

# Chapitre 5 : Statistiques à deux variables

## I Nuage de points

### Définition

On appelle série statistique à deux variables une série statistique dans laquelle deux caractères  $X$  et  $Y$  sont étudiés simultanément.

Exemples : étude de la consommation d'électricité et de la température extérieure, du prix de vente d'un objet et du nombre d'objets vendus, ....

Pour chacun des  $n$  individus (numérotés de 1 à  $n$ ) de la population, notons  $x_i$  et  $y_i$  la valeur prise respectivement par les caractères  $X$  et  $Y$ .

On présente les données de la série statistique à deux variables obtenue sous forme d'un tableau :

Valeurs prises par $X$	$x_1$	$x_2$	...	$x_n$
Valeurs prises par $Y$	$y_1$	$y_2$	...	$y_n$

Exemple :

Année	2014	2015	2016	2017	2018
Rang de l'année $x_i$	0	1	2	3	4
Nombre d'habitants $y_i$ (en milliers)	15,2	15,25	15,4	15,5	15,55

### Définition (nuage de points)

On considère une série statistique à deux variables définie par l'ensemble des couples  $(x_i; y_i)$  où  $i$  est un entier variant de 1 à  $n$ .

Dans un repère orthogonal, on appelle nuage de points de la série statistique l'ensemble des points  $A_i$  de coordonnées  $(x_i; y_i)$ .

Si la variable  $X$  correspond à des dates, la série est dite chronologique.

### Définition (Point moyen du nuage)

Notons  $\bar{x} = \frac{x_1 + x_2 + x_3 + \dots + x_n}{n}$  la moyenne de la série des  $x_i$ ,

et  $\bar{y} = \frac{y_1 + y_2 + y_3 + \dots + y_n}{n}$  la moyenne des  $y_i$  ( $1 \leq i \leq n$ ).

Le point moyen du nuage est  $G(\bar{x}; \bar{y})$ .

### Exercice 1

Le tableau suivant présente l'évolution du budget publicitaire et du chiffre d'affaire d'une société au cours des 6 dernières années :

Budget publicitaire $x_i$ (en milliers d'euros)	8	10	12	14	16	18
Chiffre d'affaires $y_i$ (en milliers d'euros)	40	55	55	70	75	95

1. Représenter le nuage de points dans un repère orthogonal.
2. Déterminer les coordonnées du point moyen  $G$ , puis placer  $G$ .

## II Ajustement affine

### Définition

Effectuer un ajustement de  $y$  en  $x$  d'un nuage de points, c'est trouver une fonction  $f$  dont la courbe représentative passe "au plus près" des points du nuage.

On parle d'ajustement affine si l'ajustement se fait par une fonction affine, la courbe de  $f$  est une droite.

### Remarque

- Il est intéressant de faire un ajustement affine lorsque le nuage a une forme plutôt allongée.
- Parfois on peut se contenter de tracer la droite "au jugé" pour qu'elle passe au plus près du nuage.
- Cela va permettre de faire des interpolations et extrapolations.
- Il existe d'autres types d'ajustements, c'est-à-dire d'autres fonctions  $f$  qui peuvent modéliser un nuage de points.

### Exercice 2 (exemple d'ajustement affine : la méthode de Mayer)

On reprend la série de l'exercice 1.

Soit  $G_1$  le point moyen associé aux trois premiers points du nuage et  $G_2$  le point moyen associé aux trois derniers points du nuage.

1. Calculer les coordonnées de  $G_1$  et  $G_2$ .
2. On prend  $(G_1G_2)$  comme droite d'ajustement. Tracer cette droite.
3. À l'aide du graphique :
  - (a) Estimer le chiffre d'affaire à prévoir pour un budget publicitaire de 22 000 euros.
  - (b) Estimer le budget publicitaire qu'il faudrait prévoir pour obtenir un chiffre d'affaire de 100 000 euros.

## III Méthode des moindres carrés

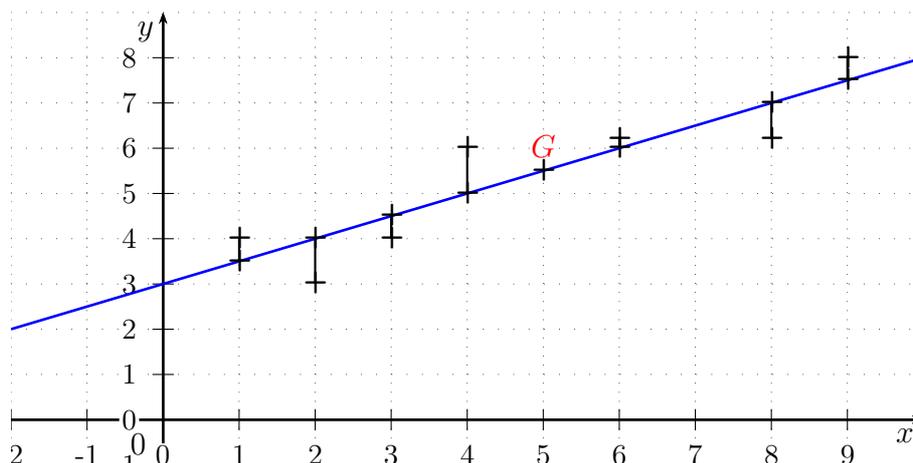
### Propriété (moindres carrés)

Pour toute série statistique  $(x_i; y_i)$  à deux variables, il existe une unique droite d'équation

$y = ax + b$  réalisant le minimum de  $\sum_{i=1}^n (y_i - (ax_i + b))^2$ .

Elle est appelée droite de régression de  $y$  en  $x$  ou droite d'ajustement par la méthode des moindres carrés.

Elle passe toujours par le point moyen  $G$  du nuage.



### Remarque

On obtient les valeurs de  $a$  et  $b$  à l'aide de la calculatrice.

### Utilisation de la calculatrice

	Casio	Texas	Numworks
Entrer les données	Menu Statistique Rentrer les $x_i$ dans $L_1$ , et les $y_i$ dans $L_2$	Menu Statistique $x_i$ dans $L_1$ $y_i$ dans $L_2$	Menu Regression $x_i$ dans X1 $y_i$ dans Y1
Droite de régression	Calc Set 2VarXlist : list1 et 2VarYList : list2 REG, X, $ax + b$	Stat Calc RegLin( $ax + b$ ) $L_1, L_2$	Onglet Graphique regression linéaire $ax + b$
Point moyen	Calc 2-Var	Calc 2-Var $L_1, L_2$	Onglet Graphique

### Exercice 3

On considère la série statistique à deux variables donnée dans le tableau suivant :

$x_i$	5	10	15	20	25	30	35	40
$y_i$	13	23	34	44	50	65	75	90

1. Dans un repère, représenter le nuage de points  $(x_i; y_i)$ .
2. À l'aide de la calculatrice, déterminer une équation de la droite  $d$  d'ajustement par la méthode des moindres carrés.
3. Représenter la droite d'ajustement de  $y$  en  $x$ .
4. Donner les coordonnées du point moyen  $G$ .  
On peut vérifier que la droite de régression  $d$  passe par  $G$ .
5. Estimer graphiquement la valeur de  $x$  pour  $y = 70$ .  
Retrouver ce résultat par le calcul.

### Exercice 4

Le tableau suivant indique les effectifs de la population en France de 2000 à 2009.

Année	2000	2001	2002	2003	2004	2005	2006	2007	2008	2009
Rang $x_i$	0	1	2	3	4	5	6	7	8	9
Population $y_i$ (millions d'hab.)	58,86	59,27	59,69	60,1	60,51	60,96	61,40	61,80	62,13	62,47

1. Donner les coordonnées du point moyen de la série. Arrondir à 0,01.
2. Donner une équation de la droite d'ajustement par la méthode des moindres carrés. Arrondir les coefficients à 0,01.
3. Utiliser cette droite pour proposer une estimation de la population en 2012.

## Exercices sur les statistiques à deux variables

### Exercice 1 (comparaison de deux ajustements affines)

Le tableau suivant donne le nombre de clients du téléphone mobile en France atteint à la fin de chaque année.

Année	1998	1999	2000	2001	2002	2003	2004	2005
Rang de l'année $x_i$	0	1	2	3	4	5	6	7
Nombre de clients en millions $y_i$	11,5	20,6	29,7	37,0	39,6	41,7	44,5	48,0

Source : ARCEP observatoire des mobiles

- Déterminer le taux d'évolution du nombre de clients de téléphonie mobile de 1998 à 2005.  
On arrondira le résultat à 0.1 %.
- Donner les coordonnées du point moyen  $G$  du nuage associé à la série statistique.  
On arrondira les coefficients au dixième. On ne demande pas de justifier.
- Représenter le nuage de points associée à la série dans un repère orthogonal. Placer le point  $G$ .
- Déterminer une équation de la droite d'ajustement  $\Delta$  obtenue par la méthode des moindres carrés. (Arrondir les coefficients au centième).
- Tracer  $\Delta$  (justifier le tracé).
- En supposant que ce modèle reste valable pour 2006 et 2007, prévoir le nombre de clients pour la fin de l'année 2007. Indiquer la méthode utilisée.
- On note  $A(0; 11.5)$  et  $B(7; 48)$  les points extrêmes du nuage.
  - Déterminer une équation de la droite  $(AB)$  sous la forme  $y = ax + b$ .  
Arrondir  $a$  et  $b$  au centième.
  - En déduire une nouvelle estimation du nombre de clients du téléphone mobile pour la fin 2007.
- À la fin de l'année 2007, on a dénombré 58.7 millions de clients du téléphone mobile. Quelle était la meilleure estimation ?

### Exercice 2

En un lieu on relève la pression atmosphérique en fonction de l'altitude.

Altitude $x_i$ (km)	0	0,5	1	1,5	2	2,5	3
Pression $y_i$ (hPa)	1013	955	900	847	797	750	705

- Construire le nuage de points.
- Calculer les coordonnées du point moyen  $G$ , arrondir l'ordonnée à l'unité.
- Soit  $A(0; 1013)$ . On prend la droite  $(GA)$  pour droite d'ajustement.  
Déterminer une équation de  $(GA)$ , et tracer  $(GA)$ .
- En utilisant ce modèle, donner une estimation de l'altitude correspondant à une pression de 650 hPa.
- On a observé une pression de 170 hPa à une altitude de 13 km. L'ajustement affine convient-il à cette altitude ?

### Exercice 3

Dans le cadre de cet exercice, on s'intéresse à la consommation d'électricité en France (exprimée en TWh, c'est-à-dire en milliards de kWh) dans le secteur des transports urbains et ferroviaires pour les années  $1994 + x_i$  où  $x_i$  est un nombre entier naturel.

Année : $1994 + x_i$	1995	2000	2004	2005	2006	2007
Rang de l'année : $x_i$	1	6	10	11	12	13
Consommation : $y_i$	8,6	10,4	12,2	11,9	12,1	12,2

Source : <http://www.developpement-durable.gouv.fr>

On décide d'effectuer un ajustement affine.

- (a) Représenter le nuage de points associé à la série dans un repère orthogonal. Unités : 0.5 cm en abscisses et 0.5 cm en ordonnées.  
(b) Donner les coordonnées  $\bar{x}$  et  $\bar{y}$  du point moyen G du nuage. Placer G sur le graphique.
- Au moyen de la calculatrice, donner une équation de la droite de régression de  $y$  en  $x$  par la méthode des moindres carrés (arrondir les coefficients à  $10^{-3}$  près).
- Pour toute la suite de l'exercice, on utilisera la droite d'équation  $y = 0,31x + 8,46$  comme droite d'ajustement.  
Tracer cette droite sur le graphique. Justifier par un tableau de valeurs.
- On considère que cette droite fournit un bon ajustement jusqu'en 2015. Estimer la consommation d'électricité en France pour l'année 2010. Justifier.
- Estimer à partir de quelle année la consommation d'électricité en France dans le secteur des transports urbains et ferroviaires dépassera 14,5 TWh.