

**06-05 Corrélation et ajustements****Définition**

Le **coefficient de corrélation linéaire** de deux séries de valeurs  $(x_1 ; x_2 ; \dots ; x_n)$  et  $(y_1 ; y_2 ; \dots ; y_n)$  est le nombre  $r$  défini par  $r = \frac{\text{cov}(x ; y)}{\sigma(x)\sigma(y)}$

**Exemple**

$x_i$	161	141	127	150	159	129	148	135
$y_i$	21,5	23,3	17,2	15,6	18,8	10,1	14,1	15,7

**Remarques**

- Le coefficient de corrélation linéaire est un nombre compris entre (-1) et 1. Lorsqu'il est proche de (-1) ou 1, on dit que la corrélation est forte entre  $x$  et  $y$ .
- Effectuer un ajustement, c'est faire une **interpolation**. Utiliser un ajustement pour un calcul, c'est faire une **extrapolation**.
- Il est parfois possible de réaliser des ajustements non affines de nuages dont les points rappellent des courbes connues. On procède pour cela à un changement de variable.

**Exemple**

En utilisant l' ..... effectuée dans le cours 06-04, on peut émettre l' ..... suivante:

« La température moyenne d'une ville ensoleillée un jour sur deux sera aux alentours de ..... ».

## 06-05 Exercices

## Exercice 1

1. Calculer le coefficient de corrélation linéaire de la série à deux variables ci-dessous.

$x_i$	2	3,2	4,3	5	8,5	9,7	12	14
$y_i$	13,526	7,673	4,773	3,497	3,323	3,109	3,004	2,755

2. On pose  $z = \frac{1}{y}$

a) Compléter le tableau ci-dessous.

$x_i$	2	3,2	4,3	5	8,5	9,7	12	14
$z_i$								

- b) Calculer le coefficient de corrélation linéaire de la série  $(x ; z)$ .  
c) Déterminer l'équation de la droite des moindres carrés de cette série.

3. a) Dédire des questions précédentes une interpolation de  $y$  en fonction de  $x$ .  
b) Calculer une extrapolation au dixième de la valeur  $y$  correspondant à  $x = 7$ .

## Exercice 2

## Épidémie de grippe

Calculer, modéliser, communiquer



Notions revues : Logarithme népérien (chap. 4), Exponentielle (1<sup>re</sup>)



Pour étudier la propagation d'une épidémie de grippe, une enquête est faite auprès d'un échantillon de 1000 personnes. Le tableau ci-dessous donne les valeurs  $N_i$  de la variable  $N$  représentant le nombre d'individus ayant été contaminés à la date  $t_i$  du mois de janvier (la variable  $t$  est exprimée en jours).

$t_i$	1	2	5	10	15	20
$N_i$	89	171	304	418	488	499

1. Tracer le nuage de points de cette série statistique, dans un repère orthogonal. On prendra comme unité 0,5 cm pour 1 jour sur l'axe des abscisses et 1 cm pour 50 individus sur l'axe des ordonnées.  
2. Le nuage de points permet-il d'envisager un ajustement affine ?

3. Déterminer une valeur approchée à  $10^{-2}$  près du coefficient de corrélation linéaire  $r$  de cette série statistique à deux variables. Interpréter le résultat en termes de corrélation. Peut-on intuitivement envisager un lien de causalité entre la date et le nombre d'individus contaminés ?

4. On effectue le changement de variable suivant :

$$y = -5 \ln \left( 1 - \frac{N}{500} \right).$$

- a. Recopier et compléter le tableau suivant. Arrondir les valeurs au millième.

$t_i$	1	2	5	10	15	20
$N_i$	89	171	304	418	488	499
$y_i$						

- b. Déterminer, avec la calculatrice, l'équation de la droite de régression de  $y$  en  $t$ . Arrondir les coefficients à  $10^{-4}$  près. Dans la suite de l'exercice, on considère que  $y = 1,508t - 2,236$ .

- c. Montrer que la variable  $N$  s'exprime en fonction de  $y$  par la relation :  $N = 500 \left( 1 - e^{-\frac{y}{5}} \right)$ .

- d. En déduire une expression de  $N$  en fonction de  $t$ .  
5. En utilisant l'expression précédente comme modèle du nombre de personnes contaminées, déterminer la date à laquelle le nombre d'individus contaminés dépasse pour la première fois le quart de la population étudiée.