

Distribution conjointe

- 1 **Distribution d'une variable** [sur un échantillon] : on rappelle que la distribution d'une variable X [sur un échantillon] est la liste des modalités de la variable, chacune étant associée à son effectif ou à sa fréquence dans l'échantillon ; cette liste est généralement présentée sous la forme d'un tableau de contingence.

- 2 ^{déf} **Modalité conjointe.** Lorsqu'on mesure simultanément X et Y sur un individu e de l'échantillon, la mesure de X sur e notée x_e est une modalité m_i de X , de même que la mesure de Y sur e notée y_e est une modalité m'_j de Y : le résultat est le couple (x_e, y_e) égal au couple de modalités (m_i, m'_j) ; les différents couples de modalités, formés d'une modalité de X et d'une modalité de Y sont au nombre de $k \cdot p$, sont les **modalités conjointes** [de X et Y].

- 3 ^{déf} **Distribution conjointe de X et Y** : c'est la liste des $k \cdot p$ modalités conjointes (m_i, m'_j) associées chacune à son effectif n_{ij} ou à sa fréquence f_{ij} : dans le premier cas la distribution conjointe est dite en effectif, dans le second en proportion ou en pourcentage selon que f_{ij} désigne la proportion n_{ij}/n ou le pourcentage $100 * n_{ij}/n$.

Dans le tableau de contingence de la distribution conjointe, les modalités de X sont placées dans la première colonne (chaque ligne concerne une modalité de X), et celles de Y dans la première ligne (chaque colonne concerne une modalité de Y).

X/Y	m'_1	m'_2	...	m'_j	...	m'_p
m_1	n_{11} ou f_{11}	n_{12} ou f_{12}	...	n_{1j} ou f_{1j}	...	n_{1p} ou f_{1p}
m_2	n_{21} ou f_{21}	n_{22} ou f_{22}	...	n_{2j} ou f_{2j}	...	n_{2p} ou f_{2p}
...
m_i	n_{i1} ou f_{i1}	n_{i2} ou f_{i2}	...	n_{ij} ou f_{ij}	...	n_{ip} ou f_{ip}
...
m_k	n_{k1} ou f_{k1}	n_{k2} ou f_{k2}	...	n_{kj} ou f_{kj}	...	n_{kp} ou f_{kp}

Distribution conjointe de X et Y sous forme de tableau de contingence.

Voilà, par exemple, les distributions en effectif et en proportion de l'exemple 1, « niveau scolaire et absentéisme » :

X / Y	Rare	Moyen	Fréquent
A	7	4	4
B	8	2	2

X / Y	Rare	Moyen	Fréquent	Total X
A	$7/27=0,26$	0,15	0,15	0,56
B	0,3	0,07	0,07	0,44
Total Y	0,56	0,22	0,22	1

- 4 [☞] **Construction.** À partir des données brutes et du modèle statistique de la situation, on construit la distribution conjointe en effectif (respectivement en proportion) en associant à chaque modalité conjointe (m_i, m'_j) son effectif n_{ij} (resp. sa proportion $f_{ij} = n_{ij}/n$) ; n_{ij} s'obtient en comptant le nombre d'individus de l'échantillon ayant simultanément les modalités m_i et m'_j pour X et Y .

Exemple de la taille des pères et fils : on choisit arbitrairement comme modalités pour X et Y les 4 intervalles [62 ; 65[, [65 ; 68[, [68 ; 71[et [71 ; 74] ; on trouve 0 individu pour la modalité conjointe (m_1, m'_1) ($n_{11} = 0$), 3 individus (2, 4 et 6) pour la modalité (m_1, m'_2) ($n_{12} = 3$), etc. ; on obtient finalement la distribution conjointe :

X/Y	[62 - 65[[65 - 68[[68 - 71[[71 - 74]
[62 - 65[0	3	0	0
[65 - 68[0	2	1	1
[68 - 71[0	0	4	0
[71 - 74]	0	0	1	0

Distributions marginales

5 déf La **distribution marginale de X** (resp. de Y) est la distribution de X (resp. Y) sur l'échantillon, calculée à partir de la distribution conjointe. Le nom vient de ce qu'elles sont souvent présentées en marge du tableau de contingence, parallèlement à la liste des modalités.

6 déf L'**effectif marginal de la modalité m_i de X** est le nombre des individus de E dont la mesure par X est m_i ; ces individus sont ceux qui contribuent aux effectifs de la ième ligne du tableau de contingence en effectif, et leur nombre est la somme des p effectifs situés sur la ième ligne, $n_{i1}, n_{i2}, \dots, n_{ip}$; on le note $n_{i.}$: le point signifie qu'on effectue un parcours cumulatif, des colonnes quand il est placé en seconde place comme ici ou des lignes quand il est placé en première place (comme dans $n_{.3}$ par exemple) : dans $n_{i.}$ on se place sur la ligne i et on parcourt les colonnes en cumulant successivement le contenus des cellules $c_{i1}, c_{i2}, \dots, c_{ij}, \dots, c_{ip}$; ce qui se résume par la formule :

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

Dans une formule de cette nature, la lettre \sum indique un parcours cumulatif, n_{ij} les éléments visités, $j = 1, p$ la description du parcours : ici, on fait varier j de 1 à p pour passer par les p colonnes, et on ne fait pas varier i pour rester sur la ligne i .

7 déf La **fréquence marginale de la modalité m_i de X** est notée $f_{i.}$; elle est égale à la somme $n_{i.}$ de la ième ligne divisée par la taille de l'échantillon : $f_{i.} = n_{i.}/n$.

8 L'**effectif marginal de la modalité m'_j de Y** se calcule de manière duale, en pensant colonne à la place de ligne et réciproquement : $n_{.j}$ est la somme des k nombres situés sur la jème colonne, $n_{1j}, n_{2j}, \dots, n_{kj}$:

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

9 Le **tableau de contingence avec marges** permet de représenter simultanément la distribution conjointe et les deux distributions marginales :

X/Y	m'_1	m'_2	...	m'_j	...	m'_p	Marge X
m_1	n_{11} ou f_{11}	n_{12} ou f_{12}		n_{1j} ou f_{1j}		n_{1p} ou f_{1p}	$n_{1.}$ ou $f_{1.}$
m_2	n_{21} ou f_{21}	n_{22} ou f_{22}		n_{2j} ou f_{2j}		n_{2p} ou f_{2p}	$n_{2.}$ ou $f_{2.}$
...							
m_i	n_{i1} ou f_{i1}	n_{i2} ou f_{i2}		n_{ij} ou f_{ij}		n_{ip} ou f_{ip}	$n_{i.}$ ou $f_{i.}$
...							
m_k	n_{k1} ou f_{k1}	n_{k2} ou f_{k2}		n_{kj} ou f_{kj}		n_{kp} ou f_{kp}	$n_{k.}$ ou $f_{k.}$
Marge Y	$n_{.1}$ ou $f_{.1}$	$n_{.2}$ ou $f_{.2}$		$n_{.j}$ ou $f_{.j}$		$n_{.p}$ ou $f_{.p}$	$n_{..}$ ou $f_{..}$

Ce tableau doit être visuellement décomposé en cinq parties :

- Première colonne : modalités de X
- Dernière colonne : distribution [marginale] de X
- Première ligne : modalités de Y
- Dernière ligne : distribution [marginale] de Y
- L'intérieur : distribution conjointe de X et Y

Il faut remarquer que les sommes des trois distributions sont égales à la taille de l'échantillon.

- 10 Exemple : niveau scolaire et absentéisme.** X ayant deux modalités, A et B, construire la distribution marginale de X revient à calculer leur effectif $n_{1.}$ et $n_{2.}$; les élèves de niveau A se composent des élèves de niveau A étant peu absents (il y en a 7, n_{11}), des élèves de niveau A étant moyennement absents (il y en a 4, n_{12}) et des élèves de niveau A étant souvent absents (il y en a 4, n_{13}) : au total $n_{1.} = 15$; de la même façon on trouve $n_{2.} = 12$; naturellement, la somme de ces deux effectifs est égale à 27, la taille de l'échantillon.

X / Y	Rare	Moyen	Fréquent	Total X
A	7	4	4	15
B	8	2	2	12
Total Y	15	6	6	27

Le tableau de contingence en fréquence-proportion est :

X / Y	Rare	Moyen	Fréquent	Total X
A	$7/27=0,26$	0,15	0,15	0,56
B	0,3	0,07	0,07	0,44
Total Y	0,56	0,22	0,22	1

Questions de cours

1. Qu'appelle-t-on modalité conjointe ?
2. Définition d'une distribution conjointe ?
3. Définition d'une distribution marginale ?
4. Que désignent les notations x_1 y_3 k p n m_2 m'_3 c_{44} n_{12} f_{32} $n_{2.}$ $n_{.3}$ f_4 $f_{.1}$ $n_{..}$ dans le modèle d'une situation statistique ?
5. X et Y ont respectivement 4 et 5 modalités : combien y-a-t-il de modalités conjointes ? de distributions marginales ? d'effectifs marginaux ?
6. Quelle est la valeur de $f_{..}$ et $n_{..}$?

Questions sur le cours

1. À quoi est égal la somme des effectifs marginaux des modalités de X ? de Y ?
2. À partir du tableau suivant vérifier les formules suivantes :

X \ Y	m'_1	m'_2	m'_3	m'_4	m'_5
m_1	1	3	6	1	3
m_2	2	4	0	5	1
m_3	3	2	3	1	4
m_4	4	5	3	5	4
m_5	5	2	5	0	1
m_6	6	4	1	2	2

- a) $\sum_{i=1}^3 n_{i5} = 8$;
- b) $\sum_{i=1,3} n_{i4} = 7$;
- c) $\sum_{j=2}^4 n_{5j} = 7$;
- d) $\sum_{j=1,5} n_{4j} = n_{4.} = 21$;
- e) $\sum_{i=4,5} n_{i3}^2 = 34$;
- f) $\sum_{i=1,3} (n_{i5} - 2) = 2$;
- g) $\sum_{i=2,5} (n_{i2} + n_{i4}) = 22$;
- h) $\sum_{j=1,4} (n_{6j} - n_{1j}) = 2$;
- i) $\sum_{i=2,5} (n_{i(i-1)} - n_{4i}) = 0$;
- j) $\sum_{i=2,4; j=1,4} n_{ij} = 37$;
- k) $\sum_{i=4,6; j < 4} n_{ij} = 35$;
- l) $\sum_{i=3,6; j >= i} n_{ij} = 18$;