


الجمهورية الجزائرية الديمقراطية الشعبية

République Algérienne Démocratique et Populaire

وزارة التعليم العالي والبحث العلمي

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

Université Ferhat Abbas / Sétif 1
Faculté des Sciences
Économiques, Commerciales et
de Gestion
Département d'enseignement
fondamental



جامعة فرحات عباس سطيف 1
كلية العلوم الاقتصادية، التسيير والتجارة
قسم التعليم الاساسي

STATISTIQUES 1

Polycopié pédagogique

Présenté par :

BOURIOUNE Tahar

Maitre de Conférences B

Année universitaire : 2023-2024

Table des matières

Introduction Générale.....	
CH1. STATISTIQUE UNIVARIEE.....	5
1.1 TABLEAU STATISTIQUE & REPRESENTATION GRAPHIQUE	6
1.1.1 Tableau statistique (TS)	6
1.1.2 Représentation graphique (RG).....	6
1.1.2.1 Caractère qualitatif	6
1.1.2.2 Caractère quantitatif.....	9
1.2 PARAMETRES CARACTERISTIQUES	13
1.2.1 PARAMETRES DE POSITION	14
1.2.1.1 Mode (M_0).....	14
1.2.1.2 Médiane (Me).....	19
1.2.1.3 Moyenne (\bar{X}).....	24
1.2.2 PARAMETRES DE DISPERSION	33
1.2.2.1 Etendue.....	33
1.2.2.2 Quartiles	35
1.2.2.3 Intervalle interquartile.....	38
1.2.2.4 Déciles et percentiles.....	39
1.2.2.5 Ecart absolu moyen	44
1.2.2.6 Variance et écart-type	46
1.2.2.7 Coefficient de variation.....	49
1.2.2.8 Moments	50
1.2.3 PARAMETRES DE CONCENTRATION	53
1.2.3.1 Courbe de Lorenz	53
1.2.3.2 Indice de Gini.....	53
1.2.3.3 Médiale	53
1.2.4 PARAMETRES DE FORME	57
1.2.4.1 Coefficient d'asymétrie (skewness)	57
1.2.4.2 Coefficient d'aplatissement (kurtosis)	58
CH2. STATISTIQUE BIVARIEE	62
2.1 Distribution conjointe	62
2.2 Distributions marginales.....	64
2.3 Distributions conditionnelles	66
2.4 Indépendance	68
2.5 Représentation graphique.....	69
2.6 Covariance, corrélation et régression	78

CH3.	STATISTIQUE MULTIVARIEE.....	84
3.1	ACP.....	84
3.1.1	Formalisation	84
3.1.2	Exemple	87
3.2	Régression Logistique	90
3.2.1	Formalisation	90
3.2.2	Exemple	92
CH4.	LES INDICES	98
4.1	Indices simples	98
4.1.1	Propriétés	98
4.1.2	<i>Opérations sur les indices</i>	100
4.2	Indices synthétiques	101
4.2.1	<i>Indices arithmétiques</i>	101
4.2.2	<i>Indices géométriques</i>	103
4.2.3	<i>Indices synthétiques Laspeyers, Paashe et Fisher</i>	105

Liste des tableaux

Tableau 1	TF d'un caractère qualitatif.....	6
Tableau 2	TF d'une vs discrète.....	6
Tableau 3	TF d'une vs continue	6
Tableau 4	EX.1 caractère qualitatif	7
Tableau 5	EX.2 caractère qualitatif	8
Tableau 6	EX.3 vs discrète	9
Tableau 7	Solution EX.3.....	10
Tableau 8	EX.4 vs continue.....	12
Tableau 9	Solution1 EX.4.....	12
Tableau 10	Solution2 EX.4.....	13
Tableau 11	EX.5 Mode.....	14
Tableau 12	EX.6 Mode.....	15
Tableau 13	Solution1 EX.6.....	15
Tableau 14	Solution2 EX.6.....	16
Tableau 15	EX.7 Mode.....	16
Tableau 16	EX.8 Mode.....	18
Tableau 17	EX.9 Médiane	19
Tableau 18	EX.10 Médiane	20
Tableau 19	Solution EX.10.....	20
Tableau 20	EX.11 Médiane	21
Tableau 21	Solution EX.11.....	22
Tableau 22	EX.12 Médiane	23
Tableau 23	Solution1 EX.12.....	23
Tableau 24	Solution2 EX.12.....	24
Tableau 25	Moyenne Arithmétique simple et pondérée	24
Tableau 26	EX.13 Moyenne	26
Tableau 27	Solution EX.13.....	26
Tableau 28	Changement de variable d'une vs discrète.....	26
Tableau 29	Changement de variable d'une vs continue	27
Tableau 30	Les moyennes de grandeurs simples et pondérées.....	28
Tableau 31	Solution moyenne composée	29
Tableau 32	EX.14 Moyenne composée	30
Tableau 33	Solution EX.14.....	30
Tableau 34	EX.15 Moyenne composée	32
Tableau 35	Solution EX.15.....	32
Tableau 36	EX.16 Etendue	34
Tableau 37	EX.17 Etendue	34
Tableau 38	Solution EX.17.....	34
Tableau 39	EX.18 Quartiles	36
Tableau 40	Solution EX.18.....	36
Tableau 41	EX.19 Quartiles	37
Tableau 42	Solution EX.19.....	37
Tableau 43	EX.20 Déciles	40
Tableau 44	Solution EX.20.....	40
Tableau 45	EX.21 Déciles	41
Tableau 46	Solution EX.21.....	41
Tableau 47	EX.22 Déciles	42

Tableau 48	Solution EX.22.....	42
Tableau 49	EX.23 Centiles	43
Tableau 50	Solution EX.23.....	43
Tableau 51	EX.24 Ecart absolu	45
Tableau 52	Solution EX.24.....	45
Tableau 53	EX.25 Ecart absolu	46
Tableau 54	Solution EX.25.....	46
Tableau 55	Calcul Algébrique de la Variance d'une vs discrète.....	47
Tableau 56	EX.26 Variance	47
Tableau 57	Solution EX.26.....	47
Tableau 58	Calcul Algébrique de la Variance d'une vs continue	48
Tableau 59	EX.27 Variance	48
Tableau 60	Solution EX.27.....	48
Tableau 61	Solution Moments.....	50
Tableau 62	EX.28 Moments	51
Tableau 63	Solution EX.28.....	51
Tableau 64	EX.29 Moments	52
Tableau 65	Solution EX.29.....	52
Tableau 66	EX.30 Ic	54
Tableau 67	Solution EX.30.....	55
Tableau 68	EX.31 Ic	55
Tableau 69	Solution1 EX.31.....	56
Tableau 70	Solution2 EX.31.....	57
Tableau 71	EX.32 F_1, F_2	59
Tableau 72	Solution EX.32.....	60
Tableau 73	EX.33 F_1, F_2	61
Tableau 74	Solution EX.33.....	61
Tableau 75	Tableau de cotingence.....	62
Tableau 76	Tableau des Fréquences conjointes	63
Tableau 77	EX.34 Tableau des fréquences conjointes.....	63
Tableau 78	Tableau des Fréquences marginales des X_i	64
Tableau 79	Tableau des Fréquences marginales des Y_j	64
Tableau 80	Tableau des Fréquences conditionnelles X_i	66
Tableau 81	Tableau des fréquences conditionnelles Y_j	66
Tableau 82	EX.35 Tableau de contingence de 2 variables qualitatives	70
Tableau 83	EX.36 Tableau de contingence en %	70
Tableau 84	EX.37 Tableau de contingence	73
Tableau 85	EX.38 Distribution des pointures en fonction de l'origine.....	74
Tableau 86	EX.39 Tableau de contingence	75
Tableau 87	EX.40 Tableau de 2 variables quantitatives	76
Tableau 88	EX.41 Tableau de contingence de 2 variables continues	77
Tableau 89	EX.42 Tableau1 de contingence.....	80
Tableau 90	EX.43 Tableau 2 de contingence.....	82
Tableau 91	Solution Calcul de la droite de régression	82
Tableau 92	Exemple 1 d'ACP.....	86
Tableau 93	Exemple 2 d'ACP.....	87
Tableau 94	Exemple 1 Regression Logistique	92
Tableau 95	EX.44 Prix unitaires d'1 produit durant 2000-2003	99

Tableau 96	Indice arithmétique	102
Tableau 97	EX.45 Prix de 3 produits durant 2000-2003	102
Tableau 98	Indices géométriques	103
Tableau 99	EX.46 Prix de 3 produits durant 2000-2002	104
Tableau 100	Indice de Laspeyres $L_{v/0}(G)$	106
Tableau 101	Prix de 4 produits durant périodes 1 et 2	107
Tableau 102	Indice de Paasche $P_{v/0}(G)$	108
Tableau 103	Prix de 4 produits durant périodes 1 et 2	111

Liste des figures

Figure 1	Vocabulaire statistique.....	5
Figure 2	Taux d'analphabétisme total	7
Figure 3	Diagramme circulaire.....	8
Figure 4	Cartogramme.....	8
Figure 5	Diagramme en bâtons	10
Figure 6	Courbe en escalier	11
Figure 7	Solution Histogramme	12
Figure 8	Courbe cumulative	13
Figure 9	Diagramme en bâtons	17
Figure 10	Graphe Mode : cas continu	17
Figure 11	Histogramme de la distribution	18
Figure 12	Médiane de la vs Discrète.....	22
Figure 13	Médiane de la vs continue.....	24
Figure 14	Détermination graphique des quartiles. cas discret.....	35
Figure 15	détermination graphique des quartiles: cas continu	38
Figure 16	Détermination graphique de D_4 : cas discret	42
Figure 17	Graphe C_{80} : cas continu.....	44
Figure 18	Courbe de Lorenz.....	53
Figure 19	Indice de Gini	53
Figure 20	Médiale	54
Figure 21	Médiane.....	54
Figure 22	Coefficient de concentration I_c	56
Figure 23	Skewness.....	58
Figure 24	Kurtosis	58
Figure 25	Kurtosis < 0	59
Figure 26	Kurtosis > 0	59
Figure 27	Histogramme et courbe de fréquence.....	61
Figure 28	Graphe de deux variables qualitatives	70
Figure 29	Graphe semi-circulaire relatif aux salariés.....	71
Figure 30	Graphe semi-circulaire relatif aux Patrons.....	71
Figure 31	Graphe en anneaux.....	72
Figure 32	Graphe1 quantitatif & qualitatif	73
Figure 33	Graphe2 qualitatif & quantitatif.....	74
Figure 34	Graphe Boîte à moustache	75
Figure 35	Graphe qualitatif et quantitatif continue	76
Figure 36	Graphe en nuage de points	77
Figure 37	Graphe d'1 distribution de 2 variables continues.....	78
Figure 38	Graphe triangulaire	78
Figure 39	Graphe de la régression pondérée	83
Figure 40	Graphe des observations : ACP.....	89
Figure 41	Graphe des axes factoriels : ACP.....	89

INTRODUCTION GENERALE

L'objet de la statistique est la collecte des données, leur traitement puis leur analyse/interprétation.

Trois branches s'en distinguent : la théorie des sondages (collecte), la statistique descriptive (traitement) et la statistique mathématique (analyse/interprétation).

La méthodologie de la statistique se résume au recueil des données (choix et taille de la population, choix du caractère, ...), leur traitement (classement, présentation, synthèse, ...) puis leur analyse & interprétation (tests d'hypothèse, *modélisation*, ...).

Selon le nombre des variables étudiées, on distingue la statistique univariée, bivariée ou multivariée.

CH1. STATISTIQUE UNIVARIEE

Introduction : vocabulaire statistique

Un ensemble d'objets ou de personnes d'une étude statistique est appelé **population**. Un élément de cette population est appelé **individu**. Les individus d'une population possèdent des caractéristiques communes appelées **caractères**.

L'étude statistique porte sur un caractère. Les **modalités** d'un caractère sont les différents états qu'il peut prendre. Un **caractère** est dit **qualitatif** si ses modalités ne sont pas mesurables (exemple : sexe) : il se subdivise en **ordinal** (modalités hiérarchisables, exemple : bon, passable, médiocre) et en **nominal** (modalités non hiérarchisables, exemple : sexe).

Un **caractère** est **quantitatif** si ses modalités sont mesurables ; les mesures sont alors les valeurs d'une **variable statistique VS** (exemple : un âge, une taille...).

La **VS** est dite **discrète** si elle ne prend que des valeurs isolées (exemple : entières). La **VS** est **continue** si elle peut prendre toutes les valeurs d'un intervalle (exemple : 0 - 4).


L'**effectif N** d'une population est le nombre total d'individus de cette population. L'effectif **n** est l'effectif de l'échantillon.

L'**effectif (n_i)** de la modalité d'un caractère est le nombre d'individus possédant cette modalité.

La **fréquence (f_i)** de la modalité d'un caractère est le nombre d'individus possédant cette modalité (n_i) divisé par l'effectif total de la population (N) ou l'effectif total de l'échantillon (n).

Population, individu, caractère, modalité, type de caractère (qualitatif, quantitatif), variable statistique vs (vs discrète, vs continue), tableau statistique, représentation graphique, ...constituent l'essentiel du vocabulaire de la statistique descriptive univariée (graphe 1)

Figure 1 vocabulaire statistique



1.1 TABLEAU STATISTIQUE & REPRESENTATION GRAPHIQUE

1.1.1 Tableau statistique (TS)

Le TS diffère selon le type de caractère :

.Caractère Qualitatif

Tableau 1 TF d'un caractère qualitatif

Caractère _i	n _i	f _i	f _i [%]
modalité ₁	n ₁	f ₁	f ₁ [%]
modalité ₂	n ₂	f ₂	f ₂ [%]
...			
modalité _n	n _n	f _n	f _n [%]

.VS discrète

Tableau 2 TF d'une vs discrète

x _i	n _i	f _i	f _i [%]	n _i ↑	n _i ↓	f _i [%] ↑	f _i [%] ↓
x ₁	n ₁	f ₁	f ₁ [%]	n ₁ ↑	n ₁ ↓	f ₁ [%] ↑	f ₁ [%] ↓
...							
x _n	n _n	f _n	f _n [%]	n _n ↑	n _n ↓	f _n [%] ↑	f _n [%] ↓

.VS continue

Tableau 3 TF d'une vs continue

cl _i	n _i	c _i	f _i	f _i [%]	n _i ↑	n _i ↓	f _i [%] ↑	f _i [%] ↓
[e ₀ , e ₁ [n ₀	c ₀	f ₀	f ₀ [%]	n ₀ ↑	n ₀ ↓	f ₀ [%] ↑	f ₀ [%] ↓
.....								
[e _i , e _{i+1} [n _i	c _i	f _i	f _i [%]	n _i ↑	n _i ↓	f _i [%] ↑	f _i [%] ↓

1.1.2 Représentation graphique (RG)

La représentation graphique des données relatives à un caractère unique repose sur la **proportionnalité des hauteurs ou des aires** des graphiques **aux effectifs** ou aux fréquences des différentes modalités du caractère.

1.1.2.1 Caractère qualitatif

Pour un caractère qualitatif, on utilise principalement deux types de représentation graphique : la représentation en **tuyaux d'orgue (barres ou colonnes)** et la représentation en **secteurs**. Lorsque le caractère étudié est la répartition géographique d'une population, la représentation graphique est un **cartogramme**.

a) Tuyaux d'orgue

Nous portons en abscisses les modalités, de façon arbitraire. Nous portons en ordonnées des colonnes dont la **hauteur** est proportionnelle aux effectifs, ou aux fréquences, de chaque modalité ($h_i/n_i = ki = \overline{1..m}$)

. EXEMPLE

Le tableau suivant nous donne le taux d'analphabétisme (A) pour les garçons et les filles de plus de 10 ans, de 1966 à 2002 en Algérie selon l'ONS.


Le caractère étudié, le taux d'analphabétisme, est un caractère qualitatif. La représentation appropriée est le graphe en tuyaux d'orgue ou en secteurs.

Tableau 4 EX.1 caractère qualitatif

Ans	Garçons	Filles	Total
1966	62.30	85.40	74.60
1977	48.20	74.30	58.10
1987	30.75	56.66	43.62
1998	23.65	40.27	31.90
2002	18.20	35.00	26.50

Source : ONS

Figure 2 Taux d'analphabétisme total



b) Secteurs

Les diagrammes circulaires, ou semi-circulaires, consistent à partager un disque ou un demi disque, en secteurs, correspondant aux modalités observées et dont la **surface** est proportionnelle à l'effectif ou à la fréquence de la modalité :

$$(s_i/n_i = ki \quad i = \overline{1..m})$$

Ces diagrammes conviennent aux données politiques ou socio-économiques.


. EXEMPLE

Reprenons la distribution précédente et donnons sa représentation graphique en secteurs pour les garçons.

Tableau 5 EX.2 caractère qualitatif

Ans	Garçons	Filles	Total
1966	62.30	85.40	74.60
1977	48.20	74.30	58.10
1987	30.75	56.66	43.62
1998	23.65	40.27	31.90
2002	18.20	35.00	26.50

Figure 3 Diagramme circulaire



e) Cartogramme

Un cartogramme est une carte géographique dont les secteurs géographiques sont coloriés avec une couleur différente suivant l'effectif ou suivant la fréquence du caractère étudié.

Figure 4 Cartogramme



Source : Youtube

1.1.2.2 Caractère quantitatif

La variable statistique (VS) est la mesure du caractère. Celle-ci peut être discrète (Vd) ou continue (Vc).

Il existe deux types de représentation graphique d'une distribution statistique à caractère quantitatif :

- Le diagramme différentiel correspond à une représentation des effectifs ou des fréquences.
- Le diagramme intégral correspond à une représentation des effectifs cumulés ou des fréquences cumulées.

. VS discrète

- Diagramme différentiel : **diagramme en bâtons** des effectifs ou des fréquences.

La différence avec le cas qualitatif consiste en ce que les abscisses sont ici les valeurs ordonnées de la variable statistique.

Exemple

Soit la distribution suivante, calculer $f_i\%$, F_i et sa représentation graphique?

Tableau 6 EX.3 vs discrète


Nombre d'appels téléphoniques par minute	Nombre de minutes
0	93
1	261
2	416
3	393
4	308
5	174
6	93
7	42
8 et plus	20
TOTAL	1 800

. Solution

Tableau 7 Solution EX.3

Nombre d'appels téléphoniques par minute	Nombre de minutes (effectifs)	Fréquence (%)	Fréquence cumulée (%)
0	93	5,2	5,2
1	261	14,5	19,7
2	416	23,1	42,8
3	393	21,8	64,6
4	308	17,1	81,7
5	174	9,7	91,4
6	93	5,2	96,6
7	42	2,3	98,9
8 et plus	20	1,1	100,0
TOTAL	1 800	100,0	


Figure 5 Diagramme en bâtons



---Diagramme intégral : **courbe en escaliers** des effectifs cumulés ou des fréquences cumulées.

La représentation graphique **intégrale** correcte est la **courbe en escalier**: les fréquences des diverses valeurs de la variable statistique correspondent aux hauteurs des marches de la courbe en escalier.

Figure 6 Courbe en escalier



$$f_i^{\% \uparrow} = F(x) = \sum_{j=1}^i f_j^{\%} \quad X_i \leq X < X_{i+1}$$

. VS continue

Les observations sont regroupées en classes.

Chaque classe possède une certaine amplitude (a_i), qui est la longueur de l'intervalle définissant la classe. *Le rapport entre l'effectif d'une classe et son amplitude s'appelle la **densité d'effectif** (d_i).*

*Le rapport entre la fréquence d'une classe et son amplitude s'appelle la **densité de fréquence** (d_{ir}).*

$$d_i = n_i / a_i ; d_{ir} = f_i / a_i$$

— Diagramme différentiel : **histogramme des densités.**

Nous portons en abscisse les classes représentant les modalités et en ordonnées des rectangles dont la longueur (hauteur) est proportionnelle à la densité d'effectif ou à la densité de fréquence.

L'**aire** d'un rectangle de cet histogramme est alors proportionnelle à l'effectif ou à la fréquence de la classe.

. EXEMPLE

Soit la distribution suivante, tracer sa représentation graphique ?

Tableau 8 EX.4 vs continue

CA (millions DA)	ni
0 - 0.25	13712
0.25 - 0.50	10674
0.50 - 1.00	11221
1.00 - 2.50	15496
2.50 - 5.00	10043
5.00 - 10.00	3347
10.00-20.00	3147
Total	67640


Solution

Tableau 9 Solution1 EX.4

CA (millions DA)	ni	ai	fi	fi%	di
0 - 0.25	13712	0,25	0,203	20,3	81,09
0.25 - 0.50	10674	0,25	0,158	15,8	63,12
0.50 - 1.00	11221	0,5	0,166	16,6	33,18
1.00 - 2.50	15496	1,5	0,229	22,9	15,27
2.50 - 5.00	10043	2,5	0,148	14,8	5,94
5.00 - 10.00	3347	5	0,049	4,9	0,99
10.00-20.00	3147	50	0,047	4,7	0,09
Total	67640		1,000	100,000	

. Solution

Figure 7 Solution Histogramme



— Diagramme intégral : **courbe cumulative** des effectifs ou des fréquences.

La courbe cumulative des fréquences doit représenter la fonction de répartition de la variable statistique. La représentation graphique intégrale correcte est la courbe cumulative des fréquences. Pour que chaque point expérimental représente la fonction de répartition, il faut

prendre pour abscisses les bornes supérieures des classes et, pour ordonnées, les fréquences cumulées correspondantes.

. EXEMPLE


Soit la distribution précédente, tracer la représentation graphique des effectifs cumulés F_i ?

. Solution

Tableau 10 Solution2 EX.4

CA (millions DA)	ni	ai	fi	fi%	di	Fi
0 - 0.25	13712	0,25	0,203	20,3	81,09	20,3
0.25 - 0.50	10674	0,25	0,158	15,8	63,12	36,1
0.50 - 1.00	11221	0,5	0,166	16,6	33,18	52,7
1.00 - 2.50	15496	1,5	0,229	22,9	15,27	75,6
2.50 - 5.00	10043	2,5	0,148	14,8	5,94	90,4
5.00 - 10.00	3347	5	0,049	4,9	0,99	95,4
10.00-20.00	3147	50	0,047	4,7	0,09	100,0
Total	67640		1,000	100		

Figure 8 Courbe cumulative



1.2 PARAMETRES CARACTERISTIQUES

Le but de l'étude statistique est aussi de résumer les données par des paramètres ou synthétiseurs.

Il existe 3 types de paramètres :

— paramètres de position (ou de tendance centrale)

— paramètres de dispersion

— paramètres de forme (asymétrie, aplatissement, concentration)

1.2.1 PARAMETRES DE POSITION

Les paramètres de position (mode, médiane, moyenne) permettent de savoir autour de quelles valeurs se situent les valeurs d'une variable statistique.

1.2.1.1 Mode (M_o)

Le mode, noté M_o , est la modalité qui admet **la plus grande fréquence corrigée**: $M_o \Leftrightarrow f'(M_o) = \max (f'_i) ; i \in [1, p]$

Il est parfaitement défini pour une variable qualitative ou une variable quantitative discrète.

. Détermination algébrique

. VS discrète

i. Série numérique

Soit la série $X=2, 4, 1, 3, 6, 7, 6, 8, 9, 7$

-on ordonne la série : $X=1, 2, 3, 4, 6, 6, 7, 7, 8, 9$

-on calcule le mode : M_o =modalité qui a le plus grand effectif (n_i) :

$$M_{10}=6; M_{20}=7$$

ii. Série classée

Le mode M_o d'un tableau des effectifs est le caractère qui a le plus grand effectif (n_i). $M_o \Leftrightarrow n(M_o) = \max (n_i) ; i \in [1, p]$

. EXEMPLE : Soit la variable X_i suivante, calculer M_o ?

Tableau 11 EX.5 Mode

X_i	n_i
5	2
10	3
20	10
8	2

$$M_o = 20$$

. VS continue

Pour une variable quantitative continue nous parlerons de **classe modale** : c'est la classe dont la densité de fréquence (ou l'effectif corrigé) est maximum :

$$cl_o \Leftrightarrow \text{dir}(Cl_o) = (d_{ir})_{\max} ; i \in [1, p]$$

Une VS peut présenter plusieurs modes locaux : on dit alors qu'elle est **plurimodale**.

Si les classes ont même amplitude, la densité est remplacée par l'effectif ou la fréquence et nous retrouvons la définition précédente.

. EXEMPLE : Soit la Cl_i suivante : calculer Mo ?

Tableau 12 EX.6 Mode

cl_i	$fi\%$
[0-10[10
[10-20[20
[20-40[30
[40-45[40

. *Méthode de la densité d_{ir}*

-on calcule d'abord la classe modale cl_o

Tableau 13 Solution1 EX.6

cl_i	$fi\%$	ai	dir
[0-10[10	10	1
[10-20[20	10	2
[20-40[30	20	1.5
[40-45[40	5	8

$Cl_o \leftrightarrow dir(Cl_o) = dir_{max} = [40-45[$

-on calcule ensuite le mode par interpolation linéaire:

$$M_o = 40 + (45 - 40) (8 - 1.5) / (8 - 1.5) + (8 - 0) = 42$$

. *Méthode du coefficient*

-on calcule d'abord la classe modale Cl_o : c'est la classe ayant la plus grande fréquence corrigée.

Notons : $k_i = a_i / a$ et $f_i^* = f_i / k_i$

Tableau 14 Solution2 EX.6

cl_i	$fi\%$	ai	$k_i=ai/a$	$f' \%$
[0-10[10	10	2	5
[10-20[20	10	2	10
[20-40[30	20	4	7.5
[40-45[40	5	1	40

$$Clo \leftrightarrow f'_i\%(Clo)=f' \%_{\max}=[40-45[$$

-on calcule ensuite le mode par interpolation linéaire :

$$Mo = 40 + (45-40) (40-7.5) / (40-7.5) + (40-0) = 42$$

. Détermination graphique

. VS discrète

i. Série classée

Soit la série X_i suivante : représenter Mo ?


Tableau 15 EX.7 Mode

X_i	ni
5	2
10	3
20	1
8	2

-On représente d'abord le graphe de X_i (graphe en bâtons)

-On marque ensuite le bâton de plus grande hauteur comme étant Mo .

Figure 9 Diagramme en bâtons




$M_o=10$

. VS continue

Nous définissons le **mode**, pour une variable quantitative continue, en tenant compte des densités de fréquence (ou des effectifs corrigés) des 2 classes adjacentes à la classe modale par la méthode suivante.

Figure 10 Graphe Mode : cas continu



La classe modale $[x_i, x_{i+1} [$ étant déterminée, le mode M_o vérifie :

$$\frac{M_o - x_i}{x_{i+1} - x_i} = \frac{\Delta_1}{\Delta_1 + \Delta_2} \Rightarrow M_o = x_i + (x_{i+1} - x_i) \frac{\Delta_1}{\Delta_1 + \Delta_2} \quad / \quad \Delta_1 = n'_0 - n'_{0-1} \quad \Delta_2 = n'_0 - n'_{0+1}$$

Remarque :

Lorsque les classes adjacentes à la classe modale ont des densités de fréquences égales, le mode coïncide avec le centre de la classe modale.

Le mode dépend beaucoup de la répartition en classes.

Une variable statistique peut présenter plusieurs modes locaux : on dit alors qu'elle est **plurimodale**.

Cette situation est intéressante : elle met en évidence l'existence de plusieurs sous-populations, donc l'hétérogénéité de la population étudiée.

. EXEMPLE

Soit le tableau de la distribution précédente, calculer Mo graphiquement ?

Tableau 16 EX.8 Mode

cl_i	$f_i\%$	ai	k_i	f'
[0-10[10	10	2	5
[10-20[20	10	2	10
[20-40[30	20	4	7.5
[40-45[40	5	1	40

. Solution

1. On trace l'histogramme

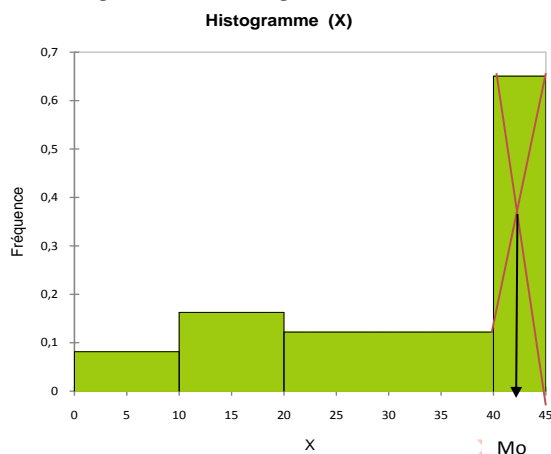
2. On détermine la classe modale : $Cl_o \leftrightarrow f'_i\%(Cl_o) = f'\%_{\max} = [40-45[$

3. On calcule ensuite le mode Mo conformément à la règle des « ciseaux » et au théorème de THALES.

$$Mo = xi + (x_{i+1} - x_i) \frac{\Delta_1}{\Delta_1 + \Delta_2}$$

$$Mo = 40 + (45 - 40) (40 - 7.5) / (40 - 7.5) + (40 - 0) = 42$$

Figure 11 Histogramme de la distribution



1.2.1.2 Médiane (Me)

La médiane Me est la modalité telle que l'effectif des observations dont les modalités sont inférieures à Me est égal à l'effectif des observations dont les modalités sont supérieures à Me .

Cette définition n'a de sens que si les modalités sont toutes ordonnées :

$$M_e \Leftrightarrow F(M_e) = 0,5$$

. Détermination algébrique

• VS discrète

i. série numérique

Soit la série $X=2, 4, 1, 3, 6, 7, 6, 8, 9, 7$

-on ordonne la série : $X=1, 2, 3, 4, 6, 6, 7, 7, 8, 9$

- on examine la parité de la suite :

.si la suite possède un nombre impair de termes $n=(2k+1); k \in \mathbb{N}$: $X_e = \frac{X_{n+1}}{2}$

.si la suite possède un nombre pair de termes $n=(2k); k \in \mathbb{N}$: $X_e = \frac{X_{n/2} + X_{n/2+1}}{2}$

Dans notre exemple $n=10$ donc $X_e = \frac{X_{n/2} + X_{n/2+1}}{2} = \frac{X_5 + X_6}{2} = 6$

ii. série classée (tableau de fréquence)

Si le nombre d'observations N est pair, $Me = (X_1 + X_2)/2$: $X_1 \leftrightarrow n^\uparrow(X_1) \geq n/2$

$X_2 \leftrightarrow n^\uparrow(X_2) \geq n/2 + 1$

. EXEMPLE

Soit le tableau des fréquences (TF) suivant, calculer Me ?

Tableau 17 EX.9 Médiane

X_i	n_i	n_i^\uparrow
5	2	2
10	3	5
20	1	6
8	2	8

$$N=8 \quad X1 \leftrightarrow n(X1) \geq n/2 = 10 \quad X2 \leftrightarrow n(X2) \geq n/2 + 1 = 10$$

$$\text{Donc } Me = (X1 + X2)/2 = 10$$

•VS continue

-On calcule d'abord l'intervalle médian $]a \ b[: Cle \leftrightarrow F(Cle) \geq 50$

-On calcule ensuite par interpolation linéaire $X_e = a + (b-a) \frac{(50 - n_{e-1}^{\uparrow})}{n_e}$

. EXEMPLE

Reprenons la distribution du tableau 12, calculer Me ?

Tableau 18 EX.10 Médiane

cl_i	$fi\%$
[0-10[10
[10-20[20
[20-40[30
[40-45[40

. Solution

Tableau 19 Solution EX.10

cl_i	$fi\%$	Fi
[0-10[10	10
[10-20[20	30
[20-40[30	60
[40-45[40	100

$$Cle \leftrightarrow F(Cle) \geq 50 = [20-40[$$

$$Me = 20 + 20 (50-30)/30 = 33.33$$

L'intervalle [20-40[est l'intervalle médian.

Dans l'intervalle médian, la médiane est calculée par interpolation linéaire : $X_e = a + (b-a) \cdot \frac{(50 - n_{e-1}^{\uparrow})}{n_e}$

$$\frac{(50 - n_{e-1}^{\uparrow})}{n_e} = 33.33$$

$$x_e = a + (b-a) \cdot \frac{rg(n/2)}{n_e} \quad / \quad rg(n/2) = n/2 - n_{e-1}^{\uparrow} \quad a$$

Remarque

La médiane ne dépend que de l'ordre des modalités, elle n'est donc pas influencée par les observations aberrantes.

La médiane partage l'histogramme des fréquences en 2 parties d'aires égales.

. Détermination graphique

. VS discrète

i. Série classée

. On trace le graphe des fréquences (effectifs) cumulées ascendantes (courbe en escalier)

. On détermine $Me \leftrightarrow n(Me) \geq N/2$ ou $F(Me) \geq 50$

. EXEMPLE

Soit le TF suivant d'une VS discrète, calculer Me graphiquement ?

Tableau 20 EX.11 Médiane

X_i	$f_i\%$
1	10
2	20
3	30
4	10
6	20
8	10

. Solution


. On calcule d'abord F_i

Tableau 21 Solution EX.11

X_i	$f_i\%$	F_i
1	10	10
2	20	30
3	30	60
4	10	70
6	20	90
8	10	100

. On détermine ensuite $Me = F(Me) \geq 50 = 3$, on le fixe sur le graphe de F_i .

Figure 12 Médiane de la vs Discrète



VS continue

. On trace le graphe des fréquences (effectifs) cumulées ascendants

. On fixe la classe médiane : $Cle \leftrightarrow F(Cle) \geq 50$

. On calcule Me par la méthode de « l'égalité des pentes »

. EXEMPLE

Soit la distribution suivante, calculer Me ?

Tableau 22 EX.12 Médiane

cl_i	$fi\%$
[0-10[10
[10-20[20
[20-40[30
[40-45[40

Solution

Tableau 23 Solution1 EX.12

cl_i	$fi\%$	Fi
[0-10[10	10
[10-20[20	30
[20-40[30	60
[40-45[40	100

$$. Cle \leftrightarrow F(Cle) \geq 50 = [20-40[$$

Par la méthode de l'égalité des pentes, nous obtenons :

$$. (F(b)-F(a))/(b-a) = (50-F(a))/(Me-20)$$

$$. (Me-20)/(b-a) = (50-F(a))/(F(b)-F(a))$$

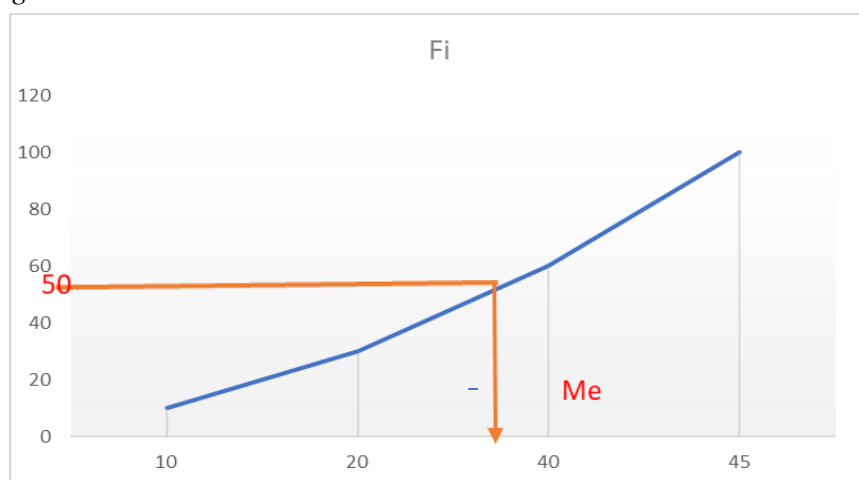
Par conséquent on déduit Me :

$$Me = a + (b-a)(50-F(a))/(F(b)-F(a)) = 20 + 20 \cdot (50-30)/30 = 33.33$$

Tableau 24 Solution2 EX.12

cl_i	ei	$ei+1$	$fi\%$	Fi	Ci
[0-10[0	10	10	10	5
[10-20[10	20	20	30	15
[20-40[20	40	30	60	30
[40-45[40	45	40	100	42,5

Figure 13 Médiane de la vs continue



1.2.1.3 Moyenne (\bar{X})

Tableau 25 Moyenne Arithmétique simple et pondérée

	Vs discrète	Vs continue
Moyenne arith. simple	$\frac{1}{n} \sum_i x_i$	$\frac{1}{n} \sum_i c_i$
Moyenne arith. pondérée	$\frac{1}{n} \sum_i n_i x_i$	$\frac{1}{n} \sum_i n_i c_i$

Propriétés de la moyenne

$$\overline{x + y} = \bar{x} + \bar{y}$$

$$\overline{\lambda x} = \lambda \bar{x}$$

$$\overline{x - x} = 0 \quad \overline{(x - \bar{x})^2} < \overline{(x - x_\alpha)^2} \quad x_\alpha \neq \bar{x}$$

. Détermination algébrique

. VS discrète

i. Série numérique

On calcule ici la moyenne par la méthode de la moyenne simple.

. EXEMPLE

Soit la série X_i suivante, calculer la moyenne ?

$$X_i = 1, 2, 3, 4, 5, 6, 7, 8, 9, 10$$

$$\bar{X} = \frac{1}{n} \sum_{i=1}^{10} X_i = \frac{(1 + 2 + \dots + 10)}{10} = 5.5$$

ii. Série classée

On calcule ici la moyenne arithmétique par la méthode de « la moyenne pondérée ».

. EXEMPLE

Reprenons le tableau 15 précédent, calculer la moyenne ?

Tableau 26 EX.13 Moyenne

X_i	n_i
1	1
2	8
3	12
4	14
5	6
6	4
7	3
8	2
	50

. Solution

Tableau 27 Solution EX.13

X_i	n_i	f_i	$f_i X_i$
1	1	0.02	0.02
2	8	0.16	0.32
3	12	0.24	0.72
4	14	0.28	1.12
5	6	0.12	0.6
6	4	0.08	0.48
7	3	0.06	0.42
8	2	0.04	0.32
	50	1	4

$$\bar{X} = \sum f_i X_i = 4$$

. Changement de variable :

$$x = a x' + b \Rightarrow x' = (x - b)/a ; \quad \bar{x} = a \bar{x}' + b \quad v(x) = a^2 v(x') ; b = x_0(c_0)$$

[centre de classe médiane]

VS discrète

Tableau 28 Changement de variable d'une vs discrète

x_i	n_i	$x'_i = (x_i - x_0)/a$	$n_i x'_i$	$n_i x'^2_i$

VS continue

Tableau 29 Changement de variable d'une vs continue

cl_i	n_i	c_i	$c'_i = (c_i - c_0)/a$	$n_i c'_i$	$n_i c'^2_i$
$[e_0, e_1[$					
$[e_1, e_2[$					
$[e_i, e_{i+1}[$					

. Moyenne conditionnée : φ -moyenne

Soit $X = \{(x_i, n_i)\}$, $i \in \square [1, p]$, une v.s. quantitative discrète à valeurs dans \mathbb{R}^+

Soit $\varphi : \square : \mathbb{R}^{+*} \rightarrow \mathbb{R}$ une application monotone (injection croissante ou décroissante) continue.

Alors $\varphi(X) = \{(\varphi(x_i), n_i)\}$, $i \in \square [1, p]$, est une v. s. quantitative discrète à valeurs dans \mathbb{R} .

On peut calculer sa moyenne $\overline{\varphi(X)} = \frac{1}{n} \sum_i n_i \varphi(x_i)$.

Comme φ est une injection continue, il existe un unique $\bar{\varphi}_\Psi \in \square \mathbb{R}^*$ tel que $\overline{\varphi(X)} = \overline{\varphi(x_\Psi)}$
 $\bar{\varphi}_\Psi$ est appelé la φ -moyenne de X .

. EXEMPLES de φ -moyennes.

$$1. \varphi(X) = X^r \quad \overline{\varphi(X)} = \overline{X^r} = \frac{1}{n} \sum_i n_i X^r = \overline{X^r} \Rightarrow \bar{X}_r = \left(\frac{1}{n} \sum_i n_i X^r \right)^{\frac{1}{r}}$$

$r=1$

$$\bar{X}_1 = \frac{1}{n} \sum_i n_i X$$

$r=2$

$$\bar{X}_2 = \sqrt{\frac{1}{n} \sum_i n_i X^2}$$

$r=-1$

$$\bar{X}_{-1} = \frac{n}{\sum_i \frac{n_i}{x_i}}$$

$$2. \varphi(X) = \ln X ; \overline{\varphi(X)} = \overline{\ln X} = \frac{1}{n} \sum_i n_i \ln X_i = \ln(\overline{X}) \Rightarrow \overline{X_g} = e(\frac{1}{n} \sum_i n_i \ln X_i) = [\prod_i x_i^{n_i}]^{\frac{1}{N}}$$

Tableau 30 Les moyennes de grandeurs simples et pondérées

	simples	pondérées
\overline{x}	$\frac{1}{n} \sum_i x_i$	$\frac{1}{n} \sum_i n_i x_i$
$\overline{x_h}$	$\frac{n}{\sum_i \frac{1}{x_i}}$	$\frac{n}{\sum_i \frac{n_i}{x_i}}$
$\overline{X_g}$	$(\prod_i x_i)^{\frac{1}{N}}$	$(\prod_i x_i^{n_i})^{\frac{1}{N}}$
$\overline{X_q} =$	$\sqrt{\frac{1}{n} \sum_i X^2}$	$\sqrt{\frac{1}{n} \sum_i n_i X^2}$

$$\overline{X_h} < \overline{X_g} < \overline{X} < \overline{X_q}$$

Il y a égalité si, et seulement si, toutes les valeurs de X sont égales.

$\overline{X_g}$ est bien adaptée à l'étude des phénomènes de croissance.

$\overline{x_h}$ est utilisée pour les calculs d'indices économiques.

$\overline{X_q}$ est utilisée en statistique pour le calcul de l'écart type.

. EXEMPLE

i. Série numérique

Soit la série X_i suivante, calculer $\overline{X_h}$, $\overline{X_g}$, $\overline{X_a}$ et $\overline{X_q}$ puis confirmer la relation théorique qui existe entre elles?

$X_i = 12, 4, 3, 8, 7, 2$

. Solution

Tableau 31 Solution moyenne composée

X_i	$1/X_i$	X_i^2	X_i	$\log X_i$
12	0.083	144	12	1.079
4	0.250	16	4	0.602
3	0.333	9	3	0.477
8	0.125	64	8	0.903
7	0.143	49	7	0.845
2	0.500	4	2	0.301
36	1.435	286	36	4.208

$$\bar{X}_h = \frac{n}{\sum_i \frac{1}{X_i}} = \frac{6}{1.435} = 4.18$$

$$\bar{X}_g = \left[\prod_i X_i \right]^{\frac{1}{n}} = \sqrt[6]{16128} = 5.03$$

ou

$$\bar{X}_g = 10^{\left(\frac{1}{n} \sum \log X_i \right)} = 10^{\left(\frac{4.207}{6} \right)} = 5.03$$

$$\bar{X}_a = \frac{1}{n} \sum_i X_i = \frac{36}{6} = 6$$

$$\bar{X}_q = \sqrt{\frac{1}{n} \sum_i X_i^2} = \sqrt{\frac{286}{6}} = 6.90$$

La relation théorique $\bar{X}_h \leq \bar{X}_g \leq \bar{X}_a \leq \bar{X}_q$ est confirmée.

ii. Série classée

Soit la distribution suivante, calculer les moyennes \bar{X}_{hp} , \bar{X}_{gp} , \bar{X}_{ap} et \bar{X}_{qp}

puis confirmer la relation théorique qui existe entre elles ?

Tableau 32 EX.14 Moyenne composée

X_i	n_i
2	2
8	3
17	1
12	3
3	2

. Solution

Tableau 33 Solution EX.14

X_i	n_i	$n_i X_i$	$n_i X_i^2$	n_i/X_i	$\log X_i$	$n \log X_i$
2	2	4	8	1	0.30	0.60
8	3	24	192	0.38	0.90	2.71
17	1	17	289	0.06	1.23	1.23
12	3	36	432	0.25	1.08	3.24
3	2	6	18	0.67	0.48	0.95
	11	87	939	2.35		8.73

$$\bar{X}_{hp} = \frac{\sum_i n_i}{\sum_i \frac{n_i}{X_i}} = \frac{11}{2.35} = 4.68$$

$$\bar{X}_{gp} = \left[\prod_i X_i^{ni} \right]^{\frac{1}{\sum_i ni}} = (541458432)^{1/11} = 6.22$$

ou

$$\bar{X}_{gp} = 10^{\left(\frac{\sum_i \frac{ni \log C_i}{\sum_i ni}}{\sum_i ni} \right)} = 10^{\left(\frac{8.73}{11} \right)} = 10^{(0.794)} = 6.22$$

$$\bar{X}_{ap} = \frac{\sum_i ni C_i}{\sum_i ni} = \frac{87}{11} = 7.90$$

$$\bar{X}_{qp} = \left(\frac{\sum_i ni C_i^2}{\sum_i ni} \right)^{1/2} = \left(\frac{939}{11} \right)^{1/2} = \sqrt{85.36} = 9.24$$

La relation théorique $\bar{X}_{hp} \leq \bar{X}_{gp} \leq \bar{X}_{ap} \leq \bar{X}_{qp}$ est confirmée.

. VS Continue

Soit la distribution de 20 exploitations agricoles selon leur superficie (en hectares), *calculer* les moyennes pondérées \bar{X}_{hp} , \bar{X}_{gp} , \bar{X}_{ap} et \bar{X}_{qp} puis confirmer la relation théorique qui existe entre elles?

Tableau 34 EX.15 Moyenne composée

Cl _i	n _i
0-5	3
5-10	12
10-20	4
20-50	1
	20

. Solution

Tableau 35 Solution EX.15

Cl _i	n _i	C _i	n _i / C _i	n _i C _i ²	n _i C _i	n _i log C _i
0-5	3	2.5	1.20	18.75	7.50	1.19
5-10	12	7.5	1.60	675.00	90.00	10.50
10-20	4	15	0.27	900.00	60.00	4.70
20-50	1	35	0.03	1225.00	35.00	1.54
	20		3.10	2818.75	192.50	17.94

$$\bar{X}_{hp} = \frac{\sum_i n_i}{\sum_i \frac{n_i}{C_i}} = \frac{20}{3.10} = 6.45$$

$$\bar{X}_{gp} = \left[\prod_i X_i^{n_i} \right]^{\frac{1}{\sum_i n_i}} = (8.76977E + 17)^{1/20} = 7.89$$

ou

$$\bar{X}_{gp} = 10^{\left(\frac{\sum_i n_i \log C_i}{\sum_i n_i} \right)} = 10^{\left(\frac{17.94}{20} \right)} = 10^{(0.897)} = 7.89$$

$$\bar{X}_{ap} = \frac{\sum_i n_i C_i}{\sum_i n_i} = \frac{192.5}{20} = 9.625$$

$$\bar{X}_{qp} = \left(\frac{\sum_i n_i C_i^2}{\sum_i n_i} \right)^{1/2} = \left(\frac{2818.75}{20} \right)^{1/2} = \sqrt{140.9375} = 11.87$$

La relation théorique $\bar{X}_{hp} \leq \bar{X}_{gp} \leq \bar{X}_{ap} \leq \bar{X}_{qp}$ est confirmée.

1.2.2 PARAMETRES DE DISPERSION

1.2.2.1 Etendue

L'étendue de X : $E = x_{\max} - x_{\min}$

Ce paramètre est souvent utilisé dans les contrôles de fabrication, pour lesquels on donne, a priori, des marges de construction. Son intérêt est limité par le fait qu'il dépend uniquement des valeurs extrêmes, qui peuvent être des valeurs aberrantes.

. EXEMPLE

. VS discrète

. Série numérique

Soit la série numérique $X_i = 1, 3, 2, 3, 3, 2, 4$. Calculer l'étendue E ?

Réponse

$$E = 4 - 1 = 3$$

. Série classée

Soit le TF ci-dessous, calculer l'étendue E ?

Tableau 36 EX.16 Etendue

Xi	ni
1	1
2	2
3	3
4	1

. Réponse

$$E = 4 - 3 = 2$$

. VS continue

Soit la Cli ci-dessous, calculer l'étendue E ?

Tableau 37 EX.17 Etendue

Cli	ni
0-5	3
5-10	12
10-20	4
20-50	1
20	

. Réponse

Tableau 38 Solution EX.17

Cli	ni	Ci
0-5	3	2.5
5-10	12	7.5
10-20	4	15
20-50	1	35
20		

$$E = C_{\text{MAX}} - C_{\text{MIN}} = 35 - 7.5 = 27.5$$

1.2.2.2 Quartiles


. Détermination algébrique

. VS discrète

Pour une variable statistique réelle discrète X , la courbe des fréquences cumulées est une **courbe en escalier**. S'il existe une valeur de x pour laquelle la fréquence cumulée est 0,25 (resp. 0,50, 0,75), le quartile correspondant est cette valeur de X .

Sinon, les quartiles seront déterminés par **interpolation linéaire** entre deux valeurs.

Figure 14 Détermination graphique des quartiles. cas discret



i. Série numérique

. EXEMPLE

Soit la série numérique $X_i = 2, 4, 1, 3, 6, 7, 6, 8, 9, 7$. Calculer Q_1, Q_3 ?

. Réponse

-On ordonne la série : 1,2,3,4,5,6,6,7,7,8,9

$$- Q_1 \Leftrightarrow X_{k \geq \frac{N}{4}} \quad / K \in \mathbb{N} \quad \Leftrightarrow X_{k \geq \frac{10}{4}} = X_3 = 3$$

$$- Q_3 \Leftrightarrow X_{k \geq \frac{3N}{4}} \quad / K \in \mathbb{N} \quad \Leftrightarrow X_{k \geq \frac{30}{4}} = X_8 = 7$$

ii. Série classée

Soit le TF suivant, calculer Q_1, Q_3 ?

Tableau 39 EX.18 Quartiles

X	n _i
1	1
2	8
3	12
4	14
5	6
6	4
7	3
8	2
<hr/>	
	50

. Réponse

Tableau 40 Solution EX.18

X	n _i	ni↑
1	1	1
2	8	9
3	12	21
4	14	35
5	6	41
6	4	45
7	3	48
8	2	50
<hr/>		
	50	

$$Q_1 \Leftrightarrow n^\uparrow(Q_1) \geq \frac{N}{4} = 21$$

$$Q_3 \Leftrightarrow n^\uparrow(Q_3) \geq \frac{3N}{4} = 41$$

$$Q_3 = 5$$

. VS continue

On appelle **quartiles** les nombres réels Q_1, Q_2, Q_3 , pour lesquels les fréquences cumulées de X sont respectivement 0,25, 0,50, 0,75. Les quartiles partagent l'étendue en quatre intervalles qui ont le même effectif. Le deuxième quartile, Q_2 , est égal à la médiane.

Soit la distribution de la vs continue, calculer Q_1, Q_3 ?

Tableau 41 EX.19 Quartiles

cl_i	$fi\%$
[0-10[10
[10-20[40
[20-30[40
[30-40[10

. Solution

Tableau 42 Solution EX.19

cl_i	$fi\%$	Fi
[0-10[10	10
[10-20[40	50
[20-30[40	90
[30-40[10	100


– On calcule $Cl(Q1)$ d'abord: $Cl(Q1) \Leftrightarrow F(Cl(Q1)) \geq 25 \Rightarrow Cl(Q1)=[10,20[$

– On calcule ensuite $Q1$: $Q1=a+(b-a) \cdot \frac{25-F(a)}{f\%(Q1)} = 10 + 10 \cdot \frac{25-10}{40} = 13.75$

– On calcule $Cl(Q3)$ d'abord: $Cl(Q3) \Leftrightarrow F(Cl(Q3)) \geq 75 \Rightarrow Cl(Q1)=[20,30[$

– On calcule ensuite $Q3$: $Q3=a+(b-a) \cdot \frac{75-F(a)}{f\%(Q3)} = 20 + 10 \cdot \frac{75-50}{40} = 26.25$

Figure 15 détermination graphique des quartiles: cas continu



1.2.2.3 Intervalle interquartile

$I_Q = Q_3 - Q_1$ est l'intervalle $[Q_1, Q_3]$. Il contient 50 % des valeurs de X .

. Détermination algébrique

. VS discrète

. EXEMPLE

Calculer I_Q sur la base du TF précédent (Tableau 39):

$$Q_3 \Leftrightarrow n^{\uparrow}(Q_3) \geq \frac{3N}{4} = 41$$

$$Q_3 = 5$$

$$Q_1 \Leftrightarrow n^{\uparrow}(Q_1) \geq \frac{N}{4} = 21$$

$$Q_1 = 3$$

On en déduit qu' $I_Q = 5 - 3 = 2$.

VS continue

Calculer I_Q sur la base de la distribution de la VS continue précédente (Tableau 41):

– On calcule $Cl(Q_3)$ d'abord: $Cl(Q_3) \Leftrightarrow F(Cl(Q_3)) \geq 75 \Rightarrow Cl(Q_3) = [20, 30[$

– On calcule ensuite Q_3 : $Q_3 = a + (b-a) \cdot \frac{75 - F(a)}{f\%(Q_3)} = 20 + 10 \cdot \frac{75 - 50}{40} = 26.25$

– On calcule $Cl(Q_1)$ d'abord: $Cl(Q_1) \Leftrightarrow F(Cl(Q_1)) \geq 25 \Rightarrow Cl(Q_1) = [10, 20[$

– On calcule ensuite Q_1 : $Q_1 = a + (b-a) \cdot \frac{25 - F(a)}{f\%(Q_1)} = 10 + 10 \cdot \frac{25 - 10}{40} = 13.75$

On en déduit que $I_Q = Q_3 - Q_1 = 26.25 - 13.75 = 12.50$

1.2.2.4 Déciles et percentiles

Les 9 déciles sont les nombres réels qui partagent l'étendue en dix intervalles de même effectif. Utilisation : en matière de salaires, le rapport interdécile est un paramètre de dispersion fréquemment utilisé.

Les 99 percentiles sont les nombres réels qui partagent l'étendue en cent intervalles de même effectif.

. Détermination algébrique

. VS discrète

. Série numérique

Soit $X_i = 12, 8, 7, 7, 5, 4, 4, 3, 2, 1, 0$. Calculer D_3, C_{12} ?

. Solution

. On ordonne d'abord la série : $X_i = 0, 1, 2, 3, 4, 4, 5, 7, 7, 8, 12$.

. On calcule D_3 :

$$D_3 = X_{k \geq \frac{3N}{10} = 4} \quad k \in N \Rightarrow D_3 = X_4 = 3$$

$$C_{12} = X_{k \geq \frac{12N}{100} = 2} \quad k \in N \Rightarrow C_{12} = X_2 = 1$$

. Série classée

Reprenons la distribution précédente de x discrète et calculons D_2 et C_{67} ?

Tableau 43 EX.20 Déciles

X	n_i
1	1
2	8
3	12
4	14
5	6
6	4
7	3
8	2
<hr/>	
	50

. Réponse

Tableau 44 Solution EX.20

X	n_i	$n_i \uparrow$
1	1	1
2	8	9
3	12	21
4	14	35
5	6	41
6	4	45
7	3	48
8	2	50
<hr/>		
	50	

$$D_2 \Leftrightarrow n^\uparrow(D_2) \geq \frac{2N}{10} = 21$$

$$D_2 = 3$$

$$C_{67} \Leftrightarrow n^\uparrow(C_{67}) \geq \frac{67N}{100} = 35$$

$$C_{67} = 4$$

. VS continue

Soit la distribution de la vs continue ci-après, calculer D_6 et C_{80} ?

Tableau 45 EX.21 Déciles

cl_i	$fi\%$
[0-10[10
[10-20[30
[20-40[40
[40-50[20

. Réponse

Tableau 46 Solution EX.21

cl_i	$fi\%$	Fi
[0-10[10	10
[10-20[30	40
[20-40[40	80
[40-50[20	100

$D_6 = ?$

–On calcule d’abord $Cl(D_6)$: $Cl(D_6) \Leftrightarrow F[Cl(D_6)] \geq 60 \Rightarrow Cl(D_6) = [20 \ 40[$

–On calcule ensuite D_6 : $D_6 = 20 + 20 \cdot \frac{60 - 40}{40} = 30$

$C_{80} ?$

–On calcule d’abord $Cl(C_{80})$: $Cl(C_{80}) \Leftrightarrow F[Cl(C_{80})] \geq 80 \Rightarrow Cl(C_{80}) = [20 \ 40[$

–On calcule ensuite C_{80} : $C_{80} = 20 + 20 \cdot \frac{80 - 40}{40} = 40$

. Détermination graphique

. VS discrète

Reprenons la distribution précédente de la vs discrète et calculons D_4 graphiquement ?

Tableau 47 EX.22 Déciles

X_i	$f_i\%$
1	10
2	20
3	30
4	10
6	20
8	10

. Solution

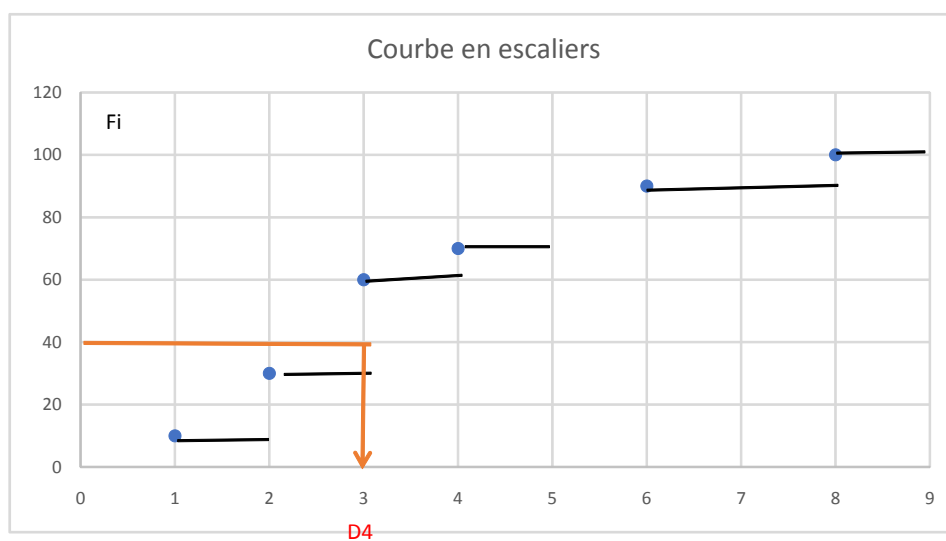
. On calcule d'abord F_i

Tableau 48 Solution EX.22

X_i	$f_i\%$	F_i
1	10	10
2	20	30
3	30	60
4	10	70
6	20	90
8	10	100

. On détermine $D_4 \leftrightarrow F(D_4) \geq 40 = 3$ puis on le fixe sur le graphe de F_i

Figure 16 Détermination graphique de D_4 : cas discret



.VS continue

Reprenons la distribution de la vs continue précédente présentée ci-dessous et calculons C_{80} graphiquement?

Tableau 49 EX.23 Centiles

cl_i	$fi\%$
[0-10[10
[10-20[20
[20-40[30
[40-45[40

. Solution

Tableau 50 Solution EX.23

cl_i	$fi\%$	Fi
[0-10[10	10
[10-20[20	30
[20-40[30	60
[40-45[40	100

. On calcule d'abord $Cl(C_{80})$: $Cl(C_{80}) \leftrightarrow F(C_{80}) \geq 80 = [40-45[$

. Ensuite, on calcule $Cl(C_{80})$: Par la méthode de l'égalité des pentes, nous obtenons :

$$(F(b)-F(a))/(b-a)=(80-F(a))/(C_{80}-40)$$

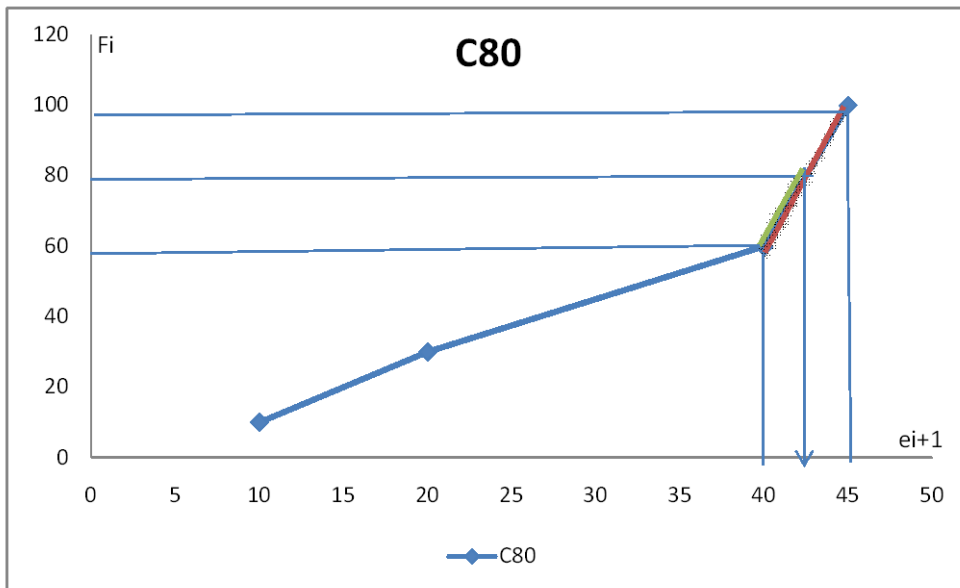
$$(C_{80}-40)/(b-a)=(80-F(a))/(F(b)-F(a))$$

Par conséquent on déduit C_{80} :

$$C_{80}=a+(b-a)(80-F(a))/(F(b)-F(a))=40+5.(80-60)/40=42.50$$

GRAPHE

Figure 17 Graphe C_{80} : cas continu



1.2.2.5 Ecart absolu moyen

Soit $X = \{(x_i, n_i)\}_{1 \leq i \leq p}$ une vs réelle.

L'**écart absolu moyen** de X est la moyenne arithmétique des valeurs absolues des écarts de X à sa moyenne : $e_a(\bar{x}) = 1/N \sum_i n_i |x_i - \bar{x}|$

L'écart absolu moyen de X par rapport à sa médiane (ou par rapport à un nombre réel a quelconque) est défini par $e_a(\text{Me}) = 1/N \sum_i n_i |x_i - x_e|$

On peut démontrer que l'écart absolu moyen par rapport à un nombre réel a est minimum lorsque a est égal à la moyenne de X .

N.B. : L'écart absolu moyen présente un inconvénient majeur : il ne se prête pas facilement aux calculs algébriques, à cause de la valeur absolue.

. EXEMPLE

. VS discrète

Soit la distribution suivante, calculer l'écart absolu par rapport à la moyenne ? puis calculer l'écart absolu par rapport à la médiane ?

Tableau 51 EX.24 Ecart absolu

X_i	n_i
5	10
10	8
15	9
20	7
30	8
40	3
	45

. Réponse

Tableau 52 Solution EX.24

X_i	n_i	$n_i X_i$	$n_i \uparrow$	$n_i X_i - \bar{X} $	$n_i X_i - Me $
5	10	50	10	120	100
10	8	80	18	56	40
15	9	135	27	18	0
20	7	140	34	21	35
30	8	240	42	104	120
40	3	120	45	69	75
	45	765		388	370

$$Me \Leftrightarrow n \uparrow (Me) \geq \frac{n+1}{2} = 23$$

$$Me = 15$$

$$Ea (Me) = 1/n \sum_i n_i |X_i - Me| = 8.22$$

$$\bar{X} = \sum_i \frac{n_i X_i}{n} = \frac{765}{45} = 17$$

$$Ea (\bar{X}) = 1/n \sum_i n_i |X_i - \bar{X}| = 8.62$$

. VS continue

Soit la distribution suivante, calculer l'écart absolu par rapport à la moyenne ? puis calculer l'écart absolu par rapport à la médiane ?

Tableau 53 EX.25 Ecart absolu

ei	ei+1	ni
5	10	10
10	15	18
15	20	40
20	30	20
30	40	8
40	45	4

. Solution

Tableau 54 Solution EX.25

e _i	e _{i+1}	cl _i	n _i	c _i	c _i - c _e	n _i c _i - c _e	n _i C _i - C̄
5	10	[5-10[10	7.5	10.25	102.5	120
10	15	[10-15[18	12.5	5.25	94.5	126
15	20	[15-20[40	17.5	0.25	10	80
20	30	[20-30[20	25	7.25	145	110
30	40	[30-40[8	35	17.25	138	124
40	45	[40-45[4	42.5	24.75	99	92
			100			589	652

$$L'e.a.(C_e) = 1/n \sum_i n_i |C_i - C_e| = 5.89$$

$$L'e.a.(\bar{C}) = 1/n \sum_i n_i |C_i - \bar{C}| = 6.52$$

1.2.2.6 Variance et écart-type

Soit $X = \{(x_i, n_i)\}_{1 \leq i \leq p}$ une vs réelle.

La **variance** de X est la moyenne arithmétique des carrés des écarts de X à sa moyenne :

$$s^2(x) = 1/N \sum_i n_i (x_i - \bar{x})^2$$

$$L'\text{écart type} = \sqrt{s^2(X)} = s(x)$$

Formule de König de la variance:

$$s^2(x) = 1/N \sum_i n_i x_i^2 - \bar{x}^2 = m_2 - m_1^2$$

Propriétés:

$$s^2(a \pm bx) = b^2 s^2(x)$$

$$s^2(a) = 0$$

. EXEMPLE

. VS discrète

Tableau 55 Calcul Algébrique de la Variance d'une vs discrète

X_i	n_i	$n_i X_i$	$n_i X_i^2$

Soit la VS discrète suivante, calculer σ^2 puis σ ?

Tableau 56 EX.26 Variance

X_i	n_i
5	2
10	3
20	1
8	2
<hr/>	
	8

. Réponse

Tableau 57 Solution EX.26

X_i	n_i	$n_i X_i$	$n_i X_i^2$
5	2	10	50
10	3	30	300
20	1	20	400
8	2	16	128
<hr/>			
	8	76	878
		$m_1 = 9.5$	$109.75 = m_2$
		$m_1^2 = 90.25$	

$$\sigma^2 = \frac{1}{n} \sum ni(X_i - \bar{X})^2 = \frac{1}{n} \sum niX_i^2 - \bar{X}^2$$

$$\sigma^2 = m_2 - m_1^2 = 109.75 - 90.25 = 19.50 \Rightarrow \sigma = 4.42$$

. VS continue

Tableau 58 Calcul Algébrique de la Variance d'une vs continue

cl _i	n _i	c _i	n _i c _i	n _i c _i ²
[e ₀ , e ₁ [
[e ₁ , e ₂ [
[e _i , e _{i+1} [

Soit la VS continue suivante, calculer σ^2 puis σ ?

Tableau 59 EX.27 Variance

cl _i	fi%
[0-10[10
[10-20[40
[20-30[40
[30-50[10

. Solution

Tableau 60 Solution EX.27

cl _i	fi%	fi	ci	fi Ci	Ci ²	fi Ci ²
[0-10[10	0.1	5	0.5	25	2.5
[10-20[40	0.4	15	6	225	90
[20-30[40	0.4	25	10	625	250
[30-50[10	0.1	40	4	1600	160

$$\sigma^2 = \frac{1}{n} \sum ni(C_i - \bar{C})^2 = \frac{1}{n} \sum_i niC_i^2 - \bar{C}^2$$

$$\sigma^2 = m_2 - m_1^2 = 502.5 - 20.5^2 = 82.25 \Rightarrow \sigma = 9.07$$

Calcul pratique de la variance

$$\text{Formule de KOENIG : } v(x) = m_2 - m_1^2 = \frac{1}{n} \sum_i n_i x_i^2 - \bar{x}^2$$

1.2.2.7 Coefficient de variation

$$cv = s(x) / \bar{x}$$

CV est un nombre sans dimension qui permet de comparer deux vs de natures différentes. On remarquera que, au signe près, c'est l'écart type de la vs x/\bar{x} .

. EXEMPLE

Soient les caractéristiques suivantes de deux distributions statistiques :

$$\sigma_1^2 = 4.16 \quad \bar{X}_1 = 16$$

$$\sigma_2^2 = 7.84 \quad \bar{X}_2 = 12$$

Comparer ces deux distributions du point de vue dispersion ?

. Solution

Parce que les moyennes des deux distributions sont différentes, la comparaison se fait par l'intermédiaire des coefficients de variations :

$$CV_1 = \frac{\sigma_1}{\bar{X}_1} = 0.13 \text{ (ou 13\%)} \quad CV_2 = \frac{\sigma_2}{\bar{X}_2} = 0.23 \text{ (ou 23\%)}$$

Parce que $CV_1 < CV_2$: la distribution '1' est meilleure que la distribution '2' de point vue dispersion.

1.2.2.8 Moments

Soit x une vs réelle.

Le **moment simple d'ordre r** de x : $m_r = 1/N \sum_i x_i^r$

$$r=0 : m_0 = 1.$$

$$r=1 : m_1 = \bar{x}$$

$$r=2 : m_2 = 1/N \sum_i x_i^2$$

Le **moment centré d'ordre r** : $\mu_r = 1/N \sum_i (x_i - \bar{x})^r$

$$r=0 : \mu_0 = 1.$$

$$r=1 : \mu_1 = 0.$$

$$r=2 : \mu_2 = s^2(X) = m_2 - m_1^2$$

. EXEMPLE

. VS discrète

. Série numérique

Soit la série numérique suivante, calculer les moments simples m_2, m_3 et m_4 puis les moments centrés μ_1, μ_2 et μ_3 ?

$$X_i = 2, 4, 8, 6$$

. Solution

Tableau 61 Solution Moments

X_i	X_i^2	x_i^3	x_i^4	μ_1	μ_2	μ_3
2	4	8	16	-3	9	-27
4	16	64	256	-1	1	-1
8	64	512	4096	3	9	27
6	36	216	1296	1	1	1
	120	800	5664	0	20	0
	30	200	1416	0	5	0

$$m_2 = 30$$

$$m_3 = 200$$

$$m_4 = 1416$$

$$\mu_1 = 0$$

$$\mu_2 = 5$$

$$\mu_3 = 0$$

. Série classée

Soit la distribution suivante, calculer les moments simples m_2 , m_3 et m_4 puis les moments centrés μ_2 , μ_3 et μ_4 ?

Tableau 62 EX.28 Moments

X_i	n_i
5	2
10	3
20	1
8	2

. Solution

Tableau 63 Solution EX.28

X_i	n_i	$n_i X_i$	$n_i X_i^2$	$n_i X_i^3$	$n_i X_i^4$	$(X_i - \bar{X})$	$n_i (X_i - \bar{X})^2$	$n_i (X_i - \bar{X})^3$	$n_i (X_i - \bar{X})^4$
5	2	10	50	250	1250	-4.5	40.5	-182.5	820.125
10	3	30	300	3000	30000	0.5	0.75	0.375	0.1875
20	1	20	400	8000	160000	10.5	110.25	1157.625	12155.0625
8	2	16	128	1024	8192	-1.5	4.5	-6.75	10.125
	8	76	878	12274	199442		156	968.75	12985.5
		9.5	109.8	1534	24930		19.5	121.09375	1623.1875

$$m_2 = \frac{\sum_i n_i X_i^2}{n} = \frac{878}{8} = 109.8 \quad m_3 = \frac{\sum_i n_i X_i^3}{n} = \frac{12274}{8} = 1534 \quad m_4 = \frac{\sum_i n_i X_i^4}{n} = \frac{199442}{8} = 24930$$

$$\mu_2 = \frac{\sum_i n_i (X_i - \bar{X})^2}{n} = \frac{156}{8} = 19.5 \quad \mu_3 = \frac{\sum_i n_i (X_i - \bar{X})^3}{n} = \frac{968.75}{8} = 121.1 \quad \mu_4 = \frac{\sum_i n_i (X_i - \bar{X})^4}{n} = \frac{12985.5}{8} = 1623.2$$

. VS continue

Soit la VS continue suivante, calculer les moments simples m_1 , m_2 et m_3 puis les moments centrés μ_1 , μ_2 puis μ_3 ?

Tableau 64 EX.29 Moments

ei	ei+1	ni
0	10	1
10	20	2
20	30	4
30	40	3
10		

. Solution

Tableau 65 Solution EX.29

ei	ei+1	ni	Ci	ni Ci	ni C ² i	ni C ³ i	μ_1	μ_2	μ_3
0	10	1	5	5	25	125	-19	361	-6859
10	20	2	15	30	450	6750	-18	162	-1458
20	30	4	25	100	2500	62500	4	4	4
30	40	3	35	105	3675	128625	33	363	3993
		10		240	6650	198000	0	890	-4320
				24	665	19800	0	89	-432

$$m_1 = 24$$

$$m_2 = 665$$

$$m_3 = 19800$$

$$\mu_1 = 0$$


$$\mu_2 = 89$$

$$\mu_3 = -432$$

1.2.3 PARAMETRES DE CONCENTRATION


1.2.3.1 Courbe de Lorenz

Figure 18 Courbe de Lorenz



1.2.3.2 Indice de Gini

Figure 19 Indice de Gini



L'indice de Gini permet de mesurer les inégalités scolaires, les inégalités de statut, les inégalités de salaires, etc.

1.2.3.3 Médiale

La **médiale** d'une variable statistique X est la valeur de X qui partage la masse globale en deux parties égales.

Figure 20 Médiale





Figure 21 Médiane



. EXEMPLE

. VS discrète

Soit la distribution de 25 entreprises selon le chiffre d'affaires, calculer la médiane 'Me', la médiale 'M_I' puis le coefficient de concentration 'Ic' ?

Tableau 66 EX.30 Ic

X_i	n_i
2	10
3	6
4	4
5	3
7	2
25	

Solution

Tableau 67 Solution EX.30

Xi	ni	ni↑	niXi	niXi↑	fi	Fi	(niXi) r	Mi	Fi-Fi-1	Mi+Mi-1 *	
2	10	10	20	20	0.40	0.4	0.24	0.24	0.40	0.24	0.10
3	6	16	18	38	0.24	0.64	0.22	0.46	0.24	0.70	0.17
4	4	20	16	54	0.16	0.80	0.19	0.65	0.16	1.11	0.18
5	3	23	15	69	0.12	0.92	0.18	0.83	0.12	1.48	0.18
7	2	25	14	83	0.08	1.00	0.17	1.00	0.08	1.83	0.15
	25		83								0.76

$$Me \Leftrightarrow n \uparrow (Me) \geq \frac{n}{2}$$

$$Me \Leftrightarrow n \uparrow (Me) \geq 12.5 \Rightarrow Me = 3 \text{ u.m.}$$

$$Ml \Leftrightarrow n \uparrow (Ml) \geq \frac{ni \text{ ci}}{2}$$

$$Ml \Leftrightarrow n \uparrow (Ml) \geq 41.5 \Rightarrow Ml = 4 \text{ u.m}$$

$$(Fi-Fi-1) (Mi+Mi-1) = 0.76$$

$Ic = 1 - 0.76 = 0.24$: La concentration du chiffre d'affaires est faible.

. VS continue

Soit la distribution de 36 ouvriers d'une entreprise selon le salaire perçu. Calculer la médiane 'Me', la médiale 'M_l' puis le coefficient de concentration 'Ic' ?

Tableau 68 EX.31 Ic

ei	ei+1	Ci	ni
1	1.4	1.2	10
1.4	1.6	1.5	12
1.6	2.4	2	6
2.4	2.6	2.5	3
2.6	3.4	3	3
3.4	4.6	4	2
36			

.Solution

Tableau 69 Solution1 EX.31

ei	ei+1	Ci	ni	ni↑	niCi	niCi↑	fi	fi↑	(nici)r	(nici)r↑
1	1.4	1.2	10	10	12	12	0.28	0.28	0.18	0.18
1.4	1.6	1.5	12	22	18	30	0.33	0.61	0.27	0.45
1.6	2.4	2	6	28	12	42	0.17	0.78	0.18	0.63
2.4	2.6	2.5	3	31	7.5	49.5	0.08	0.86	0.11	0.74
2.6	3.4	3	3	34	9	58.5	0.08	0.95	0.14	0.88
3.4	4.6	4	2	36	8	66.5	0.06	1.00	0.12	1.00
				36	66.5					

$$CLe \Leftrightarrow n \uparrow (CLe) \geq \frac{n}{2}$$

$$CLe \Leftrightarrow n \uparrow (CLe) \geq 18 \Rightarrow CLe = [1.4 \ 1.6[$$

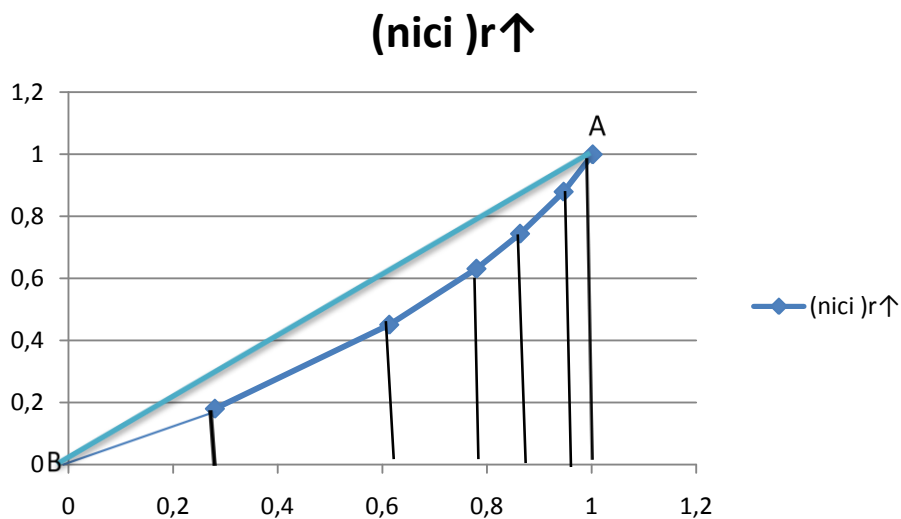
$$Me = 1.4 + 0.2 * \frac{18 - 10}{12} = 1.53 \text{ u.m.}$$

$$CL_{ml} \Leftrightarrow n \uparrow (CL_{ml}) \geq \frac{ni \ ci}{2}$$

$$CL_{ml} \Leftrightarrow n \uparrow (CL_{ml}) \geq 33.25 \Rightarrow CL_{ml} = [1.6 \ 2.4[$$

$$Ml = 1.6 + 0.8 * \frac{33.25 - 30}{12} = 1.82 \text{ u.m.}$$

Figure 22 Coefficient de concentration Ic



. Coefficient de concentration ' Ic '

. Méthode 1

$$C = \frac{\text{surface } S}{\text{surface du triangle } OAB}$$

$$\begin{aligned} \text{Surface du triangle } OAB &= \frac{0.28 \cdot 0.18}{2} + \frac{(0.18 + 0.45) \cdot (0.61 - 0.28)}{2} + \frac{(0.45 + 0.63) \cdot (0.78 - 0.61)}{2} \\ &+ \frac{(0.63 + 0.74) \cdot (0.86 - 0.78)}{2} + \frac{(0.74 + 0.88) \cdot (0.95 - 0.86)}{2} + \frac{(0.88 + 1) \cdot (1 - 0.95)}{2} = 0.0252 + \\ &0.010395 + 0.0918 + 0.0548 + 0.0729 + 0.047 = 0.39565 \end{aligned}$$

$$\text{Surface } S = \frac{1}{2} - 0.39565 = 0.10435$$

$$C = \frac{0.10435}{0.5} = 0.2087$$

. Méthode 2

Tableau 70 Solution2 EX.31

ei	ei+1	Ci	ni	ni↑	niCi	niCi↑	fi	Fi	(nici)r	Mi	Fi-Fi-1	Mi+Mi-1	*
1	1.4	1.2	10	10	12	12	0.28	0.28	0.18	0.18	0.28	0.18	0.05
1.4	1.6	1.5	12	22	18	30	0.33	0.61	0.27	0.45	0.33	0.63	0.21
1.6	2.4	2	6	28	12	42	0.17	0.78	0.18	0.63	0.17	1.08	0.18
2.4	2.6	2.5	3	31	7.5	49.5	0.08	0.86	0.11	0.744	0.08	1.38	0.11
2.6	3.4	3	3	34	9	58.5	0.08	0.95	0.14	0.879	0.08	1.62	0.14
3.4	4.6	4	2	36	8	66.5	0.06	1.00	0.12	1.00	0.06	1.88	0.10
				36	66.5								0.80

$$\begin{aligned} (Fi-Fi-1) (Mi+Mi-1) &= \\ 0.28 \cdot 0.18 + 0.63 \cdot 0.33 + 0.17 \cdot 1.08 + 0.08 \cdot 1.37 + 0.09 \cdot 1.62 + 0.05 \cdot 1.88 &= 0.0504 + 0.2 \\ 079 + 0.1836 + 0.1096 + 0.1458 + 0.094 &= 0.7913 \end{aligned}$$

Ic = 1 - 0.7913 = 0.2087 : Nous concluons que la concentration des salaires est faible

1.2.4 PARAMETRES DE FORME

1.2.4.1 Coefficient d'asymétrie (skewness)

$$\text{PEARSON : } P = \frac{x - m_0}{s(x)}$$

YULE : $Y = \frac{Q1 + Q3 - 2m_e}{2(Q3 - Q1)}$


FISHER : $F_1 = \frac{\mu_3}{s^3}$

$F_1 > 0$ courbe étalée à droite

$F_1 < 0$ courbe étalée à gauche


$F_1 > 0$

Figure 23 Skewness



$F_1 < 0$

Figure 24 Kurtosis



1.2.4.2 Coefficient d'aplatissement (kurtosis)

$$F_2 = \frac{\mu_4}{s^4}$$

$F_2 > 3$ courbe moins aplatie que $N(0,1)$

$F_2 < 3$ courbe plus aplatie que $N(0,1)$

Figure 25 $KURTOSIS < 0$





Figure 26 $KURTOSIS > 0$



. EXEMPLE

. VS discrète

Soit la distribution de 40 élèves selon la note obtenue en math (sur 10), tester l'asymétrie et l'aplatissement au moyen des paramètres de forme de Fisher F_1 et F_2 ?

Tableau 71 EX.32 F_1, F_2

Notes	nombre d'élèves
4	1
5	3
6	6
7	15
8	12
9	3
	40

. Solution

Tableau 72 Solution EX.32

X_i	n_i	$n_i x_i$	$n_i x_i^2$	$n_i (X_i - \bar{X})^3$	$n_i (X_i - \bar{X})^4$
4	1	4	16	-29.22	89.99
5	3	15	75	-27.00	56.15
6	6	36	216	-7.56	8.16
7	15	105	735	-0.01	0.00
8	12	96	768	9.34	8.60
9	3	27	243	21.23	40.77
	40	283	2053	-33.20	203.67
		7.08	51.33	-0.83	5.09

$$\sigma = \sqrt{m_2 - m_1^2} = \sqrt{51.33 - 7.08^2} = \sqrt{1.20} = 1.1$$

$$\sigma^3 = 1.33$$

$$\sigma^4 = 1.46$$

$$\mu_3 = 1/n \sum_i n_i (X_i - \bar{X})^3 = 1/40 * -33.20 = -0.83$$

$$F_1 = \frac{\mu_3}{\sigma^3} = \frac{-0.83}{1.33} = -0.62$$

$F_1 = -0.62 < 0$: La distribution est ainsi asymétrique à gauche.

$$\mu_4 = 1/n \sum_i n_i (X_i - \bar{X})^4 = 1/40 * 203.67 = 5.09$$

$$F_2 = \frac{\mu_4}{\sigma^4} - 3 = \frac{5.09}{1.46} - 3 = 0.49$$

$F_2 > 0$: la distribution est platykurtique.

. VS continue

Soit la distribution suivante d'une vs continue, tester l'asymétrie et l'aplatissement au moyen des paramètres de forme de Fisher F_1 et F_2 ?

Tableau 73 EX.33 F_1, F_2


cl_i	ni
[0-10[2
[10-20[3
[20-30[4
[30-40[1
	10

. Solution

Tableau 74 Solution EX.33

cl_i	ni	Ci	$niCi$	$(c - \bar{c})$	$(c - \bar{c})^3$	$(c - \bar{c})^4$	$ni(C - \bar{C})^3$	$ni(C - \bar{C})^4$	$niCi^2$
[0-10[2	5	10	-14	-2744	38416	-5488	76832	50
[10-20[3	15	45	-4	-64	256	-192	768	675
[20-30[4	25	100	6	216	1296	864	5184	2500
[30-40[1	35	35	16	4096	65536	4096	65536	1225
	10		190				-720	148320	4450
			19						

Figure 27 Histogramme et courbe de fréquence



$$m_2 = \frac{4450}{10} = 445 \quad m_1 = \frac{190}{10} = 19 \quad \sigma^2 = m_2 - m_1^2 = 445 - 19^2 = 84 \quad \sigma = 9.16$$

$$\sigma^3 = 768.57 \quad \sigma^4 = 7056$$

$$\mu_3 = -72 \quad F_1 = \frac{\mu_3}{\sigma^3} = \frac{-72}{768.57} = -0.09$$

$$\mu_4 = 14832 \quad F_2 = \frac{\mu_4}{\sigma^4} - 3 = \frac{14832}{7056} - 3 = 2.10 - 3 = -0.90$$

$F_1 = -0.9 < 0$: la courbe est asymétrique à gauche

$F_2 = -0.9 < 0$: la courbe est platykurtique.

CH2. STATISTIQUE BIVARIEE

Soit une population Ω de taille n décrite simultanément par rapport à deux caractères x et y respectivement de k et p modalités.

2.1 Distribution conjointe

L'effectif partiel d'un couple (x_i, y_j) est le nombre $n_{ij} = \text{card}(x=x_i \cap y=y_j)$.

La distribution des effectifs est l'application qui à tout couple (x_i, y_j) associe son effectif partiel $n_{ij} : (x_i, y_j) \rightarrow n_{ij}$

La distribution marginale d'effectif du couple (x_i, y_j) est 1 distribution d'effectif de x_i d'une part et une distribution d'effectif de y_j d'autre part :

$$X_i \rightarrow \text{card}(x=x_i, \forall y_j)$$

$$Y_j \rightarrow \text{card}(y=y_j, \forall x_i)$$

Tableau de contingence

C'est un tableau à double entrée représentant la distribution conjointe du couple (X_i, Y_j)

Tableau 75 Tableau de cotingence

	y_1	y_j	y_p	
x_1	n_{11}	n_{1j}	n_{1p}	$n_{1.}$
x_i	n_{i1}	n_{ij}	n_{ip}	$n_{i.}$
x_k	n_{k1}	n_{kj}	n_{kp}	$n_{k.}$
	$n_{.1}$	$n_{.j}$	$n_{.p}$	$n_{..} = n$

n_{ij} : effectif des éléments ayant le caractère i et le caractère j

$n_{i.}$: effectif des éléments ayant le caractère $i = \sum_j n_{ij}$

$n_{.j}$: effectif des éléments ayant le caractère $j = \sum_i n_{ij}$

$$n_{..} = \sum_i \sum_j n_{ij} = \sum_i n_{i.} = \sum_j n_{.j} = n$$

Partant de la définition de la fréquence $f_{ij} = \frac{n_{ij}}{n_{..}}$; $\sum_i \sum_j f_{ij} = 1$, le tableau des fréquences s'ensuit :

Tableau 76 Tableau des Fréquences conjointes

	y_1	y_i	y_p	
x_1	f_{11}	f_{1i}	f_{1p}	$f_{1.}$
x_i	f_{i1}	f_{ij}	f_{ip}	$f_{i.}$
x_k	f_{k1}	f_{ki}	f_{kp}	$f_{k.}$
	$f_{.1}$	$f_{.j}$	$f_{.p}$	1

. EXEMPLE

Soit la distribution de 20 travailleurs selon le salaire X et l'âge Y.

Tableau 77 EX.34 Tableau des fréquences conjointes

$\begin{matrix} Y \\ X \end{matrix}$	25	35	45	55	$n_{i.}$
3	3	1	1	0	5
5	1	5	0	0	6
7	0	1	3	0	4
9	0	0	1	2	3
11	0	0	2	0	2
$n_{.j}$	4	7	7	2	20

1. Déterminer et interpréter n_{22} , n_{32} ?

2. Déterminer et interpréter f_{23} , f_{34} et f_{44} ?

Solution

1. $n_{22}=5$ 5 ouvriers ont un salaire de 5 DA et un âge de 35 ans

$n_{32}=1$ 1 ouvrier a un salaire de 7 DA et un âge de 35 ans

2.

$\begin{matrix} Y \\ X \end{matrix}$	25	35	45	55	$f_{i.}$
3	0.15	0.05	0.05	0	0.25
5	0.05	0.25	0	0	0.3
7	0	0.05	0.15	0	0.2
9	0	0	0.05	0.1	0.15
11	0	0	0.1	0	0.1
$f_{.j}$	0.2	0.35	0.35	0.1	1

$f_{21}=0.05$: 5% des ouvriers ont un salaire de 5 DA et l'âge de 25 ans.

$f_{44}=0.1$: 10% des ouvriers ont un salaire de 11 DA et l'âge de 55 ans.

2.2 Distributions marginales

$$f_{i.} = n_{i.} / n_{..} ; \sum_i f_{i.} = 1 \quad f_{.j} = n_{.j} / n_{..} ; \sum_j f_{.j} = 1$$

Tableau 78 Tableau des Fréquences marginales des X_i

Modalités du caract. x_i	Effectif marginal	Fréquence marginale
x_1	$n_{1.}$	$f_{1.}$
x_i	$n_{i.}$	$f_{i.}$
x_k	$n_{k.}$	$f_{k.}$
\sum	$n_{..}$	1

Tableau 79 Tableau des Fréquences marginales des Y_j

Modalités du caract. y_i	Effectif marginal	Fréquence marginale
y_1	$n_{.1}$	$f_{.1}$
y_i	$n_{.2}$	$f_{.2}$
y_p	$n_{.p}$	$f_{.p}$
\sum	$n_{..}$	1

Caractéristiques des distributions marginales

$$\bar{x} = 1/n_{..} \sum_i n_{i.} x_i = \sum_i f_{i.} x_i \quad \bar{y} = 1/n_{..} \sum_j n_{.j} y_j = \sum_j f_{.j} y_j$$

$$v(x) = 1/n_{..} \sum_i n_{i.} x_i^2 - \bar{x}^2 \quad v(y) = 1/n_{..} \sum_j n_{.j} y_j^2 - \bar{y}^2$$

Selon la formule de définition :

$$v(x) = 1/n_{..} \sum_i n_{i.} (x_i - \bar{x})^2 = \sum_i f_{i.} (x_i - \bar{x})^2 \quad v(y) = 1/n_{..} \sum_j n_{.j} (y_j - \bar{y})^2 = \sum_j f_{.j} (y_j - \bar{y})^2$$

. EXEMPLE

1. Etablir les tableaux des effectifs marginaux et des fréquences marginales de x_i et de y_j ?

Déterminer et interpréter $n_{2.}$, $f_{2.}$, $n_{.4}$, $f_{.4}$, $n_{..}$ et $f_{..}$?

2. Calculer les moyennes marginales de x_i et d' y_j ?

3. Calculer les variances marginales de x_i et d' y_j ?

1a. Distribution marginale de X

$X \backslash$	$n_{i.}$	$f_{i.}$
3	5	0.25
5	6	0.3
7	4	0.2
9	3	0.15
11	2	0.1
$n_{..}$	20	1

1b. Distribution marginale de Y

$Y \backslash$	25	35	45	55	$n_{..}$
$n_{.j}$	4	7	7	2	20
$f_{.j}$	0.2	0.35	0.35	0.1	1

$$n_{2.} = 6$$

$$f_{2.} = 0.3$$

$$n_{.4} = 2$$

$$f_{.4} = 0.1$$

$$f_{..} = 1$$

$$n_{..} = 20$$

$$2. \bar{X} = \sum_{i=1}^5 f_{i\cdot} \times x_i = \frac{5 \times 3 + 6 \times 5 + 4 \times 7 + 3 \times 9 + 2 \times 11}{20} = 6.10 \text{ DA}$$

$$\bar{Y} = \sum_{j=1}^4 f_{\cdot j} \times y_j = \frac{4 \times 25 + 7 \times 35 + 7 \times 45 + 2 \times 55}{20} = 38.5 \text{ ANS}$$

3.

$$\sigma_x^2 = \sum_{i=1}^5 f_{i\cdot} (x_i - \bar{x})^2 = \left(\sum_{i=1}^5 f_{i\cdot} (x_i)^2 \right) - (\bar{x})^2 = \frac{5 \times 3^2 + 6 \times 5^2 + 4 \times 7^2 + 3 \times 9^2 + 2 \times 11^2}{20} - (6.10)^2 = 6.59 \text{ DA}^2 \quad \sigma = 2.5 \text{ ans}$$

$$\sigma_y^2 = \sum_{j=1}^4 f_{\cdot j} (y_j - \bar{y})^2 = (0.2 \times 25^2 + 0.35 \times 35^2 + 0.35 \times 45^2 + 0.1 \times 55^2) - (38.5)^2 = 82.75 \text{ da}^2 \quad \sigma = 9 \text{ ans}$$

2.3 Distributions conditionnelles

$$\mathbf{f}_i^j = \frac{n_{ij}}{n_{\cdot j}} \quad \sum_i f_i^j = 1 \quad \mathbf{f}_j^i = \frac{n_{ij}}{n_{i\cdot}} \quad \sum_j f_j^i = 1$$

Tableau 80 Tableau des Fréquences conditionnelles X_i

Modalités caract. x_i	effectif	Fréquence conditionnelle
x_1	n_{1j}	f_1^j
x_i	n_{ij}	f_i^j
x_k	n_{kj}	f_k^j
\sum	$n_{\cdot j}$	1

Tableau 81 Tableau des fréquences conditionnelles Y_j

Modalités caract. y_j	effectif	Fréquence conditionnelle
y_1	n_{i1}	f_1^i
y_j	n_{i2}	f_2^i
Y_p	n_{ip}	f_p^i
\sum	$n_{i\cdot}$	1

$$\frac{n_{ij}}{n_{\cdot\cdot}} = \frac{n_{i\cdot}}{n_{\cdot\cdot}} \frac{n_{ij}}{n_{i\cdot}} = \frac{n_{\cdot j}}{n_{\cdot\cdot}} \frac{n_{ij}}{n_{\cdot j}} \Leftrightarrow \mathbf{f}_{ij} = \mathbf{f}_{i\cdot} \mathbf{f}_j^i = \mathbf{f}_{\cdot j} \mathbf{f}_i^j \quad p(ab) = p(a) p(b/a)$$

Caractéristiques des distributions conditionnelles

$$\bar{x}_j = \frac{1}{n_{.j}} \sum_i n_{ij} x_i = \sum_i f_i^j x_i \quad \bar{y}_i = \frac{1}{n_{i.}} \sum_j n_{ij} y_j = \sum_j f_j^i y_j$$

$$v_j(x) = \frac{1}{n_{.j}} \sum_i n_{ij} x_i^2 - \bar{x}_j^2 \quad v_i(y) = \frac{1}{n_{i.}} \sum_j n_{ij} y_j^2 - \bar{y}_i^2$$

Selon la formule de définition :

$$v_j(x) = \frac{1}{n_{.j}} \sum_i n_{ij} (x_i - \bar{x}_j)^2 = \sum_i f_i^j (x_i - x_j)^2$$

$$v_i(y) = \frac{1}{n_{i.}} \sum_j n_{ij} (y_j - \bar{y}_i)^2 = \sum_j f_j^i (y_j - y_i)^2$$

. Relation entre \bar{x} et \bar{x}_j ; $v(x)$ et $v_j(x)$

$$\bar{x} = \sum_j f_{.j} \bar{x}_j$$

$$\bar{y} = \sum_i f_{i.} \bar{y}_i$$

$$v(x) = \sum_j f_{.j} v_j(x) + \sum_j f_{.j} (\bar{x}_j - \bar{x})^2 \quad v(y) = \sum_i f_{i.} v_i(y) + \sum_i f_{i.} (\bar{y}_i - \bar{y})^2$$

. **EXEMPLE**

1. Calculer les moyennes conditionnelles de x_i et d' y_j ?

2. Calculer les variances conditionnelles de x_i et d' y_j ?

Solution

1a. Distribution conditionnelle de X sachant $Y=35$ ans

X	n_{i2}	$f_i^2 = \frac{n_{i2}}{n_{.2}}$
3	1	$\frac{1}{7}$
5	5	$\frac{5}{7}$
7	1	$\frac{1}{7}$
9	0	0
11	0	0
Σ	7	1

$$\bar{x}_2 = \sum_{i=1}^5 f_i^2 x_i = \frac{1 \times 3 + 5 \times 5 + 1 \times 7}{7} = 5 \text{ DA}$$

1b. Distribution conditionnelle de Y sachant X=3 DA

Y	n_{ij}	$f_j^1 = \frac{n_{1j}}{n_{1\cdot}}$
25	3	$\frac{3}{5}$
35	1	$\frac{1}{5}$
45	1	$\frac{1}{5}$
55	0	0
Σ	5	1

$$\bar{y}_1 = \sum_{j=1}^4 f_j^1 y_j = \frac{3 \times 25 + 1 \times 35 + 1 \times 45}{5} = 31 \text{ ans}$$

$$2a. V_2(x) = \sum_{i=1}^5 f_i^2 x_i^2 - (\bar{x}_2)^2 = \frac{1 \times 3^2 + 5 \times 5^2 + 1 \times 7^2}{7} - 5^2 = 1.143 \text{ DA}^2$$

$$2b. V_1(y) = \sum_{j=1}^4 f_j^1 y_j^2 - (\bar{y}_1)^2 = \frac{3 \times 25^2 + 1 \times 35^2 + 1 \times 45^2}{5} - 31^2 = 64 \text{ ans}^2$$

2.4 Indépendance

$$x_i y \Leftrightarrow f_i^j = f_i \quad p(a/b) = p(a)$$

$$x_i y \Leftrightarrow \forall i, i=1, k \quad f_i^1 = f_i^j = f_i^k \Leftrightarrow \frac{ni1}{n.1} = \frac{nij}{n.j} = \frac{nik}{n.k} = \frac{ni1 + nij + nik}{n.1 + n.j + n.k} = \frac{ni.}{n..} \text{ cad } \frac{nij}{n.j} = \frac{ni.}{n..} \text{ ou}$$

$$f_i^j = f_i. \text{ cad } A / B_j = A$$

Considérons :

$f_{ij} = f_{i.} f_{.j} = f_{i.} f_{.j}$ lorsque x et y sont indépendantes, on a $f_{i.} = f_{i.}$ d'où $f_{.j} = f_{.j}$ et

$$f_{ij} = f_{i.} f_{.j} \quad p(ab) = p(a) \cdot p(b)$$

car $f_{ij} = \frac{n_{i.} n_{.j}}{n^2}$ (les lignes (ou les colonnes) sont proportionnelles entre elles)

x lié fonctionnellement à $y : \forall i, j \rightarrow i = \theta(j)$ est unique

. EXEMPLE

$$X \text{ et } Y \text{ indépendantes} \Leftrightarrow n_{ij} = n_{i.} \cdot n_{.j}$$

Soit $i=3$ et $j=2 : n_{32} = n_{3.} \cdot n_{.2} ?$

$1 \times 20 \neq 4 \times 7 \Rightarrow X$ n'est pas indépendante de Y

Coefficient de régression

Décomposition de $v(x)$

$$v(y) = \sum_i f_{i.} v_i(y) + \sum_i f_{i.} (\bar{y}_i - \bar{y})^2$$

var.moyenne = var.résiduelle + var.expliquée par l'hétérogénéité des var

var.totale = var.résiduelle + var. expliquée par la régression

2.5 Représentation graphique

i. Deux caractères qualitatifs : tuyaux d'orgues, graphes semi-circulaires ou

graphe en anneaux

Soit le tableau de contingence ci-dessous représentant la distribution des travailleurs selon leur statut et la branche économique, représenter graphiquement cette distribution ?

- tuyaux d'orgues


Tableau 82 EX.35 Tableau de contingence de 2 variables qualitatives

	Salariés	Patrons	Trav.Familiaux	
Agriculture	95	30	125	250
Industrie	160	25	100	285
Commerce	100	40	90	230
Fonction				
Pub	60	0	0	60
Services	80	15	70	165
Total	495	110	385	990

Tableau 83 EX.36 Tableau de contingence en %

	Salariés	Patrons	Trav.Familiaux	
Agriculture	19%	27%	32%	25%
Industrie	32%	23%	26%	29%
Commerce	20%	36%	23%	23%
Fonction				
Pub	12%	0%	0%	6%
Services	16%	14%	18%	17%
Total	100%	100%	100%	100%

Figure 28 Graphe de deux variables qualitatives



- Graphique semi-circulaire

Figure 29 Graphe semi-circulaire relatif aux salariés


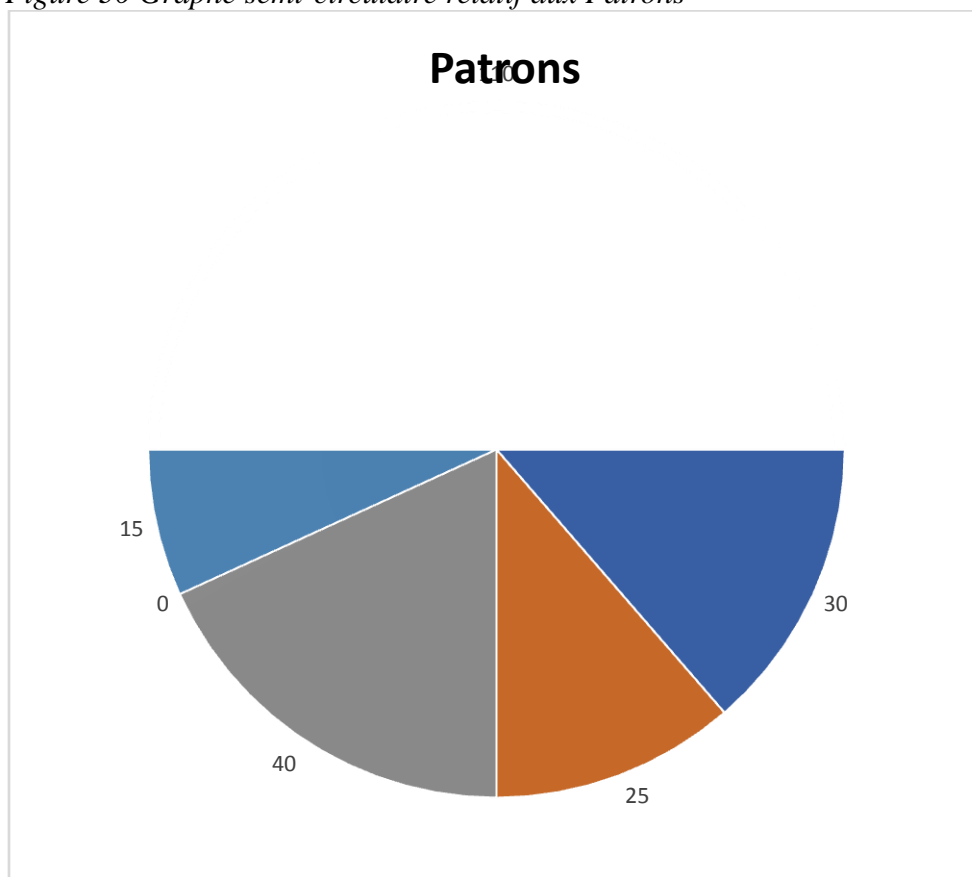



Figure 30 Graphe semi-circulaire relatif aux Patrons



- Graphe en Anneaux

Il constitue une variante du graphique circulaire.

Figure 31 Graphe en anneaux



ii. variables mixtes

-1 caractère qualitatif et 1 caractère quantitatif discret : diagramme en bâtons (1) ou tuyaux d'orgue(2)

(1) : en Y, 1 modalité du caractère qualitatif ; en X, les modalités du caractère quantitatif discret

(2) : en X, les modalités du caractère quantitatif discret (base de chaque tuyau d'orgue) ; en Y, les modalités du caractère qualitatif (fi%)

. EXEMPLE


Soit la distribution suivante des logements selon le nombre de pièces et en fonction du statut d'occupation, donner la représentation graphique appropriée ?

Tableau 84 EX.37 Tableau de contingence

	2	3	4	5
Propriétaires	1	4	5	5
Locataires	2	5	4	4
Autres	2	1	6	1
	5	10	15	10


Pour le graphe en tuyau d'orgue, on saisit en X les modalités du caractère quantitatif et en Y les modalités du caractère qualitatif

Figure 32 Graphe1 quantitatif & qualitatif



Ou on trace en X les modalités du caractère qualitatif et en Y les modalités du caractère quantitatif.

Figure 33 Graphe2 qualitatif & quantitatif




. On peut illustrer une table de contingence variable qualitative – variable quantitative par un diagramme Box plots (boîte à moustaches) : en abscisse on saisit les modalités de la variable qualitative et en ordonnée les valeurs de la variable quantitative.

Tableau 85 EX.38 Distribution des pointures en fonction de l'origine

origine	taille
m	26
p	40
m	31
m	29
p	33
m	30
m	29
m	28
m	29
m	33
m	32
m	31
.	.

Source : Wibinar Xlstat

Figure 34 Graphe Boîte à moustache



Source : Wibinar Xlstat


- 1 caractère qualitatif et 1 caractère quantitatif continue : tuyaux d'orgue

En X, les modalités du caractère quantitatif continue (base de chaque tuyau d'orgue) ; en Y, le caractère qualitatif ($f_i\%$ ↑) ;

Tableau 86 EX.39 Tableau de contingence

AGE \ VILLE	LYON	MARSEILLE	NANTES	PARIS
23-34	1	2	1	0
35-44	2	0	0	3
45-54	0	3	2	2
55-64	0	0	1	0
65-74	1	0	1	1

Figure 35 Graphe qualitatif et quantitatif continue



iii. Variables quantitatives


- 2 caractères discrets: nuage de points

Pour une variable quantitative, discrète ou continue, on peut utiliser une représentation par un **nuage de points** dans un plan. On peut remplacer chaque point par un **cercle** délimitant une **aire proportionnelle à l'effectif ou à la fréquence**.

Tableau 87 EX.40 Tableau de 2 variables quantitatives

X_i	Y_i
22	10
22.5	13
23	17
23.5	19
24	21
115	80

Figure 36 Graphe en nuage de points



- 2 caractères continus : stéréogramme


. EXEMPLE

Mariages célébrés en 1962, suivant l'âge des époux (1e colonne : âge de l'époux, 1e ligne : âge de l'épouse).

Tableau 88 EX.41 Tableau de contingence de 2 variables continues

	<20	20-25	25-30	30-35	35-40	40-50	>50
<20	6756	3051	180	15	3	3	0
20-25	29416	84556	13430	1205	168	50	10
25-30	15893	54978	22774	3890	651	113	14
30-35	1789	8289	7809	4111	1021	244	15
35-40	255	1304	1996	2078	1232	362	20
40-50	66	283	447	733	852	697	120
>50	6	46	59	83	145	336	472

Figure 37 Graphe d'1 distribution de 2 variables continues




Le volume de chaque parallélépipède est proportionnel à l'effectif

iv. Autres représentations

D'autres représentations sont citées en littérature entre autres la représentation en étoile et la représentation triangulaire ci-dessous.

Figure 38 Graphe triangulaire



2.6 Covariance, corrélation et régression

Dans l'étude de la dépendance entre 2 variables quantitatives X et Y, on se pose trois questions fondamentales :

-X et Y sont-ils liés, comment mesurer cette liaison ?

-Trouver une fonction qui permet de déterminer Y à partir de X

-Estimer les paramètres de cette fonction ?

Évaluer la liaison entre X et Y de manière à mettre en évidence

-le « sens » de la liaison ;

- la « force » de la liaison

. Covariance

cov(x,y) mesure la dépendance ou non dépendance entre x et y:

cov(x,y)= m_{xy}=

$$\frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{n} = \frac{\sum x_i y_i}{n} - \bar{x} \bar{y}.$$

cov(x,y)=0 \Leftrightarrow x, y indépendants
--

.Coefficient de corrélation

Le coeff. de corrélation **r** mesure le pouvoir explicatif du modèle.

Il met en i/i la dispersion expliquée par le modèle et la dispersion totale du modèle

$\mathbf{r} = \frac{\text{cov}(x, y)}{\sigma_x \sigma_y} = \frac{\sum_i x_i y_i - n \bar{x} \bar{y}}{\sqrt{(\sum_i x_i^2 - n \bar{x}^2)(\sum_i y_i^2 - n \bar{y}^2)}}$
--

. EXEMPLE

Sur la base tableau 76 des fréquences conjointes repris ci-dessous, calculer la covariance [cov (X, Y)] entre le salaire et l'âge, la corrélation [r(X,Y)] et l'équation de la droite de régression linéaire Y=aX+b ?

Tableau 89 EX.42 Tableau1 de contingence

$X \backslash Y$	25	35	45	55	$n_{i.}$
3	3	1	1	0	5
5	1	5	0	0	6
7	0	1	3	0	4
9	0	0	1	2	3
11	0	0	2	0	2
$n_{.j}$	4	7	7	2	20

$$\text{cov}(X, Y) = \frac{\sum_{i=1}^5 \sum_{j=1}^4 n_{ij} x_i y_j}{n_{\square}} - \bar{x}\bar{y}$$

$$\Leftrightarrow \text{cov}(X, Y) = \frac{3 \times 75 + 1 \times 105 + 1 \times 125 + 5 \times 175 + 1 \times 245 + 3 \times 315 + 1 \times 405 + 2 \times 495}{20} = 17.15 \quad (> 0)$$

Ceci signifie que l'âge et le salaire ne sont pas indépendants.

. Corrélation

Le coefficient de corrélation linéaire s'évalue par :

$$r(x, y) = \frac{\text{cov}(X, Y)}{\sigma_x \sigma_y} = \frac{17.15}{\sqrt{6.59} \cdot \sqrt{82.75}} = 0.73, \text{ Il exprime une forte relation positive entre l'âge et le salaire.}$$

a. Régression linéaire

Si x et y sont liés, la régression consiste à trouver une fonction permettant de déterminer y à partir de x . La forme de la fonction peut être linéaire ($y=ax+b$) ou linéarisable ($y=\log x+b$) ;

cas linéaire : $y = ax+b$

$$\hat{a} = \frac{\text{cov}(x, y)}{v(x)} = \frac{\sum_i x_i y_i - n \bar{x} \bar{y}}{\sum_i x_i^2 - n \bar{x}^2} ; \quad \hat{b} = \bar{y} - \hat{a} \bar{x}.$$

Démonstration

$$\min(\sum_i e_i^2) = \min(y_i - \hat{y})^2 = \min \sum_i (y_i - \hat{a}x - \hat{b})^2$$

$$\frac{\partial \sum_i e_i^2}{\partial \hat{a}} = 0 \Leftrightarrow \frac{\partial \sum_i (y_i - \hat{a}x - \hat{b})^2}{\partial \hat{a}} = \sum_i [2 \cdot (y_i - \hat{a}x - \hat{b}) \cdot (-x_i)] = 0 \Leftrightarrow \hat{a} \sum_i x_i y_i - \hat{a} \sum_i x_i^2 - \hat{b} \sum_i x_i = 0$$

$$\Leftrightarrow \hat{a} \sum_i x_i y_i - \hat{a} \sum_i x_i^2 - (\bar{y} - \hat{a}\bar{x}) \sum_i x_i = 0 \Leftrightarrow \hat{a} \sum_i x_i y_i - \hat{a} \sum_i x_i^2 - \bar{y} \sum_i x_i + \hat{a}\bar{x} \sum_i x_i = 0 \Leftrightarrow$$

$$\hat{a} = \frac{\sum_i x_i y_i - n \bar{x} \bar{y}}{\sum_i x_i^2 - n \bar{x}^2} = \frac{\text{cov}(x, y)}{v(x)}$$

$$\frac{\partial \sum_i e_i^2}{\partial \hat{b}} = 0 \Leftrightarrow \frac{\partial \sum_i (y_i - \hat{a}x - \hat{b})^2}{\partial \hat{b}} = 0 \Leftrightarrow \sum_i [2 \cdot (y_i - \hat{a}x - \hat{b}) \cdot (-1)] = 0 \Leftrightarrow \sum_i (y_i - \hat{a}x - \hat{b}) = 0 \Leftrightarrow$$

$$\sum_i y_i - \hat{a} \sum_i x_i - n \hat{b} = 0 \Leftrightarrow \hat{b} = \bar{y} - \hat{a}\bar{x}$$

. EXEMPLE

$$\hat{a} = \frac{\text{cov}(x, y)}{v(x)} = \frac{17.15}{6.59} = 2.60$$

$$\hat{b} = \bar{y} - \hat{a}\bar{x} = 0.67 - 2.6 \cdot 6.10 = -15.19$$

L'équation de la droite de régression est alors : $Y = 2.60X - 15.19$

b. Régression linéaire pondérée

Soit le tableau de contingence suivant, calculer la droite de régression ? :

Tableau 90 EX.43 Tableau 2 de contingence

	20	30	40
25	35	6	2
35	5	25	7
45	2	3	15

$$\hat{a} = \frac{\text{cov}(x, y)}{v(x)} = \frac{\sum_i n_i x_i y_i - n \bar{x} \bar{y}}{\sum_i n_i x_i^2 - n \bar{x}^2} = 4.48; \quad \hat{b} = \bar{y} - \hat{a} \bar{x} = 0.725$$


$$r = \frac{\text{cov}(x, y)}{\sigma_x \sigma_y} = \frac{\sum_i n_i x_i y_i - n \bar{x} \bar{y}}{\sqrt{(\sum_i n_i x_i^2 - n \bar{x}^2)(\sum_i n_i y_i^2 - n \bar{y}^2)}}$$

Tableau 91 Solution Calcul de la droite de régression

X_i	Y_i	n_i	$n_i X_i$	Y_i	X_i^2	$n_i X_i^2$	$n_i X_i$	$n_i Y_i$
25	20	35	17500	625	21875	875	700	
35	20	5	3500	1225	6125	175	100	
45	20	2	1800	2025	4050	90	40	
25	30	6	4500	625	3750	150	180	
35	30	25	26250	1225	30625	875	750	
45	30	3	4050	2025	6075	135	90	
25	40	2	2000	625	1250	50	80	
35	40	7	9800	1225	8575	245	280	
45	40	15	27000	2025	30375	675	600	
315	270	100	96400		112700	3270	2820	
3.15	2.7							
32.7	28.2							
1069.29								

La représentation graphique se fait par un nuage de points proportionnels.

Figure 39 Graphe de la régression pondérée



CH3. STATISTIQUE MULTIVARIEE

Soit une population Ω de taille n décrite simultanément par rapport à trois caractères ou plus x, y, z ... respectivement de k, p, r ... modalités.

3.1 ACP

3.1.1 Formalisation

Soit $X = [\underline{X}_1, \dots, \underline{X}_n]$ n points / $\underline{X}_i \in R^d$

Projetons X sur \bar{U} / $\dim \bar{U} < d$ et $\text{var}(U^t X)_{\max}$

$$\text{var}(U_i^t X)_{\max} \equiv \underset{u_i}{\text{Max}} [\text{var}(U_i^t X)]$$

$$\underset{u_i}{\text{Max}} [\text{var}(U_i^t X)]$$

Soit $\text{var}(X) = S_{d,d}$

$$\text{var}(U_i^t X) = U_i^t S U_i$$

$$\underset{u_i}{\text{Max}} [\text{var}(U_i^t X)] = \underset{u_i}{\text{Max}} (U_i^t S U_i)$$

1. méthode du Lagrangien

$$\underset{u_i}{\text{Max}} [\text{var}(U_i^t X)] = \underset{u_i}{\text{Max}} (U_i^t S U_i) \equiv \left| \underset{u_i}{\text{Max}} (U_i^t S U_i) \right| \text{ si } U_1^t U_1 = 1$$

$$L(U_1, \lambda) = U_1^t S U_1 - \lambda(U_1^t U_1 - 1)$$

$$\frac{\partial L}{\partial U_1} = 2S\underline{U}_1 - 2\lambda U_1 = 0 \Leftrightarrow S\underline{U}_1 = \lambda_1 \underline{U}_1 \quad | \underline{U}_1 : \text{vecteur propre}; \lambda_1 : \text{valeur}$$

$$\underline{U}^t S \underline{U} = U^t \lambda U = \lambda U^t U = \lambda$$

S possède au plus d vecteurs propres et d valeurs propres

$$\left. \begin{array}{l} \lambda_1 > \lambda_2 > \lambda_3 > \dots > \lambda_d \\ U_1 > U_2 > U_3 > \dots > U_d \end{array} \right\} U_1 \text{ de } S \text{ correspond au vecteur propre maximum et}$$

constitue la première composante principale.

Si l'on choisit U_2 comme solution, U_2 correspond à λ_2 / $\lambda_2 < \lambda_1$ par suite on prend U_1 comme meilleure solution.

2. La méthode SVD

$$X_{d,n} = U \Sigma V^T$$

$$\left| \begin{array}{l} U = \text{vecteur propre de } XX^T, \\ \Sigma = \begin{bmatrix} \lambda_1 & & \\ & \lambda_2 & \\ & & \lambda_d \end{bmatrix} \text{ valeurs propres de } XX^T \text{ ou } X^T X \\ V = \text{vecteurs propres de } X^T X \end{array} \right.$$

$$[X_{d,n} - U_{d,n}] = \tilde{X} \quad /$$

$$/ X = \begin{bmatrix} & & \end{bmatrix} \quad U = \begin{bmatrix} & & \end{bmatrix} \quad \bar{X} = \frac{1}{n} \sum_{i=1}^n \underline{X}_i$$

$$U \Sigma V^T = \tilde{X}$$

$$\tilde{X} \tilde{X}^T \begin{bmatrix} \lambda_1 & & \\ & \lambda_2 & \\ & & \lambda_d \end{bmatrix} \tilde{X}^T \tilde{X} \quad / \quad \tilde{X} \tilde{X}^T = \text{var}(X) = S$$

| Pour trouver U_i^* : 1. centraliser X ; 2. faire SVD: colonnes ou PC(U_i)

Passage de \mathbb{R}^d à \mathbb{R}^p puis renvoie de l'image obtenue à \mathbb{R}^d

$$X_{d,n} = [\underline{X}_1, \dots, \underline{X}_n]$$

$$Y_{1,1} = U_{1d}^T X_{d,1} \Rightarrow \hat{X}_{d,1} = U_{d,1} Y_{1,1}$$

$$Y_{2,1} = U_{2d}^T X_{d,1} \Rightarrow \hat{X}_{d,1} = U_{d,2} Y_{2,1} :$$

$$\dots = \dots \Rightarrow \dots = \dots$$

L'image (obtenue dans \mathbb{R}) renvoyée de \mathbb{R} origine c_1 est meilleure car

3.Méthode Pratique (Heuristique)

$X_{d,n} > XX'$ réduite $\Rightarrow \tilde{X} \tilde{X}' >$ orthogonalisation $U_i >$ choix du nombre de U_i sur inertie

expliquée gd $\frac{\lambda_1 + \lambda_{crit}}{\sum_i \lambda_i} = \text{grande (90\%)} \left(\sum_i \lambda_i = \text{tr } XX' \right) >$ normalisation $U_i > \lambda'_{p,n} = U'_{p,d} X_{d,n}$

. EXEMPLE 1

Un constructeur de piscine désire évaluer l'influence du revenu du propriétaire, de la surface de la propriété et de l'attitude envers le soleil dans la décision d'achat d'une piscine. Le service Marketing présente les données suivantes d'un échantillon de 24 clients potentiels.

Tableau 92 Exemple 1 d'ACP

i	R	S	SO
A	9,3	30,2	8
B	10,2	40,1	10
C	9,7	35,3	6
D	11,5	45,1	4
E	12	38	5
F	14,2	50,1	9
G	18,6	60,2	10
H	28,4	100,4	3
I	13,2	25,1	2
J	10,8	40,7	7
K	22,7	68,4	9
L	12,3	60,3	8
M	8,2	38,2	2
N	7,8	40,2	0
O	11,4	44,8	1
P	16,3	50,6	4
Q	12,4	42,5	8
R	11,5	60,3	0
S	6,8	39,7	6
T	10,4	35,4	4
U	14,2	42,6	3
V	11,6	38,4	2
X	8,4	30,2	4
Y	9,1	25,7	5

Source : Initiation à l'analyse des données Jean Lagarde p. 85

3.1.2 Exemple

Tableau 93 Exemple 2 d'ACP

i	P	Tmax	Tmin
1 Ajaccio	12,04	23,7	5,9
2 Brest	17,18	15,5	-1,8
3 Dunkerque	11,83	13,1	2,8
4 Nancy	6,23	13,5	-2,4
5 Nice	16,99	21,1	7,2
6 Toulouse	3,87	20,3	-0,90

Source : Pages J., Rennes

Cet exemple a été résolu par le logiciel Xlstat 2024.

0. Présentation des données centrées réduites

i	P	Tmax	Tmin
1 Ajaccio	0,14	1,44	1,09
2 Brest	1,17	-0,59	-0,96
3 Dunkerque	0,1	-1,18	0,27
4 Nancy	-1,03	-1,08	-1,12
5 Nice	1,13	0,8	1,44
6 Toulouse	-1,5	0,6	-0,72

1. Statistiques descriptives :

Variable	Observations	Obs. avec données manquantes	Obs. sans données manquantes	Minimum	Maximum	Moyenne	Ecart-type
P	6	0	6	-1,500	1,170	0,002	1,094
Tmax	6	0	6	-1,180	1,440	-0,002	1,094
Tmin	6	0	6	-1,120	1,440	0,000	1,098

2. Matrice de corrélation (Pearson (n)) :

Variables	P	Tmax	Tmin
P	1	0,085	0,486
Tmax	0,085	1	0,624
Tmin	0,486	0,624	1

3. Valeurs propres :

	F1	F2	F3
Valeur propre	1,833	0,917	0,249
Variabilité (%)	61,110	30,583	8,307
% cumulé	61,110	91,693	100,000

4. Vecteurs propres :

	F1	F2	F3
P	0,459	0,791	-0,406
Tmax	0,562	-0,612	-0,557
Tmin	0,688	-0,027	0,725


5. Coordonnées des variables :

	F1	F2	F3
P	0,621	0,757	-0,203
Tmax	0,761	-0,586	-0,278
Tmin	0,932	-0,026	0,362

6 Coordonnées des observations :


	F1	F2	F3
1	1,624	-0,803	-0,072
2	-0,454	1,311	-0,841
3	-0,433	0,792	0,812
4	-1,850	-0,126	0,210
5	1,958	0,363	0,136
6	-0,845	-1,538	-0,246

Figure 40 Graphe des observations : ACP



Source : Résultat Xlstat 2024

Figure 41 Graphe des axes factoriels : ACP



Source : Résultat Xlstat 2024

3.2 Régression Logistique

3.2.1 Formalisation

Le modèle « Logit binaire multiple » est un modèle statistique, à l'instar du modèle « Probit », où la variable dépendante est qualitative nominale binaire et les variables indépendantes sont un mélange de variables quantitatives et catégorielles.

Soit y_i une variable nominale binaire $y_i \in \{0,1\}$ / $y_i \in \{0,1\}$, $P(y_i=1)=p_i$; $P(y_i=0)=1-p_i$.

Essayons de regresser y_i sur k prédicteurs $(x_{i1}, x_{i2}, \dots, x_{ik}) = X_i'$ à l'instar de la régression linéaire

$y_i = X_i' \beta + u_i$. Comme il est impossible de définir la régression à partir de $p(y=+/-x) = a_0 + a_1 x_1 + \dots + a_k x_k$, le premier terme étant dans $\{0,1\}$ alors que le second est dans \mathbb{R}^k .

Une solution à ce problème passerait par la création d'une variable latente y^* telle que:

$y = 1 \Leftrightarrow y^* = X_i' \beta + u_i > 0$. Il s'ensuit : $p_i = P(y_i = 1) = P(y^* > 0) = P(X_i' \beta + u_i > 0) =$

$P(u_i > -X_i' \beta) = 1 - F(-X_i' \beta)$ c.a.d. $y_i \in \{0,1\}$ avec $p_i = 1 - F(-X_i' \beta) = \frac{1}{1 + e^{-X_i' \beta}}$

$F(X_i' \beta) = \frac{1}{1 + e^{-X_i' \beta}}$ pour le Logit d'où $X_i' \beta = \ln\left(\frac{p}{1-p}\right) = \ln(\text{Odds } p)$.

$F(X_i' \beta) = \Phi(X_i' \beta) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{X_i' \beta} e^{-z^2/2} dz$ pour le Probit d'où $X_i' \beta = \Phi^{-1}$.

$$P(y=1 / x = x_0) = \frac{1}{1 + e^{-X_i' \beta}} = \frac{e^{X_i' \beta}}{1 + e^{X_i' \beta}}$$

$$P(y=0 / x = x_0) = \frac{1}{1 + e^{X_i' \beta}}$$

$$f(y_i / x = x_i) = \left(\frac{e^{X_i' \beta}}{1 + e^{X_i' \beta}} \right)^{y_i} \left(\frac{1}{1 + e^{X_i' \beta}} \right)^{1-y_i}$$

Par MLE, $\beta_{MLE} = \arg \text{Max}$

$$L(\beta) = \prod_i P(y_i = +/x) y_i \left[1 - P(y_i = +/x)^{1 - y_i} \right]$$

$$\begin{aligned} LL(\beta) &= \sum \text{Log}[f(x_i; \beta)] = \sum y_i \left[X_i' \beta - \text{Log}(1 + e^{X_i' \beta}) \right] + (1 - y_i) - \text{Log}(1 + e^{X_i' \beta}) \\ &= \sum y_i \beta' x_i - \text{Log}(1 + e^{X_i' \beta}) \end{aligned}$$

i – Calcul du gradient $\nabla_{\beta} L(\beta)$

$$\begin{aligned} \nabla_{\beta} L(\beta) &= \nabla_{\beta} \left[\sum_i y_i x_i' \beta - \ln(1 + e^{x_i' \beta}) \right] = \left[\sum_i \nabla_{\beta} y_i x_i' \beta - \ln(1 + e^{x_i' \beta}) \right] = \left[\sum_i \nabla_{\beta} (y_i x_i' \beta) - \nabla_{\beta} [\ln(1 + e^{x_i' \beta})] \right] \\ &= \sum_i y_i x_i - x_i \frac{e^{x_i' \beta}}{1 + e^{x_i' \beta}} = \sum_i x_i (y_i - p_i) = X^T (Y - \hat{Y}) \quad \square \\ &\quad \square \\ &\quad (y_i - \hat{y}_i)_{n,1} \end{aligned}$$

ii – Calcul du Hessian $\nabla_{\beta\beta} L(\beta)$

$$\begin{aligned} \nabla_{\beta\beta} L(\beta) &= \nabla_{\beta} \left[\sum_i x_i (y_i - p_i) \right] = \sum_i \nabla_{\beta} [x_i (y_i - p_i)] = \sum_i \nabla_{\beta} [-p_i x_i] = \sum_i \nabla_{\beta} \left[-\frac{1}{1 + e^{-x_i' \beta}} x_i \right] = \\ &= \sum_i -(-1) \left[\frac{1}{1 + e^{-x_i' \beta}} \right]^2 (-x_i) e^{-x_i' \beta} x_i = - \sum_i \left[\frac{1}{1 + e^{-x_i' \beta}} \right] \left[\frac{e^{-x_i' \beta}}{1 + e^{-x_i' \beta}} \right] (-x_i) x_i = -x^T p(1 - p)x = \\ &= -X^T W X \quad W = \begin{pmatrix} p_1(1 - p_1) & 0 \\ 0 & p_n(1 - p_n) \end{pmatrix}; \end{aligned}$$

iii- Calcul des paramètres optimaux β^* par la méthode itérative de Newton-Raphson

$$\beta_{t+1} = \beta_t - H^{-1} g$$

$$\beta_{t+1} = \beta_t - \frac{\nabla_{\beta} L(\beta)}{\nabla_{\beta\beta} L(\beta)} \Leftrightarrow \beta_{t+1} = \beta_t + (X^T W X)^{-1} X^T (Y - \hat{Y}) \quad \square$$

Remarque : si H n'est pas inversible, il faut appliquer Levenberg Marquardt method ou gradient descent

3.2.2 Exemple

Soient les données suivantes ; cherchons par la régression logistique un modèle de prédiction de la maladie cardiaque en fonction des variables age, tx max et angine : cœur =f(age, tx-max et angine) / cœur = variable binaire ; age et tx max=variables quantitatives; angine= variable binaire (Résolu par Xlstat 2024).

1. trouver $\hat{\alpha}_1$ $\hat{\alpha}_2$ $\hat{\alpha}_3$?

Tableau 94 Exemple 1 Regression Logistique

age	tx_max	angine	cœur	y
50	126	1	présence	1
49	126	0	présence	1
46	144	0	présence	1
49	139	0	présence	1
62	154	1	présence	1
35	156	1	présence	1
67	160	0	absence	0
65	140	0	absence	0
47	143	0	absence	0
58	165	0	absence	0
57	163	1	absence	0
59	145	0	absence	0
44	175	0	absence	0
41	153	0	absence	0
54	152	0	absence	0
52	169	0	absence	0
57	168	1	absence	0
50	158	0	absence	0
44	170	0	absence	0
49	171	0	absence	0

Source : Rakotomala, Lyon

Statistiques descriptives (Données quantitatives) :							
Variable	Observations	Obs. avec données	Obs. sans données	Minimum	Maximum	Moyenne	Ecart-type
age	20	0	20	35,000	67,000	51,750	8,162
tx_max	20	0	20	126,000	175,000	153,850	14,438

Statistiques descriptives (Données qualitatives) :

Variable	Modalités	Comptages	Effectifs	%
y	0	14	14	70,000
	1	6	6	30,000
Statistiques descriptives (Données quantitatives) ▼				
engine	0	15	15	75,000
	1	5	5	25,000

Matrice de corrélation :

	age	tx_max	engine-0	engine-1	y
age	1	-0,025	-0,033	0,033	-0,267
tx_max	-0,025	1	0,018	-0,018	-0,606
engine-0	-0,033	0,018	1	-1,000	-0,378
engine-1	0,033	-0,018	-1,000	1	0,378
y	-0,267	-0,606	-0,378	0,378	1

Statistiques de multicollinéarité :

	age	tx_max	engine-0	engine-1
Tolérance	0,998	0,999	0,999	0,999
VIF	1,002	1,001	1,001	1,001

Régression de la variable y (Modalité témoin = 0) :

Coefficients d'ajustement (Variable y) :

Statistique	Indépendant	Complet
Observations	20	20
Somme des poids	20,000	20,000
DDL	19	16
-2 Log(Vraisemblance)	24,435	0,000
R ² (McFadden)	0,000	1,000
R ² (Cox and Snell)	0,000	0,705
R ² (Nagelkerke)	0,000	0,901
AIC	26,435	8,000
SBC	27,430	11,983
Itérations	0	22

Test de l'hypothèse nulle H0 : Pr(y=1)=0,3 :

Statistique	DDL	Khi ²	Pr > Khi ²
-2 Log(Vraisemblance)	3	24,435	<0,0001
Score	3	11,764	0,008
Wald	3	0,000	1,000

Analyse de Type II (Variable y) :

Source	DDL	Khi ² (Wald)	Pr > Wald	Khi ² (LR)	Pr > LR
age	1	0,000	0,991	7,653	0,006
tx_max	1	0,000	0,991	19,702	<0,0001
engine	1	0,000	0,991	14,229	0,000

Test de Hosmer-Lemeshow (Variable y) :

Statistique	Khi ²	DDL	Pr > Khi ²
Statistique de Hosmer-Lemeshow	0,000	4	1,000


Paramètres du modèle (Variable y) :									
Source	Valeur	Erreur standard	Khi² de Wald	Pr > Khi²	Wald Borne inf. (95%)	Wald Borne sup. (95%)	Odds ratio	Odds ratio Borne inf. (95%)	Odds ratio Borne sup. (95%)
Constante	12160,951	1128151,818	0,000	0,991	#####	#####			
age	-78,190	7338,384	0,000	0,991	-14461,158	14304,778			
tx_max	-47,373	4391,898	0,000	0,991	-8655,335	8560,589			
angine-0	-1727,071	160751,109	0,000	0,991	-316793,455	313339,312			
angine-1	0,000	0,000							

. Equation du modèle (Variable y) :

$$\text{Pr}(y=1) = 1 / (1 + \exp(-(12160,951272 - 78,190111 * \text{age} - 47,373017 * \text{tx_max} - 1727,071185 * \text{angine-0})))$$

Coefficients normalisés (Variable y) :

Source	Valeur	Erreur standard	Khi² de Wald	Pr > Khi²	Wald Borne inf. (95%)	Wald Borne sup. (95%)
age	-342,943	32186,233	0,000	0,991	-63426,799	62740,914
tx_max	-367,540	34074,208	0,000	0,991	-67151,761	66416,681
angine-0	-412,308	38376,500	0,000	0,991	-75628,866	74804,251
angine-1	0,000	0,000				



Prédictions et résidus (Variable y) :

Observation	y	Préd(y)	Pr(0)	Pr(1)
Obs1	1	1	0,000	1,000
Obs2	1	1	0,000	1,000
Obs3	1	1	0,000	1,000
Obs4	1	1	0,000	1,000
Obs5	1	1	0,000	1,000
Obs6	1	1	0,000	1,000
Obs7	0	0	1,000	0,000
Obs8	0	0	1,000	0,000
Obs9	0	0	1,000	0,000
Obs10	0	0	1,000	0,000
Obs11	0	0	1,000	0,000
Obs12	0	0	1,000	0,000
Obs13	0	0	1,000	0,000
Obs14	0	0	1,000	0,000
Obs15	0	0	1,000	0,000
Obs16	0	0	1,000	0,000
Obs17	0	0	1,000	0,000
Obs18	0	0	1,000	0,000
Obs19	0	0	1,000	0,000
Obs20	0	0	1,000	0,000






Tableau de classification pour l'échantillon d'apprentissage (Variable y) :

de \ Vers	0	1	Total	% correct
0	14	0	14	100,00%
1	0	6	6	100,00%
Total	14	6	20	100,00%



CH4. LES INDICES

4.1 Indices simples

Définition : Soit l'évolution temporelle d'une grandeur $g : g_0, g_1, \dots, g_t$ aux dates $0, 1, \dots, t$.

On appelle indice simple de g par rapport à la date t_0 , le rapport $I_{t/t_0}(g) = \frac{g_t}{g_0}$

(la date 0 s'appelle date de référence, la date t date courante). Il permet de comparer l'évolution d'une même grandeur (de plusieurs grandeurs différentes) sur 2 périodes.

4.1.1 Propriétés

Circularité (transférabilité)

$$I_{t/t_0}(g) = I_{t/t'}(g) * I_{t'/t_0}(g) \quad (1) \quad \text{puisque } g_t/g_0 = g_t/g_{t'} * g_{t'}/g_0$$

$$(1) \Rightarrow I_{t/t'}(g) = \frac{I_{t/t_0}(g)}{I_{t'/t_0}(g)} \quad (2)$$

$$(2) \Rightarrow I_{t/t'}(g) = \frac{I_{t/t_1}(g)}{I_{t'/t_1}(g)} = \frac{I_{t/t_2}(g)}{I_{t'/t_2}(g)} = \dots = \frac{I_{t/t_{t-1}}(g)}{I_{t'/t_{t-1}}(g)}$$

Ceci permet la comparaison entre 2 dates indépendamment de la date de référence.

Réversibilité

$$I_{0/t}(g) = \frac{g_0}{g_t} = \frac{1}{g_t/g_0} = \frac{1}{I_{t/0}(g)} \Rightarrow I_{0/t}(g) = \frac{1}{I_{t/0}(g)}$$

$$\text{Enchaînement } I_{t/t_0}(g) = I_{t/t_{t-1}}(g) * I_{t_{t-1}/t_{t-2}}(g) * I_{t_{t-2}/t_{t-3}}(g) * \dots * I_{1/0}(g)$$

L'indice simple est circulaire, réversible et enchaînable.

EXEMPLE 1

Le tableau suivant indique les prix unitaires d'un produit au cours de la période 2000–2003.

Tableau 95 EX.44 Prix unitaires d'l produit durant 2000-2003

AN	2000	2001	2002	2003
PRIX	120	130	125	135

1. *Calculer les indices élémentaires des prix $I_{2001/2000}$? $I_{2002/2000}$? $I_{2003/2000}$*
2. *Calculer l'indice des prix $I_{2003/2002}$*
3. *Calculer l'indice des prix $I_{2002/2003}$?*
4. *Calculer l'indice des prix $I_{2003/2001}$?*

. Solution

$$1. I_{2001/2000} = \frac{130}{120} \cdot 100 = 108 \quad I_{2002/2000} = \frac{125}{120} \cdot 100 = 104 \quad I_{2003/2000} = \frac{135}{120} \cdot 100 = 112$$

$$2. I_{2003/2002} = I_{2003/2000} / I_{2002/2000} = \frac{112}{104} \cdot 100 = 107.7 \text{ (transférabilité)}$$

$$I_{2002/2001} = I_{2002/2000} / I_{2001/2000} = \frac{104}{108} = 96.3 \text{ (transférabilité)}$$

$$3. I_{2002/2003} = \frac{1}{I_{2003/2002}} = \frac{1}{107.7} \cdot 100 = 92.8 \text{ (réversibilité)}$$

$$4. I_{2003/2001} = I_{2003/2002} \cdot I_{2002/2001} = \frac{107.7 \cdot 96.3}{100} = 104 \text{ (enchaînement)}$$

4.1.2 Opérations sur les indices

Addition

i. soit g_t une somme pondérée : $g_t = \sum_i a_i g_i$

$$I_{t/0}(g) = \frac{g_t}{g_0} = \frac{\sum_i a_i g_i}{g_0} = \sum_i a_i \frac{g_i}{g_0} \quad \text{l'indice d'une somme pondérée est la somme des indices pondérés}$$

ii. soit g_t et g_0 st des sommes pondérées: $g_t = \sum_i a_i g_t^i$; $g_0 = \sum_i a^i g_0^i$; a coeff. cstts

$$I_{t/0}(g) = \frac{\sum_i a_i g_t^i}{\sum_i a^i g_0^i} = \frac{\sum_i a_i g_0^i \frac{g_t^i}{g_0^i}}{\sum_i a^i g_0^i} = \sum_i w_i \frac{g_t^i}{g_0^i} \quad \text{L'indice élémentaire d'une somme pondérée =}$$

moyenne arithmétique pondérée des indices élémentaires.

iii. soit g_t et g_0 des sommes pondérées à coefficients variables : $g_t = \sum_i a_t^i g_t^i$; $g_0 = \sum_i a_0^i g_0^i$; a coefficients variables.

$$I_{t/0}(g) = \frac{g_t}{g_0} = \frac{\sum_i a_t^i g_t^i}{\sum_i a_0^i g_0^i} = \frac{\sum_i a_t^i g_0^i \frac{g_t^i}{g_0^i}}{\sum_i a_0^i g_0^i} = \frac{\sum_i a_t^i g_0^i I_{t/0}(g^i)}{\sum_i a_0^i g_0^i} = \sum_i w_i^t I_{t/0}(g^i)$$

L'indice élémentaire d'une somme pondérée = somme pondérée des indices.

MULTIPLICATION $\frac{a_t b_t}{a_o b_o} = \frac{a_t}{a_o} \frac{b_t}{b_o} \Leftrightarrow I_{\%}(ab) = I_{\%}(a) * I_{\%}(b)$

. EXEMPLE

Le prix du cuivre est passé de 0.212 dollars en 1950 à 0.258 dollars en 1958. Le cours du dollar est passé de 350 dinars algérien à 490. Ainsi, l'indice des prix du cuivre en dinars algérien est :

$$I_{1958/1950}(c_f) = I_{1958/1950}(d) I_{1958/1950}(c_d) = \frac{490}{350} * \frac{0.258}{0.212} = 1.7$$

DIVISION $\frac{a_t/b_t}{a_o/b_o} = \frac{a_t}{a_o} / \frac{b_t}{b_o} \Leftrightarrow I_{\%}(a/b) = \frac{I_{\%}(a)}{I_{\%}(b)}$

. EXEMPLE

Le prix du litre de lait est passé de 36.8 en Algérie en 1950 algérien à 45.6 en 1958. Pour un citoyen américain, l'indice des prix du lait français est ainsi de :

$$I_{1958/1950}(L_d) = \frac{I_{1958/1950}(L_F)}{I_{1958/1950}(d)} = \frac{45.6}{\frac{36.8}{490}} = \frac{1.24}{1.4} = 0.89$$

4.2 Indices synthétiques

4.2.1 Indices arithmétiques

Soient cette fois plusieurs produits X_j ($j=1 \dots n$) dont on veut connaître l'évolution globale au cours du temps i ($i=1 \dots m$). X_{ij} dénote la valeur de la i ème composante du produit X_j . x_{1j} est la valeur de base du produit X_j . On définit alors 3 indices arithmétiques : l'indice des moyennes, la moyenne des indices et la moyenne pondérée des indices.

Tableau 96 Indice arithmétique

L'indice des moyennes	Le moyenne des indices	La moyenne pondérée des indices
$I_{i/1} = 100 \cdot \frac{\sum_i x_{ij}}{\sum_j x_{1j}}$	$I_{i/1} = 100 \cdot \frac{1}{n} \sum_j \frac{x_{ij}}{x_{1j}}$	$I_{i/1} = \frac{\sum_j p_j (x_{ij} / x_{1j})}{\sum_j p_j}$

Propriétés : L'indice arithmétique n'est pas réversible, sa base n'est pas transférable.

. EXEMPLE

Soit la production de 3 produits (le blé, l'orge et le seigle) au cours des années 2000, 2001 et 2002. Si les pondérations associées au blé, à l'orge et au seigle sont respectivement de 100, 80 et 70. Calculer l'indice des moyennes, la moyenne des indices et la moyenne pondérée des indices ?

Tableau 97 EX.45 Prix de 3 produits durant 2000-2003

	Blé	Orge	Seigle
2000	5700	200	40
2001	6320	280	50
2002	6000	260	60

. Solution

1 .L'indice des moyennes

	Blé	Orge	Seigle	$\sum X_j$	$I_{i/1}$	base 100
2000	5700	200	40	5940	$\frac{5940}{5940} = 1$	100
2001	6320	280	50	6650	$\frac{6650}{5940} = 1.2$	120
2002	6000	260	60	6320	$\frac{6320}{5940} = 1.06$	106

2. Moyenne des indices

	<i>Blé</i>	<i>Orge</i>	<i>Seigle</i>	R_1	R_2	R_3	$1/3 \sum_{j=1}^3 R_j$	$I_{a/1}$
2000	5700	200	40	$\frac{5700}{5700} = 1$	$\frac{200}{200} = 1$	$\frac{40}{40} = 1$	1	100
2001	6320	280	50	$\frac{6320}{5700} = 1.11$	$\frac{280}{200} = 1.4$	$\frac{50}{40} = 1.25$	1.25	125
2002	6000	260	60	$\frac{6000}{5700} = 1.05$	$\frac{260}{200} = 1.3$	$\frac{60}{40} = 1.5$	1.28	128

3. Moyenne pondérée des indices

	<i>Blé</i>	<i>Orge</i>	<i>Seigle</i>	R_1	R_2	R_3	$p_1 r_1$	$p_2 r_2$	$p_3 r_3$	$\sum_{j=1}^3 p_j r_j / \sum p_j$	$I_{i/1}$
2000	5700	200	40	$\frac{5700}{5700} = 1$	$\frac{200}{200} = 1$	$\frac{40}{40} = 1$	100	80	70	1	100
2001	6320	280	50	$\frac{6320}{5700} = 1.11$	$\frac{280}{200} = 1.4$	$\frac{50}{40} = 1.25$	111	112	98	1.28	128
2002	6000	260	60	$\frac{6000}{5700} = 1.05$	$\frac{260}{200} = 1.3$	$\frac{60}{40} = 1.5$	105	104	91	1.18	118

4.2.2 Indices géométriques

On utilise ici plutôt les moyennes géométriques simple et pondérée des indices au lieu des moyennes arithmétiques simples et pondérées.

Tableau 98 Indices géométriques

<i>Indice géométrique</i>	<i>Indice géométrique pondéré</i>
$I_{i/1} = 100 \cdot \frac{[\prod_i x_{ij}]^{1/n}}{[\prod_i x_{1j}]^{1/n}}$	$I_{i/1} = \left[\prod_j \left(\frac{x_{ij}}{x_{1j}} \right)^{\alpha_j} \right]^{1/\sum_j \alpha_j} + 100$ $\log I_{i/1} = \frac{1}{\sum_j \alpha_j} \sum_i \alpha_j \log \left(\frac{x_{ij}}{x_{1j}} \right) + 2$

Propriétés : L'indice géométrique est réversible, sa base est transférable

$$G_{i/u} \cdot G_{u/i} = \frac{[\prod_i x_{ij}]^{1/n}}{[\prod_i x_{uj}]^{1/n}} \cdot \frac{[\prod_i x_{uj}]^{1/n}}{[\prod_i x_{ij}]^{1/n}} = 1 \Rightarrow G_{u/i} = \frac{1}{G_{i/u}}$$

Soit $G_{i/x}$, calculons $G_{i/y}$: $G_{i/y} = G_{i/x} G_{x/y}$

$$\begin{cases} G_{i/y} = G_{i/x} G_{x/y} \\ G_{x/y} = \frac{1}{G_{y/x}} \end{cases} \Rightarrow G_{i/y} = \frac{G_{i/x}}{G_{y/x}}$$

. EXEMPLE

Soient les prix de 3 produits (la viande, le poisson et les œufs) au cours des années 2000, 2001 et 2002. Si les pondérations associées à la viande, au poisson et aux œufs sont respectivement de 0.6, 0.3 et 0.1. Calculer les indices géométriques et géométriques pondérés des différents produits ?

Tableau 99 EX.46 Prix de 3 produits durant 2000-2002

	Viande	Poisson	Œufs
2000	1700	400	200
2001	1800	500	250
2002	1900	660	300

Solution

a. Indice géométrique

	<i>Viande</i>	<i>Poisson</i>	<i>Œufs</i>	$\prod_{j=1}^3 X_j$	$\left[\prod_{j=1}^3 X_j\right]^{1/3}$	$\frac{I_{i/1}}{100}$	I_g
2000	1700	400	200	136000000	511.06	1	100
2001	1800	500	250	225000000	604.33	1.18	118
2002	1900	660	300	376200000	717.16	1.40	140

b. Indice géométrique pondéré

	<i>Viande</i>	<i>Poisson</i>	<i>Œufs</i>	$\prod_{j=1}^3 (x_{ij}/x_{1j})^{\alpha_j}$	$\left[\prod_{j=1}^3 (x_{ij}/x_{1j})^{\alpha_j}\right]^{1/\sum \alpha_j}$	I_{g_p}
2000	1700	400	200	1	1	100
2001	1800	500	250	1.1320	1.1320	113
2002	1900	660	300	1.2935	1.2935	129

4.2.3 Indices synthétiques Laspeyers, Paashe et Fisher

Définition : soit 1 grandeur G complexe : G^1, G^2, \dots, G^i (Soit G le niveau des prix, G^i = prix de l'article i), l'indice élémentaire des constituants G^i est : $I_{t/0}(G) = \frac{G_t^i}{G_0^i}$.

Le problème est de synthétiser en un indice unique les indices des constituants G^i de G .

Soient G^1, G^2, \dots, G^i : i biens de consommation.

Soient $G_{1/0}^1, G_{1/0}^2, \dots, G_{1/0}^i$: les indices élémentaires y afférents de $1/0$

On veut synthétiser en 1 indice unique les indices élémentaires des différents biens pour connaître l'évolution de la consommation.

Les indices synthétiques Laspeyers, Paashe et Fisher emploient en plus des prix les quantités des produits.

Soit $w_0^i = \frac{p_o^i q_o^i}{\sum p_o^i q_o^i}$ l'importance relative de i dans la grandeur de l'époque t_0 (période de base)

Soit $w_t^i = \frac{p_t^i q_t^i}{\sum_i p_t^i q_t^i}$: importance relative de i dans la grandeur de l'époque t_t (période courante)

$L_{1/0}(G^i) = \sum_i w_o^i I_{1/0}(G^i) = \sum_i w_o^i \frac{G_1^i}{G_o^i}$: moyenne arithmétique pondérée des indices élémentaires par coefficients w_o^i de date base

$P_{1/0}(G) = \frac{\sum_i w_t^i}{\sum_i w_t^i \frac{G_o}{G_1}} = \frac{1}{\sum_i w_t^i \frac{G_o}{G_1}}$: moyenne harmonique pondérée des indices simples par coefficients w_t^i de la date courante

$F_{1/0}(G^i) = \sqrt{L_{1/0}(G) P_{1/0}(G)}$: moyenne géométrique simple des indices de Paasche et Laspeyres

Tableau 100 Indice de Laspeyres $L_{1/0}(G)$

$L_{p \ 1/0}$:indice L des prix(p)	$L_{p \ 1/0} = \sum_i w_o^i \frac{p_1}{p_o} = \sum_i \frac{p_o q_o}{\sum_i p_o q_o} \frac{p_1}{p_o} = \frac{\sum_i p_1^i q_o^i}{\sum_i p_o^i q_o^i}$
$L_{q \ 1/0}$:indice L des quantités(q)	$L_{q \ 1/0} = \sum_i w_o^i \frac{q_1}{q_o} = \sum_i \frac{p_o q_o}{\sum_i p_o q_o} \frac{q_1}{q_o} = \frac{\sum_i p_o^i q_1^i}{\sum_i p_o^i q_o^i}$
$L_{pq \ 1/0}$ indice	$L_{pq \ 1/0} = \sum_i w_o^i \frac{p_1 q_1}{p_o q_o} = \sum_i \frac{p_o q_o}{\sum_i p_o q_o} \frac{p_1 q_1}{p_o q_o} = \frac{\sum_i p_1^i q_1^i}{\sum_i p_o^i q_o^i}$

. EXEMPLE

Soient 4 produits X_1 , X_2 , X_3 et X_4 dont les prix et les quantités sont donnés à deux périodes différentes 1 et t. Calculer les indices L_p , L_q et L_{vg} ?

Tableau 101 Prix de 4 produits durant périodes 1 et 2

	Période 1		Période t	
	P_{i1}	Q_{i1}	P_{it}	Q_{it}
X_1	12	6	15	7
X_2	5	13	8	11
X_3	15	9	13	18
X_4	8	10	10	9

Solution

	p_1	q_1	p_t	q_t	p_1q_1	p_tq_t	p_1q_t	p_tq_1
x_1	12	6	15	7	72	105	84	90
x_2	5	13	8	11	65	88	55	104
x_3	15	9	13	18	135	234	270	117
x_4	8	10	10	9	80	90	72	100
					352	517	481	411

$$L_p = \frac{p_t q_1}{p_1 q_1} = \frac{411}{352} \cdot 100 = 116.7$$

$$L_q = \frac{p_1 q_t}{p_1 q_1} = \frac{481}{352} \cdot 100 = 136.6$$

$$L_{vg} = \frac{p_t q_t}{p_1 q_1} = \frac{517}{352} \cdot 100 = 146.8$$

Indice de PAASCHE (P (G))

Tableau 102 Indice de Paasche $P_{t/0}(G)$

$P_{p \ 1/0}$:indice P des prix(p)	$P_{p \ 1/0} = \frac{\sum w_t}{\sum w_t \frac{p_o}{p_t}} = \frac{1}{\sum \frac{p_1 q_1}{p_1} \frac{p_o}{p_1}} = \frac{\sum_i p_1^i q_1^i}{\sum_i p_o^i q_1^i}$
$P_{q \ 1/0}$:indice P des quantités(q)	$P_{q \ 1/0} = \frac{\sum w_t}{\sum w_t \frac{q_o}{q_t}} = \frac{1}{\sum \frac{p_1 q_1}{p_1} \frac{q_o}{q_1}} = \frac{\sum_i p_1^i q_1^i}{\sum_i p_1^i q_o^i}$
$P_{pq \ 1/0}$ indice	$P_{pq \ 1/0} = \frac{1}{\sum \frac{p_1 q_1}{p_1 q_1} \frac{p_o q_o}{p_1 q_1}} = \frac{1}{\sum_i \frac{p_o q_o}{p_1 q_1}} = L_{pq \ 1/0}$

Propriétés

Circularité

Aucun des trois indices ne possède la propriété de circularité.

a. Indice de Laspeyres

Le rapport des indices de Laspeyres aux dates 2 et 1 n'est pas l'indice de Laspeyres à la date 2 par rapport à la date 1.

$$\frac{L_{2/0}(G)}{L_{1/0}(G)} = \frac{\sum_i w_0^i \frac{G_2^i}{G_0^i}}{\sum_i w_0^i \frac{G_1^i}{G_0^i}} = \frac{\sum_i w_0^i \frac{G_1^i}{G_0^i} \frac{G_2^i}{G_1^i}}{\sum_i w_0^i \frac{G_1^i}{G_0^i}} = \frac{\sum_i w_0^i I_{1/0}(G^i)}{L_{1/0}(G)} I_{2/1}(G^i)$$

Tandis que

$$L_{2/1}(G) = \sum_i w_1^i I_{2/1}(G^i)$$

b. Indice de Paashe

$$\frac{P_{2/0}(G)}{P_{1/0}(G)} = \frac{\sum_i w_1^i \frac{G_0^i}{G_1^i}}{\sum_i w_2^i \frac{G_0^i}{G_2^i}}$$

Tandis que

$$P_{2/1}(G) = \sum_i I_{2/1}(G^i) = \frac{1}{\sum_i w_2^i \frac{G_1^i}{G_2^i}}$$

c. Indice de Fisher

$$F_{2/1}(G) = \frac{F_{2/0}(G)}{F_{1/0}(G)} \quad ?$$

$$F_{2/1}(G) = \sqrt{L_{2/1}(G) P_{2/1}(G)} = \frac{\sqrt{P_{2/0}(G) L_{2/0}(G)}}{\sqrt{P_{1/0}(G) L_{1/0}(G)}} \quad ?$$

$$L_{2/1}(G) P_{2/1}(G) \neq \frac{P_{2/0}(G)}{P_{1/0}(G)} \frac{L_{2/0}(G)}{L_{1/0}(G)}$$

$$\text{car } L_{2/1}(G) \neq \frac{P_{2/0}(G)}{P_{1/0}(G)} \quad (\text{non circularité de } L)$$

$$\text{et } P_{2/1}(G) \neq \frac{L_{2/0}(G)}{L_{1/0}(G)} \quad (\text{non circularité de } P)$$

Ainsi l'indice de Fisher ne possède pas à son tour la propriété de circularité.

Réversibilité

Les indices de Laspeyres et de Paasche ne possèdent pas la propriété de réversibilité contrairement à l'indice de Fisher.

a. Indice de Laspeyres

$$L_{0/1}(G) = \sum_i w_1^i \frac{G_0^i}{G_1^i} = \frac{1}{P_{1/0}(G)} \neq \frac{1}{L_{1/0}(G)}$$

b. Indice de Paasche

$$P_{0/1}(G) = \frac{1}{\sum_i w_0^i \frac{G_1^i}{G_0^i}} = \frac{1}{L_{1/0}(G)} \neq \frac{1}{P_{1/0}(G)}$$

c. Indice de Fisher

$$F_{0/1}(G) = \sqrt{L_{0/1}(G)P_{0/1}(G)} = \frac{1}{\sqrt{P_{1/0}(G)L_{1/0}(G)}} = \frac{1}{F_{1/0}(G)}$$

. EXERCICE

Soient 4 produits X_1 , X_2 , X_3 et X_4 dont les prix et les quantités sont donnés à deux périodes différentes t_1 et t .

Tableau 103 Prix de 4 produits durant périodes 1 et 2

	Période 1		Période t	
	P _{i1}	Q _{i1}	P _{it}	Q _{it}
X ₁	12	6	15	7
X ₂	5	13	8	11
X ₃	15	9	13	18
X ₄	8	10	10	9

1. Calculer les indices Pp, Pq, Pvg, Fp, Fq?

Solution

	p ₁	q ₁	p _t	q _t	p ₁ q ₁	p _t q _t	p ₁ q _t	p _t q ₁
x ₁	12	6	15	7	72	105	84	90
x ₂	5	13	8	11	65	88	55	104
x ₃	15	9	13	18	135	234	270	117
x ₄	8	10	10	9	80	90	72	100

$$P_p = \frac{\sum p_t q_t}{\sum p_1 q_t} = \frac{517}{481} \cdot 100 = 107.48$$

$$P_q = \frac{\sum p_t q_t}{\sum p_t q_1} = \frac{517}{411} \cdot 100 = 125.79$$

$$P_{vg} = \frac{\sum p_t q_t}{\sum p_1 q_1} = \frac{517}{352} \cdot 100 = 146.87$$

$$F_p = \sqrt{L_p P_p} = \sqrt{116.7 \cdot 107.48} = 111.9$$

$$F_q = \sqrt{L_q P_q} = \sqrt{136.6 \cdot 125.79} = 131.08$$

BIBLIOGRAPHIE

Bailly P., & Carrère C., (2015). « Statistiques descriptives L'économie et les chiffres ». Presses Universitaires de Grenoble.

The Open University, (2015). "Descriptive Statistics".

Chattamvelli R., & Shanmugam R., (2023). "Descriptive Statistics for Scientists and Engineers: application in R". Springer

Bernstein S., (1998). "Elements of Statistics I Descriptive Statistics and Probability". McGraw-Hill

Goos P., & Meintrup D., (2015). "Statistics with JMP_ Graphs, Descriptive Statistics and Probability". Wiley (2015)

Julie Scott Jones, & John Goldring J., (2022). "Exploratory and descriptive statistics". Sage Publications

William W.S. Wei, (2005). "Time Series Analysis _ Univariate and Multivariate Methods ". Addison Wesley.

Daniel J. Denis, (2016). "Applied Univariate, Bivariate, and Multivariate Statistics". John Wiley & Sons, Inc

Rebecca M. Warner , (2013). "Applied Statistics_ From Bivariate Through Multivariate Techniques". SAGE Publications

Husson F., Le S., & Pages J. (2010) "Exploratory Multivariate Analysis by Example Using R". Chapman & Hall _ CRC

Neil H. Timm, (2002). "Applied multivariate analysis (Springer Texts in Statistics)". Springer

Alvin C. Rencher, (2002). "Wiley series in probability and mathematical statistics - Methods of multivariate analysis" J. Wiley

Hardle et al., (2003). "Applied Multivariate Statistical Analysis", Springer

Härdle W., & Simar L., (2007) "Applied Multivariate Statistical Analysis". Springer

Daniel J. Denis , (2019). "SPSS Data Analysis for Univariate, Bivariate and Multivariate Statistics". Wiley