

Université Paul Valéry



Représentations statistiques

Administration Économique et Sociale

Mathématiques

XA100M

1. LE LANGAGE STATISTIQUE

1.1. Introduction.

Dans de nombreux domaines, on dispose d'une importante quantité de données que l'on souhaite étudier.

La statistique descriptive fournit des outils pour **décrire** toutes ces données.

Exemples :

- ☞ En démographie : nombre de naissances, de décès, d'immigrants, d'émigrants dans une ville...
- ☞ En météorologie : température, pression atmosphérique en de nombreux points de la planète.



Données statistiques : ensemble de mesures ou observations décrivant l'**état** ou l'**évolution** d'un phénomène.

La **statistique descriptive** est l'ensemble des outils mathématiques qui permettent de **décrire** ou **résumer** les données statistiques.

⚠ L'objet de la statistique descriptive n'est PAS de prédire l'évolution future d'un phénomène à partir de données actuelles.



Population : ensemble sur lequel on effectue les observations.

Échantillon : partie de la population sur laquelle on a effectivement fait les mesures (trop souvent inconnu).

Individu : élément de la population.

 Malgré la terminologie, les individus ne sont pas nécessairement des personnes et la population n'est pas nécessairement un ensemble d'êtres humains.

Variable ou **caractère** : ce qui est observé sur la population

Modalités : valeurs observables (valeurs pouvant être prises par la variable).

Exemple 1

On étudie la récolte de blé de chaque pays.

- Population : ensemble des pays ;
- Individus : chaque pays ;
- Variable : quantité de blé récoltée dans chaque pays en tonnes ;
- Modalités : les nombres positifs.

Exemple 2

On veut quantifier la famine.

- Population : tous les êtres humains ;
- Individus : chaque être humain ;
- Variable : quantité de nourriture à laquelle chacun a accès en kilogrammes ;
- Modalités : les nombres positifs.

1.2. Nature des variables.

1.2.1. *Trois exemples.*

1^{re} étude

- Population : les exploitations agricoles de l'Hérault ;
- Individus : chaque exploitation agricole de l'Hérault ;
- Variable : surface cultivée en hectares ;
- Modalités : les nombres positifs.

Les modalités sont des **nombres** sur lesquels faire des calculs a un sens.



2^e étude

- Population : les exploitations agricoles de l'Hérault ;
- Individus : chaque exploitation agricole de l'Hérault ;
- Variable : culture dominante ;
- Modalités : blé, orge, vigne.

Les modalités sont des **mots**.

◀
▶

3^e **étude** : on dit qu'une exploitation est de **type 1** si elle peut accueillir des touristes en chambres d'hôtes, de **type 2** sinon.

- Population : les exploitations agricoles de l'Hérault ;
- Individus : chaque exploitation agricole de l'Hérault ;
- Variable : type ;
- Modalités : 1 ou 2.

Les modalités sont des **nombres** sur lesquels faire des calculs n'a aucun sens (qu'est-ce qu'une exploitation de type 1+2 ?)



1.2.2. *Variables quantitatives.*

Variable quantitative : variable dont les modalités sont des nombres sur lesquels faire des calculs a un sens.

La variable « surface de terre cultivée » de la 1^{re} étude (§1.2.1) est quantitative.

La variable « type » de la 3^e étude (§1.2.1) n'est pas quantitative.

1.2.3. *Variables qualitatives.*

Variable qualitative : variable dont les modalités sont des mots ou des nombres sur lesquels faire des calculs n'a pas de sens (et qui pourraient être remplacés par des mots).

La variable « culture dominante » de la 2^e étude (§1.2.1) est qualitative.

La variable « type » de la 3^e étude (§1.2.1) est qualitative. Au lieu de dire de « type 1 » et de « type 2 », on pourrait dire de « type touristique » et de « type non touristique ».

1.2.4. *Continuité d'une variable quantitative.*

Lorsqu'une variable est quantitative, elle est soit **continue** soit **discrète**.

Variable continue : c'est une variable dont les modalités sont des intervalles.

Variable discrète : c'est une variable qui n'est pas continue.

Variable continue : exemple

La variable « âge » est continue. On peut imaginer donner l'âge avec une précision aussi grande que voulue.

Dire de quelqu'un qu'il a 19 ans, c'est dire qu'il est né depuis plus de 19 ans et moins de 20 ans. La modalité correspondante est l'intervalle $[19, 20[$.


Dire qu'une personne est dans la classe des 15 – 20 ans, c'est dire qu'elle est née depuis plus de 15 ans et moins de 21 ans. La modalité correspondante est l'intervalle $[15, 21[$.



Variable discrète : exemple

La variable « nombre d'enfants d'une famille » est discrète.

Cela n'a aucun sens de parler de 3,5 enfants.



1.2.5. *Variables ordinales.*

Une variable qualitative ou quantitative est **ordinaire** si on peut **classer** les modalités dans un certain ordre.

Une variable qui n'est pas ordinaire est **nominale**.

Exemple de variable qualitative ordinale

- Population : les enseignant-chercheurs de l'Université Paul-Valéry ;
- Individus : chaque enseignant-chercheur ;
- Variable : grade ;
- Modalités : maître de conférences *MCF* , professeur *PR*.

On peut classer les modalités par ordre hiérarchique :

$$PR > MCF.$$

1.3. Description d'une situation statistique.

Avant toute étude statistique, on précise

- ☞ La population
- ☞ L'échantillon (lorsqu'il est connu) ;
- ☞ La variable observée
 - ☞ Les modalités ;
 - ☞ Quantitative ☞ Discrète
ou qualitative ; ou continue ;
 - ☞ Ordinale
ou nominale ;

2. REPRÉSENTATIONS DES DONNÉES STATISTIQUES

2.1. Représentation en tableau.

On étudie un caractère de modalités m_1, m_2, \dots, m_p .

À la modalité m_1 est associée l'effectif n_1 ,

à la modalité m_2 est associée l'effectif n_2 etc.

Modalités	Effectifs
m_1	n_1
m_2	n_2
\vdots	\vdots
m_p	n_p

Modalités	m_1	m_2	\dots	m_p
Effectifs	n_1	n_2	\dots	n_p

Si n est l'effectif total de l'échantillon,

$$\begin{aligned}n &= \sum_{i=1}^p n_i \\ &= n_1 + n_2 + \dots + n_p.\end{aligned}$$

Lorsque la variable est ordinale, on classe toujours les modalités de la plus petite à la plus grande :

$$m_1 < m_2 < \dots < m_p.$$

Modalités	Effectifs
m_1	n_1
m_2	n_2
\vdots	\vdots
m_p	n_p

Modalités	m_1	m_2	\dots	m_p
Effectifs	n_1	n_2	\dots	n_p

❖ C'est suivant les **modalités** qu'on ordonne, PAS selon les effectifs.

2.2. Représentations graphiques.

2.2.1. *Variable qualitative.*

Dans ce cas, on utilise souvent un **diagramme en secteur**.

Dans ce diagramme, chaque modalité est représentée par un secteur circulaire d'un disque dont la **surface** est proportionnelle à l'effectif.

Modalités	m_1	m_2	\cdots	m_p
Effectifs	n_1	n_2	\cdots	n_p
Surfaces	S_1	S_2	\cdots	S_p

Il existe un nombre $c > 0$ tel que

$$S_1 = cn_1, \quad S_2 = cn_2, \cdots, S_p = cn_p.$$

 C'est le même nombre c pour S_1, S_2, \dots, S_p .

La surface totale du disque est

$$S_1 + S_2 + \cdots + S_p = c(n_1 + n_2 + \cdots + n_p) = cn.$$

Si R est le rayon du disque, sa surface est πR^2 . On a donc $cn = \pi R^2$ puis

$$c = \frac{\pi R^2}{n}.$$

Pour la modalité m_i , on a donc

$$S_i = cn_i = \pi R^2 \frac{n_i}{n}.$$

Si α_i est l'angle associé au secteur S_i , on a

$$S_i = \pi R^2 \frac{\alpha_i}{2\pi}$$

donc


$$\pi R^2 \frac{n_i}{n} = \pi R^2 \frac{\alpha_i}{2\pi}$$

et

$$\alpha_i = 2\pi \frac{n_i}{n} \text{ radians} = 360 \frac{n_i}{n} \text{ degrés.}$$

➡ Dans un diagramme en secteurs, une modalité d'effectif n_i est représentée par un secteur d'angle

$$360 \frac{n_i}{n} \text{ degrés.}$$



Exemple

Situation matrimoniale d'un échantillon de 1000 personnes.

Modalités	Mariée	Veuve	Célibataire	Divorcée
Effectifs	400	100	200	300

L'effectif total est

$$n = 400 + 100 + 200 + 300 = 1000.$$

La modalité « mariée » est représentée par un angle (en degrés) de

$$\alpha_{\text{mariée}} = 360 \frac{n_{\text{mariée}}}{n} = 360 \frac{400}{1000} = 144.$$

La modalité « veuve » est représentée par un angle (en degrés) de

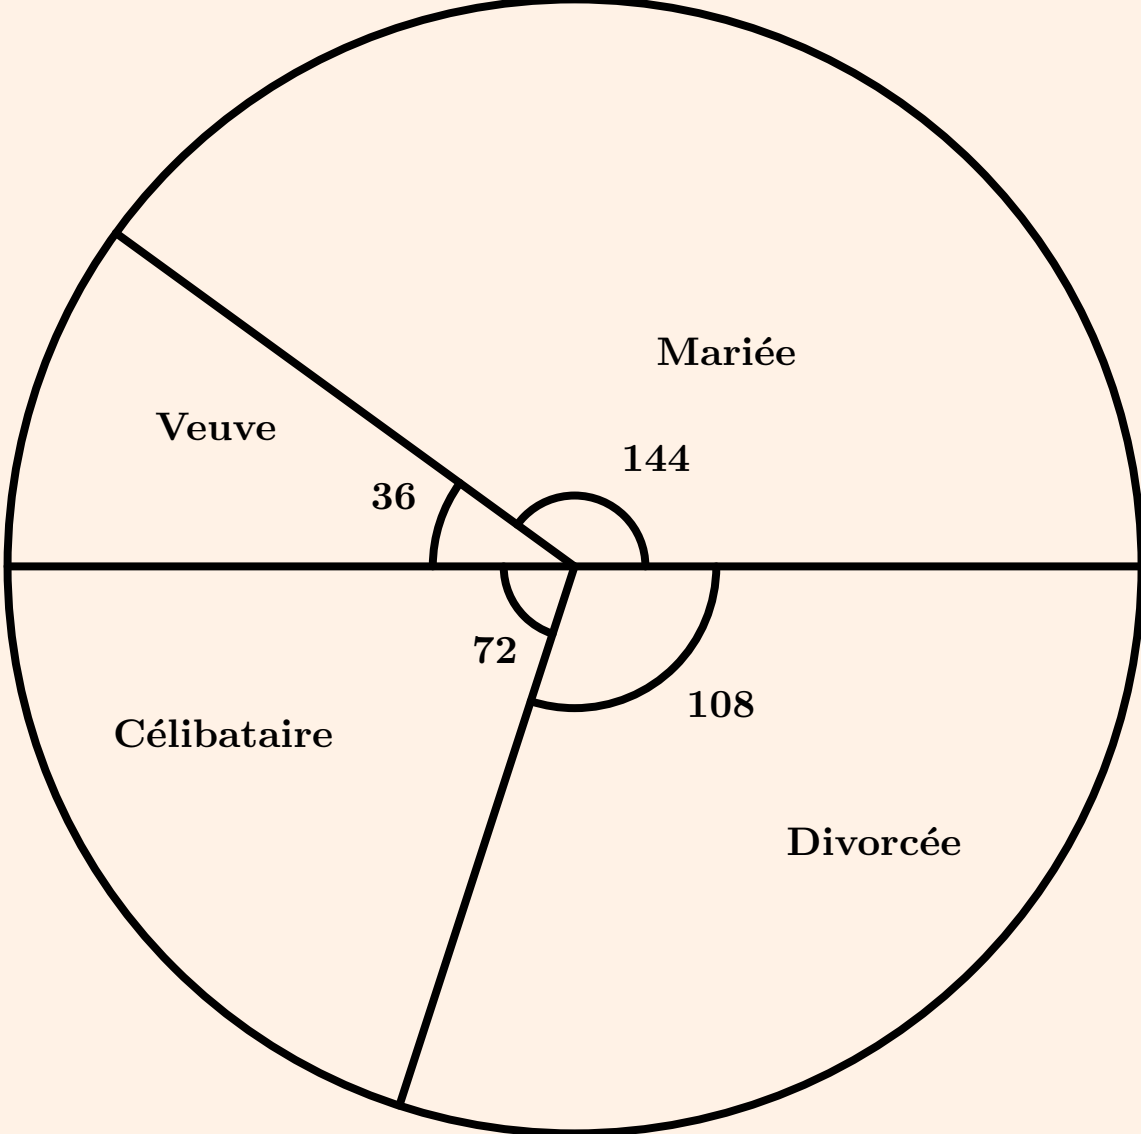
$$\alpha_{\text{veuve}} = 360 \frac{n_{\text{veuve}}}{n} = 360 \frac{100}{1000} = 36.$$

La modalité « célibataire » est représentée par un angle (en degrés) de

$$\alpha_{\text{célibataire}} = 360 \frac{n_{\text{célibataire}}}{n} = 360 \frac{200}{1000} = 72.$$

La modalité « divorcée » est représentée par un angle (en degrés) de

$$\alpha_{\text{divorcée}} = 360 \frac{n_{\text{divorcée}}}{n} = 360 \frac{300}{1000} = 108.$$



On peut aussi utiliser un **diagramme en bâtons**.

Dans ce diagramme, chaque modalité est représentée par un trait de **hauteur** proportionnelle à l'effectif.

Modalités	m_1	m_2	\cdots	m_p
Effectifs	n_1	n_2	\cdots	n_p
Hauteurs	h_1	h_2	\cdots	h_p

Il existe un nombre $K > 0$ tel que

$$h_1 = Kn_1, \quad h_2 = Kn_2, \cdots, h_p = Kn_p.$$

 C'est le même nombre K pour h_1, h_2, \dots, h_p .

Exemple

Situation matrimoniale d'un échantillon de 1000 personnes.

Modalités	Mariée	Veuve	Célibataire	Divorcée
Effectifs	400	100	200	300

On choisit

$$K = \frac{2}{100} \text{ cm.}$$

La modalité « mariée » est représentée par un trait de hauteur (en cm) de

$$h_{\text{mariée}} = \frac{2}{100} n_{\text{mariée}} = \frac{2}{100} \times 400 = 8.$$

La modalité « veuve » est représentée par un trait de hauteur (en cm) de

$$h_{\text{veuve}} = \frac{2}{100} n_{\text{veuve}} = \frac{2}{100} \times 100 = 2.$$

La modalité « célibataire » est représentée par un trait de hauteur (en cm) de

$$h_{\text{célibataire}} = \frac{2}{100} n_{\text{célibataire}} = \frac{2}{100} \times 200 = 4.$$

La modalité « divorcée » est représentée par un trait de hauteur (en cm) de

$$h_{\text{divorcée}} = \frac{2}{100} n_{\text{divorcée}} = \frac{2}{100} \times 300 = 6.$$



Effectifs

400
300
200
100

Mariée

Veuve

Célibataire

Divorcée


8 cm

2 cm

4 cm

6 cm

P
Q



2.2.2. *Variable quantitative.*

Les modalités sont des nombres, les représentations doivent en tenir compte.

Lorsque la variable discrète on utilise un diagramme en bâtons.

La hauteur des bâtons est calculée comme au §2.2.1

La **distance** des bâtons à l'origine est proportionnelle à la modalité qu'ils représentent : si les modalités sont

$$m_1 < m_2 < \dots < m_p$$

il existe $C > 0$ tel que les distances des bâtons à l'origine sont

$$\ell_1 = C m_1 \quad \ell_2 = C m_2 \quad \dots \quad \ell_p = C m_p.$$



C'est le même nombre C pour $\ell_1, \ell_2, \dots, \ell_p$.

Exemple

Nombre d'enfants par famille dans un échantillon de 17 familles.

Modalités	0	1	2	3
Effectifs	6	4	5	2


Pour la distance des bâtons à l'origine on choisit

$$C = 2 \text{ cm.}$$

Le bâton associé à la modalité « 0 enfant » est à distance (en cm)

$$\ell_0 = 0 \times 2 = 0$$

de l'origine.



Le bâton associé à la modalité « 1 enfant » est à distance (en cm)

$$\ell_1 = 1 \times 2 = 2$$

de l'origine.

De même $\ell_2 = 4$ cm et $\ell_3 = 6$ cm.




Pour la hauteur, on choisit $K = 1$ cm.

Le bâton associé à la modalité « 0 enfant » est de hauteur $h_0 = 6$ cm.

De même $h_1 = 4$ cm, $h_2 = 5$ cm et $h_3 = 2$ cm.

Effectifs



P

Q

◀
▶

Lorsque la variable continue on utilise un histogramme.

Les modalités sont des intervalles

$$m_1 = [a_1, a_2[, m_2 = [a_2, a_3[, \dots, m_p = [a_p, a_{p+1}[,$$

L'amplitude de m_1 est $a_2 - a_1$, l'amplitude de m_2 est $a_3 - a_2$ etc.

À chaque modalité $[a_i, a_{i+1}[$ correspond un rectangle.

Les **largeurs** des rectangles sont proportionnelles aux **amplitudes** des modalités correspondantes.

Les **surfaces** des rectangles sont proportionnelles aux **effectifs** des modalités correspondantes.

Modalités	$[a_1, a_2[$	$[a_2, a_3[$	\cdots	$[a_p, a_{p+1}[$
Effectifs	n_1	n_2	\cdots	n_p

À chaque modalité $[a_i, a_{i+1}[$, on associe un rectangle de hauteur h_i et de largeur ℓ_i . Sa surface est donc $S_i = h_i \ell_i$.

Il existe un nombre $C > 0$ tel que

$$\ell_1 = C(a_2 - a_1), \ell_2 = C(a_3 - a_2), \dots, \ell_p = C(a_{p+1} - a_p).$$

Il existe un nombre $K > 0$ tel que

$$S_1 = K n_1, S_2 = K n_2, \dots, S_p = K n_p.$$

◀ Pour tracer un rectangle, il faut connaître sa hauteur et sa largeur : ▶

$$S_i = K n_i$$

donc

$$h_i \ell_i = K n_i$$

donc

$$h_i = \frac{K n_i}{\ell_i}.$$

Or,

$$\ell_i = C(a_{i+1} - a_i)$$

donc

$$h_i = D \frac{n_i}{a_{i+1} - a_i}$$

avec

$$D = \frac{K}{C}.$$

Modalités	$[a_1, a_2[$	$[a_2, a_3[$	\cdots	$[a_p, a_{p+1}[$
Effectifs	n_1	n_2	\cdots	n_p

☞ Pour tracer un histogramme correspondant à la situation ci-dessus,

- on choisit des nombres $C > 0$ et $D > 0$
- à chaque modalité $[a_i, a_{i+1}[$, on associe un rectangle
 - de largeur $C(a_{i+1} - a_i)$
 - de hauteur $D \frac{n_i}{a_{i+1} - a_i}$.

Exemple

Âges d'un échantillon de 1000 personnes.

Modalités	0 à 9 ans	10 ans à 19 ans	20 ans à 49 ans	50 ans à 69 ans
Effectifs	100	500	300	100

$$m_1 = [0, 10[$$

$$a_1 = 0$$

$$a_2 = 10$$

$$n_1 = 100$$

$$m_2 = [10, 20[$$

$$a_2 = 10$$

$$a_3 = 20$$

$$n_2 = 500$$

$$m_3 = [20, 50[$$

$$a_3 = 20$$

$$a_4 = 50$$

$$n_3 = 300$$

$$m_4 = [50, 70[$$

$$a_4 = 50$$


$$a_5 = 70$$

$$n_4 = 100.$$

On choisit

$$C = 0,1 \text{ cm} \quad D = 0,2 \text{ cm.}$$

Modalités	$[0, 10[$	$[10, 20[$	$[20, 50[$	$[50, 70[$
Effectifs	100	500	300	100
Largeurs (cm)	$(10 - 0) \times 0,1$ $= 1$	$(20 - 10) \times 0,1$ $= 1$	$(50 - 20) \times 0,1$ $= 3$	$(70 - 50) \times 0,1$ $= 2$
Hauteurs (cm)	$\frac{100}{10 - 0} \times 0,2$ $= 2$	$\frac{500}{20 - 10} \times 0,2$ $= 10$	$\frac{300}{50 - 20} \times 0,2$ $= 2$	$\frac{100}{70 - 50} \times 0,2$ $= 1$



P

Q