

Faculté des sciences économique, commerciales, et sciences de gestion

Master 2 économie et gestion d'entreprise

Cours 02: Analyse univarié

DR BOUYACOU BRAHIM

**MAITRE DE CONFÉRENCES / DOCTEUR EN ÉCONOMIE
MONÉTAIRE ET FINANCIÈRE**

Les tests hypothèses statistiques (tests d'inférence)

Les tests d'hypothèses, ou tests d'inférence, ont pour objectif de mesurer l'effet d'une variable indépendante sur une variable dépendante, en fonction du nombre d'échantillons et en fonction de la nature des variables étudiées.

Tests paramétriques

C'est l'ensemble des tests qui repose sur des familles de lois de probabilités pour lequel on fait deux hypothèses paramétrique H_0 et H_1 .

- T test apparié
- T test à échantillons indépendants
- Corrélacion/ analyse de régression
- Khi 2
- ANOVA à 1 facteur
- Analyse multivariée

Tests non- paramétriques

Un test statistique utilisé dans le cas de variables indépendantes non métriques.

- TEST WILCOXON
- TEST MANN-WHITNEY
- LE TEST DE MCNEMAR
- LE KRUSKAL-WALLIS

Description de la variable qualitative

La description d'une variable qualitative consiste à présenter les effectifs, c'est-à-dire le nombre d'individus de l'échantillon pour chaque modalité de la variable, et les fréquences, c'est-à-dire le nombre de réponses associées aux modalités de la variable étudiée.

Description de la variable quantitative

Plusieurs critères permettent de décrire une variable quantitative :

- ❑ les mesures de la tendance centrale : moyenne, médiane, mode.
- ❑ les mesures de la dispersion : étendue, variance, écart type, coefficient de variation.
- ❑ les représentations graphiques : histogrammes, diagramme en bâton.

Tableau statistique

Pour créer un tableau statistique il faut déterminer :

- 1) Effectif total n : le nombre de toutes les valeurs prises par la variable.
- 2) Effectif n_i : nombre d'apparitions de la valeur x_i dans la population ou dans l'échantillon.

$$\sum_{i=1}^J n_i = n_1 + n_2 + \dots + n_J = n.$$

Fréquence f_i associée à la valeur x_i

$$\begin{cases} f_i = \frac{n_i}{n}, \\ \sum_{i=1}^J f_i = f_1 + f_2 + \dots + f_J = 1. \end{cases}$$

Pourcentage p_i associée à la valeur x_i

$$\begin{cases} p_i = 100 \times f_i \%, \\ \sum_{i=1}^J p_i = p_1 + p_2 + \dots + p_J = 100 \%. \end{cases}$$

Effectif cumulé N_i

$$\left\{ \begin{array}{l} N_1 = n_1, \\ N_2 = n_1 + n_2, \\ N_3 = n_1 + n_2 + n_3, \\ \dots\dots\dots \\ N_J = n_1 + n_2 + \dots + n_J = n. \end{array} \right.$$

Fréquence cumulé F_i

$$\left\{ \begin{array}{l} F_1 = f_1, \\ F_2 = f_1 + f_2, \\ F_3 = f_1 + f_2 + f_3, \\ \dots\dots\dots \\ F_J = f_1 + f_2 + \dots + f_J = 1. \end{array} \right.$$

Exemple 1 : Variable qualitative nominale

On note C : célibataire, M : marié, V : veuf, D : divorcé. On s'intéresse à la variable $X =$ (état-civil) sur une population de $n = 20$ personnes.

Considérons la série statistique Suivante :

MDMCCMCCCMVMVDCCMC

Tableau statistique :

x_i	n_i	f_i	$p_i\%$	N_i	F_i
C	9	0.45	45	9	0.45
M	7	0.35	35	16	0.75
V	2	0.10	10	18	0.85
D	2	0.10	10	20	1

Par exemple : le nombre d'apparition de la valeur $x_2 = M$ dans la série statistique est $n_2 = 7$, sa fréquence est $f_2 = n_2/n = 7/20 = 0,35$, son pourcentage $p_2 = 100 * f_2 = 100 * 0,35 = 35 \%$, l'effectif cumulé $N_2 = n_1 + n_2 = 9 + 7 = 16$ et la fréquence cumulée $F_2 = f_1 + f_2 = 0,45 + 0,35 = 0,75$.

Exemple 2 : Variable qualitative ordinale

On interroge une population de $n = 50$ personnes sur leur dernier diplôme obtenu. On note : Sd : Sans diplôme, P : Primaire, Se : Secondaire, Su : Supérieur non-universitaire et U Universitaire.

Sd Sd Sd Sd P P P P P P P P P P Se Se Su
Se Se Se Se Se Se Se Se Se Se Se Se Su Su Su
Su Su Su Su U U U U U U U U U U U Su

Tableau statistique

x_i	n_i	N_i	f_i	p_i	F_i
Sd	4	4	0.08	8	0.08
P	11	15	0.22	22	0.30
Se	14	29	0.28	28	0.58
Su	9	38	0.18	18	0.76
U	12	50	0.24	24	1

Exemple 3 : Variable quantitative discrète

Un quartier est composé d'une population de 50 ménages, et la variable X représente le nombre de personnes par ménage. Les valeurs de la variable sont :

1	1	1	1	1	2	2	2	2	2
2	2	2	2	3	3	3	3	3	3
3	3	3	3	3	3	3	3	3	4
4	4	4	4	4	4	4	4	4	5
5	5	5	5	5	6	6	6	8	8

Tableau statistique

x_i	n_i	N_i	f_i	F_i
1	5	5	0.10	0.10
2	9	14	0.18	0.28
3	15	29	0.30	0.58
4	10	39	0.20	0.78
5	6	45	0.12	0.90
6	3	48	0.06	0.96
8	2	50	0.04	1

Les mesures de tendance :

Les mesures de tendance centrale permettent de résumer un ensemble de données relatives à une variable quantitative. Elles permettent de déterminer une valeur «typique» ou centrale autour de laquelle des données ont tendance à se rassembler.



La moyenne


Le mode

La médiane

Les indicateurs de tendance centrale sont :

La moyenne : Somme des valeurs de toutes les observations divisée par l'effectif.

$$\bar{X} = \frac{X_1 + X_2 + \dots + X_N}{N} = \frac{\sum_{n=1}^N X_n}{N}$$



La médiane : la valeur centrale d'une série statistique dont les valeurs observées ont été rangées dans l'ordre croissant, est la valeur qui partage la population étudiée en deux sous-ensembles de même effectif.

Pour calculer la médiane :

- ❑ On classe les valeurs de la série statistique dans l'ordre croissant :
- ❑ Si le nombre de valeurs est impair, la médiane est la valeur du milieu.
- ❑ S'il est pair, la médiane est la demi-somme des deux valeurs du milieu.

Exemple 1

Déterminer la médiane de la série :

1, 4, 2, 5, 0

Premièrement, on classe les valeurs de la série statistique dans l'ordre croissant :

0, 1, 2, 4, 5

Il y a un nombre impair de valeurs, la médiane est donc la valeur du milieu.

0, 1, 2, 4, 5

La médiane est 2.

Exemple 2

Déterminer la médiane de la série :

10, 40, 20, 50

Premièrement, on classe les valeurs de la série statistique dans l'ordre croissant :

10, 20, 40, 50


Il y a un nombre pair de valeurs, on a donc 2 valeurs centrales. La médiane est alors la moyenne de ces deux valeurs.

10, 20, 40, 50

médiane = $20 + 40 / 2 = 60 / 2 = 30$

Médiane = 30

La médiane est 30.

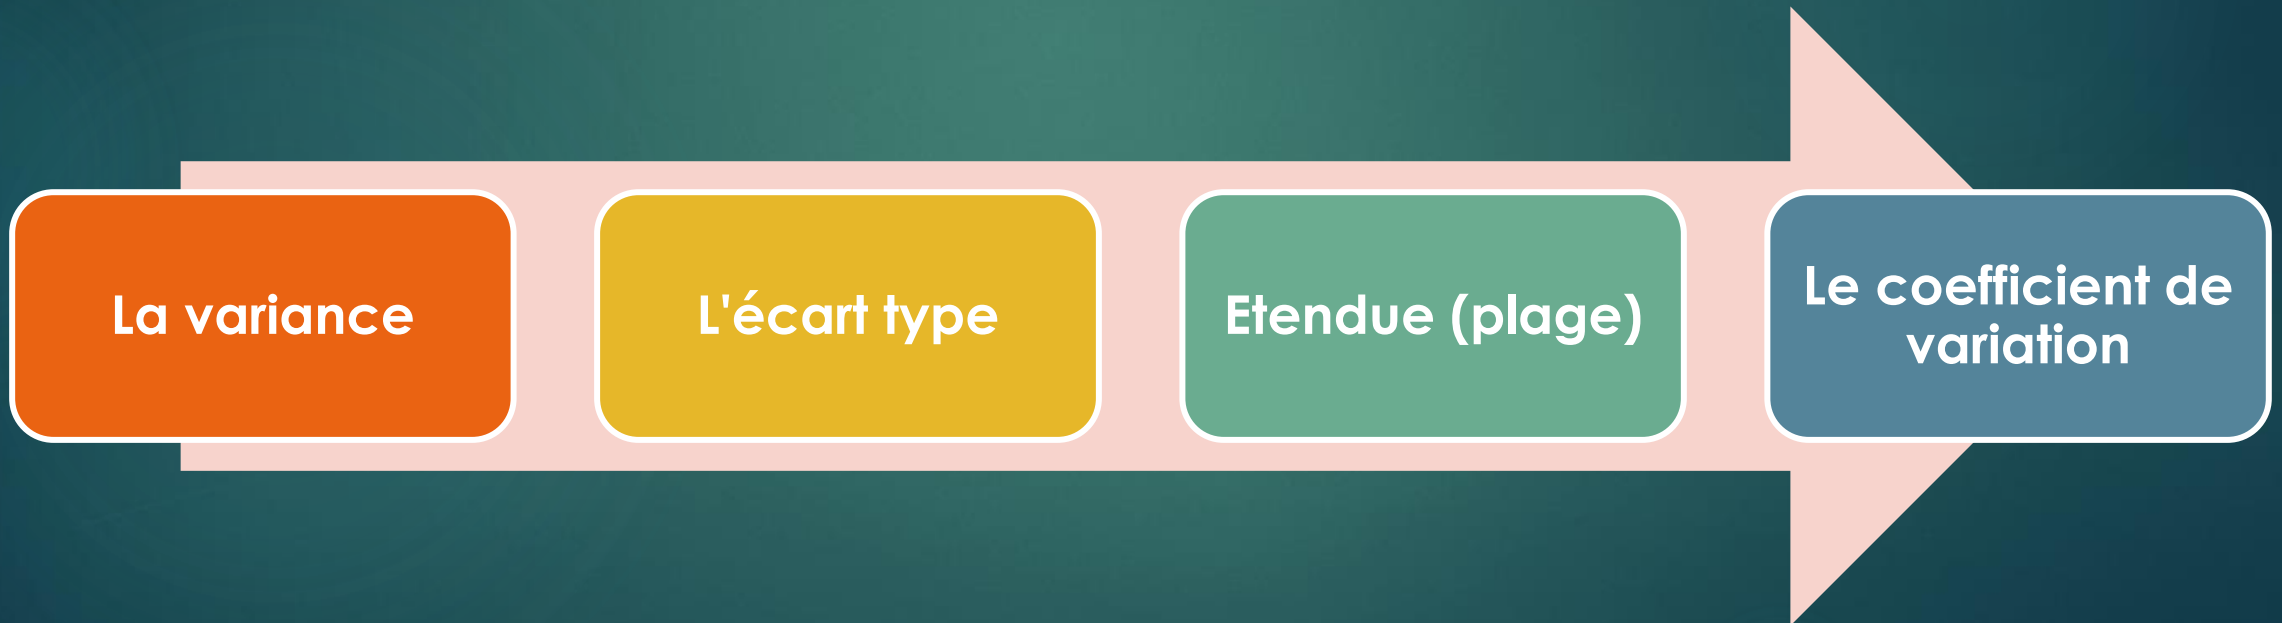


Le mode : Le mode représente la valeur présentant la plus grande fréquence d'occurrence. Il est défini comme la valeur la plus fréquente dans la série d'observation. (Cette valeur n'est pas nécessairement unique).

Les mesures de dispersion :

Comme le nom l'indique, les indicateurs de dispersions permettent de mesurer comment les données se «répartissent».

Les indicateurs de dispersions sont :



La variance :

La variance est la mesure de la dispersion autour de la moyenne, égale à la somme des carrés des écarts par rapport à la moyenne, divisée par le nombre d'observations moins un.

$$\sigma^2 = \frac{1}{N} \sum_{n=1}^N (X_n - \bar{X})^2$$

L'écart type :

L'écart type est la mesure de la dispersion autour de la moyenne, exprimée dans la même unité que la variable. Il est défini comme la racine carrée de la variance.

$$\sigma = \sqrt{\sigma^2} = \sqrt{\frac{1}{N} \sum_{n=1}^N (X_n - \bar{X})^2}$$

L'étendue :

L'étendu d'une série statistique est l'écart entre sa plus grande valeur et sa plus petite. En d'autre terme, l'étendu c'est la différence entre la valeur la plus élevé et la valeur la plus bas.

$$e = \max X - \min X$$

Le coefficient de variation :

Le coefficient de variation est le rapport de l'écart type à la moyenne, exprimé en pourcentage. Son objet est de mesurer le degré de variation de la moyenne d'un échantillon à l'autre, lorsque ceux-ci sont issus de la même distribution.

$$CV = \frac{\text{l'écart type}}{\text{la moyenne}} * 100$$