


collection
arabisation et connaissances
dirigée par : Mustafa BENYAKLEF



ELEMENTS DE STATISTIQUE DESCRIPTIVE

EL KACIMI ALAOUI Aziz

MAITRE DE CONFERENCE
A L'UNIVERSITÉ DE LILLE III

7

Prix : 20 DHS

UNIVERSITÉ DE LILLE III

PREMIÈRE ANNÉE – HISTOIRE
TÉLÉ-ENSEIGNEMENT

par

AZIZ EL KACIMI

ÉLÉMENTS DE STATISTIQUE DESCRIPTIVE

Publié comme livre en version bilingue (Français et Arabe) aux
Éditions Maghrébines collection *Arabisation et connaissances*

ANNÉE UNIVERSITAIRE 1983-1984

AVANT-PROPOS

Beaucoup de disciplines scientifiques, expérimentales (chimie, physique, biologie, médecine *etc.*) ou humaines (sociologie, économie, histoire, géographie *etc.*) ont de plus en plus besoin des méthodes statistiques et ne sauraient s'en passer la plupart du temps. Pas mal d'hypothèses scientifiques trouvent leurs origines dans des études statistiques et ceci motive fortement la mise en œuvre de leur vérification.

Un cours de géographie ou d'histoire quantitative a besoin d'être épaulé par un cours de statistiques (étude de la démographie, de la répartition des richesses, de l'évolution des prix à une certaine époque *etc.*). Ce cours se veut dans ce sens ; il constitue, sans prétention aucune, une introduction aux méthodes élémentaires de la statistique descriptive. J'ai essayé de multiplier les exemples et les exercices et d'en donner une solution détaillée (pour certains d'entre eux). J'espère qu'il pourra rendre service aux étudiants des filières susmentionnées.

Toute critique portant aussi bien sur le contenu que sur la forme sera la bienvenue !

Lille, Avril 1984
AZIZ EL KACIMI

CONTENU

CHAPITRE I

Généralités

1 - Définitions	1
2 - Séries classées	4
3 - Représentations graphiques	5
4 - Fréquence	7
5 - Exercices	9
6 - Effectifs et fréquences cumulés	11

CHAPITRE II

Valeurs moyennes

1 - Médiane	14
2 - Moyenne	20
3 - Exercices	28

CHAPITRE III

Paramètres de dispersion

1 - Variance	35
2 - Écart-type	40
3 - Exercice résolu	41

CHAPITRE IV

Indices

1 - Indices élémentaires	46
2 - Indices du coût de la vie	48
3 - Exercice résolu	51

CHAPITRE V

Concentration

1 - Généralités	54
2 - Fonction et courbe de concentration	58
3 - Exemples	65

CHAPITRE VI

Séries doubles, ajustement et corrélation

1 - Séries doubles	71
2 - Moyennes marginales	76
3 - Ajustement	77
4 - Exemple	84
5 - Exercice résolu	86

CHAPITRE VII

Séries chronologiques

1 - Généralités	89
2 - Analyse	92
3 - Exercice résolu	96

CHAPITRE VIII

Exercices résolus	102
-------------------------	-----

CHAPITRE I
GENERALITES SUR
LES SERIES STATISTIQUES

I-DEFINITIONS Toute étude statistique suppose la donnée d'une population.

Par exemple :

- La population de la France,
- L'ensemble des élèves d'un lycée,
- Une colonie de micro-organismes.

Les éléments de cette population sont appelés individus.

Toute propriété des individus de cette population est appelée caractère.

Un caractère peut être :

- Qualitatif (couleur, sexe,...)
- Quantitatif (Age, Taille,...).

Une étude statistique est en fait l'étude d'un caractère de la population considérée. Souvent le nombre d'individus est très grand voire même infini. Ceci complique l'étude. Pour ce faire on se restreint à une partie S de cette population qu'on appelle échantillon et qu'on suppose assez représentatif.

Dans la suite on supposera que le caractère est quantitatif. On a alors la :

I.I-Definition : Une série statistique est une correspondance qui à chaque individu associe une valeur de son caractère.

Exemple: Soit P la population de la France. La correspondance qui à chaque habitant associe son revenu définit une série statistique.

Une série statistique est souvent représentée par un tableau :

Individus	W_1	W_2	W_k
Valeurs du caractère	X_1	X_2	X_k

I.2.Effectifs total et partiel

-Le nombre d'individus d'un échantillon est appelé effectif total.

-Le nombre d'apparitions d'une valeur du caractère est appelé effectif partiel de cette valeur.

Si on note x_1, \dots, x_k les valeurs du caractère d'une série statistique avec les effectifs partiels respectifs n_1, \dots, n_k , on peut représenter cette série par un tableau du type suivant:


Valeurs	x_1	x_2	x_k
Effectifs partiels	n_1	n_2	n_k

Evidemment toutes ces séries statistiques peuvent être représentées graphiquement. Nous allons donner brièvement les représentations graphiques les plus utilisées. Nous nous limiterons à le faire sur des exemples.

I.3.Représentations graphiques.

I.3.I.Diagramme en bâtons. La série statistique suivante donne le nombre d'enfants par ménage dans un échantillon de 282 ménages :

0 enfants	52 ménages
1	-	80 -
2	-	60 -
3	-	24 -
4	-	18 -
5	-	16 -
6	-	14 -
7	-	12 -
8	-	6 -



La courbe obtenue en joignant par des segments de droite les extrémités des batons est appelée le polygone des effectifs.

1.3.2. Diagramme à secteurs: On construit un cercle et on partage le disque intérieur en secteurs dont les aires sont proportionnelles aux effectifs partiels.

Si on reprend la série statistique précédente on obtient le diagramme suivant :




Fig I.2.

Les séries statistiques que l'on vient de considérer sont dites à valeurs isolées. Elles sont utilisées quand le nombre des valeurs du caractère n'est pas grand. Dans le cas contraire on introduit un autre type de séries statistiques :

2-SERIES CLASSEES. Commençons par un exemple. Supposons que l'on veuille étudier la distribution des salaires mensuels de 100 employés d'une grande entreprise. Le nombre étant relativement grand, on ne considèrera pas chaque salaire isolément mais on constituera des intervalles de variation des salaires qu'on appellera des classes et qu'on pourra représenter de la façon suivante :

Classes de salaires(en NF)	3500 à 4500	4500 à 5500	5500 à 8000	plus de 8000
Effectifs partiels	48	27	17	8

2.1

D'une manière générale une série statistique classée peut se représenter à l'aide d'un tableau du type suivant (qui est le même d'ailleurs que le tableau 2.1) :

Classes	$[x_1, x_2[$ $[x_2, x_3[$ $[x_k, x_{k+1}[$
Effectifs partiels	n_1 n_2 n_k

2.2

L'intervalle $[x_i, x_{i+1}[$ qu'on prendra généralement fermé à gauche et ouvert à droite est appelé classe et le nombre n_i correspondant (voir tableau 2.2) est l'effectif de cette classe.

Les nombres :

$$e_i = x_{i+I} - x_i \quad \text{et} \quad c_i = \frac{x_i + x_{i+I}}{2}$$

sont appelés respectivement l'étendue et le centre de la classe $[x_i, x_{i+I}]$.

A une série classée est naturellement associée une série à valeurs isolées qui est la série des centres des différentes classes. Ainsi la série des centres associée à 2.I est donnée par le tableau suivant :

Centres des classes	4000	5000	6750	9250
Effectifs	48	27	17	8

Remarque : La dernière classe de cet exemple n'a pas d'étendue. On convient généralement de prendre comme étendue celle de la classe qui précède. Il arrive aussi que la première classe considérée n'ait pas d'étendue. Dans ce cas on prendra celle de la classe qui suit.

On verra que la série des centres d'une série classée est largement utilisée dans la pratique.


3-DIFFERENTES REPRESENTATIONS GRAPHIQUES D'UNE SERIE CLASSEE

Considérons une série classée dont les classes sont $[x_i, x_{i+I}]$ et les effectifs partiels n_i où l'indice i varie de 1 à k .


3.1-Diagramme en escalier. On trace un repère dont l'axe des abscisses représente les classes et l'axe des ordonnées les effectifs partiels.

Effectifs
partiels

Fig 2.I



3.2-Histogramme des effectifs. On considère toujours un repère et on trace des rectangles qui ont comme largeur l'étendue de la classe mesurée sur l'axe des abscisses et dont les aires sont proportionnelles aux effectifs partiels. Représentons par exemple la série classée 2.I par un histogramme des effectifs :



Important : Les hauteurs des différents rectangles ne sont pas proportionnelles aux effectifs partiels (sauf si les classes ont la même étendue) mais les aires doivent l'être.

Regardons par exemple comment on a construit les rectangles de l'histogramme ci-dessus.

Les 2 premières classes ont la même étendue, donc dire que les aires sont proportionnelles revient à dire que les hauteurs le sont. On peut donc choisir 48 mm pour la hauteur du 1^{er} rectangle et 27 mm pour le second. Pour le 3^{ème} on notera H sa hauteur. On a alors les relations de proportionnalité :

$$\frac{48 \cdot 1000}{48} = \frac{H \cdot 2500}{17}$$

D'où l'on tire :

$$H = 6,8 \text{ mm}$$

On fera la même chose pour construire le dernier rectangle en comparant son aire à celle du 2^{ème} par exemple.

2.3-Pyramide des âges. C'est une représentation qui est souvent utilisée pour illustrer la répartition des âges d'une population suivant le sexe. Elle se présente sous la forme suivante :




Fig 3.3

4-FREQUENCE.

4.1-Série à valeurs isolées .Soit la série à valeurs isolées:

$$\begin{array}{cccc} x_1 & x_2 & \dots & x_k \\ n_1 & n_2 & \dots & n_k \end{array}$$

où n_1, n_2, \dots, n_k sont les effectifs partiels respectivement des valeurs x_1, x_2, \dots, x_k .

On appelle fréquence de la valeur x_i , le nombre f_i défini par l'égalité:

$$f_i = \frac{n_i}{N} \quad \text{où } N = n_1 + n_2 + \dots + n_k \text{ est l'effectif total.}$$

4.2-Série classée. Soit $[x_1, x_2[\dots [x_k, x_{k+1}[$
 $n_1 \dots n_k$

une série classée. On définit de la même manière la fréquence de la classe

$[x_i, x_{i+1}[$ qu'on note aussi f_i par l'égalité :

$$f_i = \frac{n_i}{N} .$$

On vérifie aisément aussi bien pour une série à valeurs isolées que pour une série classée que la somme des fréquences est toujours égale à 1.

En effet on a :

$$f_1 + f_2 + \dots + f_k = \frac{n_1}{N} + \frac{n_2}{N} + \dots + \frac{n_k}{N} = \frac{N}{N} = 1 .$$

On peut aussi obtenir une distribution des fréquences de la même manière qu'on a une distribution des effectifs. On la représente par un tableau :

Classes	$[x_1, x_2[$...	$[x_k, x_{k+1}[$
Fréquences	f_1	...	f_k

auquel on peut associer un diagramme en escalier et un histogramme des fréquences.

Reprenons le tableau 2.I mais en considérant cette fois-ci la distribution des fréquences. On obtient alors :

Classes de salaires (en NF)	3500 à 4500	4500 à 5500	5500 à 8000	plus de 8000
Fréquences	0,48	0,27	0,17	0,08

5-EXERCICES.

5.I-Exercice resolu. Le tableau suivant donne le produit national brut par habitant de 50 pays africains (tiré de "Dossiers et Documents Le Monde"

N° 108 du mois de Fev 1984) :

PNB par habitant(en dollars)	Nombre de pays (Effectifs)
Moins de 1000	39
1000 à 2000	7
2000 à 3000	2
3000 à 4000	2

Tab 5.I °

Les PNB de 3 pays ne sont pas comptés : Celui de la Libye qui est de 8640 dollars et ceux de la Guinée équatoriale et de la Somalie qui ne sont pas connus.

a) Donner la distribution des fréquences.

b) Tracer l'histogramme des fréquences associé.

Solution.


a) Par définition la fréquence d'une classe est égale au rapport de l'effectif partiel de cette classe à l'effectif total. On calcule successivement ces rapports et on obtient le tableau :

Tab 5.2

PNB par habitant(en dollars)	Fréquences
Moins de 1000	$\frac{39}{50} = 0,78$
1000 à 2000	$\frac{7}{50} = 0,14$
2000 à 3000	$\frac{2}{50} = 0,04$
3000 à 4000	$\frac{2}{50} = 0,04$

b) Toutes les classes de cette série ont la même étendue et par conséquent on peut choisir les hauteurs des différents rectangles de l'histogramme des fréquences proportionnelles aux fréquences. On choisira 1 mm comme unité représentant une fréquence de 0,01. Ceci nous donne le diagramme :

Fréquence



5.2-Exercices supplémentaires.

5.2.I-Soit la série des nombres :

10, 10, 11, 13, 13, 13, 17, 20, 25, 26, 33, 33, 33, 33, 46, 53, 56, 59;

a) Mettre cette série sous forme d'une série classée dont les classes ont une étendue égale à 10.

b) Donner la distribution des effectifs et tracer l'histogramme associé.

c) Donner la distribution des fréquences et tracer l'histogramme associé.

5.5.2-Le tableau suivant donne la repartion de la population immigrée en France (aux alentours de l'année 1974)tiré de "Les immigrés" CEDETIM

Age	Hommes	%	Femmes	%
moins de 19	366840	22,66	344330	32,92
De 20 à 64	1105760	68,32	555120	53,08
65 et plus	145740	9,02	146220	13,98

Tab 5.3

Tracer la pyramide des âges associée à cette statistique et interpreter les resultats.

6-EFFECTIFS ET FREQUENCES CUMULES.

Soit x_1, \dots, x_k une série à valeurs isolées telle que $x_1 < x_2 < \dots < x_k$
 n_1, \dots, n_k

On appelle effectif cumulé de la valeur x_i la somme des effectifs partiels de x_i et de toutes les valeurs de la série qui sont inférieures à x_i , c'est à dire :

$$N_i = n_1 + n_2 + \dots + n_i \quad (N_i \text{ denote cet effectif cumulé}) .$$

On appelle fréquence cumulée de la valeur x_i le nombre :

$$F_i = f_1 + f_2 + \dots + f_i .$$

Pour une série classée on definit de la même manière l'effectif cumulé d'une classe (respectivement la fréquence cumulée) comme étant la somme des effectifs partiels (respectivement les fréquences) de cette classe et de toutes celles qui la précèdent.

Par exemple si on reprend le tableau 2.I on obtient les distributions des effectifs cumulés et fréquences cumulées:

Tab 6.I

Classes de salaires(en NF)	Effectifs cumulés
3500 à 4500	48
4500 à 5500	48 + 27 = 75
5500 à 8000	48 + 27 + 17 = 92
plus de 8000	48 + 27 + 17 + 8 = 100

Classes de salaires (en NF)	Fréquences cumulées
3500 à 4500	0,48
4500 à 5500	0,75
5500 à 8000	0,92
plus de 8000	I

Tab 6.2

On peut remarquer que l'effectif cumulé de la $i^{\text{ème}}$ valeur ou de la $i^{\text{ème}}$ classe (la fréquence cumulée) est égal à l'effectif partiel de cette valeur ou de cette classe et que l'effectif cumulé (la fréquence cumulée) de la dernière valeur ou la dernière classe est égal à l'effectif total (à I).

Il existe aussi un histogramme des effectifs cumulés et un histogramme des fréquences cumulées. Ils consistent en des rectangles dont les aires sont proportionnelles aux effectifs cumulés ou aux fréquences cumulées suivant le cas.

Représentons par exemple celui de l'exercice 5.1. Commençons d'abord par donner la distribution des effectifs cumulés :

PNB par habitant(en dollars)	Effectifs cumulés
Moins de 1000	39
1000 à 2000	46
2000 à 3000	48
3000 à 4000	50

Tab 6.3

Ceci nous permet donc de construire l'histogramme :

Effectifs cumulés




Fig 6.I

CHAPITRE II
VALEURS MOYENNES

Les valeurs moyennes sont des constantes naturellement associées à une série statistique et qui donnent une idée assez globale de la distribution des valeurs de cette série.

I. MEDIANE.

I. I-Cas d'une série isolée. Soit x_1, \dots, x_k (I)
 n_1, \dots, n_k

une série statistique à valeurs isolées. On supposera qu'on a $x_1 < x_2 < \dots < x_k$. On peut alors écrire la série sous la forme $\underbrace{x_1, \dots, x_1}_{n_1 \text{ fois}}, \underbrace{x_2, \dots, x_2}_{n_2 \text{ fois}}, \dots, \underbrace{x_k, \dots, x_k}_{n_k \text{ fois}}$.

Par exemple la série 23, 34, 45, 47, 68 (valeurs)
? 1 3 3 2 (effectifs)

peut être écrite sous la forme 23, 23, 34, 45, 45, 45, 47, 47, 47, 68, 68. avec des effectifs partiels tous égaux à 1.

N'importe quelle série statistique à valeurs isolées du type (I) se ramène à une série du type $x_1 \leq x_2 \leq \dots \leq x_k$ avec des effectifs partiels tous égaux à 1.

Dans ce cas la Médiane sera par définition la valeur qui partage la série en 2 séries qui ont le même effectif total. Suivant que k est un nombre pair ou impair on va calculer explicitement la médiane.

i) k impair i.e. s'écrit comme suit : $k = 2r - 1$. La série se met alors sous la forme $x_1, \dots, x_{r-1}, x_r, x_{r+1}, \dots, x_{2r-1}$ la médiane est alors le nombre $M = x_r$.

ii) k pair. On peut l'écrire sous la forme $k = 2r$. On écrit alors la série $x_1, \dots, x_r, x_{r+1}, \dots, x_{2r}$. Dans ce cas pour la médiane on prend généralement $M = \frac{x_r + x_{r+1}}{2}$.

I.I.I-Exemples.

i) Soit la série 23, 23, 34, 45, 45, 45, 47, 47, 47, 68, 68.

Elle a $II = 6.2 - I$ termes. Par conséquent sa médiane est égale au 6^{ème} terme c.a.d $M = 45$.

ii) Soit la série 47, 47, 56, 59, 68, 70, 87, 87. Elle a $8 = 2.4$ termes.

Sa médiane est donc $M = \frac{59 + 68}{2} = 63,5$.

I.2-Cas d'une série classée. Commençons par regarder les calculs

sur un exemple. Soit la série classée donnée par le tableau suivant :

Classes	Effectifs partiels
10 à 20	2
20 à 30	1
30 à 40	5
40 à 50	2

Tab I.1


Dans ce cas où toutes les classes ont la même étendue on peut déterminer la médiane graphiquement. Pour ce, donnons d'abord la distribution des effectifs cumulés de cette série :

Classes	Effectifs cumulés
10 à 20	2
20 à 30	3
30 à 40	8
40 à 50	10

Tab I.2

et traçons l'histogramme associé :

Fig I.I



Les deux 1^{ères} ne donnent pas la moitié de l'effectif total et les 3 1^{ères} donnent un effectif supérieur à cette moitié. La médiane est donc dans la classe [30 , 40]. Pour la déterminer on procède par interpolation proportionnelle. Ceci suppose que la distribution des valeurs de la série dans la classe [30 , 40] est uniforme (car a priori il n'y a aucune raison pour qu'il y ait plus de valeurs proches de 30 que de 40). Les triangles OAB et O'A'B' sont semblables. Ils ont donc leurs côtés homologues proportionnels. Ceci nous donne :

$$\frac{OA}{OA'} = \frac{AB}{A'B'} \quad \text{c'est-à-dire } OA = OA' \cdot \frac{AB}{A'B'}$$

D'autre part $OA' = 10$, $AB = 5 - 3 = 2$ et $A'B' = 8 - 3 = 5$.

En remplaçant les différentes expressions par leurs valeurs respectives on obtient $OA = 4$ et donc $M = 30 + 4 = 34$.


Si l'histogramme des effectifs cumulés est tracé d'une manière précise on détermine la médiane en lisant directement l'abscisse du point B dont l'ordonnée est égale à $N/2$.

Dans le cas général d'une série statistique $[x_1, x_2[\dots [x_k, x_{k+1}[$ on supposera que les étendues sont toutes égales. $n_1 \dots n_k$

On montre sans peine que la médiane appartient à un intervalle $[x_i, x_{i+1}[$. On note N_i l'effectif cumulé de cette classe et on trace l'histogramme des effectifs cumulés associé :

Effectifs
cumulés

Fig I.2



Comme précédemment on a l'égalité : $\frac{OA}{OA'} = \frac{AB}{A'B'}$.

D'où l'on déduit $OA = OA' \cdot \frac{AB}{A'B'}$. D'autre part on a :

$$OA' = e_i = x_{i+I} - x_i \quad , \quad A'B' = N_i - N_{i-I} \quad \text{et} \quad AB = N/2 - N_{i-I} .$$

On obtient finalement $OA = e_i \cdot \frac{N/2 - N_{i-I}}{N_i - N_{i-I}}$ et :

$$M = x_i + e_i \cdot \frac{N/2 - N_{i-I}}{N_i - N_{i-I}} \quad (I.I)$$

Remarque : On peut montrer facilement que cette formule donnant la médiane reste valable lorsque les étendues ne sont pas égales. Par contre la détermination graphique directe ne l'est plus. En effet les hauteurs n'étant plus proportionnelles aux effectifs cumulés on ne peut plus repérer $N/2$.

I.3-Quantiles. On a vu que la médiane est une valeur qui partage la série en 2 séries qui ont le même effectif. De la même façon on définit les quantiles Q_1 , Q_2 , Q_3 comme étant les valeurs qui partagent la série en 4 parties qui ont toutes le même effectif. Ainsi soit la série :

$$x_1 \leq x_2 \leq \dots \leq x_k \quad \text{avec des effectifs partiels}$$

tous égaux à I (on a vu au I.I qu'on peut toujours se ramener à ce cas pour une série à valeurs isolées bien-sûr). On a alors :

$$\underbrace{x_1 \dots Q_1}_{25\%} \underbrace{\dots Q_2}_{25\%} \underbrace{\dots Q_3}_{25\%} \underbrace{\dots x_k}_{25\%} .$$

Bien-sûr Q_2 n'est rien d'autre que la médiane. Q_1 et Q_3 sont appelés

le premier et le troisième quartiles. Le nombre $Q_3 - Q_1$ est l'interquartile. Il donne une idée de la façon dont la série est étalée autour de la médiane.

Les deciles Q_1, \dots, Q_9 sont des valeurs qui partagent la série en 10 parties qui ont toutes le même effectif. Le nombre $Q_9 - Q_1$ est l'interdecile et joue le même rôle que l'interquartile.

De manière analogue on définit les quantiles d'ordre p comme étant les valeurs Q_1, \dots, Q_{p-1} qui divisent la série en p parties ayant toutes le même effectif.

Pour déterminer graphiquement les quantiles d'ordre p d'une série classée (ayant des classes de même étendue) on procède de la même façon que pour la médiane mais en choisissant les points d'ordonnées $\frac{N}{p} \dots \frac{(p-1)N}{p}$.

On pourra à titre d'exercice calculer le 1^{er} et le 2^{ème} quantiles de la série 2.I du chap I.

2-MOYENNE. Un étudiant passe un examen en 5 matières et obtient les notes suivantes :

	7	I3	I2	II	9,5
coefficients	2	2	I	3	2 .

Pour savoir son niveau il calcule évidemment la "moyenne" de ses notes :

$$\bar{X} = \frac{2 \cdot 7 + 2 \cdot I3 + I \cdot I2 + 3 \cdot II + 2 \cdot 9,5}{2+2+I+3+2} = 10,4 .$$

On peut interpréter ces notes comme étant la série statistique à valeurs isolées :

7 , I3 , I2 , II , 9,5 (valeurs)

2 , 2 , I , 3 , 2 (effectifs partiels)

à laquelle on attache la valeur 10,4 et qui permet de dire si cet étudiant est ou non reçu à son examen.

Ceci se généralise au cas d'une série statistique à valeurs isolées quelconque.

Soit la série statistique à valeurs isolées:

$$\begin{matrix} x_I , \dots , x_k \\ n_I , \dots , n_k \end{matrix}$$

On appelle moyenne arithmétique de cette série le nombre :

$$(2.I) \quad \bar{X} = \frac{n_I \cdot x_I + \dots + n_k \cdot x_k}{N} \quad \text{où } N = n_I + \dots + n_k \text{ est}$$

l'effectif total de la série.

Avant de passer au cas d'une série classée on va donner quelques propriétés de la moyenne arithmétique.

— Considérons une série X $\begin{matrix} x_I \dots x_k \\ n_I \dots n_k \end{matrix}$. On obtient une nouvelle

série Y en ajoutant à chaque terme de X la constante a, c'est à dire

que Y est donnée par :

$$\begin{matrix} y_I = x_I + a , \dots , y_k = x_k + a . \\ n_I , \dots , n_k \end{matrix}$$

Par definition la moyenne arithmétique de Y est le nombre :

$$\bar{Y} = \frac{n_I(x_I+a) + \dots + n_k(x_k+a)}{N}$$

En developpant on obtient:

$$\begin{aligned} \bar{Y} &= \frac{(n_I x_I + n_I a) + \dots + (n_k x_k + n_k a)}{N} \\ &= \frac{(n_I x_I + \dots + n_k x_k) + (n_I + \dots + n_k) a}{N} \end{aligned}$$

$$(2.2) \quad \bar{Y} = \frac{n_I x_I + \dots + n_k x_k}{N} + \frac{N}{N} a = \bar{X} + a .$$

La moyenne de la série Y est donc obtenue en ajoutant la constante a à celle de la série X.

On peut remarquer que la moyenne d'une série dont toutes les valeurs sont égales à une même constante est elle aussi égale à cette constante. La verification est immediate et est laissée au lecteur comme exercice.

— Soient X et Y deux séries :

$$\begin{array}{l} x_I, \dots, x_k \text{ et} \\ n_I, \dots, n_k \end{array}$$

$$\begin{array}{l} y_I, \dots, y_k \\ n_I, \dots, n_k \end{array}$$

dont les valeurs respectives ont les mêmes effectifs partiels. On note $Z = X+Y$ la somme de ces deux séries c'est à dire la série dont les termes sont les sommes respectives des termes de X et Y.

On peut l'écrire donc :

$$\begin{array}{l} z_I = x_I + y_I, \dots, z_k = x_k + y_k \\ n_I, \dots, n_k \end{array}$$

Calculons sa moyenne arithmétique.

$$\bar{z} = \frac{n_I z_I + \dots + n_k z_k}{N} = \frac{n_I(x_I + y_I) + \dots + n_k(x_k + y_k)}{N}$$

On développe :

$$\bar{z} = \frac{(n_I x_I + \dots + n_k x_k)}{N} + \frac{(n_I y_I + \dots + n_k y_k)}{N}$$

c'est-à-dire :

(2.3)

$$\boxed{\bar{z} = \bar{x} + \bar{y}}$$

La moyenne arithmétique de deux séries ayant les mêmes effectifs partiels est égale à la somme des moyennes des deux séries.

-Considérons toujours une série X x_I, \dots, x_k et multiplions
 n_I, \dots, n_k

toutes ses valeurs par une même constante a. Calculons la moyenne arithmétique de cette série. On a en notant \bar{P} cette moyenne :

$$\bar{P} = \frac{n_I(ax_I) + \dots + n_k(ax_k)}{N} ;$$

on met a en facteur commun et on obtient :

$$(2.4) \quad \bar{P} = \frac{n_I x_I + \dots + n_k x_k}{N}, \quad a = a \cdot \bar{x} .$$

Si on multiplie toutes les valeurs d'une série par une même constante la moyenne de la série est aussi multipliée par cette constante pour donner la moyenne de la nouvelle série obtenue.

-En raison de la commutativité de l'addition des nombres réels la moyenne arithmétique d'une série ne dépend pas de l'ordre dans lequel on écrit ses termes.

Moyenne arithmétique d'une série classée.

Pour une série classée on définit sa moyenne comme étant celle de la série des centres associée. Plus précisément soit $[x_1, x_2[\dots [x_k, x_{k+1}[$

$n_1 \dots n_k$

et notons $c_i = \frac{x_i + x_{i+1}}{2}$ le centre de la classe $[x_i, x_{i+1}[$. On obtient ainsi la série à valeurs isolées : c_1, \dots, c_k .

n_1, \dots, n_k

Par définition on pose :

$$(2.5) \quad \bar{X} = \bar{C} = \frac{n_1 c_1 + \dots + n_k c_k}{N} \quad \text{avec } N = n_1 + \dots + n_k.$$

Exemple.

Le tableau suivant donne une estimation de la population de 27 pays européens :

Population (en millions)	Nombre de pays
Moins de 5	7
5 à 10	7
10 à 15	3
15 à 20	2
20 à 25	2
25 à 40	2
40 à 55	1
55 à 70	3

Tab 2.I

Cette statistique est tirée de "Dossiers et Documents Le Monde" N° 108 du mois de Fev 1984).

La population de l'URSS n'est pas comptée dans le tableau. Elle est de 270 millions. La compter nous oblige à introduire une classe d'une grande étendue relativement aux autres alors que ce n'est vraiment pas nécessaire pour comprendre la méthode de calcul.

Calculons la série des centres. On obtient alors la série à valeurs isolées :

2,5	7,5	12,5	17,5	22,5	32,5	47,5	62,5	(valeurs)
7	7	3	2	2	2	1	3	(effectifs)

En utilisant la formule (2.1) et en designant par \bar{P} la population moyenne on aura :

$$\bar{P} = \frac{7 \cdot 2,5 + 7 \cdot 7,5 + 3 \cdot 12,5 + 2 \cdot 17,5 + 2 \cdot 22,5 + 2 \cdot 32,5 + 1 \cdot 47,5 + 3 \cdot 62,5}{27}$$

ceci donne $\bar{P} = 18,06$ Millions ha.

Le calcul de la moyenne arithmétique risque quelquefois d'être un peu lourd quand on le fait à la main. Pour ce on le ramène à celui d'une série plus simple en effectuant un changement de variable.

Soit $x_I \dots x_k$ une série à valeurs isolées et posons pour tout $i=I, \dots, k$

$$z_i = \frac{x_i - x_0}{e} \quad \text{où } x_0 \text{ et } e \text{ sont des nombres reels quelconques mais } e \text{ non nul.}$$

Ceci nous donne une nouvelle série Z $z_I \dots z_k$. De manière équivalente on a :

$$x_i = e \cdot z_i + x_0$$

On peut donc considerer la série X comme la somme de 2 séries qui sont :

La serie Y $e \cdot z_I \dots e \cdot z_k$ et la série dont tous les termes $n_I \dots n_k$

sont égaux à x_0 . Cette dernière a pour moyenne arithmétique x_0 . Pour Y on applique la formule (2.4) et on obtient $\bar{Y} = e \cdot \bar{Z}$. D'où finalement :

$$(2.6) \quad \bar{X} = e \cdot \bar{Z} + x_0 \quad .$$

Comme exemple d'application on prend $X = P$ (Tab 2.I).

On applique donc ce changement de variable à la série du Tab 2.I en prenant $x_0 = 22,5$ et $e = 5$ par exemple. La série que l'on obtient

sera	-4	-3	-2	-1	0	2	5	8	(valeurs)
	7	7	3	2	2	2	1	3	(effectifs)

Cette série est obtenue en retranchant 22,5 à tous les termes de la série 2,5 7,5 12,5 17,5 22,5 32,5 47,5 62,5 et en divisant ensuite par 5. La formule (2.6) étant vraie pour tout x_0 et tout e non nul on choisit évidemment ces deux valeurs de façon à simplifier au maximum la série.

La nouvelle série obtenue a donc pour moyenne :

$$\bar{Z} = \frac{7 \cdot (-4) + 7 \cdot (-3) + 3 \cdot (-2) + 2 \cdot (-1) + 2 \cdot 0 + 2 \cdot 2 + 1 \cdot 5 + 3 \cdot 8}{27} = -0,89 \quad .$$

D'où $\bar{X} = 5 \cdot (-0,89) + 22,5 = 18,06$. On retrouve ainsi le résultat obtenu par la méthode directe.

Autre expression de la moyenne arithmétique. Soit X une série statistique

à valeurs isolées : x_1, \dots, x_k
 n_1, \dots, n_k $N = n_1 + \dots + n_k$.

On sait que la moyenne arithmétique de cette série s'écrit :

$$\bar{X} = \frac{n_1 x_1 + \dots + n_k x_k}{N} \quad ,$$

ou encore :

$$\bar{X} = \frac{n_1}{N} x_1 + \dots + \frac{n_k}{N} x_k = f_1 x_1 + \dots + f_k x_k \quad .$$

$$\bar{X} = f_1 x_1 + \dots + f_k x_k \quad . \quad (2.7)$$

AUTRES MOYENNES. Il existe d'autres moyennes que la moyenne arithmétique et qui sont d'un usage en statistiques. Donnons brièvement la définition de quelques-unes d'entre elles :

-Moyenne géométrique. Soit x_1, \dots, x_k une série statistique à valeurs isolées. n_1, \dots, n_k

Par définition la moyenne géométrique de cette série est le nombre :

$$G = \sqrt[N]{x_1^{n_1} \cdot \dots \cdot x_k^{n_k}} \quad (2.8) \quad (\text{on suppose } x_i \text{ positif pour tout } i)$$

Par exemple la moyenne géométrique de la série

3	II	I2	(valeurs)
2	I	3	(effectifs)

est donnée par :

$$G = \sqrt[6]{3^2 \cdot II^1 \cdot I2^3} = \sqrt[6]{171072} = 7,45$$

Pour calculer la moyenne géométrique il est souvent plus commode de calculer $\text{Log}G$. Plus précisément on a :

$$\text{Log}G = \text{Log} \sqrt[N]{x_1^{n_1} \cdot \dots \cdot x_k^{n_k}}$$

$$\text{Log}G = \frac{n_1 \text{Log}x_1 + \dots + n_k \text{Log}x_k}{N} \quad (2.9)$$

Par exemple pour la série ci-dessus on a :

$$\text{Log}G = \frac{2 \cdot \text{Log}3 + 1 \cdot \text{Log}II + 3 \cdot \text{Log}I2}{6}$$

$$= \frac{2 \cdot 1,0986 + 1 \cdot 2,3978 + 3 \cdot 2,4849}{6} = 2,0082.$$

En cherchant le nombre réel G dont le logarithme neperien vaut 2,0082 on trouve $G = 7,4505$. Ce qui correspond au résultat par le calcul direct. L'avantage de passer à une série de logarithmes est évidemment de ramener

le calcul d'une moyenne géométrique à celui d'une moyenne arithmétique.

-Moyenne harmonique. On se donne toujours une série :

$$\begin{array}{c} x_I, \dots, x_k \\ n_I, \dots, n_k \end{array}$$

La moyenne harmonique de cette série est le nombre H défini par la relation :

$$\frac{N}{H} = \frac{n_I}{x_I} + \dots + \frac{n_k}{x_k} \quad (2.10) \quad \text{On suppose bien-sûr que } x_i \text{ est non nul pour tout } i = I, \dots, k.$$

Le nombre H n'est pas défini d'une manière explicite; il est préférable de calculer d'abord le membre de droite. Par exemple pour la série :

3	II	I2	(valeurs)
2	I	3	(effectifs)

on a :

$$\frac{6}{H} = \frac{2}{3} + \frac{I}{II} + \frac{3}{I2} = \frac{98 + 12 + 33}{I32} = \frac{I33}{I32}$$

D'où $H = \frac{I32.6}{I33}$, c'est-à-dire $H = 5,954$.

Evidemment dans le cas d'une série classée la moyenne géométrique et la moyenne harmonique sont celles de la série des centres associée.

3-MODE. On appelle mode d'une série statistique à valeurs isolées ou classe modale dans le cas d'une série classée, la valeur de la série, ou la classe, qui a le plus grand effectif.

Par exemple le mode de la série : 3 3 3 4 II I3 I3 I3 est la valeur 3 ou I3.

Cet exemple montre que certaines séries peuvent avoir plusieurs modes ou plusieurs classes modales si la série est classée.

EXERCICES

I) Soit la série à valeurs isolées x_1, x_2 (valeurs) x_1 et x_2 positifs.
I I (effectifs) .

On désigne par \bar{X} , G, H respectivement les moyennes arithmétique, géométrique et harmonique.

Démontrer la double inégalité :

$$H \leq G \leq \bar{X} .$$

II)

On considère la statistique suivante :

I39	I71	I34	I55	I44	I53	I75	I36	I49	I54
I37	I40	I42	I68	I52	I49	I48	I55	I68	I44
I34	I44	I37	I56	I53	I49	I69	I58	I47	I50
I52	I40	I62	I53	I77	I46	I52	I40	I45	I52
I51	I45	I57	I56	I60	I70	I65	I58	I58	I61

Tab 2.2

1°-Mettre cette série sous forme d'une série classée dont les classes ont une étendue égale à 10.

2°-Construire l'histogramme des effectifs cumulés .

3°-Calculer la médiane de cette série statistique. Calculer le 1^{er} et le 3^{ème} quartiles.

4°-Calculer la moyenne arithmétique de cette série en effectuant un changement de variable (Prendre $x_0 = 155$ et $e = 10$).

III) Tracer l'histogramme des effectifs de la série :

Classes	[10 , 20[[20 , 40[[40 , 70[
Effectifs partiels	6	20	15

Expliquer comment vous faites la construction des différents rectangles.

SOLUTIONS

I) Si $x_1 = x_2 = a$ on a immédiatement :

$$\bar{x} = \frac{x_1 + x_2}{2} = \frac{a+a}{2} = a, \quad G = \sqrt{x_1 \cdot x_2} = \sqrt{a \cdot a} = a \quad \text{et}$$

$$\frac{2}{H} = \frac{1}{x_1} + \frac{1}{x_2} = \frac{1}{a} + \frac{1}{a} = \frac{2}{a} \quad \text{ce qui donne } H = a.$$

D'où : $\bar{x} = G = H$.

Supposons x_1 et x_2 distincts.

Pour comparer 2 réels positifs il suffit de comparer leurs carrés. On a successivement :

$$G^2 = x_1 \cdot x_2, \quad \bar{x}^2 = \frac{(x_1 + x_2)^2}{4} \quad \text{et de } \frac{2}{H} = \frac{1}{x_1} + \frac{1}{x_2} \quad \text{on tire}$$

$$H = \frac{2x_1 x_2}{x_1 + x_2}.$$

$$\text{Calculons } \bar{x}^2 - G^2 = \frac{(x_1 + x_2)^2}{4} - x_1 x_2 = \frac{(x_1 + x_2)^2 - 4x_1 x_2}{4}$$

$$= \frac{(x_1^2 + x_2^2 + 2x_1 x_2) - 4x_1 x_2}{4} = \frac{x_1^2 + x_2^2 - 2x_1 x_2}{4}$$

$$= \frac{(x_1 - x_2)^2}{4}$$

Cette dernière quantité est toujours positive car c'est un carré. On en déduit $\bar{x}^2 - G^2 > 0$ et donc $\bar{x} > G$.

C.Q.F.D.

Calculons maintenant la différence :

$$G^2 - H^2 = \frac{x_1 x_2}{(x_1 + x_2)^2} - \frac{4x_1^2 x_2^2}{(x_1 + x_2)^2} = \frac{x_1 x_2 (x_1 + x_2)^2 - 4x_1^2 x_2^2}{(x_1 + x_2)^2}$$

On met $x_1 x_2$ en facteur au numérateur; on obtient :

$$G^2 - H^2 = \frac{x_1 x_2 ((x_1 + x_2)^2 - 4x_1 x_2)}{(x_1 + x_2)^2} = \frac{x_1 x_2 (x_1 - x_2)^2}{(x_1 + x_2)^2}$$

Ceci montre que $G^2 - H^2$ est toujours positif et donc $G > H$.

C.Q.F.D.

II)

I°-On remarque que les valeurs de cette série sont comprises entre I30 et I80. Nous allons donc constituer les classes de la façon suivante :

Classes	Effectifs partiels
[I30 , I40 [6
[I40 , I50 [15
[I50 , I60 [18
[I60 , I70 [7
[I70 , I80 [4

Tab 2.4

Il y a 5 classes d'étendue égale à 10.

2°-On calcule d'abord les effectifs cumulés des différentes classes. On a le tableau suivant :

Classes	Effectifs cumulés
[I30 , I40 [6
[I40 , I50 [21
[I50 , I60 [39
[I60 , I70 [46
[I70 , I80 [50

Tab 2.5

On trace l'histogramme correspondant en choisissant les hauteurs des rectangles proportionnelles aux effectifs cumulés puisque on est dans le cas où les classes ont la même étendue :




Fig 2.I

3°-L'effectif total de cette série est égal à 50. La moitié de l'effectif $N/2 = 25$ est dans l'intervalle associée à la classe $[150, 160[$. Pour calculer la médiane M on procède comme au 1.° :




Fig 2.2

On a $\frac{OA}{OA'} = \frac{AB}{A'B'}$, c'est à dire $\frac{M - 150}{160 - 150} = \frac{25 - 21}{39 - 21}$. D'où on déduit :

$$M = 150 + \frac{10 \cdot 4}{18} = 150 + 2,22 = 152,22 .$$

Pour calculer le 1^{er} et le 3^{ème} quartiles Q_1 et Q_3 on considère le 1/4 et les 3/4 de l'effectif total qui sont respectivement $N/4 = 12,5$ et $3N/4 = 37,5$. Faisons le calcul par exemple de Q_3 (celui de Q_1 se fait d'une manière analogue) :

Le nombre $3N/4$ est dans l'intervalle de la classe $[150, 160[$. En procédant comme pour la médiane on obtient (voir Fig 2.2) :

$$\frac{OA''}{OA'} = \frac{A''B''}{A'B'} \quad \text{c'est à dire} \quad \frac{Q_3 - 150}{160 - 150} = \frac{37,5 - 21}{39 - 21}$$

$$\text{Ce qui donne} \quad Q_3 = 150 + \frac{10 \cdot 16,5}{18} = 159,16 .$$

Faire attention pour le calcul de Q_1 car $N/4 = 12,5$ est dans l'intervalle associé à la classe $[140, 150[$.

4°-La série des centres est la série à valeurs isolées :

I35	I45	I55	I65	I75	(Valeurs)
6	I5	I8	7	4	(effectifs partiels)

Si on désigne par x_i le terme général de cette série, on obtient en effectuant le changement de variable :

$$z_i = \frac{x_i - x_0}{e} = \frac{x_i - I55}{10}$$

une nouvelle série à valeurs isolées :

-2	-I	0	I	2	(valeurs)
6	I5	I8	7	4	(effectifs partiels)

et qui a comme moyenne arithmétique :

$$\bar{z} = \frac{6 \cdot (-2) + I5 \cdot (-I) + I8 \cdot 0 + 7 \cdot I + 4 \cdot 2}{50} = -0,24 .$$

On en déduit :

$$\bar{x} = e \cdot \bar{z} + x_0 = 10 \cdot (-0,24) + I55 = I52,6 .$$

III)

Notons h_1, h_2 et h_3 les hauteurs des différents rectangles de l'histogramme des effectifs respectivement associés aux classes $[10, 20[$, $[20, 40[$ et $[40, 70[$. Les aires de ces rectangles seront donc :

$$S_1 = (20 - 10)h_1 \quad , \quad S_2 = (40 - 20)h_2 \quad \text{et} \quad S_3 = (70 - 40)h_3 .$$

Les aires : S_1 , S_2 et S_3 doivent être proportionnelles aux effectifs partiels 6 , 20 et I5 , c'est à dire :

$$\frac{S_1}{6} = \frac{S_2}{20} = \frac{S_3}{I5} \quad \text{d'où on tire les relations :}$$

$$h_2 = 5h_1/3 \quad \text{et} \quad h_3 = 5h_1/6 .$$

Si donc on choisit $h_1 = 6$ cm par exemple on doit prendre $h_2 = 10$ cm et $h_3 = 5$ cm .On obtient finalement l'histogramme suivant :




Fig 3.3

CHAPITRE III

PARAMETRES DE DISPERSION

Considérons les séries statistiques suivantes :

X : 2 4 9 13 17
 Y : 7 9 9 10 10 .

Les effectifs partiels sont tous égaux à 1 aussi bien pour X que pour Y. Il est facile de voir que ces deux séries ont la même moyenne arithmétique $\bar{X} = \bar{Y} = 9$ et la même médiane aussi $M_X = M_Y = 9$. Si on interprète ces deux séries comme les notes de deux étudiants X et Y, on dira que Y est plus régulier que X. La moyenne et la médiane - plus généralement les valeurs moyennes - sont donc insuffisantes pour donner "certains renseignements" sur la série. Il faut introduire d'autres paramètres qui permettent de mesurer la dispersion d'une série autour de sa moyenne. C'est ce que nous allons faire dans ce chapitre.

I. VARIANCE.

Soit X : x_1, \dots, x_k une série à valeurs isolées.
 (I) n_1, \dots, n_k

I.1-Definition. On appelle variance de X et on note $\text{Var}(X)$ le nombre défini par :

$$\text{Var}(X) = \frac{1}{N} (n_1(x_1 - \bar{X})^2 + \dots + n_k(x_k - \bar{X})^2) \quad (\text{I.1})$$

On remarque que $\text{Var}(X) \geq 0$ et ce n'est rien d'autre que la moyenne arithmétique de la série $(x_1 - \bar{X})^2, \dots, (x_k - \bar{X})^2$.
 n_1, \dots, n_k

I.2-Exemple. Calculons les variances des séries X et Y ci-dessus. On peut résumer les calculs dans le tableau suivant :

\bar{X}	2	4	9	13	17
Effectifs	1	1	1	1	1
$x_i - \bar{X}$	-7	-5	0	4	8
$(x_i - \bar{X})^2$	49	25	0	16	64
\bar{Y}	7	9	9	10	10
Effectifs	1	1	1	1	1
$y_i - \bar{Y}$	-2	0	0	1	1
$(y_i - \bar{Y})^2$	4	0	0	1	1

On en deduit donc
$$\text{Var}(X) = \frac{49 + 25 + 0 + 16 + 64}{5} = 30,8 .$$

$$\text{Var}(Y) = \frac{4 + 0 + 0 + 1 + 1}{5} = 1,2 .$$

On voit donc sur cet exemple que plus la variance est grande, plus la série est dispersée autour de la moyenne.

Le cas où $\text{Var}(X)$ est égale à 0 signifie que chaque terme de la série

$$(x_1 - \bar{X})^2, \dots, (x_k - \bar{X})^2$$

$$n_1, \dots, n_k$$

est nul et donc pour tout $i = 1, \dots, k$ on a $x_i = \bar{X}$, c'est-à-dire que la série est constante.

I.3-Définition. Soit $[x_1, x_2 [, \dots , [x_k, x_{k+1} [$
 $n_1 \quad , \dots , \quad n_k$

une série classée. On appelle variance de cette série la variance de la série des centres des classes.

On peut donc toujours supposer que la série est à valeurs isolées tout le long de ce chapitre.

I.4-Quelques propriétés et règles de calcul.

I.4.I-Autre expression de la variance.

Par définition on a :

$$\text{Var}(X) = \frac{1}{N} (n_1(x_1 - \bar{X})^2 + \dots + n_k(x_k - \bar{X})^2) .$$

On développe chaque terme $(x_i - \bar{X})^2 = x_i^2 - 2\bar{X}x_i + \bar{X}^2$. On obtient :

$$\text{Var}(X) = \frac{(n_1x_1^2 + \dots + n_kx_k^2) - 2\bar{X}(n_1x_1 + \dots + n_kx_k) + (n_1 + \dots + n_k)\bar{X}^2}{N}$$

$$= \frac{n_1x_1^2 + \dots + n_kx_k^2}{N} - 2\bar{X} \frac{n_1x_1 + \dots + n_kx_k}{N} + \frac{N}{N} \bar{X}^2$$

Or on a :

$$\bar{X} = \frac{n_1x_1 + \dots + n_kx_k}{N} \quad \text{et} \quad \frac{n_1x_1^2 + \dots + n_kx_k^2}{N} = \text{Moyenne de } X^2 .$$

D'où on déduit :

$$\text{Var}(X) = \text{Moyenne}(X^2) - 2\bar{X}^2 + \bar{X}^2 = \overline{X^2} - \bar{X}^2 \quad (\text{I.2})$$

Cette formule nous donne une façon de calculer la variance d'une série .

Exemple d'application.

Reprenons la série : X : 2 4 9 13 17 (valeurs)
 I I I I I (effectifs)

La série X^2 est obtenue à partir de X en élevant toutes ses valeurs

au carré : X^2 : 4 16 81 169 289 (valeurs)
 I I I I I (effectifs)

D'où :

$$\overline{X^2} = \frac{4 + 16 + 81 + 169 + 289}{5} = 111,8$$

et par conséquent

$$\text{Var}(X) = \overline{X^2} - \bar{X}^2 = 111,8 - 81 = 30,8 .$$

Pour calculer la variance on pourra se servir aussi bien de la formule I.1 que I.2; mais évidemment suivant le type de problèmes il faut choisir celle qui facilite le calcul.

I.4.2-Propriétés de la variance.

On considère toujours une série X du type (I) (voir p.35). Soit a un nombre reel. Calculons $\text{Var}(X + a)$. Posons $Z = X + a$. On a :

$$\text{Var}(Z) = \text{Moyenne arithmétique de } (Z - \bar{Z})^2 .$$

Or $\bar{Z} = \text{Moyenne arithmétique de } (X + a) = \bar{X} + a$ d'après la formule (2.2) du Chap II (voir p.21). D'où :

$$\begin{aligned} \text{Var}(Z) &= \text{Moyenne arithmétique de } (X + a - \bar{X} - a)^2 \\ &= \text{Moyenne arithmétique de } (X - \bar{X})^2 \\ &= \text{Var}(X) \text{ d'après la remarque qui suit la définition I.1} \end{aligned}$$

(voir p.35). On a donc :

$\text{Var}(X + a) = \text{Var}(X)$	(I.3)
-------------------------------------	-------

Posons maintenant $P = aX$. On a alors:

$$\text{Var}(P) = \text{Var}(aX) = \text{Moyenne arithmétique de } (aX - a\bar{X})^2 .$$

Or $a\bar{X} = a\bar{X}$. D'où :

Moyenne arithmétique de $(aX - a\bar{X})^2 =$ Moyenne arithmétique de la série $a^2(X - \bar{X})^2$. D'après la formule (2.4) (voir p.22) on a :

Moyenne arithmétique de $a^2(X - \bar{X})^2 = a^2$ (Moyenne arithmétique de $(X - \bar{X})^2$). Et finalement on obtient le resultat :

$$\boxed{\text{Var}(aX) = a^2\text{Var}(X)} \quad (\text{I.4})$$

I.4.3-Calcul de la variance par changement de variable.

Soient x_0 et $e \neq 0$ deux nombres réels. Posons pour tout $i = 1, \dots, k$

$$z_i = \frac{x_i - x_0}{e} . \text{ Ceci est équivalent à } x_i = ez_i + x_0 .$$

Par (I.3) (p.38) on a : $\text{Var}(eZ + a) = \text{Var}(eZ)$. Ce qui est aussi égal à $e^2\text{Var}(Z)$ (formule I.4 ci-dessus). On a finalement:

$$\boxed{\text{Var}(X) = e^2\text{Var}(Z)} \quad (\text{I.5})$$

Exemple d'application.

Calculons la variance de la série classée de l'exercice II p.28. Sa série des centres est donnée à la page.33 :

X	I35	I45	I55	I65	I75
	6	15	18	7	4

En effectuant le changement de variable :

$$z_i = \frac{x_i - 155}{10}$$

on obtient une nouvelle série

Z	-2	-1	0	1	2	(valeurs)
	6	15	18	7	4	(effectifs)

On calcule donc la variance de Z en suivant les étapes rassemblées dans le tableau :

Valeurs	-2	-1	0	1	2
Effectifs	6	15	18	7	4
z_i^2	4	1	0	1	4

$$\text{Moyenne de } Z = \frac{6 \cdot (-2) + 15 \cdot (-1) + 18 \cdot 0 + 7 \cdot 1 + 4 \cdot 2}{50} = -0,24 .$$

$$\text{Moyenne de } Z^2 = \frac{6 \cdot 4 + 15 \cdot 1 + 18 \cdot 0 + 7 \cdot 1 + 4 \cdot 4}{50} = 1,24 .$$

D'où :

$$\text{Var}(Z) = \text{Moyenne de } Z^2 - \bar{Z}^2 = 1,24 - 0,0576 = 1,1824$$

et donc :

$$\text{Var}(X) = 10^2 \text{Var}(Z) = 100 \cdot 1,1824 = 118,24 .$$

2. ECART-TYPE.

Souvent pour mesurer la dispersion d'une série autour de sa moyenne on utilise une autre grandeur appelée écart-type et qui est définie par l'égalité :

$$\sigma(X) = \sqrt{\text{Var}(X)} \quad (1.6)$$

Par exemple pour les séries qu'on a considérées à la page 35 on a :

$$\text{Var}(X) = 30,8 \quad \text{et} \quad \text{Var}(Y) = 1,2 \quad \text{et donc :}$$

$$\sigma(X) = \sqrt{30,8} = 5,54$$

$$\sigma(Y) = \sqrt{1,2} = 1,09 .$$

EXERCICE RESOLU

On considère les deux séries statistiques suivantes donnant la répartition en fonction de l'âge de la population espagnole en 1960. Les données ont été obtenues à partir de deux échantillons de 10000 personnes de chaque sexe.

Classes	Hommes	Femmes
0 à 5	1041	943
5 à 10	948	825
10 à 15	903	833
15 à 25	1565	1484
25 à 35	1600	1551
35 à 45	1301	1351
45 à 55	1083	1151
55 à 65	855	926
65 à 75	704	936

1°-Donner la distribution des effectifs cumulés et calculer l'âge médian masculin.

2°-Calculer l'âge moyen pour :

-Le sexe masculin,

-le sexe féminin.

3°-Calculer la variance et l'écart-type de chacune de ces deux séries.

SOLUTION.

1°-Rappelons que l'effectif cumulé d'une classe est égal à la somme de l'effectif de cette classe et ceux de toutes les classes qui la précèdent. On a ainsi :

Classes	Effectifs cumulés sexe masculin	Effectifs cumulés sexe féminin
0 à 5	1041	943
5 à 10	1989	1768
10 à 15	2892	2601
15 à 25	4457	4085
25 à 35	6057	5636
35 à 45	7358	6987
45 à 55	8441	8138
55 à 65	9296	9064
65 à 75	10000	10000

On voit donc que l'âge médian masculin tombe dans la classe [25 , 35[.

Notons le M_h . Pour le calculer on peut utiliser la formule (I.I) (voir p.18)

$$M_h = x_i + e_i \frac{N/2 - N_{i-1}}{N_i - N_{i-1}}$$

où dans le cas qui nous interesse on a :

$$x_i = 25 \quad e_i = 35 - 25 = 10$$

$$N_i = 6057 \quad N_{i-1} = 4457 \quad \text{et} \quad N/2 = 5000$$

On obtient en reportant toutes ces valeurs dans la formule ci-dessus :

$$M_h = 25 + 10 \frac{5000 - 4457}{6057 - 4457} = 28,39 .$$

2°-Pour l'âge moyen masculin et l'âge moyen féminin on cherche d'abord les séries des centres qu'on notera X et Y. Ces deux séries X et Y vont avoir les mêmes valeurs puisque elles proviennent des mêmes classes. Par contre elles n'auront pas les mêmes effectifs partiels.

Classes	effectifs masculins	effectifs féminins	X	Y	$X^2 = Y^2$
0 à 5	1041	943	2,5	2,5	6,25
5 à 10	948	825	7,5	7,5	56,25
10 à 15	903	833	12,5	12,5	156,25
15 à 25	1565	1484	20	20	400
25 à 35	1600	1551	30	30	900
35 à 45	1301	1351	40	40	1600
45 à 55	1083	1151	50	50	2500
55 à 65	855	926	60	60	3600
65 à 75	704	936	70	70	4900

On aura alors :

$$\bar{X} = 30,70 \quad \text{et} \quad \bar{Y} = 32,78 .$$

Le lecteur est invité à faire le calcul en détail.

3°-On sait que :

$$\text{Var}(X) = \overline{X^2} - \bar{X}^2 \quad \text{et} \quad \text{Var}(Y) = \overline{Y^2} - \bar{Y}^2 .$$

En utilisant le tableau ci-dessus on trouve:

$$\overline{X^2} = 1358,36 \quad \text{et} \quad \overline{Y^2} = 1513,10 \quad \text{donc}$$

$$\text{Var}(X) = 1358,36 - (30,70)^2 = 415,87$$

$$\text{Var}(Y) = 1513,10 - (32,78)^2 = 438,57$$

On en déduit :

$$\sigma(X) = \sqrt{415,87} = 20,39$$

$$\sigma(Y) = \sqrt{438,57} = 20,94 .$$

On remarque qu'en moyenne la population féminine est un peu plus vieille que la population masculine. Mais les dispersions sont pratiquement les mêmes.

CHAPITRE IV

LES INDICES

On a besoin souvent de mesurer les variations dans le temps d'une ou plusieurs variables statistiques. Par exemple si le prix de l'essence est :

$$- P_0 = 2,80 \text{ F à l'époque } 0,$$

$$- P_I = 4,70 \text{ F à l'époque } I,$$

on pose :

$$P_{I/0} = \frac{P_I}{P_0} = \frac{4,70}{2,80} = 1,67 .$$

Ce rapport nous dit que le prix de l'essence à l'époque I est 1,67 fois plus élevé qu'à l'époque 0. Il mesure donc les variations du prix de l'essence par rapport à l'époque 0 qu'on appelle époque de référence.

Bien-sûr on peut faire la même chose en prenant l'époque I comme époque de référence. Dans ce cas on obtient :

$$P_{0/I} = \frac{P_0}{P_I} = \frac{2,80}{4,70} = 0,59 .$$

Le nombre $P_{I/0}$ est appelé indice élémentaire .

D'une manière générale on considère une grandeur G qui varie dans le temps. On appelle alors indice élémentaire de G à l'époque I par rapport à l'époque 0 le nombre :

$$\boxed{G_{I/0} = \frac{G_I}{G_0}} \quad (0.I)$$

Nous nous limiterons dans ce chapitre à l'étude des indices des prix et des quantités et qui permettent de mesurer l'évolution du coût de certains biens de consommation.

I. INDICES ELEMENTAIRES

I. I-Indices élémentaires des prix.

Considérons un article et supposons que son prix est :

- P_0 à l'époque 0,

- P_I à l'époque I.

On pose :

$$\boxed{P_{I/0} = \frac{P_I}{P_0}} \quad (I.1)$$

Le nombre $P_{I/0}$ est appelé l'indice élémentaire du prix de cet article à l'époque I par rapport à l'époque 0.

On définit de façon analogue :

$$\boxed{P_{0/I} = \frac{P_0}{P_I}} \quad (I.2)$$

Cette fois-ci on a choisi l'époque I comme époque de référence. On vérifie facilement la relation :

$$\boxed{P_{I/0} \cdot P_{0/I} = I} \quad (I.3)$$

Généralement on exprime cet indice en pourcentage.

I. I. I-Exemple. Le litre de lait coûtait :

- $P_0 = 0,38$ F en 1950 (époque 0)

- $P_I = 0,41$ F en 1958 (époque I).

On a alors :

$$P_{I/0} = \frac{\text{Prix du lait en 1958}}{\text{Prix du lait en 1950}} = \frac{P_I}{P_0} = \frac{0,41}{0,38} = 1,08 \text{ .Ce qui}$$

correspond à 108% .

I. I. 2-Remarques

i) L'indice élémentaire du prix à une époque par rapport à elle-même est égal à I. En effet on a :

$$\boxed{P_{0/0} = \frac{P_0}{P_0} = I} \text{ ou } 100\% \text{ .} \quad (I.4)$$

ii) En considérant cette fois-ci les prix P_0, P_I et P_2 d'un article respectivement aux époques 0, I et 2 on a :

$$P_{2/0} = \frac{P_2}{P_0} = \frac{P_I \cdot P_2}{P_I \cdot P_0} = \frac{P_I}{P_0} \cdot \frac{P_2}{P_I} = P_{I/0} \cdot P_{2/I} \quad (I.5)$$

I.I.3-Exemple. Un article coûte :

$-P_0 = 180 \text{ F}$ en 1973 (époque 0)

$-P_I = 220 \text{ F}$ en 1975 (époque I)

$-P_2 = 300 \text{ F}$ en 1980 (époque 2).

On a :

$$P_{I/0} = \frac{220}{180} = 1,22 \quad (122\%) \quad \text{et} \quad P_{2/I} = \frac{300}{220} = 1,36 \quad (136\%) .$$

D'où :

$$P_{2/0} = P_{I/0} \cdot P_{2/I} = 1,22 \cdot 1,36 = 1,65 \quad (165\%) .$$

N.B

Le lecteur pourra aisément constater que pour multiplier les indices il évitera de prendre les expressions en pourcentage.

I.I.4-Exercice.

Le prix d'un article était $P_I = 270 \text{ F}$ en 1982 et l'indice élémentaire du prix de cet article en 1982 par rapport à 1975 est 170%.

Calculer son prix P_0 en 1975.

I.2-Indice élémentaire des quantités.

On définit de manière analogue que ce qui précède l'indice élémentaire des quantités.

Si Q_0 désigne la quantité d'un produit à l'époque de référence 0 et Q_I à l'époque I on pose :

$$Q_{I/0} = \frac{Q_I}{Q_0} \quad (I.6)$$

On vérifie facilement que cet indice possède les mêmes propriétés que l'indice élémentaire des prix.

Quand on veut voir comment évolue le coût de la vie dans le temps on calcule son indice. Pour cela on choisit plusieurs biens de consommation par exemple le pain, la viande, le lait, le sucre, les vêtements, le ticket de bus etc...

Dans ce paragraphe nous donnerons quelques exemples d'indices permettant de mesurer cette variation du coût de la vie.

On supposera qu'on a N articles - qu'on numérotera de I jusqu'à N - dont :

i) Les prix sont :

P_0^I, \dots, P_0^N à l'époque 0

P_I^I, \dots, P_I^N à l'époque I

ii) Les quantités sont :

Q_0^I, \dots, Q_0^N à l'époque 0

Q_I^I, \dots, Q_I^N à l'époque I

Le numéro du bas indique l'époque. Celui du haut indique l'article.

2. INDICES DU COUT DE LA VIE.

2.1-Indice global des prix.

On définit l'indice global des prix de ces articles à l'époque I par rapport à l'époque 0 comme étant le rapport :

$$I_{I/0} = \frac{\sum P_I^i}{\sum P_0^i} \quad (I.7)$$

Tout le long de ce paragraphe la sommation \sum porte sur $i = I, \dots, N$.

2.1.1-Exemple. Considérons les prix des 4 produits suivants à 2 époques différentes :

Année	Viande Kg	Oeufs I2	Beurre 250 g	Vin Litre
I959	6	2,20	I,80	I
I962	IO	3	2,50	I,30

On calcule l'indice global des prix :

$$I_{I/O} = \frac{IO + 3 + 2,50 + I,30}{6 + 2,20 + I,80 + I} = \frac{I6,80}{II} = I,52 \quad (I52\%) .$$

2.2-Moyenne arithmétique des indices.

On calcule l'indice élémentaire $P_{I/O}^i = \frac{P_I^i}{P_O^i}$ du prix de chaque

article et on fait leur moyenne arithmétique :

$$\bar{I}_{I/O} = \frac{I}{N} \sum P_{I/O}^i \quad (I.8) .$$

Reprenons l'exemple 2.I.I et calculons l'indice élémentaire du prix de chacun des produits considérés :

$$P_{I/O}^I = \frac{IO}{6} = I,66 \quad (I66\%) \quad P_{I/O}^2 = \frac{3}{2,20} = I,36 \quad (I36\%)$$

$$P_{I/O}^3 = \frac{2,50}{I,80} = I,38 \quad (I38\%) \quad P_{I/O}^4 = \frac{I,30}{I} = I,30 \quad (I30\%)$$

Ce qui donne en appliquant la formule (I.8) :

$$\bar{I}_{I/0} = \frac{I}{4} (I,66 + I,36 + I,38 + I,30) = I,42 \quad (I42\%) .$$

L'indice global des prix et la moyenne arithmétique des indices élémentaires présentent un inconvénient majeur : Ils ne tiennent pas compte de l'importance de chaque bien de consommation par rapport aux autres. Pour cela on introduit d'autres indices donnant des informations plus précises que celles que l'on peut obtenir à l'aide des indices que l'on vient de voir.

2.3-Indice pondéré.

Pour faire apparaître l'importance de chaque bien de consommation par rapport aux autres on pondère par sa quantité. On obtient alors les indices suivants :

i) Indice de Laspeyres qui se calcule en pondérant les prix par les quantités à l'époque de référence :

$$\boxed{I_{I/0}^L = \frac{\sum Q_0^i P_I^i}{\sum Q_0^i P_0^i}} \quad (I.9)$$

ii) Indice de Paasche. Il se calcule en pondérant les prix par les quantités à l'époque I :

$$\boxed{I_{I/0}^P = \frac{\sum Q_I^i P_I^i}{\sum Q_I^i P_0^i}} \quad (I.I0)$$

Mais on peut très bien pondérer par la moyenne arithmétique de la quantité à l'époque 0 et la quantité à l'époque I. Dans ce cas on a :

iii) Indice de Marshall.

$$I_{I/O}^M = \frac{\sum (Q_0^i + Q_I^i) P_I^i}{\sum (Q_0^i + Q_I^i) P_0^i} \quad (I.II) .$$

En faisant la moyenne géométrique des indices de Laspeyres et de Paasche on obtient un nouvel indice connu sous le nom de :

iv) Indice de Fisher.

$$I_{I/O}^F = \sqrt{I_{I/O}^L \cdot I_{I/O}^P} \quad \text{i.e}$$

$$I_{I/O}^F = \sqrt{\frac{\sum Q_0^i P_I^i}{\sum Q_0^i P_0^i} \cdot \frac{\sum Q_I^i P_I^i}{\sum Q_I^i P_0^i}} \quad (I.I2) .$$

Comme pour les indices élémentaires, l'indice de Fisher vérifie la propriété de réversibilité du temps, c'est à dire :

$$I_{I/O}^F \cdot I_{O/I}^F = I \quad (I.I3) .$$

3. EXERCICE RESOLU.

Le tableau suivant donne les prix et les quantités de 3 produits à 2 époques différentes : Tab 3.I

Produit (i)	1972 (époque 0)		1980 (époque I)	
	Prix P_0^i	Quantités Q_0^i	P_I^i	Q_I^i
I	I2	6	I5	7
2	5	I3	8	II
3	I5	9	I3	I8

1°. Calculer l'indice global rendant compte de l'évolution de ces biens de consommation.

2°. Calculer les indices de :

-Laspeyres,

-Paasche,

-Marshall.

En déduire l'indice de Fisher.

On prendra 1972 comme époque de référence.

Solution.

1°. On calcule la somme $\sum P_0^i$ où i varie de 1 à 3. On obtient :

$$\sum P_0^i = 12 + 5 + 15 = 32$$

De même on a :

$$\sum P_1^i = 15 + 8 + 13 = 36$$

D'où, en appliquant la formule (I.7) :

$$I_{I/0} = \frac{36}{32} = 1,125 \quad (12,5\%) .$$

2°. Pour traiter cette question on aura besoin de calculer les différentes expressions qui interviennent dans les formules (I.9), (I.10) et (I.11).

On résumera tous ces calculs dans le tableau suivant :

Produit (i)	$Q_{0P_0}^i$	$Q_{0P_I}^i$	$Q_{IP_0}^i$	$Q_{IP_I}^i$	$(Q_0^i + Q_I^i)P_0^i$	$(Q_0^i + Q_I^i)P_I^i$
I	72	90	84	105	156	195
2	65	104	55	88	120	192
3	135	117	270	234	405	351
<u>Total</u>	272	311	409	427	681	738

Tab 3.2

Ceci nous donne :

$$\text{-Indice de Laspeyres} = I_{I/0}^L = \frac{311}{272} = 1,14 \quad (114\%) .$$

$$\text{-Indice de Paasche} = I_{I/0}^P = \frac{427}{409} = 1,04 \quad (104\%) .$$

$$\text{-Indice de Marshall} = I_{I/0}^M = \frac{738}{681} = 1,08 \quad (108\%) .$$

Par définition l'indice de Fisher est la moyenne géométrique des indices de Laspeyres et de Paasche, on obtient en appliquant la formule (I.12) :

$$\text{-Indice de Fisher} = I_{I/0}^F = \sqrt{1,14 \cdot 1,04} = 1,09 \quad (109\%) .$$

CHAPITRE V

LA CONCENTRATION

I. GENERALITES ET DEFINITIONS.

On considère une série statistique classée :

$$(I) \quad \begin{array}{ccc} [a_1, a_2[& \dots & [a_k, a_{k+1}[\\ n_1 & \dots & n_k \end{array} \quad \begin{array}{l} \text{(classes)} \\ \text{(effectifs)} \end{array} \quad \begin{array}{l} \text{avec } a_i \geq 0 \text{ pour} \\ \text{tout } i=1, \dots, k+1 \end{array}$$

On note :

$$x_i = \frac{a_i + a_{i+1}}{2} \quad \text{le centre de la classe } [a_i, a_{i+1}[\quad .$$

On suppose que le caractère mesuré par cette série est additif, c'est-à-dire que la somme de deux valeurs a un sens. Par exemple

- on peut additionner le revenu, le salaire, etc...
- on ne peut pas additionner l'âge, la taille, etc...

Pour chaque classe on peut considérer :

- son effectif partiel,
- l'importance du caractère (notion que l'on va préciser).

A ces deux points de vue on peut associer deux représentations graphiques :

- l'histogramme des effectifs cumulés qu'on a déjà étudié,
- un histogramme qui décrit l'importance du caractère cumulé de chaque classe.

Ces deux représentations nous permettent de calculer:

- la médiane (valeur qui partage la série en deux séries ayant toutes les deux le même effectif total),
- une valeur qui partage la série en deux séries dont le caractère a la même importance aussi bien pour l'une que pour l'autre.

Cette dernière valeur est appelée la médiale. Son écart à la médiane est parfois utilisé pour faire l'analyse de la concentration.

I.I-Caractère.

On reprend la série classée (I).

I.I.I-Definition.

On appelle caractère de la classe $[a_i, a_{i+1}[$ le nombre $n_i x_i$.
On peut dresser un tableau donnant le caractère de chaque classe ainsi que le caractère cumulé :

Classes	centre x_i	effectif n_i	caractère $n_i x_i$	caractère cumulé
$[a_1, a_2[$	x_1	n_1	$n_1 x_1$	$n_1 x_1$
$[a_2, a_3[$	x_2	n_2	$n_2 x_2$	$n_1 x_1 + n_2 x_2$
...
$[a_k, a_{k+1}[$	x_k	n_k	$n_k x_k$	$\sum_{i=1}^k n_i x_i$


Tab I.I

I.2-Calcul de la médiale.

On calcule le caractère cumulé de chaque classe (voir Tab I.I) et on note C le caractère total. La médiale est alors la valeur qui partage la série en deux séries dont chacune a un caractère total égal à C/2. La médiale tombe dans une classe $[a_i, a_{i+1}[$. On procède par interpolation proportionnelle comme pour la médiane.

Caractère cumulé

Fig I.I



Pour tout $i=1, \dots, k$ on note C_i le caractère cumulé de la classe $[a_i, a_{i+1}]$, c'est à dire :

$$C_i = \sum_{s=1}^i n_s x_s \quad (I.I) .$$

On a alors les relations de proportionnalité :

$$\frac{OF}{OF'} = \frac{EF}{E'F'} \quad \text{i.e} \quad \frac{M_l - a_i}{a_{i+1} - a_i} = \frac{C/2 - C_{i-1}}{C_i - C_{i-1}}$$

D'où l'on déduit :

$$M_l = a_i + (a_{i+1} - a_i) \frac{C/2 - C_{i-1}}{C_i - C_{i-1}} \quad (I.2) .$$

I.3-Un exemple de calcul de la médiale.

On considère la statistique suivante donnant la production mondiale de blé en 1982. (Source : Perspectives de l'alimentation, 26 mai F.A.O., Rome).

Production en millions de tonnes	Nombre de pays
0 à 10	19
10 à 20	4
20 à 40	2
40 à 60	1
60 à 80	2

Tab I.2

Calculons le centre, le caractère et le caractère cumulé de chaque classe de cette série :

Classe	centre x_i	effectif n_i	caractère $n_i x_i$	caractère cumulé C_i
[0, 10[5	19	95	95
[10, 20[15	4	60	155
[20, 40[30	2	60	215
[40, 60[50	1	50	265
[60, 80[70	2	140	405

Tab I.3

Le caractère total est $C = 405$. Donc $C/2 = 202,5$. La médiale tombe dans la classe $[20, 40[$. On applique alors la formule (I.2) avec dans le cas qui nous intéresse :

$$\begin{aligned} a_i &= 20 & a_{i+I} &= 40 \\ C_i &= 215 & C_{i-I} &= 155 \end{aligned}$$

On obtient :

$$M_1 = 20 + (40 - 20) \cdot \frac{202,5 - 155}{215 - 155} \quad \text{et finalement :}$$

$$M_1 = 35,83$$

2. FONCTION ET COURBE DE CONCENTRATION.

On reprend les notations du paragraphe I, c'est-à-dire on considère une série classée :

$$\begin{array}{ccc} [a_I, a_2[& \dots & [a_k, a_{k+I}[& \text{(Classes)} \\ n_I & \dots & n_k & \text{(Effectifs)} \end{array}$$

avec $N = n_I + \dots + n_k$ et $x_i = \frac{a_i + a_{i+I}}{2}$ pour $i=I, \dots, k$.

On note f_i et F_i respectivement la fréquence et la fréquence cumulée de la classe $[a_i, a_{i+I}[$ i.e :

$$f_i = \frac{n_i}{N} \quad \text{et} \quad F_i = f_I + \dots + f_i \quad \text{pour tout } i = I, \dots, k.$$

2.1.1-Definition.

La fonction de concentration est l'application qui à tout x_i associe le nombre :

$$\frac{\sum_{s=I}^i n_s x_s}{C}$$

2.1.2-Exemple.

Determinons la fonction de concentration dans le cas de l'exemple I.3. En utilisant le tableau I.3, on calcule la concentration pour tout x_i . On obtient :

Centre x_i	Fréquence cumulée F_i	caractère $n_i x_i$	caractère cumulé	concentration
5	0,67	95	95	0,23 (23%)
15	0,82	60	155	0,38 (38%)
30	0,89	60	215	0,53 (53%)
50	0,92	50	265	0,65 (65%)
70	1	140	405	1 (100%)

Tab 2.1

2.2-Courbe de concentration.

2.2.1-Construction.

Considérons la correspondance qui à la fréquence cumulée F_i de la classe $[a_i, a_{i+1}]$ associe la concentration :

$$\frac{\sum_{s=1}^i n_s x_s}{C}$$

et portons dans un repère orthonormé F_i en abscisse et $\sum_{s=1}^i n_s x_s / C$ en ordonnée. On obtient un ensemble de points à l'intérieur du carré

OABD de côté égal à 1 (voir Fig 2.1).




Fig 2.I

Si le nombre de classes est assez grand, ces points seront assez nombreux et on peut considérer qu'ils déterminent pratiquement une courbe. On l'appelle la courbe de Lorenz

Le rapport de l'aire de la région du carré notée S à celle du triangle OAB est appelé Indice de concentration ou indice de Gini.

On le note :

$$\nu = \frac{\text{Aire de S}}{\text{Aire de OAB}} \quad (2.I) .$$

(Le caractère " ν " se lit "nu").

2.2.2-Remarques.

i) L'aire de S étant toujours inférieure ou égale à celle du triangle OAB, l'indice est donc un nombre compris entre 0 et 1.

ii) Si $\mathcal{D} = 0$, l'aire de S est nulle et donc la courbe de Lorentz se confond avec le segment OB. Ceci signifie qu'un point quelconque sur cette courbe a son abscisse égale à son ordonnée. On en déduit donc que pour tout $i=1, \dots, k$ on a :

$$F_i = \frac{\sum_{s=1}^i n_s x_s}{C} \quad (2.2)$$

Or $F_i = f_1 + \dots + f_i$ et $\frac{\sum_{s=1}^i n_s x_s}{C} = \frac{n_1 x_1 + \dots + n_i x_i}{C}$

On divise le numérateur et le dénominateur par $N = n_1 + \dots + n_k$.

On obtient alors en posant $A = \frac{C}{N}$:

$$\frac{\sum_{s=1}^i n_s x_s}{C} = \frac{\frac{n_1}{N} x_1 + \dots + \frac{n_i}{N} x_i}{A} = \frac{f_1 x_1 + \dots + f_i x_i}{A}$$

La relation (2.2) devient alors :

$$f_1 + \dots + f_i = \frac{f_1 x_1 + \dots + f_i x_i}{A} \quad \text{pour tout } i = 1, \dots, k,$$

c'est-à-dire :

$$f_1 = \frac{f_1 x_1}{A} \quad f_1 + f_2 = \frac{f_1 x_1 + f_2 x_2}{A} \quad \text{etc...}$$

La 1^{ère} égalité donne $f_I A = f_I x_I$ et en simplifiant par f_I on obtient $A = x_I$. On remplace x_I par A dans la 2^{ème} égalité. Cette dernière devient alors :

$$f_I + f_2 = \frac{f_I A + f_2 x_2}{A} = \frac{f_I A}{A} + \frac{f_2 x_2}{A} = f_I + \frac{f_2 x_2}{A} .$$

D'où : $f_2 = \frac{f_2 x_2}{A}$. Ceci implique $f_2 A = f_2 x_2$ et donc $A = x_2$.

De la même manière on montre que $x_3 = x_4 = \dots = x_k = A$.

On peut donc énoncer la proposition :

-Si l'indice de concentration est nul tous les termes de la série des centres sont égaux .

Dans ce cas on dit qu'il n'y a pas de concentration.


iii) Si $\mathcal{D} = I$ on dit qu'il y a concentration totale. Dans ce cas la courbe de Lorentz est soit le segment AB soit le segment OA. La série des centres x_1, x_2, \dots, x_k étant croissante, il en est de même de la série F_1, F_2, \dots, F_k des fréquences cumulées. On en déduit que pour F_i donné le nombre :

$$\frac{\sum_{s=1}^i n_s x_s}{C} \quad (\text{qui n'est rien d'autre que } \frac{f_I x_I + \dots + f_i x_i}{A} \text{ via$$

la remarque ii)) est unique, et donc sur la courbe de Lorentz il n'y a qu'un seul point pour lequel l'abscisse soit égale à I , et c'est le point B. Le premier cas ne peut donc se présenter. La courbe de Lorentz est confondue avec le segment OA. Ce n'est donc pas une courbe continue puisque le point B n'est pas sur OA. Toutefois on peut considérer que la courbe de Lorentz est constituée par le segment OA et le segment AB.

Fig 2.2


Concentration



Absence de concentration $\mathcal{D} = 0$

Fig 2.3


Concentration



Concentration totale $\mathcal{D} = I$

iv) Deux séries statistiques peuvent avoir le même indice de concentration. La Fig 2.4 donne un exemple de deux courbes de Lorentz qui délimitent avec le segment OB deux portions du carré OABD ayant des aires égales.

Concentration



Ces deux courbes sont symétriques par rapport à l'axe AD.

Fig 2.4

2.2.3-Calcul de l'indice de Gini.

Considérons toujours une série statistique de type (I). On a la série des fréquences cumulées F_1, F_2, \dots, F_k ; on lui rajoute une "fréquence" $F_0 = 0$ pour la commodité du calcul. On pose :

$$h_0 = 0 \quad \text{et} \quad h_i = \frac{\sum_{s=1}^i n_s x_s}{c} \quad \text{la concentration de la valeur } x_i.$$

On a vu que les points P_i dont les abscisses (respectivement les ordonnées) sont F_i (resp h_i) permettent de construire la courbe de Lorentz de cette série.

Pour calculer l'indice de Gini on doit calculer l'aire de S. Pour cela il suffit de calculer celle de S' (le complémentaire de S dans le triangle OAB) . Si on construit la courbe de Lorentz en joignant les points P_i par des segments de droite, on voit que l'aire de S' est la somme des aires des trapèzes $P_i P_{i+1} P'_{i+1} P'_i$. Or l'aire d'un trapèze de ce type est :

$$A_i = \frac{(P'_i P_i + P'_{i+1} P_{i+1}) \cdot P'_i P'_{i+1}}{2} \quad \text{c'est-à-dire}$$

$$A_i = \frac{(h_i + h_{i+1})(F_{i+1} - F_i)}{2} \quad \text{.Mais } F_{i+1} - F_i = f_{i+1}$$

D'où :

$$\text{Aire de S} = 0,5 - \text{Aire de S}' = \frac{I}{2} - \sum_{i=0}^{k-1} A_i$$

et finalement :

$$J = I - \sum_{i=0}^{k-1} (h_i + h_{i+1}) f_{i+1} \quad (2.3)$$

Cette relation permet donc de calculer l'indice de Gini.

Concentration




Fig 2.5

Dans la partie qui suit nous donnerons quelques exemples sur lesquels on fera l'analyse de la concentration en calculant les différents paramètres : Médiane ,fonction de concentration ,courbe de Lorenz et indice de Gini etc...

3. EXEMPLES.

3.1-Exemple où la concentration est presque totale.

Une famille constituée de 10 personnes (4 filles, 4 garçons, la mère et le père) s'est partagée une somme de 10000F d'une manière très inégale :

- 50F pour chaque fille,
- 100F pour chaque garçon,
- 400F pour la mère,
- 9000F pour le père.

On peut considérer qu'on a une série à valeurs isolées :

$x_1=50$ $x_2=100$ $x_3=400$ $x_4=9000$ (Valeurs)
 $n_1=4$ $n_2=4$ $n_3=1$ $n_4=1$ (Effectifs)

Calculons d'abord les différentes valeurs dont on aura besoin.

On dresse le tableau suivant :

x_i	n_i	f_i	F_i	$f_i x_i$	$\sum_{s=1}^i f_s x_s$	Concentration notée h_i
50	4	0,4	0,4	20	20	0,02
100	4	0,4	0,8	40	60	0,06
400	1	0,1	0,9	40	100	0,1
9000	1	0,1	1	900	1000	1

Tab 3.I

i) Courbe de Lorentz

On porte les F_i en abscisses et les h_i en ordonnées. On obtient alors la courbe suivante :

Concentration h_i




Fig 3.I
Courbe de Lorentz

ii) Indice de concentration de Gini.

Pour calculer cet indice on applique la formule (2.3) p.64.

On aura :

$$J = 1 - (0,02 \cdot 0,4 + 0,08 \cdot 0,4 + 0,16 \cdot 0,1 + 1,1 \cdot 0,1).$$

$$J = 0,834.$$

L'indice J est voisin de 1, la concentration est presque totale, chose à laquelle on peut s'attendre d'ailleurs puisque le père s'est accaparé pratiquement la totalité de la somme.

3.2- Autre exemple d'analyse de la concentration.

On reprend le tableau de l'exemple de la page.23 qui donne la répartition de la population de 27 pays européens. On le complète en calculant les différents paramètres qui permettent de faire l'analyse de la concentration.

Centre x_i	n_i	f_i	F_i	$n_i \cdot x_i$	C_i cumulé	Concentration h_i
2,5	7	0,26	0,26	17,5	17,5	0,036
7,5	7	0,26	0,52	52,5	70	0,143
12,5	3	0,11	0,63	37,5	107,5	0,220
17,5	2	0,07	0,70	35	142,5	0,292
22,5	2	0,07	0,77	45	187,5	0,384
32,5	2	0,07	0,84	65	252,5	0,517
47,5	1	0,05	0,89	47,5	300	0,615
62,5	3	0,11	1	187,5	487,5	1

Tab 3.2

Dans cet exemple nous ferons l'analyse de la concentration de deux façons différentes :

- En calculant l'indice de Gini,
- en calculant l'écart entre la médiane et la médiale.

i) Calcul de la médiane.

L'effectif total est $N=27$ et donc $N/2 = 13,5$. La médiane tombe donc dans la classe $[5, 10[$. On applique alors la formule (I.1) p.18 avec :

$$a_i = 5 \text{ (noté } x_i \text{ dans la formule)} \quad e_i = 5; N_i = 14 \text{ et } N_{i-1} = 7 .$$

On obtient :

$$M_e = 5 + (10 - 5) \cdot \frac{13,5 - 7}{7}$$

$$M_e = 9,64 .$$

ii) Calcul de la médiale.

Le caractère total est $C = 487,5$. D'où $C/2 = 243,5$. De la même manière la médiale se calcule par la formule (I.2) p.56 avec :

$$a_i = 25. \quad a_{i+1} = 40 \quad C_i = 252,5 \quad C_{i-1} = 187,5 .$$


On a =

$$M_l = 25 + (40 - 25) \cdot \frac{243,75 - 187,5}{65}$$

$$M_l = 37,98 . \quad (\text{la médiale tombe dans la classe } [25, 40[) .$$

iii) Courbe de Lorentz.

On construit la courbe de Lorentz en portant les F_i en abscisses et les h_i en ordonnées (voir Tab 3.2). On obtient alors :



iv) Indice de Gini.

On applique la formule (2.3) p.64 qui s'écrit dans le cas qui nous intéresse ici :

$$D = I - [h_1 f_1 + (h_1 + h_2) f_2 + \dots + (h_7 + h_8) f_8]$$

où :

$h_1=0,036$	$h_2=0,143$	$h_3=0,220$	$h_4=0,292$	
$h_5=0,384$	$h_6=0,517$	$h_7=0,615$	$h_8=1$	et
$f_1=0,26$	$f_2=0,26$	$f_3=0,11$	$f_4=0,07$	
$f_5=0,07$	$f_6=0,07$	$f_7=0,05$	$f_8=0,11$.

On obtient finalement :

$$D = I - 0,48 = 0,52 \text{ (52\%) .}$$

La concentration est donc moyenne.

v) Calcul de la médiale à l'aide de la courbe de Lorentz.

On peut remarquer que les concentrations sont obtenues en divisant les $\sum_{s=1}^i n_s x_s$ par le caractère total C. Il en résulte que les concentrations h_i sont respectivement proportionnelles à ces caractères cumulés. Donc la médiale sera "l'abscisse" du point de la courbe de Lorentz dont l'ordonnée est égale à 0,5. En fait elle sera donnée en "pourcentage". Il faudra donc reconvertir après. Pour le cas qui nous intéresse on lit graphiquement l'abscisse du point K et on trouve 0,83. Or on sait que 0,77 correspond à 25 et 0,84 correspond à 40. En faisant une interpolation proportionnelle on trouve que 0,83 correspond à :

$$25 + 15 \cdot \frac{0,83 - 0,77}{0,84 - 0,77} = 37,85 \text{ .Ce qui est à peu près le}$$

resultat trouvé en ii).

vi) On peut aussi pour faire l'analyse de la concentration calculer l'écart entre la médiane et la médiale. On aura :

$$M_1 - M_e = 37,98 - 9,64 = 28,34 \text{ .}$$

On voit donc que cet écart est relativement important "par rapport" à la plus grande valeur de la série.

vii) La courbe de concentration de Lorentz nous dit par exemple que 83% des pays européens (sans l'URSS) se partagent 50% de la population totale européenne (sans l'URSS évidemment).

CHAPITRE VI
SERIES DOUBLES
AJUSTEMENT CORRELATION

Il arrive quelquefois que deux séries statistiques mesurant deux caractères X et Y d'un échantillon d'une même population soient liées par une relation dans le sens que les valeurs de l'une peuvent être obtenues à partir de celles de l'autre à l'aide d'une correspondance. On dira que X et Y sont dépendantes. Nous essayerons dans ce chapitre de préciser le sens de cette "dépendance" et de la calculer du moins approximativement.

Quitte à passer à la série des centres on pourra toujours supposer que les séries considérées sont à valeurs isolées.

I. SERIES DOUBLES.

I. I-Exemple.

On étudie le poids et la taille notés P et T de 100 élèves pris au hasard dans un lycée. On a obtenu les données suivantes :

T \ P	150cm	155	160	165	170	
50 Kg	3	5	4	3	2	17
55	5	7	7	8	7	34
60	6	6	4	6	8	30
65	4	5	3	2	5	19
	18	23	18	19	22	100

Tab I.I

La case de la 3^{ème} colonne et la 2^{ème} ligne représente le nombre d'élèves qui ont un poids de 55 Kg et une taille de 160 cm c'est-à-dire 7. On note cette valeur n_{23} . C'est l'effectif partiel de la 2^{ème} valeur du caractère poids et la 3^{ème} valeur du caractère taille.

On peut s'intéresser uniquement au caractère poids. Par exemple le nombre d'élèves ayant un poids égal à 55 Kg et une taille quelconque est 34. Ceci figure sur la dernière colonne. On note ce nombre $n_{2.} = 34$. C'est l'effectif marginal de la 2^{ème} valeur du caractère poids. Il s'obtient en faisant la somme de tous les termes de la 2^{ème} ligne. On a : $n_{2.} = n_{21} + n_{22} + \dots + n_{25}$.

De la même manière on peut se restreindre au caractère taille. La 2^{ème} valeur 23 de la dernière ligne donne le nombre d'élèves mesurant 155 cm (avec un poids quelconque). De manière analogue $n_{.2}$ s'obtient en faisant la somme de tous les termes de la 2^{ème} colonne :

$$n_{.2} = n_{12} + n_{22} + \dots + n_{42}$$

On dira que $n_{.2}$ est l'effectif marginal de la 2^{ème} valeur du caractère taille.

I.2-Quelques définitions.

L'exemple que l'on vient de considérer est typique de ce qu'on appelle une série double ou à deux dimensions (parce qu'on étudie deux caractères sur un même échantillon).

I.2.1-Presentation.

On peut résumer tout dans un tableau semblable au Tab I.1 :

X \ Y	y _I	...	y _j	...	y _l	Effectif marginal
x _I	n _{I1}	...	n _{Ij}	...	n _{Il}	n _{I.}
...
x _i	n _{i1}	...	n _{ij}	...	n _{il}	n _{i.}
...
x _k	n _{k1}	...	n _{kj}	...	n _{kl}	n _{k.}
Effectif marginal	n _{.1}	...	n _{.j}	...	n _{.l}	N

Tab I.2

où :

- x_I, ..., x_k sont les valeurs du caractère X,
- y_I, ..., y_l sont les valeurs du caractère Y
- n_{ij} est l'effectif partiel du couple (x_i, y_j) c'est-à-dire le nombre d'individus de l'échantillon pour lesquels les caractères X et Y valent respectivement x_i et y_j,
- n_{i.} (resp n_{.j}) l'effectif marginal de x_i (resp de y_j) i.e le nombre d'individus pour lesquels X (resp Y) vaut x_i (resp y_j) et qui est tel que :

$$n_{i.} = \sum_{j=1}^l n_{ij} \quad (\text{resp } n_{.j} = \sum_{i=1}^k n_{ij}) \quad (\text{I.1}),$$

$$\text{-et } N = \sum_{i,j} n_{ij} = \sum_{i=1}^k n_{i.} = \sum_{j=1}^l n_{.j} \quad (\text{I.2})$$

est l'effectif total.

On gardera les notations de cette partie tout le long de ce chapitre.

I.2.2-Fréquences partielles et marginales.

On définit la fréquence partielle du couple (x_i, y_j) et la fréquence marginale de la valeur x_i (resp y_j) par les égalités :

$$f_{ij} = \frac{n_{ij}}{N} \quad \text{fréquence partielle} \quad (\text{I.3.1}) ,$$

$$f_{i.} = \frac{n_{i.}}{N} \quad (\text{resp } f_{.j} = \frac{n_{.j}}{N}) \quad (\text{I.3.2}) .$$

On vérifie aisément les relations :

$$f_{i.} = \sum_{j=1}^l f_{ij} \quad \text{et} \quad f_{.j} = \sum_{i=1}^k f_{ij} \quad (\text{I.4.1})$$

$$\sum_{i,j} f_{ij} = I \quad (\text{I.4.2}) .$$

Calculons par exemple les fréquences partielles et marginales des couples de valeurs de la série double donnée par le Tab (I.1) :

T \ P	I50	I55	I60	I65	I70	$f_{.j}$
50	0,03	0,05	0,04	0,03	0,02	0,17
55	0,05	0,07	0,07	0,08	0,07	0,34
60	0,06	0,06	0,04	0,06	0,08	0,30
65	0,04	0,05	0,03	0,02	0,05	0,19
$f_{i.}$	0,18	0,23	0,18	0,19	0,22	I

Tab I.2

I.2.3-Effectifs et fréquences cumulés.

On appelle effectif cumulé du couple de valeurs (x_i, y_j) le nombre d'individus N_{ij} de l'échantillon pour lesquels le caractère X est inférieur ou égal à x_i et le caractère Y est inférieur ou égal à y_j . On l'exprime en fonction des effectifs partiels par la relation :

$$(I.5) N_{ij} = \sum_{s \leq i, t \leq j} n_{st} = (n_{11} + \dots + n_{1j}) + (n_{21} + \dots + n_{2j}) + \dots + (n_{i1} + \dots + n_{ij}).$$

La fréquence partielle cumulée de (x_i, y_j) est définie comme suit :

$$F_{ij} = \frac{N_{ij}}{N} \quad (I.6) .$$

Si $i = k$ (resp $j = l$) on a :

$$N_{ij} = \sum_{t=1}^j n_{.t} \quad (\text{resp } N_{ij} = \sum_{s=1}^i n_{s.})$$

et dans ce cas on parlera d'effectif marginal cumulé de y_j (resp de x_i). On le notera alors $N_{.j}$ (resp $N_{i.}$).

De même on a la fréquence cumulée d'une valeur x_i ou y_j qui se calcule de manière analogue. On se contentera de le faire sur l'exemple qui suit .

I.2.4-Considérons le Tab I.2. Par exemple :

-La fréquence cumulée F_{22} de $(55, I55)$: On fait la somme des fréquences de tous les couples (P_i, T_j) pour lesquels $P_i \leq 55$ et $T_j \leq I55$. Ces couples sont $(50, I50), (50, I55), (55, I50)$ et $(55, I55)$.

Ce qui donne :

$$F_{22} = 0,03 + 0,05 + 0,05 + 0,07 = 0,2 .$$

-La fréquence marginale cumulée de la valeur $P_3 = 60$ est la somme des fréquences de tous les couples (P_i, T_j) pour lesquels

$P_i \leq 60$, c'est-à-dire :

$$F_{3.} = 0,17 + 0,34 + 0,30 = 0,81 .$$

2. MOYENNES MARGINALES.

2.1-Definition.

Les moyennes marginales \bar{X} et \bar{Y} sont les moyennes arithmétiques de X et Y respectivement. Elles se calculent en fonction des valeurs de chacune des séries X et Y mais en considérant les effectifs marginaux:

$$\bar{X} = \frac{1}{N} \sum_{i=1}^k n_{i.} x_i = \sum_{i=1}^k f_{i.} x_i$$

$$\bar{Y} = \frac{1}{N} \sum_{j=1}^l n_{.j} y_j = \sum_{j=1}^l f_{.j} y_j$$

De la même manière on a :

$$\text{Var}(X) = \frac{1}{N} \sum_{i=1}^k n_{i.} (x_i - \bar{X})^2 = \sum_{i=1}^k f_{i.} (x_i - \bar{X})^2$$

$$\text{Var}(Y) = \frac{1}{N} \sum_{j=1}^l n_{.j} (y_j - \bar{Y})^2 = \sum_{j=1}^l f_{.j} (y_j - \bar{Y})^2 .$$

$$\sigma(X) = \sqrt{\text{Var}(X)} \quad \text{et} \quad \sigma(Y) = \sqrt{\text{Var}(Y)} .$$

2.2-Exemple.

Les moyennes marginales de la série double de l'exemple I.I sont :

$$\bar{P} = \frac{17.50 + 34.55 + 30.60 + 19.65}{100} = 57,55$$

$$\bar{T} = \frac{18.150 + 23.155 + 18.160 + 19.165 + 22.170}{100} = 160,2$$

Le calcul des variances est laissé en exercice.

Dans la suite on se donnera une série double (X,Y) formée de deux séries simples X et Y dont les valeurs x_i et y_i sont numérotées de la même manière de 1 à N.

Nous allons étudier le lien qui peut exister entre X et Y.

3. AJUSTEMENT LINEAIRE. CORRELATION.

On peut représenter chaque couple de valeurs (x_i, y_i) par un point M_i dans le plan. On obtient un ensemble de points qu'on appelle un nuage de points (Voir Fig 3.I).




Fig 3.I

On se propose alors de chercher la courbe qui soit la plus proche possible de tous les points M_i . Lui imposer d'être très proche d'un point peut l'éloigner d'autres points. Il s'agit donc de trouver un "juste milieu".

La recherche d'une telle courbe est ce qu'on appelle l'ajustement de ce nuage de points.




Fig 3.2




Fig 3.3

Le choix de la courbe n'est pas facile, encore moins son calcul. Nous nous contenterons de traiter le problème dans le cas d'une droite. On dira que l'ajustement est linéaire.

3.1-Droite de Mayer.

Considérons les N points M_i dont les coordonnées sont x_i et y_i . On appelle point moyen du nuage défini par ces points le point G dont les coordonnées sont les moyennes arithmétiques \bar{X} et \bar{Y} .

On peut ranger la série double S de telle sorte que la série des abscisses soit croissante (celle des ordonnées ne le sera pas forcément). On partage alors S en deux séries doubles S_1 et S_2 ayant toutes les deux le même effectif total (plus ou moins un terme). On notera G_1 et G_2 les points moyens associés à S_1 et S_2 respectivement.

3.1.1-Définition.

La droite de Mayer associée à S est la droite définie par les points G_1 et G_2 .

Cette droite permet d'ajuster le nuage de points associé à S .

On vérifie qu'elle passe par le point moyen G .

3.I.2-Exemple.

Considérons la série double suivante :

$$S = \{(2,3) (3,6) (3,4) (4,7) (4,5) (5,8) (6,5)\} .$$

On partage S en deux séries S_I et S_2 en choisissant les 4 premiers termes pour S_I par exemple. Les points moyens de S_I et S_2 sont alors :

$$G_I = (3,5) \quad \text{et} \quad G_2 = (5,6).$$




Fig 3.4

Cherchons l'équation de cette droite. On remarque que les points G_I et G_2 ont des abscisses distinctes. L'équation de la droite $G_I G_2$ est donc de la forme :

$$Y = aX + b \quad (3.I) .$$

Pour déterminer a et b il suffit d'exprimer le fait que cette droite passe par G_I et G_2 , c'est-à-dire que les coordonnées de ces points vérifient cette équation i.e :

$$\begin{cases} 3a + b = 5 \\ 5a + b = 6 \end{cases} .$$

On en déduit :

$$a = 1/2 \quad \text{et} \quad b = 7/2 .$$

Finalement G_1G_2 a pour équation : $Y = 1/2(X + 7)$.

L'ajustement par la droite de Mayer n'est pas satisfaisant et est peu utilisé dans la pratique. Nous ajusterons plutôt par la droite des moindres carrés que nous allons introduire dans la partie qui suit.

3.2-Droite des moindres carrés.

3.2.I-Position du problème.

Considérons les N points M_i dans le plan et notons D la droite cherchée. La distance de M_i à D est la mesure du segment M_iH_i où H_i est le pied de la perpendiculaire à D passant par M_i (Voir Fig 3.5). Le calcul de cette distance est relativement compliqué. On calculera plutôt la distance "verticale" de M_i à D . Notons K_i le point de rencontre de D et de la droite d'équation $X = x_i$ et supposons que l'équation de D est de la forme :

$$Y = aX + b .$$

La distance de M_i à K_i est alors le nombre :

$$d_i = |ax_i + b - y_i| .$$

Nous chercherons donc la droite D de telle sorte que la somme :

$$U = \sum_{i=1}^N d_i^2$$

soit minimale.

Une telle droite D est appelée la droite des moindres carrés ou droite de regression de Y en X.

3.2.2-Existence et unicité de D.

Tout revient à montrer que a et b existent et sont uniques et rendent U minimale.

Reprenons la quantité :

$$U = \sum_{i=1}^N (ax_i + b - y_i)^2 .$$

On a d'abord :

$$(ax_i + b - y_i)^2 = x_i^2 a^2 - 2x_i(y_i - b)a + (y_i - b)^2$$

et par suite :

$$U = \left(\sum_{i=1}^N x_i^2 \right) a^2 - 2 \left(\sum_{i=1}^N x_i (y_i - b) \right) a + \sum_{i=1}^N (y_i - b)^2 .$$

On pose :

$$\lambda = \sum_{i=1}^N x_i^2 \quad \beta = \sum_{i=1}^N x_i (y_i - b) \quad \text{et} \quad \gamma = \sum_{i=1}^N (y_i - b)^2$$

L'expression de U est alors un polynôme du second degré en a :

$$U = \lambda a^2 - 2\beta a + \gamma$$

avec λ positif .

Le nombre a cherché est la racine de la dérivée de U considérée comme fonction de a. On a :

$$U'(a) = 2\lambda a - 2\beta$$

et donc $U'(a) = 0$ si et seulement si :

$$a = \frac{\beta}{\lambda} \quad \text{c'est-à-dire :}$$

$$a = \frac{\sum_{i=1}^N x_i (y_i - b)}{\sum_{i=1}^N x_i^2} \quad (3.3) .$$

Si on considère cette fois-ci U comme un polynôme du second degré en b, un calcul analogue à celui que l'on vient de faire donne :

$$b = \frac{1}{N} \left(\sum_{i=1}^N (y_i - ax_i) \right) = \frac{1}{N} \sum_{i=1}^N y_i - \frac{a}{N} \sum_{i=1}^N x_i$$

qui n'est rien d'autre que :

$$b = \bar{Y} - a\bar{X} \quad (3.4) .$$

On remarque donc que le point moyen $G = (\bar{X}, \bar{Y})$ est sur la droite des moindres carrés.

Les équations (3.3) et (3.4) donnent finalement :

$$a = \frac{\sum_{i=1}^N (x_i - \bar{X})(y_i - \bar{Y})}{\sum_{i=1}^N (x_i - \bar{X})^2} \quad (3.5)$$

$$b = \bar{Y} - a\bar{X}$$




Fig 3.5

3.3-Covariance.

Divisons le numérateur et le dénominateur du second membre de (3.5) par N. On obtient alors :

$$a = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{X})(y_i - \bar{Y})}{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{X})^2} \quad (3.6)$$

On voit que le dénominateur n'est rien d'autre que la variance de X. Le numérateur :

$$\frac{1}{N} \sum_{i=1}^N (x_i - \bar{X})(y_i - \bar{Y})$$

est un paramètre associé à (X,Y) et qu'on appelle la covariance de X et Y. On la note Cov(X,Y).

La formule (3.6) s'écrit alors :

$$a = \frac{\text{Cov}(X,Y)}{\text{Var}(X)} \quad (3.7)$$

La covariance a le signe de a. Elle peut être positive ou négative contrairement à la variance. On peut aussi l'exprimer sous la forme suivante :

$$\text{Cov}(X,Y) = \frac{1}{N} \sum_{i=1}^N x_i y_i - \bar{X} \cdot \bar{Y} \quad (3.8)$$

3.4-Corrélation linéaire.

On appelle coefficient de corrélation de X et Y le nombre :

$$r = \frac{\text{Cov}(X,Y)}{\sigma(X) \sigma(Y)} \quad (3.9)$$

où $\sigma(X)$ (resp $\sigma(Y)$) est l'écart-type de X (resp de Y). On montre que r possède les propriétés suivantes (les détails et les démonstrations sont laissés au lecteur en exercice) :

- i) r a toujours le signe de $\text{Cov}(X,Y)$,
- ii) r est compris entre -1 et $+1$
- iii) $|r| = 1$ si et seulement si la droite des moindres carrés passent par tous les points M_i et dans ce cas on a :

$$y_i = ax_i + b \quad \text{pour tout } i = 1, \dots, N .$$

Si $r = 0$ i.e $\text{Cov}(X,Y) = 0$, on dit que X et Y ne sont pas corrélées.

Nous allons reprendre les calculs que nous venons de faire sur un exemple simple. Ceci nous permettra de mieux comprendre les différentes étapes par lesquelles nous sommes passés.

4. EXEMPLE.

Considérons la série double :

$$(X,Y) = \{ (2,3) (3,4) (4,8) \}$$

Pour fixer les idées commençons par tracer cette droite n'importe comment pour le moment :




Fig 4.I

Cette série définit un nuage de points M_1, M_2 et M_3 . On calcule la somme des carrés des distances $M_i K_i$. On obtient :

$$U = (2a + b - 3)^2 + (3a + b - 4)^2 + (4a + b - 8)^2 .$$

On développe U et on l'écrit sous forme d'un polynôme du second degré en a :

$$\begin{aligned} U &= 29a^2 - 2(50 - 9b)a + (3 - b)^2 + (4 - b)^2 + (8 - b)^2 \\ &= 29a^2 - 2(50 - 9b)a + 3b^2 - 30b + 89 . \end{aligned}$$

On calcule la dérivée de U par rapport à a :

$$U'(a) = 2(29a - (50 - 9b))$$

qui s'annule pour :

$$a = \frac{50 - 9b}{29} \quad (4.1) .$$

D'autre part on a :

$$\bar{X} = 3 \quad \text{et} \quad \bar{Y} = 5 \quad \text{et donc} \quad 5 = 3a + b \quad (4.2) .$$

Il suffit donc de résoudre le système linéaire en a et b formé par les équations (4.1) et (4.2), c'est-à-dire :

$$\begin{cases} 29a + 9b = 50 \\ 3a + b = 5 \end{cases}$$

qui donne $\hat{a} = 5/2$ et $\hat{b} = -5/2$.

La droite des moindres carrés a donc pour équation :

$$Y = \frac{5}{2}(X - 1) .$$

Le lecteur pourra construire cette droite à titre d'exercice.

5. EXERCICE RESOLU.

Le tableau suivant indique la production interieure brute par secteur au Maroc de 1970 à 1976 (en Millions de DH) :

Année	Agriculture et Pêche X	Industrie et Mines Y
1970	3,72	3,31
1971	3,95	3,53
1972	4,09	3,77
1973	3,65	4,08
1974	13,39	4,44
1975	3,66	4,91
1976	4,12	5,43

Tab 5.I

Source : Secrétariat d'Etat chargé du Plan et du développement Régional.

On considère la P.I.B agricole et la P.I.B industrielle comme deux séries statistiques X et Y et on se propose d'étudier la corrélation qui peut exister entre elles.

1°-Calculer $\text{Var}(X)$, $\text{Var}(Y)$, $\text{Cov}(X,Y)$ et le coefficient de corrélation r de X et Y.

2°-Donner la droite de regression de Y en X.

SOLUTION.

On calcule les moyennes arithmétiques X et Y. On trouve :

$$\bar{X} = 5,22 \quad \text{et} \quad \bar{Y} = 4,21$$

et on complète le tableau 5.1 de la façon suivante :

Année	x_i	y_i	x_i^2	y_i^2	$x_i y_i$
1970	3,72	3,37	13,83	11,35	12,53
1971	3,95	3,53	15,60	12,46	13,94
1972	4,09	3,77	16,72	14,21	15,41
1973	3,65	4,08	13,22	16,64	14,89
1974	13,39	4,44	179,29	19,71	65,74
1975	3,66	4,91	13,39	24,10	17,97
1976	4,12	5,43	16,97	29,48	22,37

Tab 5.2

1°- On en déduit :

$$\text{Var}(X) = \frac{1}{N} \sum_{i=1}^N x_i^2 - \bar{X}^2 = 38,45 - (5,22)^2 = 11,20$$

$$\text{Var}(Y) = \frac{1}{N} \sum_{i=1}^N y_i^2 - \bar{Y}^2 = 18,28 - (4,21)^2 = 0,55$$

$$\text{Cov}(X, Y) = \frac{1}{N} \sum_{i=1}^N x_i y_i - \bar{X} \cdot \bar{Y} = 23,26 - 21,97 = 1,29$$

et par conséquent :

$$r = \frac{\text{Cov}(X,Y)}{\sigma(X)\sigma(Y)} = \frac{1,29}{\sqrt{11,20 \cdot 0,55}} = 0,51$$

La corrélation est assez apparente.

2°- Droite de regression de Y en X.

Elle est de la forme $Y = aX + b$ avec :

$$a = \frac{\text{Cov}(X,Y)}{\text{Var}(X)} = \frac{1,29}{11,20} = 0,11$$

et :

$$b = \bar{Y} - a\bar{X} = 4,21 - 0,11 \cdot 5,22 = 3,66$$

c'est-à-dire :

$$Y = 0,11x + 3,66.$$

CHAPITRE VII
SERIES CHRONOLOGIQUES

Considérons le tableau suivant donnant le nombre d'émigrants en France des départements d'Outre-Mer (Martinique, Guadeloupe, Réunion et Guyane) de 1962 à 1971.

Année	1962	63	64	65	66	67	68	69	70	71
Total	1004	2091	4532	7006	7811	7962	7514	8398	8807	9165

Tab 0.0

Source : Bilan d'activités 1971 du BUMIDOM (Bureau pour le développement des Migrations Intéressant les Département d'Outre Mer).

On peut interpréter cette série comme une suite d'observations dans le temps. Par exemple on observe qu'en :

- i) 1964 il y a eu 4532 émigrants,
- ii) 1968 il y a eu 7514 émigrants etc...

On dira qu'on a une série chronologique.

Nous allons introduire cette notion d'une façon plus précise et étudier ses propriétés et applications.

I. GENERALITES.

I.1-Définition.

On appelle série chronologique une série statistique dont les valeurs sont obtenues à partir d'observations ordonnées dans le temps. Par exemple :

-La production annuelle de blé ,

-Le taux annuel d'inflation,

-La production annuelle de pétrole etc...

sont des séries chronologiques.

On notera une telle série Y_t qui est la valeur prise par le caractère Y à l'instant t . Par exemple pour la série ci-dessus on a :

Pour $t = 1962$	$Y_t = 1004$	qu'on note Y_1
$t = 1963$	$Y_t = 2091$	" Y_2
...
$t = 1971$	$Y_t = 9165$	" Y_{10}

Une série chronologique est une fonction du temps, donc peut être représentée graphiquement par une "courbe" (s'il y a suffisamment de points) :




Fig I.1

L'analyse des séries chronologiques permet de prévoir certaines variations à différents niveaux. Ce qui justifie leur utilité et rend leur intérêt incontestable.

I.2-Mouvements des séries chronologiques.

Ils sont au nombre de quatre.

I.2.1-Mouvement séculaire.

Il s'étend sur une période de temps assez longue. On s'intéresse beaucoup plus aux variations globales. Ceci est représenté en trait interrompu sur la Fig I.1. On parlera alors de tendance séculaire.

Exemple : Série chronologique correspondant à la population mondiale de 1800 à 1980.

I.2.2-Mouvement saisonnier.

C'est un mouvement pendant une période relativement courte généralement d'une année. Dans la série ce mouvement correspond à des événements périodiques d'année en année.

Exemple : Nombre de vacanciers sur les routes au mois de juillet.

I.2.3-Mouvement cyclique.

C'est un cas intermédiaire entre le mouvement séculaire et le mouvement saisonnier. Son étendue est généralement de la décennie.

Exemple : Baisse de la production d'acier etc...

I.2.4-Mouvement aléatoire.

Ce sont des mouvements qui sont dus au hasard et qu'on ne peut contrôler. Ils introduisent des "discontinuités" dans l'évolution d'un phénomène.

Exemple : Tremblement de terre, grève, résultat inattendu d'élections etc...

2. ANALYSE.

Analyser une série chronologique c'est étudier les mouvements qui la composent.

Nous présenterons dans ce paragraphe quelques méthodes qui permettent de faire cette analyse.

2.1- Moyennes mobiles.

On se donne une série chronologique $Y = (y_1, \dots, y_N)$.

On appelle moyenne mobile d'ordre k, la suite des moyennes arithmétiques :

$$Y_1 = \frac{y_1 + \dots + y_k}{k} \quad Y_2 = \frac{y_2 + \dots + y_{k+1}}{k} \quad Y_3 = \frac{y_3 + \dots + y_{k+2}}{k}$$
$$\dots \quad Y_{N-k+1} = \frac{y_{N-k+1} + \dots + y_N}{k}$$

On remarque donc que la moyenne mobile est constituée de $N-k+1$ valeurs.

Reprenons la série chronologique donnée par le tableau (0.0) p.89. Elle est constituée de 10 termes et donc sa moyenne mobile d'ordre 4 aura 7 termes dont le premier et le deuxième sont :

$$Y_1 = \frac{1004 + 2091 + 4532 + 7006}{4} = 3658$$

$$Y_2 = \frac{2091 + 4532 + 7006 + 7811}{4} = 5360$$

etc...

Quand les valeurs de la série chronologique sont obtenues par des observations annuelles, mensuelles ou sur une période quelconque on parlera de moyenne mobile sur k années, k mois ou k périodes.

L'intérêt de la moyenne mobile est de "régulariser" les valeurs de la série chronologique.

2.2-Estimation de la tendance séculaire.

Si on porte le temps en abscisse et Y en ordonnée on peut représenter la série chronologique par un ensemble de points dans le plan. On pourra donc estimer la tendance en procédant à un ajustement généralement linéaire par exemple par la méthode des moindres carrés, notion qui a déjà été introduite et étudiée au chapitre qui précède.

On peut aussi utiliser la moyenne mobile.

Regardons comment on procède concrètement sur un exemple. Reprenons le tableau (0.0) .

t (temps)	1	2	3	4	5	6	7	8	9	10
Y_t (observation au temps t)	1004	2091	4532	7006	7811	7962	7514	8398	8807	9165

Tab 2.I

Calculons la moyenne mobile d'ordre 3. On trouve une nouvelle série à 8 valeurs en remplaçant chaque y_t par :


$$\frac{y_{t-1} + y_t + y_{t+1}}{3}$$

On obtient alors le tableau suivant :

t	Y_t	$\frac{y_{t-1} + y_t + y_{t+1}}{3}$
1	1004	
2	2091	2542
3	4532	4543
4	7006	6449
5	7811	7593
6	7962	7762
7	7514	7958
8	8398	8239
9	8807	8790
10	9165	

Tab 2.2

Par exemple la première moyenne mobile 2542 est obtenue en faisant la somme des 3 premières valeurs de la colonne 2 et en divisant ensuite par 3.



On peut remarquer que dans l'exemple que l'on vient de traiter on a omis le premier et le dernier termes de la série. Si on avait utilisé la définition de la moyenne mobile telle qu'elle a été donnée en 2.1 page 92 on aurait omis les deux dernières valeurs de la série. Dans la pratique on peut prendre l'une ou l'autre des définitions de la moyenne mobile. Les deux sont pratiquement les "mêmes".

2.3-Coefficient saisonnier.

On détermine la tendance séculaire à l'aide de la moyenne mobile ou la méthode des moindres carrés suivant le cas considéré (évidemment on choisira celle qui s'adapte mieux au problème). On obtient pour chaque valeur y_t une valeur ajustée qu'on notera y_t^a . Le coefficient saisonnier à l'instant t est alors le rapport de la valeur observée y_t à la valeur ajustée y_t^a :

$$e_t = \frac{y_t}{y_t^a} \quad (2.2) .$$

2.4-Desaisonnalisation.

On divise chaque observation initiale par le coefficient saisonnier moyen \bar{e}_t (moyenne des coefficients saisonniers de la même époque calculée sur des années différentes). Plus précisément la valeur desaisonnalisée y_t^d de y_t est définie par :

$$y_t^d = \frac{y_t}{\bar{e}_t} \quad (2.3) .$$

3. EXERCICE RESOLU.

On suppose que les livraisons trimestrielles d'une certaine marchandise de 1976 à 1980 sont données par le tableau suivant (en milliers de tonnes) :

Année	1 ^{er} Trimestre	2 ^{ème} Tri	3 ^{ème} Tri	4 ^{ème} Tri
1976	140	142	144	141
1977	142	147	147	149
1978	150	150	152	152
1979	153	155	158	158
1980	160	163	165	166

Tab 3.I

1°-Estimer la tendance séculaire par :

-La méthode des moyennes mobiles,

-La méthode des moyennes échelonnées (que l'on va introduire).

2°-Ajuster cette série chronologique par la droite des moindres carrés.

3°-Calculer les coefficients saisonniers.

SOLUTION.

1°-Rappelons que la moyenne mobile d'ordre 3 est donnée par:

$$Y_1 = \frac{y_1 + y_2 + y_3}{3}, \quad Y_2 = \frac{y_2 + y_3 + y_4}{3} \dots$$

$$Y = \frac{y_{18} + y_{19} + y_{20}}{3}$$

Dans le cas qui nous interesse ici on a $N = 20$.

Calculons par exemple Y_{II} : y_{II} est la valeur de Y au 3^{ème} trimestre de l'année 1978. On aura ainsi :

$$Y_{II} = \frac{I52 + I52 + I53}{3} = I52,33 .$$

On rassemble tous ces calculs dans le tableau 3.2.

t	y_t	Moyenne mobile
I	I40	I42
2	I42	I42,33
3	I44	I42,33
4	I4I	I43,33
5	I42	I45,33
6	I47	I47,66
7	I47	I48,66
8	I49	I49,66
9	I50	I50,66
I0	I50	I5I,33
II	I52	I52,33
I2	I52	I53,33
I3	I53	I55,33
I4	I55	I57
I5	I58	I58,66
I6	I58	I60,33
I7	I60	I62,66
I8	I63	I64,66
I9	I65	
20	I66	

Tab 3.2

Pour fixer un peu les idées traçons un graphique représentant la série chronologique.




Fig 3.I

Les moyennes échelonnées se calculent en faisant la moyenne sur les quatres trimestres d'une même année. Le calcul est décrit ci-dessous :

t	Y_t	Moyenne échelonnée
1976 I	I40	141,75
2	I42	
3	I44	
4	I41	
1977 5	I42	146,25
6	I47	
7	I47	
8	I49	
1978 9	I50	151
10	I50	
11	I52	
12	I52	
1979 13	I53	156
14	I55	
15	I58	
16	I58	
1980 17	I60	163,50
18	163	
19	I65	
20	I66	

Tab 3.3

2°-Ajustement par la méthode des moindres carrés.

Cette droite des moindres carrés a une équation de la forme :

$$Y=at + b$$

où a et b sont donnés par les formules (3.5) et (3.4) page 82,

c'est à dire :

$$a = \frac{\sum_{t=1}^N ty_t - N\bar{t}\bar{Y}}{\sum_{t=1}^N t^2 - N\bar{t}^2} \quad (3.1)$$

Ici t joue le rôle de X et prend les valeurs 1, ..., 20;

$$b = \bar{Y} - a\bar{t} \quad (3.2)$$

Nous rassemblerons les différents calculs dans le tableau (3.4).

En utilisant ce tableau on calcule successivement :

$$\bar{t} = \frac{1+2+\dots+20}{20} = 10,5 \quad \text{et} \quad \bar{t}^2 = 110,25$$

$$\sum_{t=1}^{20} ty_t = 32745 \quad \sum_{t=1}^{20} t^2 = 2870$$

En portant toutes ces valeurs dans l'expression (3.1) on trouve :

$$a = 1,33 \quad \text{et donc} \quad b = \bar{Y} - a\bar{t} = 151,70 - 1,33 \cdot 10,5 = 137,73$$

L'équation de la droite des moindres carrés est finalement :

$$Y = \frac{133t + 13773}{100} \quad (3.3)$$

On choisira de faire le calcul des valeurs ajustées en utilisant l'équation (3.3). On obtient le tableau (3.4) dans lequel on a aussi inséré les coefficients saisonniers e_t .

t	y_t	ty_t	t^2	y_t^a	e_t (en %)
1	140	140	1	139,06	100,07
2	142	284	4	140,39	101,14
3	144	432	9	141,72	101,60
4	141	564	16	143,05	98,56
5	142	710	25	144,38	97,45
6	147	882	36	145,71	100,88
7	147	1029	49	147,09	99,93
8	149	1192	64	148,37	100,42
9	150	1350	81	149,70	100,20
10	150	1500	100	151,03	99,31
11	152	1672	121	152,36	99,76
12	152	1824	144	153,69	98,98
13	153	1989	169	155,02	98,69
14	155	2170	196	156,35	99,13
15	158	2370	225	157,68	100,20
16	158	2528	256	159,01	99,36
17	160	2720	289	160,34	99,78
18	163	2934	324	161,48	100,82
19	165	3135	361	163,00	101,22
20	166	3320	400	164,33	101,01

Tab 3.4

On constate que les coefficients saisonniers sont très voisins de 1 (i.e de 100%). Ce qui signifie que la série chronologique étudiée est pratiquement la fonction linéaire du temps donnée par (3.3).

CHAPITRE VIII

EXERCICES RESOLUS

Dans ce chapitre nous donnons une correction détaillée pour certains exercices ayant été proposés à différentes sessions d'examen de Statistiques de l'Unité 01103 à l'Université de Lille III.

Il est bien clair que ce chapitre ne remplira sa fonction que si l'étudiant manifeste au préalable sa volonté de résoudre chaque exercice avant de consulter sa solution.

Session de Juin 1974.

Exercice

On donne le tableau suivant traduisant une correspondance entre deux séries X et Y.

X	250	300	350	400	450	500	550	600	650	700	750	800	850	900	950	1000
Y	174	218	263	309	356	404	453	503	554	605	658	711	766	821	877	934

1°-Représenter graphiquement cette correspondance.

2°-Dites pourquoi on peut considérer comme valable un ajustement linéaire.

3°-Chercher la droite d'ajustement par les moindres carrés en donnant son équation.

Solution

Considérons un repère constitué de deux axes rectangulaires dans lequel on portera les valeurs de X en abscisses et celles de Y en ordonnées. Chaque couple de valeurs (x,y) définit un point dans ce repère. Par exemple le point A a pour abscisse $x = 650$ et pour ordonnée $y = 554$. On obtient le nuage de points suivant :

1°-Représentation graphique.




Fig 1.1

2°-On remarque que tous les points obtenus sont presque alignés. Ceci justifie fortement un ajustement linéaire que nous allons déterminer.

3°-Ajustement par la méthode des moindres carrés.

L'équation de la droite des moindres carrés est de la forme : $Y = aX + b$. Ici $a = \frac{\text{Cov}(X,Y)}{\text{Var}(X)}$ et $b = \bar{Y} - a\bar{X}$ (Voir p.82).

Pour déterminer a et b il suffit donc de calculer \bar{X} , \bar{Y} , $\text{Var}(X)$ et $\text{Cov}(X,Y)$.

Rappelons que :

$$\text{Var}(X) = \overline{X^2} - \bar{X}^2 \quad \text{et} \quad \text{Cov}(X,Y) = \overline{XY} - \bar{X} \cdot \bar{Y} .$$

Nous résumons tous les calculs dans le tableau suivant :

X	Y	X ²	XY
250	174	62500	43500
300	218	90000	65400
350	263	122500	92050
400	309	160000	123600
450	356	202500	160200
500	404	250000	202000
550	453	302500	249150
600	503	360000	301800
650	554	422500	360100
700	605	490000	423500
750	658	562500	493500
800	711	640000	568800
850	766	722500	651100
900	821	810000	738900
950	877	902500	833150
1000	934	1000000	934000

En utilisant ce tableau on trouve :

$$\bar{X} = 625 \text{ et } \bar{Y} = 537.$$

$$\text{De la même manière on a } \text{Var}(X) = \overline{X^2} - \bar{X}^2 = 444375 - 390625 = 53750$$

$$\text{Cov}(X,Y) = \overline{XY} - \bar{X} \cdot \bar{Y} = 390046 - 335625 = 54421.$$

$$\text{D'où } a = \frac{54421}{53750} = 1,01$$

$$\text{et } b = \bar{Y} - a\bar{X} = 537 - 1,01 \cdot 625 = -95,81.$$

Finalement on a l'équation de la droite des moindres carrés :

$Y = 1,01 \cdot X - 95,81$

Session d'Octobre 1974.

Exercice

On considère le tableau :

X	x_1	x_2	...	x_{19}	x_{20}
Y	y_1	y_2	...	y_{19}	y_{20}

En vue d'ajuster la correspondance ainsi définie à une droite on a préparé les calculs suivants :

Posant $z_i = x_i - 50$ et $w_i = y_i - 70$ on a obtenu :

$$\sum z_i = -41, \quad \sum w_i = 39, \quad \sum z_i w_i = 7153 \text{ et } \sum z_i^2 = 8369.$$

Les sommes \sum étant prises pour i variant de 1 à 20.

1°-Calculer les moyennes de Z et W. En déduire celles de X et Y.

2°-Déterminer l'équation de la droite des moindres carrés

donnant un ajustement linéaire entre X et Y.

Solution

1°-En utilisant la relation 2.6 p.25 avec $e=1$ on voit que :

$$\bar{X} = \bar{Z} + 50 \text{ et } \bar{Y} = \bar{W} + 70.$$

$$\text{Or : } \bar{Z} = \frac{\sum z_i}{20} = \frac{-41}{20} = -2,05 \text{ et } \bar{W} = \frac{\sum w_i}{20} = \frac{39}{20} = 1,95.$$

$$\text{D'où : } \bar{X} = \bar{Z} + 50 = -2,05 + 50 = 47,95$$

$$\bar{Y} = \bar{W} + 70 = 1,95 + 70 = 71,95.$$

2°-La droite des moindres carrés a pour équation :

$$Y = aX + b \text{ avec } a = \frac{\text{Cov}(X, Y)}{\text{Var}(X)} \text{ et } b = \bar{Y} - a \cdot \bar{X}.$$

$$\text{On sait que } \text{Var}(X) = \text{Var}(X + 50) = \text{Var}(Z) = \bar{Z}^2 - \bar{Z}^2.$$

$$\text{Donc : } \text{Var}(X) = \frac{8369}{20} - (-2,05)^2 = 418,45 - 4,2025 = 414,25$$

Avant de calculer $\text{Cov}(X,Y)$ démontrons d'abord la proposition :

Si a et b sont des constantes réelles on a : $\text{Cov}(X+a,Y+b)=\text{Cov}(X,Y)$.

En effet on a :

$$\text{Cov}(X+a,Y+b) = \overline{(X+a)(Y+b)} - \overline{(X+a)} \cdot \overline{(Y+b)} .$$

Or $(X+a)(Y+b) = XY + bX + aY + ab$ donc $\overline{(X+a)(Y+b)} = \overline{XY} + b\bar{X} + a\bar{Y} + ab$.

De la même façon on a :

$$\begin{aligned} \overline{(X+a)} \cdot \overline{(Y+b)} &= (\bar{X} + a) \cdot (\bar{Y} + b) \\ &= \bar{X} \cdot \bar{Y} + b \cdot \bar{X} + a \cdot \bar{Y} + ab \end{aligned}$$

On en déduit donc :

$$\text{Cov}(X,Y) = \overline{XY} - \bar{X} \cdot \bar{Y} = \text{Cov}(X+a,Y+b) \cdot \text{Ce qui démontre la proposition.}$$

En appliquant cette proposition à $X = Z + 50$ et $Y = W + 70$ on obtient :

$$\begin{aligned} \text{Cov}(X,Y) &= \text{Cov}(Z,W) = \overline{ZW} - \bar{Z} \cdot \bar{W} \\ &= \frac{7153}{20} - (-2,05 \cdot 1,95) \\ &= 357,65 - 3,9975 \\ &= 353,66. \end{aligned}$$

$$\text{Finalement } a = \frac{353,66}{414,25} = 0,85 \quad \text{et} \quad b = \bar{Y} - a \cdot \bar{X} = 71,95 - 0,85 \cdot 47,95$$

c'est-à-dire $b = 31,01$

Ce qui donne l'équation :

$$Y = \frac{85X + 3101}{100} .$$

Session de Juin 1975.

Exercice 1

Pour la série classée suivante :

Classes	Effectifs partiels
[145,150[51
[150,155[95
[155,160[131
[160,165[152
[165,170[120
[170,175[77
[175,180[48

1°-Calculer la médiane et la moyenne arithmétique.

2°-Construire l'histogramme des effectifs cumulés et déterminer graphiquement les valeurs des quartiles.

Solution

1°-Calculons les effectifs cumulés de chaque classe :

Classes	Effectifs cumulés
[145,150[51
[150,155[146
[155,160[277
[160,165[429
[165,170[549
[170,175[626
[175,180[674

L'effectif total est $N = 674$; donc $N/2 = 337$. La médiane tombe donc dans la classe [160,165[. Pour la calculer on utilise alors la formule 1.1 p.18 et on obtient :

$$M = 160 + (165 - 160) \cdot \frac{337 - 277}{429 - 277} = 160 + 5 \cdot \frac{60}{152} = 161,97 .$$

Pour calculer la moyenne arithmétique on fait un changement de variable en posant : $z_i = \frac{c_i - 162,5}{5}$ où c_i est le centre de la classe $[x_i, x_{i+1}]$. On obtient alors la série à valeurs isolées :


-3	-2	-1	0	1	2	3	(Valeurs)
51	95	131	152	120	77	48	(Effectifs).

Cette série a pour moyenne :

$$z = \frac{-3 \cdot 51 + (-2) \cdot 95 + (-1) \cdot 131 + 0 \cdot 152 + 1 \cdot 120 + 2 \cdot 77 + 3 \cdot 48}{674} = -0,83$$

Ce qui donne $X = 5 \cdot (-0,83) + 162,5 = 162,08$.

2°-Pour construire l'histogramme des effectifs cumulés on trace un repère sur lequel on porte les classes en abscisse et les effectifs cumulés en ordonnée. On obtient le diagramme suivant :



On lit alors sur le diagramme les valeurs des quartiles :

$$Q_1 = 156 \quad \text{et} \quad Q_3 = 168 .$$

Exercice 2

Le tableau suivant représente la moyenne des prix de gros et la production de lait, de beurre et de fromage aux Etats-Unis pour les années 1949 et 1958.

En prenant 1949 comme année de référence calculer :

1°-L'indice de Laspeyres pour l'année 1958,

2°-L'indice de Paasche pour l'année 1958 toujours.

Produits	Prix(en francs par Kg ou litre)		Quantités produites en millions de Kgs ou litres	
	1949	1958	1949	1958
Lait	0,40	0,41	9,6	10,4
Beurre	6,1	6	117	115
Fromage	3,4	3,9	78	83

Solution

Les indices de Laspeyres et de Paasche sont donnés respectivement par les formules (1.9) et (1.10) p.50. Dans le cas qui nous intéresse ici on a :

1°-Indice de Laspeyres :

$$\sum Q_0^i P_1^i = (9,6).(0,41) + (117).6 + 78.(3,9) = 1010,13$$

$$\sum Q_0^i P_0^i = (9,6).(0,40) + (117).(6,1) + 78.(3,4) = 982,74$$

On a donc $I_{1/0}^L = \frac{1010,13}{982,74} = 1,02$ (102%) .

De la même manière on a :

2°-Indice de Paasche :

$$\sum Q_1^i P_1^i = (10,4).(0,41) + 115.6 + 83.(3,9) = 1017,96$$

$$\sum Q_1^i P_0^i = (10,4) \cdot (0,40) + 115 \cdot (6,1) + 83 \cdot (3,4) = 987,86 .$$

D'où :

$$I_{1/0}^P = \frac{1017,96}{987,86} = 1,03 \quad (103%) .$$

Exercice 3

La série chronologique suivante indique pour les années 1948 à 1958 la production de houille grasse en millions de tonnes aux U.S.A.

<u>Année</u>	1948	1949	1950	1951	1952	1953	1954	1955	1956	1957	1958
<u>Production</u>	50	37	43	44	39	38	33	39	42	41	34

1°-Construire le tableau des moyennes mobiles sur 5 ans.

2°-Quel est l'inconvénient de la méthode des moyennes mobiles pour l'estimation de la tendance?

3°-Ajuster cette série par la méthode des moindres carrés.

4°-Utiliser cet ajustement pour estimer la production en 1962.

Solution

1°-Moyennes mobiles sur 5 ans.

<u>Année</u>	1948	1949	1950	1951	1952	1953	1954	1955	1956	1957	1958
<u>Production</u>	50	37	43	44	39	38	33	39	42	41	34
<u>Moyennes mobiles</u>	42,6	40,2	39,4	38,6	38,2	38,6	37,6				

2°-Parmi les inconvénients que présente la méthode des moyennes mobiles on peut citer :

-La réduction du nombre de termes dans la série. Par exemple la série initiale ci-dessus a 11 termes et celle obtenue par les moyennes mobiles n'en a que 7. Il y a un peu d'information qui se perd.

-Elle risque de donner lieu à des mouvements et des cycles nouveaux.

3°-Droite des moindres carrés.

On réécrit la série chronologique en considérant les années comme une série variant de 1 à 11. On obtient ainsi en designant par y_t la production à l'année t le tableau suivant :

t	1	2	3	4	5	6	7	8	9	10	11
y_t	50	37	43	44	39	38	33	39	42	41	34

La droite des moindres carrés a pour équation :

$$Y_t = at + b \quad \text{avec :}$$

$$a = \frac{\sum_{t=1}^{11} ty_t - N\bar{t}\bar{y}_t}{\sum_{t=1}^{11} t^2 - N\bar{t}^2} \quad \text{et} \quad b = \bar{y}_t - a\bar{t} .$$

En utilisant le tableau ci-dessus on trouve :

$$\sum_{t=1}^{11} t^2 = 506 \quad \sum_{t=1}^{11} ty_t = 2557$$

$$\bar{t} = 6 \quad \bar{t}^2 = 36 \quad \text{et} \quad \bar{y}_t = 40 .$$

$$\text{On en déduit : } a = \frac{2557 - 11 \cdot 6 \cdot 40}{506 - 11 \cdot 36} = \frac{-83}{110} = -0,75$$

$$\text{et} \quad b = 40 + 0,75 \cdot 6 = 42,70$$

$$\text{Ce qui donne} \quad Y_t = \frac{-75t + 4270}{100} .$$

4°-L'année 1962 correspond à $t = 15$. D'où :

$$\text{Production en 1962} = y_{15} = \frac{-75 \cdot 15 + 4270}{100} = 31,45 .$$

Session de Septembre 1975.

On considère la série statistique classée suivante :

Classes	Effectifs
[40 , 45[8
[45 , 50[11
[50 , 55[31
[55 , 60[61
[60 , 65[54
[65 , 70[58
[70 , 75[43
[75 , 80[25
[80 , 85[17
[85 , 90[7

1°-Déterminer la moyenne arithmétique \bar{X} et l'écart-type σ .

2°-Quel est le pourcentage des valeurs comprises entre $\bar{X} - 2\sigma$ et $\bar{X} + 2\sigma$?

Solution

1°-La série des centres est :

C	42,5	47,5	52,5	57,5	62,5	67,5	72,5	77,5	82,5	87,5
	8	11	31	61	54	58	43	25	17	7

On pose : $z_i = \frac{c_i - 62,5}{5}$.On obtient une nouvelle série :

Z	-4	-3	-2	-1	0	1	2	3	4	5
	8	11	31	61	54	58	43	25	17	7 (Effectifs)

qui a pour moyenne arithmétique :

$$\bar{z} = \frac{134}{315} = 0,42 \text{ et donc } \bar{X} = 5\bar{z} + 62,5 = 5 \cdot 0,42 + 62,5 = 64,62.$$

$$\text{On a d'autre part : } \sigma(X) = 5 \sigma(Z).$$

Il suffit donc de calculer $\sigma(Z)$ lequel est :

$$\sigma(Z) = \sqrt{\overline{z^2} - \bar{z}^2}.$$

On calcule $\overline{z^2}$ et on trouve :

$$\overline{z^2} = \frac{1252}{315} = 3,97.$$

$$\text{D'où : } \sigma(Z) = \sqrt{3,97 - (0,42)^2} = 1,94$$

$$\text{et } \sigma(X) = 5 \cdot 1,94 = 9,73.$$

$$2^\circ\text{-On a } \bar{X} - 2\sigma = 64,62 - 2 \cdot 9,73 = 45$$

$$\bar{X} + 2\sigma = 64,62 + 2 \cdot 9,73 = 84$$

Commençons d'abord par calculer l'effectif des valeurs qui sont comprises entre 45 et 84. Il est égal à l'effectif des valeurs qui sont comprises entre 45 et 80 + l'effectif des valeurs qui sont comprises entre 80 et 84 qui est égal à 4/5 fois celui de la classe [80, 85[. Ce qui donne en définitive $283 + 4/5(17) = 297$. Ce qui représente 94% de l'effectif total.

Session de Juin 1977.

Exercice

On considère la série à valeurs isolées suivante :

X	13	14	15	16	17	18	19	20	21	22
n_i	4	6	7	15	24	16	14	7	4	3

1°-Représenter graphiquement cette série par un diagramme en bâtons et tracer le polygone des effectifs.

2°-Calculer la moyenne, la variance et l'écart-type de cette série.

2°-Par définition la moyenne arithmétique de cette série

est :

$$\bar{X} = \frac{1}{N} \sum_{i=1}^k n_i x_i = \frac{1}{100} (4 \cdot 13 + 6 \cdot 14 + \dots + 4 \cdot 21 + 3 \cdot 22) = 17,33$$

$$\text{On a } \text{Var}(X) = \overline{X^2} - (\bar{X})^2 .$$

Or :

$$\overline{X^2} = \frac{1}{100} (4 \cdot 13^2 + 6 \cdot 14^2 + \dots + 4 \cdot 21^2 + 3 \cdot 22^2) = 304,57$$

$$\text{D'où } \text{Var}(X) = 304,57 - (17,33)^2 = 4,24 \quad \text{et donc :}$$

$$\sigma(X) = \sqrt{\text{Var}(X)} = 2,05 .$$