

STATISTIQUE DESCRIPTIVE ET ELEMENTS DE PROBABILITES

Bertrand Mareschal

bmaresc@ulb.ac.be

<http://homepages.ulb.ac.be/~bmaresc/stat-s-102.html>

2019/2020

1

Gestion

**Approche quantitative
en gestion**

Statistique

Informatique

Mathématique

2019/2020

2

Statistique descriptive et éléments de probabilités

- Notes de cours
 - Copie des transparents
<http://homepages.ulb.ac.be/~bmaresc/stat-s-102.html>
 - Exercices : voir assistants
 - Ouvrages de référence optionnels
 - Notes de cours et exercices PUB
 - Éléments de Statistique (J.J. Dreesbeke, Editions de l'ULB)
 - Autres livres...
- Examen écrit sans notes (janvier)
 - Partie théorique (QCM + question ouverte)
 - Partie pratique (questions ouvertes)

2019/2020

3

Plan du cours

1. Introduction
2. Statistique descriptive - séries univariées
3. Calcul des probabilités
4. Arbres de décision
5. Variables aléatoires et lois de probabilité
6. Statistique descriptive - séries bivariées
7. Méthodes de prévision

2019/2020

4

1. Introduction

- Contexte
- Historique
- Prise de décision
- Aide à la décision
- Modélisation
- Principaux outils
- Statistique

Contexte

- Augmentation de la taille et de la complexité des organisations.
- Division du travail, spécialisation, décentralisation des responsabilités et de la gestion.
- Nouveaux problèmes liés à la spécialisation :
 - Plus grande autonomie des départements au sein des organisations,
 - Manque de coordination,
 - Objectifs conflictuels,
 - Difficulté d'allouer des ressources limitées aux départements d'une façon globalement optimale.



2019/2020

7



2019

8

Historique

2ème guerre mondiale

- Allocation de ressources limitées aux opérations militaires.
- Idée : approche scientifique (UK - USA).
- “Research on Operations” par des équipes multidisciplinaires de scientifiques (Cf. “Blackett’s Circus”, UK).
- Grand succès : amélioration de l’efficacité des opérations militaires complexes
 - déploiement des radars en Angleterre,
 - détermination de la taille des convois,
 - logistique ...

2019/2020

9

Déploiement des radars




2019/2020

10

Déploiement des radars



2019/2020



11

Protection des convois



2019/2020

12



2019/2020

13


Historique Après-guerre

- Succès des applications militaires.
- Intérêt marqué des entreprises pour la RO.
- Applications civiles, d'abord dans les grandes entreprises industrielles :
 - Ex: industrie pétrolière - programmation linéaire pour la gestion de la production
- Plus tard, résultats utilisés (à moindre coût) par des organisations plus petites.
- Facteur clé : développement de l'informatique.

2019/2020

14

Prise de Décision




- Décrire la Réalité,
- Comprendre la Réalité,
- Gérer la Réalité.

2 Approches :

- Approche Qualitative,
- Approche Quantitative.


Aide à la Décision



Modèle quantitatif

- Décisions possibles ?
- Comment les comparer ?
- Préférences, Objectifs ?

Aide à la Décision



- Approximation de la réalité !
- Aide à la décision.

Quelques techniques

- Statistique
- Programmation mathématique (optimisation)
- Aide à la décision de type multicritère
- Simulation
- Gestion de projets : PERT/CPM
- Gestion des stocks et de la production
- Réseaux (transport)
- Fiabilité des équipements

Statistique ?

- Techniques et procédures pour la collecte, la description, l'analyse et l'interprétation de données.
- Transformer des données en information.
- Données, numériques ou non :
 - démographie, emploi, ventes, production, stocks, index des prix, intentions de votes, habitudes de consommation, ...

Sondages

Grand Baromètre: le Vlaams Belang devient le plus grand parti de Flandre

RTL INFO avec Antonio Solimando, publié le 13 septembre 2019 à 19h00, mis à jour à 20h41

...

Le Vlaams Belang devient le plus grand parti de Flandre devant la N-VA. C'est l'enseignement majeur de notre Grand Baromètre de rentrée ce vendredi soir. Si on devait voter ce dimanche, le Vlaams Belang récolterait **24,9%** des voix, soit une hausse de 6,2 points par rapport à son score lors des élections du 26 mai.

La N-VA, elle, perdrait près de 3 points (-2,8) avec un score de **22,7%**. Attention, il y a toutefois une nuance à faire: **l'écart entre les deux partis est faible, sous les marges d'erreurs**. La première place du parti d'extrême droite est donc surtout symbolique.



Les résultats se basent sur une vague de **2540** répondants, formant des échantillons représentatifs des Belges de 18 ans et plus à raison de **992** en Wallonie, **1000** en Flandre et **548** dans les 19 communes de la Région Bruxelles-Capitale, réalisée du 2 au 10 septembre 2019. Les interviews ont eu lieu en ligne. La marge d'erreur maximale, pour un pourcentage de 50% et un taux de confiance de 95% est de **+3,1** en Wallonie et en Flandre et de **+4,2** à Bruxelles. Affiliations: ESOMAR, Consumer Understanding Belgium.

Exemple 1 - Pepsi

In the last few years, colleges and universities have signed exclusivity agreements with a variety of private companies. These agreements bind the university to sell that company's products exclusively on the campus. Many of the agreements involve food and beverage firms.

A large university with a total enrollment of about 50,000 students has offered Pepsi-Cola an exclusivity agreement that would give Pepsi exclusive rights to sell its products at all university facilities for the next year and an option for future years. In return, the university would receive 35% of the on-campus revenues and an additional lump sum of \$200,000 per year. Pepsi has been given 2 weeks to respond.

The management at Pepsi quickly reviews what they know. The market for soft drinks is measured in terms of 12-ounce cans. Pepsi currently sells an average of 22,000 cans per week (over the 40 weeks of the year that the university operates). The cans sell for an average of 75 cents each. The costs including labor amount to 20 cents per can. Pepsi is unsure of its market share but suspects it is considerably less than 50%. A quick analysis reveals that if its current market share were 25%, then, with an exclusivity agreement, Pepsi would sell 88,000 (22,000 is 25% of 88,000) cans per week or 3,520,000 cans per year. The gross revenue would be computed as follows:

$$3,520,000 \times \$0.75/\text{can} = \$2,640,000$$

2019/2020

23

Exemple 1 - Pepsi

This figure must be multiplied by 65% because the university would rake in 35% of the gross. Thus,

$$65\% \times \$2,640,000 = \$1,716,000$$

The total cost of 20 cents per can (or \$704,000) and the annual payment to the university of \$200,000 are subtracted to obtain the net profit:

$$\text{Net profit} = \$1,716,000 - \$704,000 - \$200,000 = \$812,000$$

Pepsi's current annual profit is

$$40 \text{ weeks} \times 22,000 \text{ cans/week} \times \$0.55 = \$484,000$$

If the current market share is 25%, the potential gain from the agreement is

$$\$812,000 - \$484,000 = \$328,000$$

The only problem with this analysis is that Pepsi does not know how many soft drinks are sold weekly at the university. Coke is not likely to supply Pepsi with information about its sales, which together with Pepsi's line of products constitute virtually the entire market.

Pepsi assigned a recently hired university graduate to survey the university's students to supply the missing information. Accordingly, she organizes a survey that asks 500 students to keep track of the number of soft drinks they purchase in the next 7 days.

2019/2020

24


Statistique - 2 composantes

- Statistique descriptive
 - Organiser, résumer, représenter un ensemble de données.
 - Représentations graphiques.
 - Mesures statistiques (moyenne,...).
- Inférence statistique
 - Tirer des conclusions pour une population à partir d'un échantillon prélevé dans cette population.
 - Mesurer et prendre en compte l'erreur d'échantillonnage.

2019/2020

25

Terminologie



- Population
 - Ensemble des éléments étudiés. (individus, pays, entreprises, ...)
- Echantillon
 - Sous-ensemble de la population pour lequel on récolte des observations et qui peut être analysé.

2019/2020

26

Terminologie

- **Variable**
 - Caractéristique mesurable de la population. (chiffre d'affaire d'une entreprise, temps consacré par un individu à l'utilisation d'une base de données, ...)
- **Paramètre**
 - Quantité numérique qui résume un aspect de la population. (valeur moyenne d'une variable)
- **Statistique**
 - Quantité numérique qui résume un aspect d'un échantillon. (valeur moyenne observée sur un échantillon)

Types de données

- **Nominales**
 - Catégories
 - Ex: sexe, état-civil, nationalité, secteur économique, ...
 - Dénombrement
- **Ordinales**
 - Catégories ordonnées
 - Ex: mentions (Aj., réussi, S, D, GD, LPGD), tailles (S,M,L,XL), ...
 - Dénombrements, comparaison
- **Numériques**
 - Nombres
 - Ex: cotes, quantités vendues, revenus, ...
 - Dénombrement, comparaison, différence, rapport, moyenne, ...

Plan du cours

1. Introduction
2. Statistique descriptive - séries univariées
3. Calcul des probabilités
4. Arbres de décision
5. Variables aléatoires et lois de probabilité
6. Statistique descriptive - séries bivariées
7. Méthodes de prévision

2. Stat. Descriptive - 1 dim

- **Objectif** : Résumer les caractéristiques d'un (grand) ensemble de données. Mettre en évidence les points importants.
- **Tableaux** : Première étape. Tri et regroupement des observations. Distribution de fréquences.
- **Graphiques** : Visualisation des données. Lignes, barres, histogrammes, diagrammes en secteurs, ...
- **Mesures** : Synthèse des données en quelques grandeurs représentatives.
 - Quel est l'ordre de grandeur des valeurs observées ?
Paramètres de position (moyenne, médiane, ...)
 - Y a-t-il de grands écarts entre les valeurs observées ?
Paramètres de dispersion (variance, écart-type, ...)

Données brutes

$$\{x_1, x_2, \dots, x_n\} = \{x_i; i = 1, \dots, n\}$$

- Données telles que recueillies
 - n observations d'une variable x : série statistique univariée
 - Exemple 2 : Ages de 100 employés d'une entreprise (échantillon...)

60	39	23	30	29	26	29	41	40	32
63	22	32	52	46	35	25	28	33	33
20	25	42	34	29	43	41	31	30	36
58	21	24	55	51	28	18	40	44	38
32	21	30	31	25	49	31	26	33	36
43	34	35	22	33	38	34	34	33	34
23	26	57	23	26	36	39	31	35	34
34	51	40	50	35	45	28	36	32	39
26	48	17	45	45	25	25	30	36	30
43	25	27	21	53	25	38	33	37	33

2019/2020

31

Série ordonnée

- Si x est ordinale ou quantitative

$$\{x_{(1)}, x_{(2)}, \dots, x_{(n)}\} \text{ avec } x_{(i)} \leq x_{(j)} \text{ si } i \leq j$$

17	18	20	21	21	21	22	22	23	23
23	24	25	25	25	25	25	25	25	26
26	26	26	26	27	28	28	28	29	29
29	30	30	30	30	30	31	31	31	31
32	32	32	32	33	33	33	33	33	33
33	34	34	34	34	34	34	34	35	35
35	35	36	36	36	36	36	37	38	38
38	39	39	39	40	40	40	41	41	42
43	43	43	44	45	45	45	46	48	49
50	51	51	52	53	55	57	58	60	63

2019/2020

32

Distribution observée

Age	Effectif
15-19	2
20-24	10
25-29	19
30-34	27
35-39	16
40-44	10
45-49	6
50-54	5
55-59	3
60-64	2
Total	100

- Données regroupées en classes (intervalles).
- Effectif d'une classe = nombre d'observations dans cette classe.

Exemple 3

- Nb de voitures dans 10 familles de même taille.

i	1	2	3	4	5	6	7	8	9	10
x_i	2	0	1	1	2	3	1	1	1	0

- Série observée :

$$\{x_i\} = \{2, 0, 1, 1, 2, 3, 1, 1, 1, 0\}$$

$$n = 10$$

- Série ordonnée :

$$\{x_{(i)}\} = \{0, 0, 1, 1, 1, 1, 1, 2, 2, 3\}$$

Exemple 3

- Distribution observée :


Valeurs observées	→	x_j	0	1	2	3
Effectifs associés	→	n_j	2	5	2	1

$j = 1, 2, 3, 4$ $J = 4 =$ nb de valeurs distinctes

$$n_1 + n_2 + \dots + n_J = \sum_{j=1}^J n_j = n$$

Représentations graphiques



- Diagramme en bâtons : exemple 3



Représentations graphiques

- Diagramme en barres : pour variables qualitatives

Cas ordinal
(avis pédagogiques)




Cas nominal
(continents)

2019/2020

37

Représentations graphiques

- Diagramme en secteurs (tarte, camembert):



2019/2020

38

Fréquences

• Définition : $f_j = \frac{n_j}{n} \quad j = 1, 2, \dots, J$

• Exemple 3 : distribution de fréquences

x_j	n_j	f_j
0	2	0.2
1	5	0.5
2	2	0.2
3	1	0.1

$$n = 10$$

$$\sum_{j=1}^J f_j = 1$$

Effectifs et fréquences cumulés

• Effectifs cumulés :

nombre d'observations $\leq x_j$

$$N_j = n_1 + n_2 + \dots + n_j$$

• Fréquences cumulées :

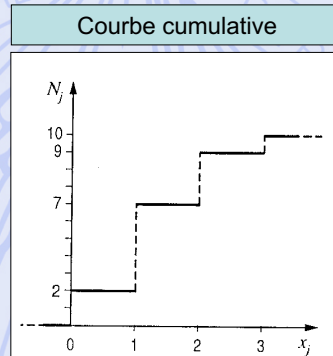
pourcentage d'observations $\leq x_j$

$$F_j = \frac{N_j}{n}$$

Effectifs et fréquences cumulés

- Exemple 3 :

x_j	n_j	f_j	N_j	F_j
0	2	0.2	2	0.2
1	5	0.5	7	0.7
2	2	0.2	9	0.9
3	1	0.1	10	1.0



Effectifs et fréquences cumulés à droite

- Effectifs cumulés à droite :
nombre d'observations $\geq x_j$

$$N_j^* = n_j + n_{j+1} + \dots + n_n$$


- Fréquences cumulées à droite :
pourcentage d'observations $\geq x_j$

$$F_j^* = \frac{N_j^*}{n}$$

Effectifs et fréquences cumulés à droite

- Exemple 3 :

x_j	n_j	f_j	N_j^*	F_j^*
0	2	0.2	10	1.0
1	5	0.5	8	0.8
2	2	0.2	3	0.3
3	1	0.1	1	0.1



Distribution groupée

- Cf. exemple 2 :
 - Grand nombre de valeurs distinctes,
 - Petits effectifs.
- Regroupements des valeurs en classes

Exemple 4

- Série de 175 tailles

176	175	185	176	190	163	185
166	152	178	172	178	190	176
177	160	183	186	182	154	172
150	168	174	180	173	174	157
181	171	181	192	188	171	176
169	184	168	179	185	189	165
175	170	176	184	189	176	171
173	189	177	170	165	182	174
184	178	161	150	175	171	194
162	187	166	170	176	183	175
169	198	185	171	184	177	166
171	180	158	177	155	184	195
193	176	192	169	181	178	180
154	155	196	175	175	190	191
170	165	151	191	177	153	180
155	177	187	180	169	198	156
186	164	178	187	183	175	183
163	182	177	183	170	169	182
184	170	190	164	186	164	160
176	175	175	185	169	170	174
180	173	162	161	196	181	181
188	182	181	177	179	177	179
178	172	163	165	198	167	180
169	184	172	167	151	183	161
177	175	168	174	197	179	179

150	160	165	169	172	175	177	178	181	184	187	192
150	161	165	170	172	175	177	179	181	184	187	193
151	161	166	170	172	175	177	179	181	184	187	194
151	161	166	170	173	175	177	179	181	184	188	195
152	162	166	170	173	175	177	179	182	184	188	196
153	162	167	170	173	175	177	179	182	184	189	196
154	163	167	170	174	176	177	180	182	184	189	197
154	163	168	170	174	176	177	180	182	185	189	198
155	163	168	171	174	176	177	180	182	185	190	198
155	164	168	171	174	176	177	180	183	185	190	198
155	164	169	171	174	176	178	180	183	185	190	
156	164	169	171	175	176	178	180	183	185	190	
157	165	169	171	175	176	178	180	183	186	191	
158	165	169	171	175	176	178	181	183	186	191	
160	165	169	172	175	176	178	181	183	186	192	





Diagramme en tiges et feuilles

- « Stem and leaf display »

15	04525810514376
16	69253908548162389415759939475601
17	67531068751086705325846787526290017574835657094161785079626145499
18	14640849702245315716040735285941369234135003210
19	38260210687008451

Groupement en classes

- Intervalles disjoints
- Recouvrir toutes les valeurs observées




2019/2020

47

Groupement en classes

- J classes : $j = 1, 2, \dots, J$



- $J = ?$ Règle de Sturges :

$$J \approx 1 + \frac{10}{3} \log_{10} n$$


2019/2020

48

Distribution groupée


$(l_j^- ; l_j^+)$	x_{cj}	n_j	f_j	N_j	F_j	N_j^*	F_j^*
149.5-159.5	154.5	14	0.080	14	0.080	175	1
159.5-169.5	164.5	32	0.183	46	0.263	161	0.920
169.5-179.5	174.5	65	0.371	111	0.634	129	0.737
179.5-189.5	184.5	47	0.269	158	0.903	64	0.366
189.5-199.5	194.5	17	0.097	175	1	17	0.097
		n=175	1				

Histogramme des effectifs



Histogramme des effectifs


- Attention à l'unité sur l'axe vertical !
- Cas de classes de longueurs différentes.



2019/2020

51


Polygone des effectifs



2019/2020

52

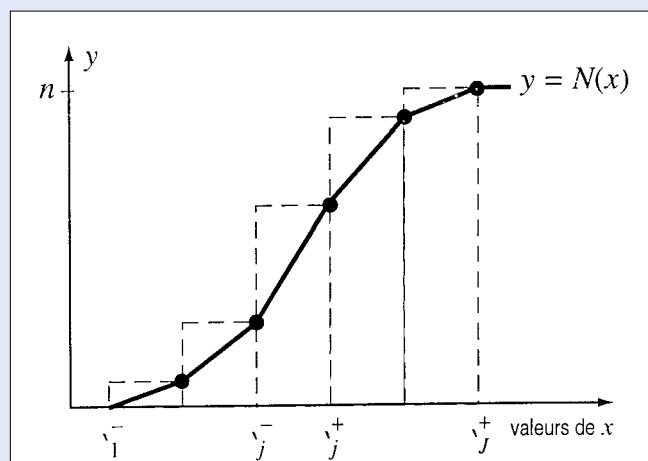
Histogramme des effectifs cumulés



2019/2020

53

Courbe cumulative




2019/2020

54


Utilisation de graphiques

- Inclure informations utiles.
- Eviter éléments inutiles !
- Préférer la simplicité à la sophistication.
- Choix des unités et des axes.
- ...


Graphiques !



Graphiques !

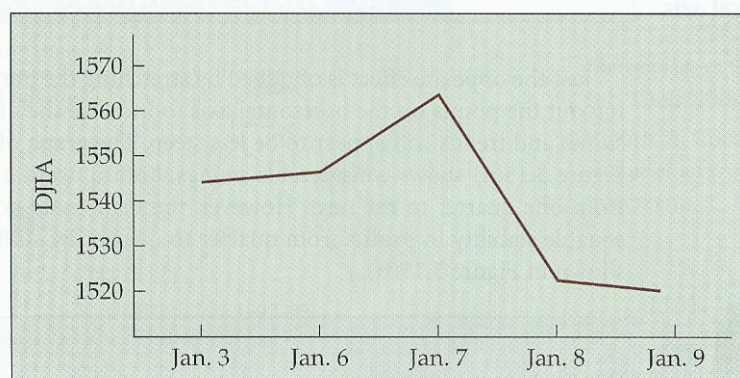


(a) Interest rates have finally begun to turn downward.

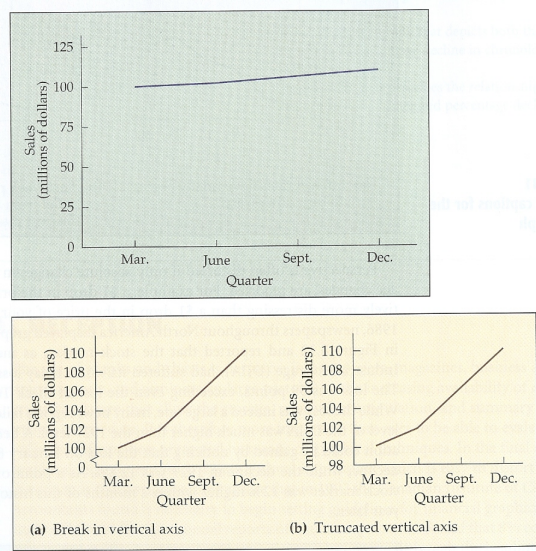


(b) Last week provided temporary relief from the upward trend in interest rates.

Graphiques !



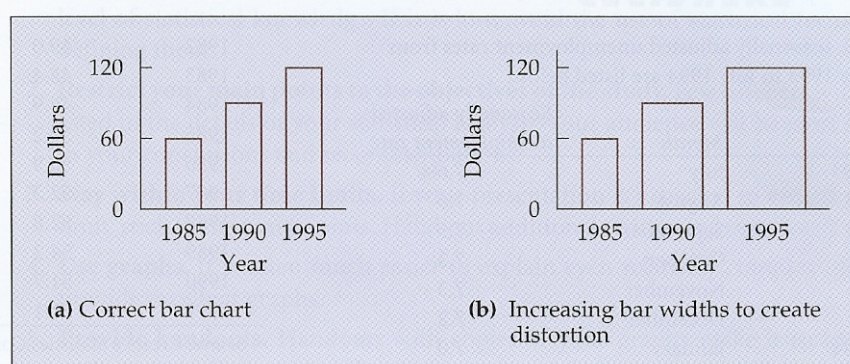
Graphiques !



2019/2020

59

Graphiques !




2019/2020

60

Graphiques !

Snowfall in Metro climbs relentlessly

Snowfall last winter was more than 50% greater than the previous winter, and more than double what fell four winters ago.




Shareholders Get More for Their Money

Return on Coca-Cola's shareholders' equity, in percent.



This line, representing 18 miles per gallon in 1978, is 0.6 inches long.




This line, representing 27.5 miles per gallon in 1985, is 5.3 inches long.

Fuel Economy Standards for Autos
Set by Congress and supplemented by the Transportation Department. In miles per gallon.

New York Times, August 9, 1978, p. D-2.

REQUIRED FUEL ECONOMY STANDARDS:
NEW CARS BUILT FROM 1978 TO 1985






Figure 9. An example of how to goose up the effect by squaring the eyeball (© 1978, The Washington Post).

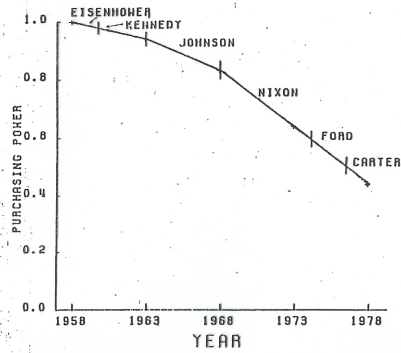


Figure 10. The data in Figure 9 as an unadorned line chart (from Wainer, 1980).




Figure 11. The White House showing neither scale nor context (© 1981, The New York Times, reprinted with permission).




Figure 13. Changing scale in mid-axis to make exponential growth linear (© The Washington Post).


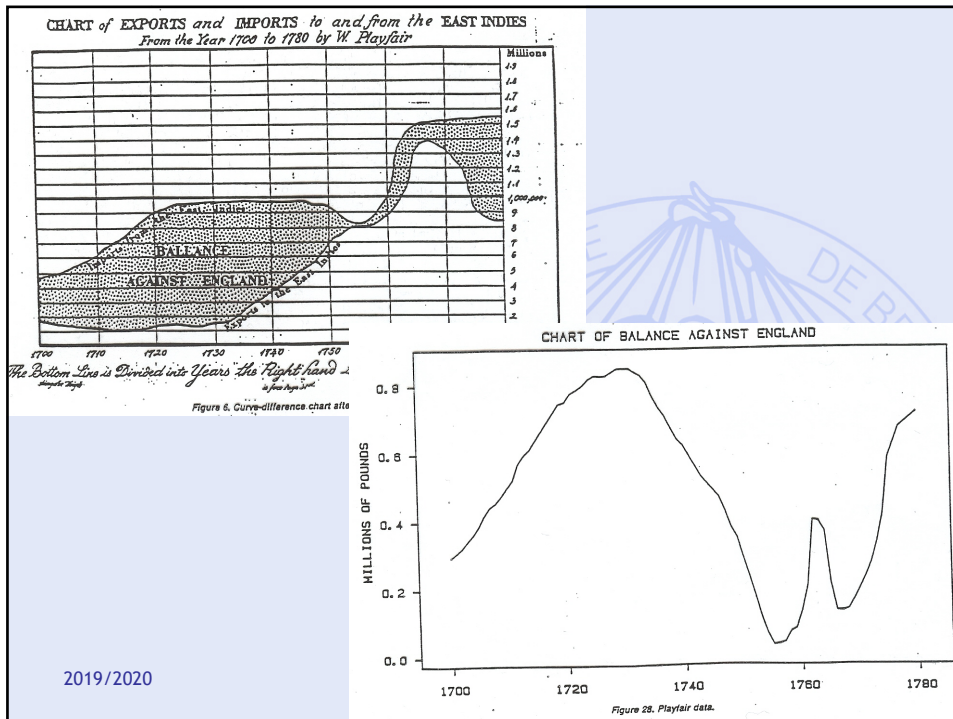


Figure 14. Data from Figure 13 redone with linear scale (from Wainer 1980).

2019/2020

65



2019/2020

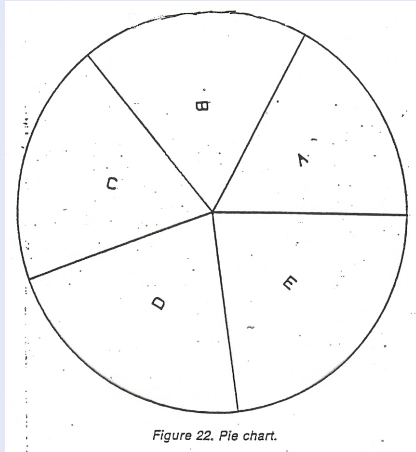


Figure 22. Pie chart.




Figure 23. Dot chart.

Statistique du jour

Davis challenges Schwarzenegger to debate

Issa endorses actor-turned-politician

CNN.com, Friday, September 26, 2003 Posted: 8:14 PM EDT (0014 GMT)

LOS ANGELES, California (CNN) -- Charging that Arnold Schwarzenegger is misleading voters in the recall campaign, Democratic Gov. Gray Davis on Friday challenged the actor-turned-politician to a debate.



...
 The latest poll in the recall race, by the Public Policy Institute of California, showed Bustamante with support from 28 percent of likely voters, Schwarzenegger with 26 percent and McClintock with 14 percent. With a margin of error of plus-or-minus 3 percentage points, Bustamante and Schwarzenegger were locked in a statistical tie.
 ...




Paramètres d'une série

- Résumer la série en quelques grandeurs-clé !
- 3 catégories de paramètres :
 - Position
 - Valeur typique ? Valeur « centrale » ?
 - Moyenne, médiane, mode, ...
 - Dispersion
 - Ecart entre valeurs observées ?
 - Etendue, écart interquartile, variance, écart-type, ...
 - Forme
 - Symétrie ? Asymétrie ?

Exemples

<i>i</i>	S1	S2	S3	S4	S5
1	1	6	2	3	3
2	2	7	3	2	4
3	2	7	3	4	2
4	1	6	2	1	5
5	3	8	3	3	3
6	4	9	3	5	1
7	5	10	4	5	1
8	3	8	3	4	2
9	4	9	3	5	1
10	5	10	4	5	1

Moyenne	3,00	8,00	3,00	3,70	2,30
Médiane	3,00	8,00	3,00	4,00	2,00
Mode	1,00	6,00	3,00	5,00	1,00
Variance	2,00	2,00	0,40	1,81	1,81
Ecart-type	1,41	1,41	0,63	1,35	1,35
Skewness	0,00	0,00	0,00	-0,80	0,80
Kurtosis	-1,33	-1,33	0,08	-0,38	-0,38



Paramètres de position

- Objectif : déterminer une valeur centrale
- ① Moyenne arithmétique
 - Exemple 3 :

$$\{x_i\} = \{2, 0, 1, 1, 2, 3, 1, 1, 1, 0\}$$

$$\bar{x} = \frac{2 + 0 + 1 + 1 + 2 + 3 + 1 + 1 + 1 + 0}{10} = 1.2$$

- Définition :

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

Moyenne

- Propriétés de la moyenne arithmétique
 - Uniquement pour données numériques !
 - Fortement influencée par les valeurs extrêmes :

$$\{x_i\} = \{2, 0, 1, 1, 2, 30, 1, 1, 1, 0\}$$

$$\bar{x} = \frac{2 + 0 + 1 + 1 + 2 + 30 + 1 + 1 + 1 + 0}{10} = 3.9$$

Moyenne

- Pour une distribution observée :

$$\bar{x} = \frac{1}{n} \sum_{j=1}^J n_j x_j = \sum_{j=1}^J f_j x_j$$

- Exemple 3 :

x_j	n_j	f_j
0	2	0.2
1	5	0.5
2	2	0.2
3	1	0.1

$$\begin{aligned} \bar{x} &= \frac{1}{10} (2 \times 0 + 5 \times 1 + 2 \times 2 + 1 \times 3) \\ &= 0,2 \times 0 + 0,5 \times 1 + 0,2 \times 2 + 0,1 \times 3 \\ &= 1,2 \end{aligned}$$

Moyenne

- Pour une distribution groupée :

$$\bar{x} = \frac{1}{n} \sum_{j=1}^J n_j x_{c_j}$$

$(\ell_j^- ; \ell_j^+)$	x_{c_j}	n_j	f_j	N_j	F_j	N_j^*	F_j^*
149.5-159.5	154.5	14	0.080	14	0.080	175	1
159.5-169.5	164.5	32	0.183	46	0.263	161	0.920
169.5-179.5	174.5	65	0.371	111	0.634	129	0.737
179.5-189.5	184.5	47	0.269	158	0.903	64	0.366
189.5-199.5	194.5	17	0.097	175	1	17	0.097
		n=175	1				

$$\bar{x} = \frac{14 \times 154,5 + 32 \times 164,5 + \dots + 17 \times 194,5}{175}$$

👉 Approximation !

Paramètres de position

- ② Médiane : $x_{1/2}$
Valeur telle que le nombre d'observations qui la précèdent est égal au nombre d'observations qui la suivent, dans la série ordonnée.
- Exemple : $\{x_{(i)}\} = \{1, 3, 7, 8, 9, 13, 17\}$
 $\rightarrow x_{1/2} = 8$


Médiane

- Pour n impair : $x_{1/2} = x_{\left(\frac{n+1}{2}\right)}$
 - Pour n pair :
(convention) $x_{1/2} = \frac{x_{\left(\frac{n}{2}\right)} + x_{\left(\frac{n}{2}+1\right)}}{2}$
- $\{x_{(i)}\} = \{1, 3, 7, 8, 9, 13\} \rightarrow x_{1/2} = \frac{7+8}{2} = 7,5$
- Avantage de la médiane : pas influencée par les valeurs extrêmes.

Médiane

- Pour une distribution observée :

$$x_{1/2} \text{ telle que } N(x_{1/2}) = N^*(x_{1/2})$$



$$N(x_{1/2}) = N^*(x_{1/2}) \geq \frac{n}{2}$$

Médiane

- Pour une distribution groupée :

$$x_{1/2} \text{ solution de } N(x_{1/2}) = N^*(x_{1/2}) = \frac{n}{2}$$

- Classe médiane : (l_m^-, l_m^+)
- Valeur approchée de la médiane :

$$x_{1/2} = l_m^- + h_m \frac{\frac{n}{2} - N_{m-1}}{n_m}$$

Médiane

- Exemple 4 :

$(\ell_j^-; \ell_j^+)$	x_{ej}	n_j	f_j	N_j	F_j	N_j^*	F_j^*
149.5-159.5	154.5	14	0.080	14	0.080	175	1
159.5-169.5	164.5	32	0.183	46	0.263	161	0.920
169.5-179.5	174.5	65	0.371	111	0.634	129	0.737
179.5-189.5	184.5	47	0.269	158	0.903	64	0.366
189.5-199.5	194.5	17	0.097	175	1	17	0.097
		n=175	1				

$$\frac{n}{2} = \frac{175}{2} = 87,5$$


$$(l_m^-, l_m^+) = (169,5 ; 179,5)$$

$$x_{1/2} = 169,5 + 10 \times \frac{87,5 - 46}{65} = 175,88$$

Paramètres de position

- Quantiles (percentiles) :

quantile d'ordre p : $x_p \quad p \in (0,1)$



$$x_p \quad \text{tel que} \quad \begin{cases} N(x_p) \geq np \\ N^*(x_p) \geq n(1-p) \end{cases}$$

Quantiles

- Quartiles :

$$p = \frac{1}{4}$$



$$Q_1 = x_{1/4}$$

$$p = \frac{2}{4}$$



$$Q_2 = x_{1/2}$$

$$p = \frac{3}{4}$$



$$Q_3 = x_{3/4}$$

- Déciles :

$$p = \frac{1}{10}$$

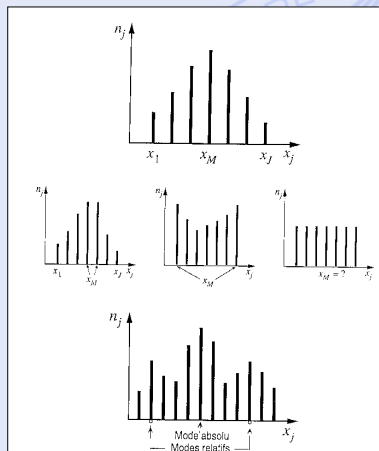
$$p = \frac{2}{10}$$

...

$$p = \frac{9}{10}$$

Paramètres de position

- ④ Mode : Valeur la plus fréquente.



Paramètres de position

- Autres paramètres :

- Moyenne tronquée d'ordre 1 : $\bar{x}_{t,2} = \frac{1}{n-2} \sum_{i=2}^{n-1} x_{(i)}$

- Moyenne harmonique : $H = n / \sum_{i=1}^n \frac{1}{x_i}$

- Moyenne géométrique : $G = \sqrt[n]{\prod_{i=1}^n x_i}$

Moyenne géométrique

- pour des ratios, des taux, des pourcentages (valeurs positives uniquement).

Exemple : ventes d'une entreprise sur 5 ans :

Année	1	2	3	4	5
Ventes	100	110	132	151,8	170,02
Variation		+10%	+20%	+15%	+12%

→ Augmentation moyenne annuelle des ventes ?

$\bar{x} = 14,25\%$

Moyenne géométrique

$= 14,19\%$

$\frac{(10 + 20 + 15 + 12)}{4}$

$100 \times (1,1425)^4 = 170,38$

$\sqrt[4]{1,10 \times 1,20 \times 1,15 \times 1,12}$

$100 \times (1,1419)^4 = 170,02$

Moments

- Moment d'ordre r par rapport à c :

$$m_r(c) = \frac{1}{n} \sum_{i=1}^n (x_i - c)^r$$

- Moment par rapport à l'origine ($c = 0$) :

$$m'_r = \frac{1}{n} \sum_{i=1}^n x_i^r$$

- Moment centré :

$$m_r = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^r$$

Paramètres de dispersion

- Etendue :

$$E = x_{(n)} - x_{(1)}$$

- Ecart interquartile :

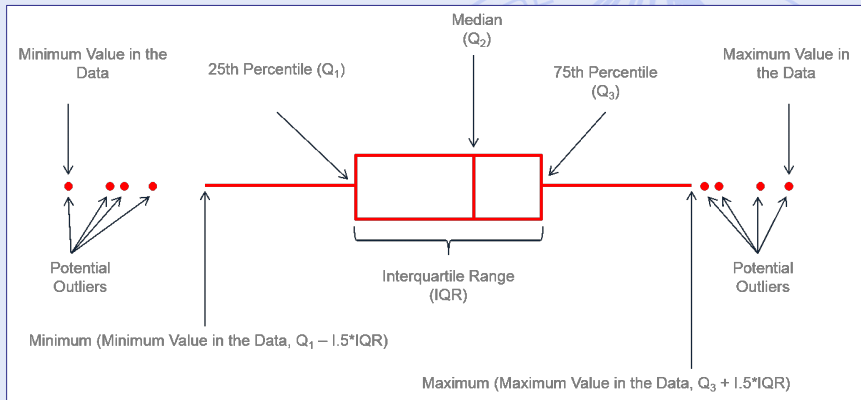
$$E_Q = x_{3/4} - x_{1/4}$$

- Ecart interdécile :

$$E_D = x_{9/10} - x_{1/10}$$


Paramètres de dispersion

• Box-Plot :



leansigmacorporation.com
2019/2020

Box-Plots



	C1	C2	C3	C4	C5	C6	C7
4	42	19	33	21	14	18	
12	44	23	47	24	75	19	
23	46	25	59	27	76	21	
35	47	27	67	29	77	23	
46	49	31	69	77	78	24	
52	51	43	73	79	79	25	
67	54	48	75	83	80	27	
75	56	51	77	85	81	29	
83	57	63	83	86	83	30	
92	58	73	85	87	84	93	

2019/2020

Paramètres de dispersion

- Ecart moyen absolu :

$$e_m = \frac{1}{n} \sum_{i=1}^n |x_i - \bar{x}|$$

- Ecart médian absolu :

$$e_m^* = \frac{1}{n} \sum_{i=1}^n |x_i - x_{1/2}|$$

Paramètres de dispersion

- Variance :

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

- Ecart-type :

$$s = \sqrt{s^2}$$

- Coefficient de variation :

$$CV = \frac{s}{\bar{x}}$$

Variance

- Agrégation de deux séries

$$[n_1 \quad \bar{x}_1, s_1^2] \quad [n_2 \quad \bar{x}_2, s_2^2]$$



$$n = n_1 + n_2$$

$$s^2 = \frac{n_1 s_1^2 + n_2 s_2^2}{n} + \frac{n_1 (\bar{x}_1 - \bar{x})^2 + n_2 (\bar{x}_2 - \bar{x})^2}{n}$$

Variance dans les « groupes »

Variance entre les « groupes »

Variance

- Calcul :

$$s^2 = \frac{1}{n} \sum_{i=1}^n x_i^2 - \bar{x}^2$$

- Pour une distribution observée :

$$s^2 = \frac{1}{n} \sum_{j=1}^J n_j (x_j - \bar{x})^2 = \frac{1}{n} \sum_{j=1}^J n_j x_j^2 - \bar{x}^2$$

Variance

- Exemple 3 :

$$s^2 = \frac{1}{10} (2 \times (0-1,2)^2 + 5 \times (1-1,2)^2 + 2 \times (2-1,2)^2 + 1 \times (3-1,2)^2)$$

$$= \frac{1}{10} (2 \times 0^2 + 5 \times 1^2 + 2 \times 2^2 + 1 \times 3^2) - 1,2^2$$



$$= 0,76$$

$$s = \sqrt{0,76} = 0,87$$

x_j	n_j	f_j
0	2	0.2
1	5	0.5
2	2	0.2
3	1	0.1

Paramètres de forme


- Box-plot
- Graphique des quantiles



Graphique des quantiles

- Exemple C5 :


C1	C2	C3	C4	C5	C6	C7
4	42	19	33	21	14	18
12	44	23	47	24	75	19
23	46	25	59	27	76	21
35	47	27	67	29	77	23
46	49	31	69	77	78	24
52	51	43	73	79	79	25
67	54	48	75	83	80	27
75	56	51	77	85	81	29
83	57	63	83	86	83	30
92	58	73	85	87	84	93




2019/2020

97


Asymétrie



Symétrie



Asymétrie à droite



Asymétrie à gauche

2019/2020

98

Coefficients d'asymétrie

- Moment centré d'ordre 3 :

$$m_3 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^3$$

asymétrie à gauche	$m_3 > 0$
symétrie	$m_3 = 0$
asymétrie à droite	$m_3 < 0$

- Coefficient de Fisher (« skewness ») :

$$g_1 = m_3 / s^3$$

Coefficients d'asymétrie

- Coefficient empirique de Pearson :

$$S_k = \frac{\bar{x} - x_M}{s}$$

- Coefficient empirique de Yule et Kendall :

$$Y_K = \frac{x_{1/4} + x_{3/4} - 2x_{1/2}}{x_{3/4} - x_{1/4}}$$


Coefficients d'aplatissement

- Coefficient de Pearson :

$$b_2 = \frac{m_4}{s^4} \quad \text{où} \quad m_4 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^4$$

- Coefficient de Fisher (Kurtosis) :

$$g_2 = b_2 - 3$$






2019/2020

101

Exemples

<i>i</i>	S1	S2	S3	S4	S5
1	1	6	2	3	3
2	2	7	3	2	4
3	2	7	3	4	2
4	1	6	2	1	5
5	3	8	3	3	3
6	4	9	3	5	1
7	5	10	4	5	1
8	3	8	3	4	2
9	4	9	3	5	1
10	5	10	4	5	1

Moyenne	3,00	8,00	3,00	3,70	2,30
Médiane	3,00	8,00	3,00	4,00	2,00
Mode	1,00	6,00	3,00	5,00	1,00
Variance	2,00	2,00	0,40	1,81	1,81
Ecart-type	1,41	1,41	0,63	1,35	1,35
Skewness	0,00	0,00	0,00	-0,80	0,80
Kurtosis	-1,33	-1,33	0,08	-0,38	-0,38



2019/2020

102

Transformations de variables

- Transformation linéaire :
 - Changement d'origine et d'unité

$$x \rightarrow u = \frac{x - x_0}{d} \quad x_0 \in \mathbb{R}_0 \quad d \in \mathbb{R}_0^+$$

- Exemple :

$$t_{\circ C} = \frac{t_{\circ F} - 32}{1,8}$$

Transformations de variables

- Influence sur les paramètres de position :

$$x_i \rightarrow u_i = \frac{x_i - x_0}{d}$$

$$\bar{u} = \frac{\bar{x} - x_0}{d} \Leftrightarrow \bar{x} = x_0 + \bar{u}d$$

- Même transformation pour les autres paramètres de position :

$$u_{1/2} \quad u_M \quad u_p \quad \dots$$

Transformations de variables

- Influence sur les paramètres de dispersion :
 - Changement d'origine : sur CV seulement,
 - Changement d'unité : sur tous sauf CV.
- Exemple :

$$s_x^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \quad s_u^2 = \frac{1}{n} \sum_{i=1}^n (u_i - \bar{u})^2$$

$$\rightarrow s_u^2 = \frac{s_x^2}{d^2}$$

Transformations de variables

- Influence sur les paramètres de forme :
 - Pas d'influence sur g_1, S_k, Y_k, b_2, g_2
- Autres transformations :
 - Transformation logarithmique : $y = \log_{10} x$
 - Famille de transformations de Tukey :
 - $\dots, \frac{1}{x^2}, \frac{1}{x}, \frac{1}{\sqrt{x}}, \log x, \sqrt{x}, x, x^2, x^3, \dots$
 - Différence (données chronologiques) :

$$\nabla x_t = x_t - x_{t-1}$$