

Année Universitaire 2021-2022

## Partie 2. Séries statistiques à deux dimensions (Bidimensionnelle)

Pr. Aicha EL ALAOU

Université Sultan Moulay Slimane  
Faculté d'Economie et de Gestion

جامعة السلطان مولاي سليمان  
الكلية الاقتصادية والتجارية  
بني ملال

## Plan

- Chapitre I : Caractéristiques marginales et conditionnelles d'une distribution à deux variables
- Chapitre II : Régression, ajustement linéaire et corrélation

2

## Chapitre I: Caractéristiques marginales et conditionnelles d'une distribution à deux variables

3

## Rappel

- Une population peut être classée non seulement par rapport à un seul caractère, mais également selon deux ou plusieurs caractères.
- Lorsque l'on décrit une population selon deux caractères, le tableau correspondant est un **tableau croisé à deux dimensions (double entrée)**.
- Les tableaux croisés sont appelés ainsi car ils « croisent » deux **distributions au sein d'un même tableau**.
- Ainsi, on étudiera, par exemple, un ensemble de salariés non plus seulement selon le salaire, mais encore selon l'âge ou bien le nombre d'enfants, etc.

4

- Soit une population pour laquelle on observe le caractère X et le caractère Y.
- Le caractère X peut prendre les k modalités  $x_1, x_2, \dots, x_k$ .
- Le caractère Y peut prendre les l modalités  $y_1, y_2, \dots, y_l$ .
- L'effectif total de la population est noté « n ».
- Le nombre d'individus présentant la modalité  $x_i$  ET la modalité  $y_j$  est noté  $n_{ij}$ .
- Le tableau à double entrée représentant les séries statistiques à deux variables, prennent le nom de **tableaux de contingence**.

5

## Tableau de contingence

- Considérons la distribution, selon les deux variables statistiques X et Y, d'une population P d'effectif total n (Tableau 1).

Variable Y Variable X	$y_1$	$y_2$	...	$y_j$	...	$y_l$	Totaux
$x_1$	$n_{11}$	$n_{12}$	...	$n_{1j}$	...	$n_{1l}$	$n_{1.}$
$x_2$	$n_{21}$	$n_{22}$	...	$n_{2j}$	...	$n_{2l}$	$n_{2.}$
...	...	...	...	...	...	...	...
$x_i$	$n_{i1}$	$n_{i2}$	...	$n_{ij}$	...	$n_{il}$	$n_{i.}$
...	...	...	...	...	...	...	...
$x_k$	$n_{k1}$	$n_{k2}$	...	$n_{kj}$	...	$n_{kl}$	$n_{k.}$
<b>Totaux</b>	$n_{.1}$	$n_{.2}$	...	$n_{.j}$	...	$n_{.l}$	<b>n</b>

6

**Distribution de 17500 jeunes selon leurs âges et leurs salaires nets (103DH). Tableau 2**

Salaire ( $y_j$ ) Âge ( $x_i$ )	[5,6[	[6,7[	[7,8[	Total
[20,22[	1 200	500	100	1 800
[22,24[	2 500	3 500	600	6 600
[24,26[	1 800	5 000	2 300	9 100
<b>Total</b>	<b>5 500</b>	<b>9 000</b>	<b>3 000</b>	<b>17 500</b>

- Les modalités du caractère Y apparaissent en ligne, celles du caractère X apparaissent en colonne.
- Les effectifs apparaissant à l'intérieur du tableau ( $n_{ij}$ ) sont toujours notés en prenant l'indice de x « i » d'abord, et celui de y « j » ensuite.
- Exemple :
  - $n_{21}$  du tableau est égal à 2500
  - $n_{12}$  du tableau est égal à 500
  - $n_{kl} = n_{33} = 2300$
- La ligne et la colonne appelées ici « Total », prennent le nom de « marges ».

7

## Caractéristiques marginales

- Le nombre d'individus présentant la modalité  $x_i$  (quelle que soit la modalité  $y_j$ ) s'écrit:

$$n_{i.} = \sum_{j=1}^l n_{ij}$$

- Le nombre d'individus présentant la modalité  $y_j$  (quelle que soit la modalité  $x_i$ ) s'écrit:

$$n_{.j} = \sum_{i=1}^k n_{ij}$$

- Cette notation applique la convention selon laquelle une sommation sur l'une ou l'autre des dimensions se représente en remplaçant l'indice correspondant par un point.

8

- Dans les marges, ainsi que pour toute somme, on remplace l'indice qui varie par un point.
- Exemple : «  $n_{1.}$  » signifie que l'on a sommé les effectifs de la première ligne. C'est l'indice  $j$  qui varie de 1 à  $l$  ; on le remplace par «  $\bullet$  ». Dans le tableau 2,  $n_{1.} = 1800$ .
- De la même manière «  $n_{.j}$  » représente l'effectif de la modalité  $y_j$ , pour l'ensemble des modalités de  $x$ . Ici c'est l'indice «  $i$  » qui varie de 1 à  $k$  ; on le remplace par «  $\bullet$  ».
- «  $n_{.j}$  » signifie que l'on a sommé les effectifs de la première colonne.
- Les effectifs de la distribution marginale de X (Y) seront repérés par le terme générique «  $n_{i.}$  » («  $n_{.j}$  »). L'effectif total s'écrit donc «  $n_{..}$  », c'est le nombre d'individus de la population étudiée.

9

## Distributions marginales : effectifs et fréquences

- La somme des effectifs des lignes fournit la distribution marginale du caractère X, comme si l'on étudiait seulement le caractère X.
- La somme des effectifs des colonnes fournit la distribution marginale du caractère Y, comme si l'on étudiait seulement le caractère Y.
- Les distributions marginales de X et de Y représentent des distributions à une seule dimension où les individus sont distribués suivant le seul caractère X ou selon le seul caractère Y.
- Les effectifs marginaux : Ce sont les effectifs lus dans les deux marges du tableau (marge du bas « ligne total » et celle de droite « colonne total »):
  - $n_{1.}, n_{2.}, \dots, n_{i.}, \dots, n_{k.}$  pour x
  - $n_{.1}, n_{.2}, \dots, n_{.j}, \dots, n_{.l}$  pour y
- Il y aura autant d'effectifs marginaux que de modalités («  $k$  » pour X et «  $l$  » pour Y)
- La fréquence marginale,  $f_{i.}$ , représente la fréquence de la modalité  $x_i$
- La fréquence marginale,  $f_{.j}$ , représente la fréquence de la modalité  $y_j$

10

## Fréquences

- $f_{ij} = n_{ij}/n$  : la proportion d'individus présentant à la fois la modalité  $x_i$  et la modalité  $y_j$ .
- $f_{i.} = \sum_{j=1}^l f_{ij} = n_{i.}/n$  est la somme des fréquences de la ligne  $i$ .

$f_{i.}$  représente la proportion des individus présentant la modalité  $x_i$  quelle que soit la modalité  $y_j$  (fréquences marginales du caractère X).

- $f_{.j} = \sum_{i=1}^k f_{ij} = n_{.j}/n$  est la somme des fréquences de la colonne  $j$  ;

$f_{.j}$  représente la proportion des individus présentant la modalité  $y_j$  quelle que soit les modalités  $x_i$  (fréquences marginale du caractère Y).

11

- Si l'on reprend le tableau 2 on a par exemple :
- $f_{22} = n_{22}/n_{..} = 3500/17500 = 0,2 \Rightarrow 20\%$  des individus étudiés ont entre 22 et 24 ans, **et** gagnent entre 6000 et 7000 DH de salaire net.
- $f_{.2} = n_{.2}/n_{..} = 6600/17500 = 0,377 \Rightarrow 37,7\%$  des individus étudiés sont âgé de 22 à 24 ans.
- $f_{2.} = n_{2.}/n_{..} = 9000/17500 = 0,514 \Rightarrow 51,4\%$  des individus étudiés touchent un salaire net compris entre 6000 et 7000 DH.

12

### Exemple

Âge ( $x_i$ )	$n_i$	$f_i = \frac{n_i}{n}$ (%)	Salaire ( $y_j$ )	$n_j$	$f_j = \frac{n_j}{n}$ (%)
[20,22[	$n_1 = 1\ 800$	10,29	[5,6[	$n_1 = 5\ 500$	31,43
[22,24[	$n_2 = 6\ 600$	37,71	[6,7[	$n_2 = 9\ 000$	51,43
[24,26[	$n_3 = 9\ 100$	52	[7,8[	$n_3 = 3\ 000$	17,14
Total	$n = 17\ 500$	100	Total	17 500	100

13

### Distributions conditionnelles de X liées par $y_j$

- Si on ne s'intéresse qu'aux individus présentant la modalité  $y_j$ , l'effectif de ce groupe est  $n_j$  ;
- La fréquence conditionnelle de la modalité  $x_i$  liée par  $y_j$  est:
 
$$f_{i|j} = f_{x_i|y_j} = \frac{n_{ij}}{n_{.j}}$$
- Les  $k$  fréquences conditionnelles pour la modalité  $y_j$  forment la distribution conditionnelle de X liée par  $y_j$ .
- Dans un tableau, il y a « 1 » **distributions conditionnelles en colonne** (1 = modalités du caractère Y).

14

### Exemple

Distribution conditionnelle de l'âge liée par la classe de salaire [5,6[

$x_i | y_1$

$x_i   y_1$ $y_1 = [5,6[$	$n_{i/j} = n_{ij}$	$f_{i 1} = \frac{n_{ij}}{n_{.1}}$ (%)
[20,22[	$n_{11} = 1\ 200$	21,82
[22,24[	$n_{21} = 2\ 500$	45,45
[24,26[	$n_{31} = 1\ 800$	32,73
Total	$n_{.1} = 5\ 500$	100

Distribution conditionnelle de l'âge liée par la classe de salaire [6,7[

$x_i | y_2$

$x_i   y_2$ $y_2 = [6,7[$	$n_{i/j} = n_{ij}$	$f_{i 2} = \frac{n_{ij}}{n_{.2}}$ (%)
[20,22[	$n_{12} = 500$	5,55
[22,24[	$n_{22} = 3\ 500$	38,89
[24,26[	$n_{32} = 5\ 000$	55,56
Total	$n_{.2} = 9\ 000$	100

15

### Distributions conditionnelles de Y liées par $x_i$

- De même, si on ne s'intéresse qu'aux individus présentant la modalité  $x_i$ , l'effectif de ce groupe est  $n_i$  ;
- La fréquence conditionnelle de la modalité  $y_j$  liée par  $x_i$  est:
 
$$f_{j|i} = f_{y_j|x_i} = \frac{n_{ij}}{n_{i.}}$$
- Les « 1 » fréquences conditionnelles pour la modalité  $x_i$  forment la distribution conditionnelle de Y liée par  $x_i$ .
- Dans un tableau, il y a **k distributions conditionnelles en ligne** (k = nombre de modalités du caractère X).

16

### Exemple

**Distribution conditionnelle du salaire liée par la classe d'âge [20,22[**  
 $y_j | x_1$

$y_j   x_1$ $x_1 = [20,22[$	$n_{j/i} = n_{ij}$	$f_{ji} = \frac{n_{ij}}{n_{i.}}$ en %
[5,6[	$n_{11} = 1\ 200$	66,67
[6,7[	$n_{12} = 500$	27,78
[7,8[	$n_{13} = 100$	5,55
Total	$n_{1.} = 1\ 800$	100

**Distribution conditionnelle du salaire liée par la classe d'âge [22,24[**  
 $y_j | x_2$

$y_j   x_2$ $x_2 = [22,24[$	$n_{j/i} = n_{ij}$	$f_{ji} = \frac{n_{ij}}{n_{i.}}$ en %
[5,6[	$n_{21} = 2\ 500$	37,88
[6,7[	$n_{22} = 3\ 500$	53,03
[7,8[	$n_{23} = 600$	9,09
Total	$n_{2.} = 6\ 600$	100

17

- La somme des fréquences est égale à l'unité :
- Fréquences marginales :
 
$$\sum_{j=1}^l f_{.j} = \sum_{j=1}^l \frac{n_{.j}}{n_{..}} = \frac{1}{n_{..}} \sum_{j=1}^l n_{.j} = \frac{n_{..}}{n_{..}} = 1$$

$$\sum_{i=1}^k f_{i.} = \sum_{i=1}^k \frac{n_{i.}}{n_{..}} = \frac{1}{n_{..}} \sum_{i=1}^k n_{i.} = \frac{n_{..}}{n_{..}} = 1$$
- Fréquences conditionnelles :
 
$$\sum_{i=1}^k f_{i/j} = \sum_{i=1}^k \frac{n_{ij}}{n_{.j}} = \frac{1}{n_{.j}} \sum_{i=1}^k n_{ij} = \frac{n_{.j}}{n_{.j}} = 1$$

$$\sum_{j=1}^l f_{j/i} = \sum_{j=1}^l \frac{n_{ij}}{n_{i.}} = \frac{1}{n_{i.}} \sum_{j=1}^l n_{ij} = \frac{n_{i.}}{n_{i.}} = 1$$

18

### Application

- Le directeur d'un établissement privé veut étudier la liaison entre l'âge de ses cadres et le niveau du salaire mensuel. L'enquête portant sur un échantillon de 195 cadres a donné les résultats suivants :

		$y_j$ : salaire mensuel en $10^2$ DH							
		[10,16[	[16,22[	[22,28[	[28,34[	[34,40[	[40,46[	[46,52[	[52,58[
Âge $x_i$	[22,28[	5	4	1	0	0	0	0	0
	[28,34[	4	5	8	6	3	2	1	0
	[34,40[	0	2	8	10	9	6	4	2
	[40,46[	1	2	6	8	10	8	6	2
	[46,52[	0	0	2	4	8	6	8	4
	[52,58[	0	0	1	7	10	10	8	4

19

- Déterminer les distributions marginales (en termes d'effectifs) des deux caractères : âge et salaire mensuel
- Donner la signification des valeurs des  $n_{.5}$  ;  $n_{.4}$  ;  $n_{45}$  ;  $n_{54}$
- Dégager les distributions conditionnelles (en termes de fréquences) de  $x$  liée à  $y = y_3$  et à  $y = y_7$ . De même donner les distributions conditionnelles (en termes de fréquences) de  $y$  liées à  $x = x_4$  et à  $x = x_6$
- Trouver :
  - La proportion des salariés âgés entre 46 et 52 ans quel que soit leur salaire
  - La proportion des salariés qui gagnent entre 4600 et 5200 DH quel que soit leur âge
  - La proportion des salariés âgés entre 28 et 34 ans et dont le salaire est compris entre 2800 et 3400 DH.
  - La proportion des salariés qui gagnent entre 2200 et 2800 DH sachant qu'ils sont âgés entre 40 et 46 ans
  - La proportion des salariés âgés entre 34 et 40 ans sachant que leur salaire est compris entre 2800 et 3400 DH.

20

## Relations entre fréquences marginales et conditionnelles

- On démontre également que le produit des fréquences marginales par les fréquences conditionnelles est égal aux fréquences conjointes :

$$f_{i.} \times f_{j/i} = \frac{n_{i.}}{n_{..}} \times \frac{n_{ij}}{n_{i.}} = \frac{n_{ij}}{n_{..}} = f_{ij}$$

$$f_{.j} \times f_{i/j} = \frac{n_{.j}}{n_{..}} \times \frac{n_{ij}}{n_{.j}} = \frac{n_{ij}}{n_{..}} = f_{ij}$$

$$f_{i.} \times f_{j/i} = f_{ij} \text{ et } f_{.j} \times f_{i/j} = f_{ij}$$

21

## Remarques sur l'effectif total

- $n_{..}$ , l'effectif total, est égal, soit à la somme des  $n_{i.}$ , soit à celle des  $n_{.j}$  (effectifs marginaux), qui sont eux-mêmes des sommes. Donc :

$$n_{..} = \sum_{i=1}^k n_{i.} = \sum_{i=1}^k \sum_{j=1}^l n_{ij}$$

$$n_{..} = \sum_{j=1}^l n_{.j} = \sum_{j=1}^l \sum_{i=1}^k n_{ij}$$

- On voit donc que l'on peut inverser l'ordre des sommes (commutativité) :

$$\sum_i \sum_j = \sum_j \sum_i$$

22

## Caractéristiques des séries à deux caractères

- On se limitera aux moyennes arithmétiques et aux variances. Puisqu'il existe des distributions marginales et conditionnelles, il est logique de déterminer des moyennes et des variances marginales et conditionnelles.
- Si nous reprenons l'exemple de la distribution de 17500 jeunes selon leurs âges et leurs salaires nets, l'âge moyen et la variance des âges seront calculés à partir de la distribution marginale de l'âge (caractère x). De la même manière le salaire moyen et la variance des salaires seront calculés à partir de la distribution marginale du salaire (caractère y).
- L'âge moyen et la variance des âges pour chaque classe de salaire  $y_j$  seront tirés des distributions conditionnelles de x liées par y (« i » varie et « j » est fixé), et inversement.

23

## Caractéristiques des distributions marginales

**Caractéristiques marginales du caractère x**

**Caractéristiques marginales du caractère y**

24

## Caractéristiques marginales du caractère x

- Les caractéristiques marginales de x (moyenne et variance) s'obtiennent à partir de la distribution marginale de x, c'est-à-dire à partir des « k » modalités ( $x_i$ ) et des « k » effectifs marginaux ( $n_i$ ).
- La **moyenne marginale**  $\bar{x}$
- Il s'agit d'une moyenne arithmétique, que l'on note  $\bar{x}$  (lue : « x double barre »).
- Sa détermination relève de la même logique que celle utilisée pour les séries à une seule dimension. On a :

$$\bar{x} = \frac{1}{n} \sum_{i=1}^k n_i x_i = \frac{1}{n} \sum_{i=1}^k n_i x_i$$

25

- L'effectif marginal  $n_i$ , étant lui-même une somme, on peut écrire :

$$\bar{x} = \frac{1}{n} \sum_{i=1}^k \sum_{j=1}^l n_{ij} x_i$$

- Selon les données du tableau 2 :

$$\bar{x} = \frac{1}{17500} [(1800 \times 21) + (6600 \times 23) + (9100 \times 25)] = 23,83$$

- L'âge moyen des individus est donc de 23,83 ans (soit 23 ans, 9 mois et 29 jours)

26

## La variance marginale de x : V(x)

- La formule de définition est la même que pour les séries à une seule dimension :

$$V(x) = \frac{1}{n} \sum_{i=1}^k n_i (x_i - \bar{x})^2$$

- La formule développée est :

$$V(x) = \frac{1}{n} \sum_{i=1}^k n_i x_i^2 - \bar{x}^2$$

- L'écart-type est égal à la racine carrée de la variance.
- Dans le tableau 2 :

$$\frac{1}{n} \sum_{i=1}^k n_i x_i^2 = \frac{1}{17500} [(1800 \times 21^2) + (6600 \times 23^2) + (9100 \times 25^2)] = 569,869$$

$$\bar{x}^2 = (23,8)^2 = 566,44$$

$$\text{Et } V(x) = 569,869 - 566,44 = 3,43$$

$$\sigma_x = 1,85 \text{ an}$$

27

## Caractéristiques marginales du caractère y

- La démarche est la même que précédemment : les caractéristiques marginales de y s'obtiennent à partir des « l » modalités ( $y_j$ ) et des « l » effectifs marginaux ( $n_j$ ).

- La moyenne s'écrit :

$$\bar{y} = \frac{1}{n} \sum_{j=1}^l n_j y_j = \frac{1}{n} \sum_{j=1}^l \sum_{i=1}^k n_{ij} y_j$$

- La variance s'écrit :

$$V(y) = \frac{1}{n} \sum_{j=1}^l n_j (y_j - \bar{y})^2$$

- Soit, par la formule développée :

$$V(y) = \frac{1}{n} \sum_{j=1}^l n_j y_j^2 - \bar{y}^2 \quad \sigma_y = \sqrt{V(y)}$$

28

## Application numérique

- Selon les données du tableau 2 :

$$\bar{y} = \frac{1}{17500} [(5500 \times 5,5) + (9000 \times 6,5) + (3000 \times 7,5)] = 6,36$$

$$\frac{1}{n} \sum_{j=1}^l n_j y_j^2 = \frac{1}{17500} [(5500 \times 5,5^2) + (9000 \times 6,5^2) + (3000 \times 7,5^2)] = 40,88$$

$$\bar{y}^2 = (6,36)^2 = 40,45$$

$$\text{Et } V(y) = 40,88 - 40,45 = 0,43$$

$$\sigma_y = 0,65 \text{ soit } 650 \text{ DH}$$

29

## Caractéristiques conditionnelles des distributions

**Caractéristiques conditionnelles de x lié par y**

**Moyennes conditionnelles de x lié par y**

30

## Caractéristiques conditionnelles de x lié par y

- Il existe deux types de distributions conditionnelles : celle de x lié par y (où x varie et y est fixe) ; celle de y lié par x (où y varie et x est fixe).
- Les caractéristiques de x lié par y (moyenne, variance) s'obtiennent à partir des distributions conditionnelles de x lié par y, c'est-à-dire à partir des « k » modalités de x et des « l » colonnes d'effectifs, à l'intérieur du tableau de contingence.
- Il y a en effet « l » distributions conditionnelles de x lié par y. Les distributions conditionnelles de x lié par y sont les colonnes d'effectifs du tableau de contingence associées aux modalités de x.

31

## Moyennes conditionnelles de x lié par y

- Les « l » moyennes conditionnelles de x lié par y (ou « de x si y ») sont de la forme :

$$\bar{x}_j = \frac{1}{n_{.j}} \sum_{i=1}^k n_{ij} x_i$$

- La notation  $\bar{x}_j$  signifie : « moyenne conditionnelle de x, si y =  $y_j$  ».
- La sommation se fait par rapport à « i », puisque l'on somme « en colonne ». Les effectifs par lesquels on multiplie chaque valeur du caractère  $x(x_i)$  sont les effectifs conjoints  $n_{ij}$  du tableau de contingence. L'effectif par lequel on divise la somme pondérée est  $n_{.j}$ , c'est-à-dire la somme des effectifs conjoints de la colonne « j ».

32

- Par exemple:
  - Sur les données chiffrées du tableau 2, la moyenne conditionnelle  $\bar{x}_3$  est :
- $$\bar{x}_3 = \frac{1}{3000} [(100 \times 21) + (600 \times 23) + (2300 \times 25)] = 24,47$$
- L'âge moyen des individus qui gagnent entre 7000 et 8000 DH est donc de 24,47 ans (environ 24 ans et 6 mois)

33

## Variances conditionnelles de x lié par y

- Les « l » variances conditionnelles de x lié par y (ou « de x si y ») se notent  $V_j(x)$ . Elles sont de la forme :

$$V_j(x) = \frac{1}{n_j} \sum_{i=1}^k n_{ij} (x_i - \bar{x}_j)^2$$

- Ou bien par la formule développée :

$$V_j(x) = \frac{1}{n_j} \sum_{i=1}^k n_{ij} x_i^2 - \bar{x}_j^2$$

- Les sommations se font « par rapport à i » puisque l'on somme, en colonne, des effectifs se rapportant aux valeurs du caractère x. Les écarts que l'on élève au carré, sont des écarts entre la variable ( $x_i$ ) et la moyenne conditionnelle correspondante  $\bar{x}_j$ .

34

- En utilisant les données du tableau 1, la variance conditionnelle de x si  $y = y_3$  est  $V_3(x)$  :

$$\frac{1}{n_3} \sum_{i=1}^k n_{3i} x_i^2 = \frac{1}{3000} [(100 \times 21^2) + (600 \times 23^2) + (2300 \times 25^2)] = 599,67$$

$$\bar{x}_3^2 = (24,47)^2 = 598,78$$

$$\text{Donc : } V_3(x) = 599,67 - 598,78 = 0,89$$

- Donc l'écart-type des âges des individus gagnant entre 7000 et 8000 DH de salaire est de 0,94 année.

35

## Moyennes conditionnelle de y lié par x

- Elles s'obtiennent à partir des « l » modalités du caractère y et à partir des « k » lignes d'effectifs conjoints du tableau de contingence.
- Il y a donc « k » distributions, « k » moyennes et « k » variances, conditionnelles de y lié par x.

$$\bar{y}_i = \frac{1}{n_i} \sum_{j=1}^l n_{ij} y_j$$

- La notation  $\bar{y}_i$  signifie : « moyenne conditionnelle de y, si  $x = x_i$  ».
- La sommation se fait par rapport à « j », puisque l'on somme « en ligne ». Les effectifs par lesquels on multiplie chaque valeur du caractère y ( $y_j$ ) sont les effectifs conjoints  $n_{ij}$  du tableau de contingence. L'effectif par lequel on divise la somme pondérée est  $n_i$ , c'est-à-dire la somme des effectifs conjoints de la ligne « i ».

36

### Variances conditionnelles de y lié par x

- Les « k » variances conditionnelles de y lié par x (ou « de y si x ») se notent  $V_i(y)$ . Elles sont de la forme :

$$V_i(y) = \frac{1}{n_i} \sum_{j=1}^l n_{ij} (y_j - \bar{y}_i)^2$$

- Ou bien par la formule développée :

$$V_i(y) = \frac{1}{n_i} \sum_{j=1}^l n_{ij} y_j^2 - \bar{y}_i^2$$

- Les sommations se font « par rapport à j » puisque l'on somme, en ligne, des effectifs se rapportant aux valeurs du caractère x. Les écarts que l'on élève au carré, sont des écarts entre la variable ( $x_i$ ) et la moyenne conditionnelle correspondante.

37

### Exemple

- Combien gagnent en moyenne les individus de l'échantillon sachant qu'ils sont âgés de 22 à 24 ans, et avec quelle dispersion?
- Pour répondre à cette question, il faudrait calculer la moyenne et variance de la distribution conditionnelle de y lié à  $x = x_2$ .

$$\bar{y}_2 = \frac{1}{6600} [(2500 \times 5,5) + (3500 \times 6,5) + (600 \times 7,5)] = 6,21$$

$$\frac{1}{n_2} \sum_{j=1}^3 n_{2j} y_j^2 = \frac{1}{6600} [(2500 \times 5,5^2) + (3500 \times 6,5^2) + (600 \times 7,5^2)] = 38,98$$

$$\text{Donc : } V_2(y) = 38,98 - 38,56 = 0,42$$

- En moyenne, les jeunes âgés entre 22 et 24 ans gagnent 6210 DH avec une dispersion de 420 DH.

38

### Relations entre caractéristiques marginales et conditionnelles

- La population P peut être considérée comme composée :
- Soit des l sous-population  $P_1, P_2, \dots, P_l$  d'effectifs  $n_{.1}, n_{.2}, \dots, n_{.l}$ , correspondant aux distributions conditionnelles de X lié par Y ;
- Soit des k sous-population  $P'_1, P'_2, \dots, P'_k$  d'effectifs  $n_{1.}, n_{2.}, \dots, n_{k.}$ , correspondant aux distributions conditionnelles de Y lié par X.
- Expression de la moyenne marginale en fonction des moyennes conditionnelles :**
- La moyenne relative à l'ensemble de la population est égale à la moyenne pondérée des moyennes des sous-populations. Les coefficients de pondération sont les proportions des sous-populations dans la population totale.

39

### Relations entre les moyennes marginales et les moyennes conditionnelles

- On a par définition :
- Ou :
- Or :
- Donc :
- La démonstration est faite pour x ; elle est identique pour y :

$$\bar{x} = \frac{1}{n_{..}} \sum_{i=1}^k \sum_{j=1}^l n_{ij} x_i$$

$$\bar{x} = \frac{1}{n_{..}} \sum_{j=1}^l \left( \sum_{i=1}^k n_{ij} x_i \right)$$

$$\bar{x}_j = \frac{1}{n_{.j}} \sum_{i=1}^k n_{ij} x_i \Rightarrow \sum_{i=1}^k n_{ij} x_i = n_{.j} \times \bar{x}_j$$

$$\bar{x} = \frac{1}{n_{..}} \sum_{j=1}^l n_{.j} \bar{x}_j$$

$$\bar{y} = \frac{1}{n_{..}} \sum_{i=1}^k n_{i.} \bar{y}_i$$

40

- La moyenne marginale est égale à la moyenne des moyennes conditionnelles, pondérée par les effectifs marginaux.

41

### Relations entre les variances

- La variance relative à l'ensemble d'une population est égale à la somme de deux termes, la moyenne pondérée des variances des sous-populations (variances conditionnelles) et la variance pondérée des moyennes des sous-populations (moyennes conditionnelles).
- Par conséquent, en considérant la distribution marginale de X comme formée de distributions conditionnelles de X lié par Y, on obtient :

$$V(x) = \frac{1}{n_{..}} \sum_{j=1}^l n_{.j} (\bar{x}_j - \bar{x})^2 + \frac{1}{n_{..}} \sum_{j=1}^l V_j(x) \times n_{.j}$$

- Autre notation :

$$V(x) = V(\bar{x}_j) + \overline{V_j(x)}$$

42

### Démonstration

- Nous démontrons ici pour x ; la démonstration pour y est identique. On a :

$$\sum_{j=1}^l n_{ij} (x_i - \bar{x})^2$$

- Ajoutons et retranchons la même valeur, la moyenne conditionnelle de x, dans le terme entre parenthèses :

$$V(x) = \frac{1}{n_{..}} \sum_{i=1}^k \sum_{j=1}^l n_{ij} [(x_i - \bar{x}_j) + (\bar{x}_j - \bar{x})]^2$$

$$= \frac{1}{n_{..}} \sum_{i=1}^k \sum_{j=1}^l n_{ij} (x_i - \bar{x}_j)^2 + \frac{2}{n_{..}} \sum_{i=1}^k \sum_{j=1}^l n_{ij} (x_i - \bar{x}_j) (\bar{x}_j - \bar{x}) + \frac{1}{n_{..}} \sum_{i=1}^k \sum_{j=1}^l n_{ij} (\bar{x}_j - \bar{x})^2$$

43

$$\text{Soit } A = \frac{1}{n_{..}} \sum_{i=1}^k \sum_{j=1}^l n_{ij} (x_i - \bar{x}_j)^2 = \frac{1}{n_{..}} \sum_{j=1}^l \sum_{i=1}^k n_{ij} (x_i - \bar{x}_j)^2$$

Or :  $V_j(x) = \frac{1}{n_{.j}} \sum_{i=1}^k n_{ij} (x_i - \bar{x}_j)^2$

$$\Rightarrow \sum_{i=1}^k n_{ij} (x_i - \bar{x}_j)^2 = n_{.j} V_j(x)$$

Donc  $A = \frac{1}{n_{..}} \sum_{j=1}^l n_{.j} V_j(x)$

$$\text{Soit } B = \frac{2}{n_{..}} \sum_{i=1}^k \sum_{j=1}^l n_{ij} (x_i - \bar{x}_j) (\bar{x}_j - \bar{x})$$

44

$$= \frac{2}{n_{..}} \sum_{j=1}^l \left( \sum_{i=1}^k n_{ij} (x_i - \bar{x}_j) (\bar{x}_j - \bar{x}) \right) = \frac{2}{n_{..}} \sum_{j=1}^l (\bar{x}_j - \bar{x}) \sum_{i=1}^k n_{ij} (x_i - \bar{x}_j)$$

$$\text{Or } \sum_{i=1}^k n_{ij} x_i - \sum_{i=1}^k n_{ij} \bar{x}_j = n_j \bar{x}_j - n_j \bar{x}_j = 0$$

$$\text{Soit } C = \frac{1}{n_{..}} \sum_{j=1}^l \sum_{i=1}^k n_{ij} (\bar{x}_j - \bar{x})^2 = \frac{1}{n_{..}} \sum_{j=1}^l (\bar{x}_j - \bar{x})^2 \sum_{i=1}^k n_{ij}$$

$$C = \frac{1}{n_{..}} \sum_{j=1}^l n_j (\bar{x}_j - \bar{x})^2$$

$$\text{En définitive : } V(x) = \frac{1}{n_{..}} \sum_{j=1}^l n_j (\bar{x}_j - \bar{x})^2 + \frac{1}{n_{..}} \sum_{j=1}^l V_{j(x)} n_j$$

45

- La variance marginale est égale à la moyenne des variances conditionnelles augmentée de la variance des moyennes conditionnelles.

$$V(y) = \frac{1}{n_{..}} \sum_{j=1}^l n_j (\bar{y}_j - \bar{y})^2 + \frac{1}{n_{..}} \sum_{j=1}^l V_j(y) \times n_j$$

- Autre notation :

$$V(y) = V(\bar{y}_j) + \overline{V_j(y)}$$

46

- La variance marginale est égale à la somme de la moyenne pondérée des variances conditionnelles et de la variance pondérée des moyennes conditionnelles.
- La dispersion de la distribution marginale résulte donc de deux facteurs :
  - - La dispersion de chacune des distributions conditionnelles autour de leur moyenne ;
  - - La dispersion des moyennes conditionnelles entre elles.
- Ainsi une partie de la variance totale de X (ou de Y) peut être expliquée par la variance des moyennes conditionnelles.
- La variance moyenne des hétérogénéités propres à chacune des distributions conditionnelles (Moyenne des variances conditionnelles) apparaît alors comme une variance résiduelle. C'est sur cette décomposition de la variance totale que sera fondée la définition du rapport de corrélation.

47

## Covariance

- La notion de covariance nous servira pour étudier la corrélation. On appelle covariance entre deux variables statistiques x et y [notée cov(x,y)] l'expression définie par :

$$\text{Cov}(x,y) = \frac{1}{n_{..}} \sum_i \sum_j n_{ij} (x_i - \bar{x})(y_j - \bar{y})$$

- On remarquera que si l'on pose y = x, on retrouve la formule de la variance.
- La covariance sert à vérifier l'existence de **lien de dépendance** ou pas entre deux variables. La covariance est nulle si les deux variables indépendantes. Cette grandeur interviendra dans l'étude de la liaison entre deux variables et, notamment, dans celle de la corrélation linéaire.

48

### Calcul pratique

- Pour simplifier le calcul de la covariance, on utilise des méthodes analogues à celles employées pour le calcul de la variance : formule développée et changement de variable.
- **Formule développée:**
- Il est possible de développer la formule de définition pour obtenir une expression mieux adaptée au calcul numérique :
 
$$Cov(x, y) = \frac{1}{n} \sum_i \sum_j n_{ij} (x_i - \bar{x})(y_j - \bar{y})$$

$$= \frac{1}{n} \sum_i \sum_j n_{ij} x_i y_j - \bar{y} \frac{1}{n} \sum_i \sum_j n_{ij} x_i - \bar{x} \frac{1}{n} \sum_i \sum_j n_{ij} y_j + \bar{x} \bar{y} \frac{1}{n} \sum_i \sum_j n_{ij}$$

- Or, par définition :

$$\sum_i \sum_j n_{ij} = 1$$

$$\sum_i \sum_j n_{ij} x_i = \sum_i x_i \sum_j n_{ij} = \sum_i n_i x_i = n \bar{x}$$

$$\sum_i \sum_j n_{ij} y_j = \sum_j y_j \sum_i n_{ij} = \sum_j n_j y_j = n \bar{y}$$

- D'où :

$$Cov(x, y) = \frac{1}{n} \sum_i \sum_j n_{ij} x_i y_j - \bar{x} \bar{y}$$

## Grille du calcul des caractéristiques des séries à deux dimensions

y(i) x(i)	y <sub>1</sub>	y <sub>2</sub>	y <sub>3</sub>	y <sub>4</sub>	(7) n <sub>i</sub>	(8) n <sub>i</sub> x <sub>i</sub>	(9) n <sub>i</sub> x <sub>i</sub> <sup>2</sup>	(10) Σ n <sub>ij</sub> y <sub>j</sub>	(11) Σ n <sub>ij</sub> y <sub>j</sub> <sup>2</sup>	(12) Σ n <sub>ij</sub> x <sub>i</sub> y <sub>j</sub>
x <sub>1</sub>	n <sub>11</sub>	n <sub>12</sub>	n <sub>13</sub>	n <sub>14</sub>	n <sub>1.</sub>	n <sub>1.</sub> x <sub>1</sub>	n <sub>1.</sub> x <sub>1</sub> <sup>2</sup>	Σ n <sub>1j</sub> y <sub>j</sub>	Σ n <sub>1j</sub> y <sub>j</sub> <sup>2</sup>	Σ n <sub>1j</sub> x <sub>1</sub> y <sub>j</sub>
x <sub>2</sub>	n <sub>21</sub>	n <sub>22</sub>	n <sub>23</sub>	n <sub>24</sub>	n <sub>2.</sub>	n <sub>2.</sub> x <sub>2</sub>	n <sub>2.</sub> x <sub>2</sub> <sup>2</sup>	Σ n <sub>2j</sub> y <sub>j</sub>	Σ n <sub>2j</sub> y <sub>j</sub> <sup>2</sup>	Σ n <sub>2j</sub> x <sub>2</sub> y <sub>j</sub>
x <sub>3</sub>	n <sub>31</sub>	n <sub>32</sub>	n <sub>33</sub>	n <sub>34</sub>	n <sub>3.</sub>	n <sub>3.</sub> x <sub>3</sub>	n <sub>3.</sub> x <sub>3</sub> <sup>2</sup>	Σ n <sub>3j</sub> y <sub>j</sub>	Σ n <sub>3j</sub> y <sub>j</sub> <sup>2</sup>	Σ n <sub>3j</sub> x <sub>3</sub> y <sub>j</sub>
x <sub>4</sub>	n <sub>41</sub>	n <sub>42</sub>	n <sub>43</sub>	n <sub>44</sub>	n <sub>4.</sub>	n <sub>4.</sub> x <sub>4</sub>	n <sub>4.</sub> x <sub>4</sub> <sup>2</sup>	Σ n <sub>4j</sub> y <sub>j</sub>	Σ n <sub>4j</sub> y <sub>j</sub> <sup>2</sup>	Σ n <sub>4j</sub> x <sub>4</sub> y <sub>j</sub>
x <sub>5</sub>	n <sub>51</sub>	n <sub>52</sub>	n <sub>53</sub>	n <sub>54</sub>	n <sub>5.</sub>	n <sub>5.</sub> x <sub>5</sub>	n <sub>5.</sub> x <sub>5</sub> <sup>2</sup>	Σ n <sub>5j</sub> y <sub>j</sub>	Σ n <sub>5j</sub> y <sub>j</sub> <sup>2</sup>	Σ n <sub>5j</sub> x <sub>5</sub> y <sub>j</sub>
(1) n <sub>j</sub>	n <sub>.1</sub>	n <sub>.2</sub>	n <sub>.3</sub>	n <sub>.4</sub>	n <sub>..</sub>	Σ =	Σ =			Σ Σ =
(2) n <sub>j</sub> y <sub>j</sub>	n <sub>.1</sub> y <sub>1</sub>	n <sub>.2</sub> y <sub>2</sub>	n <sub>.3</sub> y <sub>3</sub>	n <sub>.4</sub> y <sub>4</sub>	Σ n <sub>.j</sub> y <sub>j</sub>					
(3) n <sub>j</sub> y <sub>j</sub> <sup>2</sup>	n <sub>.1</sub> y <sub>1</sub> <sup>2</sup>	n <sub>.2</sub> y <sub>2</sub> <sup>2</sup>	n <sub>.3</sub> y <sub>3</sub> <sup>2</sup>	n <sub>.4</sub> y <sub>4</sub> <sup>2</sup>	Σ n <sub>.j</sub> y <sub>j</sub> <sup>2</sup>					
(4) Σ n <sub>ij</sub> x <sub>i</sub>	Σ n <sub>11</sub> x <sub>1</sub>	Σ n <sub>12</sub> x <sub>1</sub>	Σ n <sub>13</sub> x <sub>1</sub>	Σ n <sub>14</sub> x <sub>1</sub>						
(5) Σ n <sub>ij</sub> x <sub>i</sub> <sup>2</sup>	Σ n <sub>11</sub> x <sub>1</sub> <sup>2</sup>	Σ n <sub>12</sub> x <sub>1</sub> <sup>2</sup>	Σ n <sub>13</sub> x <sub>1</sub> <sup>2</sup>	Σ n <sub>14</sub> x <sub>1</sub> <sup>2</sup>						
(6) Σ n <sub>ij</sub> x <sub>i</sub> y <sub>j</sub>	Σ n <sub>11</sub> x <sub>1</sub> y <sub>1</sub>	Σ n <sub>12</sub> x <sub>1</sub> y <sub>2</sub>	Σ n <sub>13</sub> x <sub>1</sub> y <sub>3</sub>	Σ n <sub>14</sub> x <sub>1</sub> y <sub>4</sub>	Σ Σ =					

### Calcul pratique des caractéristiques marginales et conditionnelles

- Le principe de calcul consiste à ajouter des colonnes et des lignes, en bon ordre, au tableau de contingence.
- Les variables  $x_i$  et  $y_j$  seront représentées par leurs centres de classe, si elles sont continues.
- Pour le calcul de la moyenne marginale de x on doit calculer la colonne :  $n_i x_i$ , que l'on ajoutera à droite du tableau de contingence. Pour la moyenne marginale de y il nous faudra la ligne  $n_j y_j$ . On la rajoutera en bas du tableau de contingence.
- Pour les calculs des variances marginales (de x et de y) il nous faudra calculer respectivement la colonne  $n_i x_i^2$  et la ligne  $n_j y_j^2$ .
- Pour le calcul des moyennes et des variances conditionnelles de y il nous faudra ajouter les deux colonnes  $\sum n_{ij} y_j$  et  $\sum n_{ij} y_j^2$ . De même pour obtenir les moyennes et des variances conditionnelles de x, on ajoute les deux lignes  $\sum n_{ij} x_i$  et  $\sum n_{ij} x_i^2$

53

- Le calcul de la covariance dans cette présentation, nécessite le calcul des « nombres en coin » ; chaque « coin » des cases  $n_{ij}$  du tableau de contingence correspond au calcul des produits  $n_{ij} x_i y_j$  ; on somme des nombres en coins dans la dernière colonne ou la dernière ligne. Si l'on retranche de cette somme, divisée par  $n_{..}$ , le produit  $\bar{x} \bar{y}$ , on obtient la covariance.
- Les trois premières lignes (1,2,3) et colonnes (7,8,9) ajoutées au tableau de contingence servent pour le calcul des moyennes et des variances marginales, respectivement de x et de y.
- Les 2 lignes (4,5) et colonnes (10, 11) d'après servent au calcul des moyennes et des variances conditionnelles, respectivement de x et de y. La dernière ligne (6) et la dernière colonne (12) dans le tableau servent à calculer la covariance.
- Chaque case des 3 dernières lignes et colonnes correspond à la somme d'un produit. La 1ère case de la ligne 4 :
- $\sum n_{11} x_i = n_{11} x_1 + n_{21} x_2 + n_{31} x_3 + n_{41} x_4 + n_{51} x_5$
- La 1ère case de la colonne 11 :
- $\sum n_{1j} y_j^2 = n_{11} y_1^2 + n_{12} y_2^2 + n_{13} y_3^2 + n_{14} y_4^2$

54

**Exemple 1**

	2	4	6	$n_i$	$n_i x_i$	$n_i x_i^2$	$\sum n_{ij} y_j$	$\sum n_{ij} y_j^2$	$\sum n_{ij} x_i y_j$
2	0	8	12	2	4	8	$\sum n_{1j} y_j = 10$	$\sum n_{1j} y_j^2 = 20$	$\sum n_{1i} x_i y_j = 20$
4	16	48	0	5	20	80	$\sum n_{2j} y_j = 16$	$\sum n_{2j} y_j^2 = 56$	$\sum n_{2i} x_i y_j = 64$
6	12	24	36	3	18	108	$\sum n_{3j} y_j = 12$	$\sum n_{3j} y_j^2 = 56$	$\sum n_{3i} x_i y_j = 72$
$n_j$	3	5	2	$\Sigma = 10$	$\Sigma = 42$	$\Sigma = 196$			$\Sigma \Sigma = 156$
$n_j y_j$	6	20	12	$\Sigma = 38$					
$n_j y_j^2$	12	80	72	$\Sigma = 164$					
$\sum n_{ij} x_i$	$\sum n_{i1} x_i = 14$	$\sum n_{i2} x_i = 20$	$\sum n_{i3} x_i = 8$						
$\sum n_{ij} x_i^2$	$\sum n_{i1} x_i^2 = 68$	$\sum n_{i2} x_i^2 = 88$	$\sum n_{i3} x_i^2 = 40$						
$\sum n_{ij} x_i y_j$	$\sum n_{i1} x_i y_j = 28$	$\sum n_{i2} x_i y_j = 80$	$\sum n_{i3} x_i y_j = 48$	$\Sigma \Sigma =$					156

55

### Caractéristiques marginales

$$\bar{x} = \frac{1}{n_{..}} \sum_{i=1}^k n_{i.} x_i = \frac{42}{10} = 4,2$$

$$\bar{y} = \frac{1}{n_{..}} \sum_{j=1}^l n_{.j} y_j = \frac{38}{10} = 3,8$$

$$V(x) = \frac{1}{n_{..}} \sum_{i=1}^k n_{i.} x_i^2 - \bar{x}^2 = \frac{196}{10} - (4,2)^2 = 1,96$$

$$V(y) = \frac{1}{n_{..}} \sum_{j=1}^l n_{.j} y_j^2 - \bar{y}^2 = \frac{164}{10} - (3,8)^2 = 1,96$$

56

### Caractéristiques conditionnelles

$$\bar{x}_1 = \frac{1}{n_{.1}} \sum_{i=1}^3 n_{i1}x_i = \frac{14}{3} = 4,67 \quad \bar{y}_1 = \frac{1}{n_{.1}} \sum_{j=1}^3 n_{1j}y_j = \frac{10}{2} = 5$$

$$\bar{x}_2 = \frac{1}{n_{.2}} \sum_{i=1}^3 n_{i2}x_i = \frac{20}{5} = 4 \quad \bar{y}_2 = \frac{1}{n_{.2}} \sum_{j=1}^3 n_{2j}y_j = \frac{16}{5} = 3,2$$

$$\bar{x}_3 = \frac{1}{n_{.3}} \sum_{i=1}^3 n_{i3}x_i = \frac{8}{2} = 4 \quad \bar{y}_3 = \frac{1}{n_{.3}} \sum_{j=1}^3 n_{3j}y_j = \frac{12}{3} = 4$$

57

$$V_1(x) = \frac{1}{n_{.1}} \sum_{i=1}^3 n_{i1}x_i^2 - \bar{x}_1^2 = \frac{68}{3} - (4,66)^2 = 0,96$$

$$V_2(x) = \frac{1}{n_{.2}} \sum_{i=1}^3 n_{i2}x_i^2 - \bar{x}_2^2 = \frac{88}{5} - (4)^2 = 1,6$$

$$V_3(x) = \frac{1}{n_{.3}} \sum_{i=1}^3 n_{i3}x_i^2 - \bar{x}_3^2 = \frac{40}{2} - (4)^2 = 4$$

$$V_1(y) = \frac{1}{n_{.1}} \sum_{j=1}^3 n_{1j}y_j^2 - \bar{y}_1^2 = \frac{52}{2} - (5)^2 = 1$$

$$V_2(y) = \frac{1}{n_{.2}} \sum_{j=1}^3 n_{2j}y_j^2 - \bar{y}_2^2 = \frac{56}{5} - (3,2)^2 = 0,96$$

$$V_3(y) = \frac{1}{n_{.3}} \sum_{j=1}^3 n_{3j}y_j^2 - \bar{y}_3^2 = \frac{56}{3} - (4)^2 = 2,67$$

$$Cov(x,y) = \frac{1}{n_{.}} \sum_{i=1}^3 \sum_{j=1}^3 n_{ij}x_i y_j - \bar{x}\bar{y} = \left(\frac{1}{10} \cdot 156\right) - (4,2)(3,8) = -0,36$$

58

### Calcul de la covariance et changement de variable

- Un changement de variable judicieux appliqué à x et à y permettra souvent une simplification supplémentaire des calculs. Choisissons pour x et y de nouvelles origines  $x_0$  et  $y_0$  et de nouvelles unités de mesure  $\alpha$  et  $\beta$ , de façon à ce que les nouvelles variables  $x'$  et  $y'$  soient des nombres entiers plus simples que les valeurs originelles de x et y :

$$x'_i = \frac{x_i - x_0}{\alpha}, \quad y'_j = \frac{y_j - y_0}{\beta}$$

59

$$x_i = \alpha x'_i + x_0, \quad y_j = \beta y'_j + y_0$$

- En vertu des propriétés de la moyenne arithmétique, les mêmes relations existent entre les moyennes :
 
$$\bar{x} = \alpha \bar{x}' + x_0 ; \quad \bar{y} = \beta \bar{y}' + y_0$$
- Par soustraction :
 
$$x_i - \bar{x} = \alpha(x'_i - \bar{x}') ; \quad y_j - \bar{y} = \beta(y'_j - \bar{y}')$$
- Par conséquent :
 
$$Cov(x,y) = \frac{1}{n_{.}} \sum_i \sum_j n_{ij}(x_i - \bar{x})(y_j - \bar{y})$$

$$= \alpha\beta \frac{1}{n_{.}} \sum_i \sum_j n_{ij}(x'_i - \bar{x}')\beta(y'_j - \bar{y}')$$

$$= \alpha\beta Cov(x',y')$$

60

## Exemple 2

- Soit la distribution à deux caractères x et y suivante :

y	40	60	80
x			
50	0	1	1
60	2	3	0
70	1	1	1

- En se servant des résultats de l'exemple 1, montrez que la covariance de x et de y est égale à -18.
- On remarque que chaque valeur de x et de y peut s'écrire comme une combinaison linéaire des valeurs de x et de y dans l'exemple 1 :
  - $50 = (5 \times 2) + 40$        $40 = (10 \times 2) + 20$
  - $60 = (5 \times 4) + 40$        $60 = (10 \times 4) + 20$
  - $70 = (5 \times 6) + 40$        $80 = (10 \times 6) + 20$

61

- Par suite, les valeurs de x et de y dans l'exemple 1 ( $x_1, y_1$ ) constituent des changements de variables.
- Ainsi, on peut écrire :
  - $x_2 = \alpha x_1 + x_0 \Rightarrow x_1 = (x_2 - x_0)/\alpha$
  - $y_2 = \beta y_1 + y_0 \Rightarrow y_1 = (y_2 - y_0)/\beta$
- avec  $\alpha = 5$  et  $\beta = 10$
- $x_0 = 40$  et  $y_0 = 20$
- Par conséquent :
- $\text{Cov}(x_2, y_2) = \alpha\beta \text{Cov}(x_1, y_1) = 50 \cdot (-0,36) = -18.$

62