2, 3, 4 . . . N), s'exprime par la formule: $y_i = a_1 + b_1 x_i$, ou bien par la formule:

$$x_i = a_2 + b_2 y_i.$$

Ici, les coefficients a_1 , a_2 , b_1 et b_2 sont constants („paramètres“) de l'équation et on suppose qu'ils restent invariables pour tous les N couples observés. Les valeurs de tous les termes des deux séries étant connues, on dispose, pour le calcul des 4 paramètres inconnus a_1 , b_1 , a_2 , b_2 , de $2N$ équations: N équations pour le calcul de a_1 et b_1 et N équations pour celui de a_2 et b_2 . Ces équations paraîtront, dans la plupart des cas, réciproquement incompatibles, chaque groupe de 4 équations donnant aux a_1 , b_1 , a_2 et b_2 des valeurs numériques autres que celles qu'on cherche. Pour éviter cette contradiction interne, on a recours à la „méthode des moindres carrés“. On raisonne alors de la manière suivante:

Supposons que dans l'équation $y_i = a_1 + b_1 x_i$ les grandeurs a_1 et b_1 aient des valeurs arbitraires a_1' et b_1' . Dans ce cas, naturellement, la partie droite de l'équation ne peut être égale à la partie gauche. Si on désigne leur différence par e_i , il est évident que

$$y_i - a_1' - b_1' x_i = e_i,$$

et que e_i peut être considéré comme erreur de la détermination de a_1 et b_1 .

On cherche à présent de telles valeurs de a_1' et b_1' , afin que la somme des carrés des erreurs de toutes les N équations soit la moindre (d'où la dénomination: „méthode des moindres carrés“), c'est-à-dire,

$$\sum_{i=1}^N e_i^2 = \sum_{i=1}^N (y_i - a_1' - b_1' x_i)^2 = \text{minimum}^*)$$

La question ainsi posée, le problème de trouver les valeurs de a_1' et b_1' devient mathématiquement tout à fait précisé. Conformément aux règles du calcul différentiel (réduction à zéro des dérivées par a_1' , par b_1' , etc.), on obtient aisément:

Le signe $\sum_{i=1}^N$ indique qu'on doit prendre la somme

qui embrasse toutes les grandeurs à indices 1, 2, 3, 4, etc., en se terminant par l'indice N . Par exemple:

$$\sum_{i=1}^N e_i^2 = e_1^2 + e_2^2 + e_3^2 + \dots + e_N^2$$

$$a_1' = 0; \quad b_1' = \frac{\sum_{i=1}^N x_i y_i}{\sum_{i=1}^N x_i^2}$$

De la même manière, de l'équation conditionnelle $\sum_{i=1}^N (e_i')^2 = \sum_{i=1}^N (x_i - a_2' - b_2' y_i)^2 = \text{minimum}$ on obtient:

$$a_2' = 0; \quad b_2' = \frac{\sum_{i=1}^N x_i y_i}{\sum_{i=1}^N y_i^2}$$

Les valeurs a_1' , a_2' , b_1' , b_2' ne sont pas les véritables valeurs des paramètres de la fonction qui lie, *peut-être*, en réalité x_i et y_i , mais seulement les valeurs approchées de ces paramètres, obtenues par la méthode des moindres carrés. Si nous avons posé comme condition:

$$\sum_{i=1}^N e_i^3 = \text{minimum}, \text{ ou } \sum_{i=1}^N E_i^4 = \text{minimum}, \text{ nous}$$

aurions obtenu des valeurs tout différentes.

En désignant la moyenne géométrique des deux paramètres b_1' et b_2' par r_{12}' , on aura:

$$r_{12}' = \sqrt{b_1' b_2'} = \frac{\sum_{i=1}^N x_i y_i}{\sqrt{\sum_{i=1}^N x_i^2 \sum_{i=1}^N y_i^2}} \quad [1]$$

Considérant que les Anglais appellent „déviation-type“ ou „écart-type“ les grandeurs

$$\sigma_1' = \sqrt{\frac{\sum_{i=1}^N x_i^2}{N}} \text{ et } \sigma_2' = \sqrt{\frac{\sum_{i=1}^N y_i^2}{N}} \quad [2]$$

nous pouvons écrire:

$$r_{12}' = \frac{\sum_{i=1}^N x_i y_i}{N \sigma_1' \sigma_2'} \quad [3]$$

D'autre part, en désignant b_1' par b_{21}' et b_2' par b_{12}' , nous avons:

$$b_{12}' = \frac{\sigma_1'}{\sigma_2'} r_{12}'; \quad b_{21}' = \frac{\sigma_2'}{\sigma_1'} r_{21}' \text{ (puisque } r_{12}' = r_{21}') \quad [4]$$

*) Il serait plus exact de mettre au dénominateur de la grandeur sous racine non pas N , mais $(N-1)$: Or, si N est quelque peu significatif, cette correction n'a presque aucune importance.