



N° Réf :.....

## Centre Universitaire de Mila

Institut des Sciences et de la Technologie

Département de Mathématiques et Informatique

**Mémoire préparé En vue de l'obtention du diplôme de licence**

**en : Filière mathématiques fondamentales**

### Thème

***STATISTIQUE INFERENTIELLE ET ECHANTION***

***Préparé par :***

- 1. Djamaa AHLAM***
- 2. Bazoula SOUHILA***
- 3. Laib SARRA***

***En cadré par :Zerari AMEL***

***Année universitaire : 2013/2014***

## *Remerciements*

Nous tenons à remercier dieu le plus puissant pour nous avoir donné le courage d'accomplir ce modeste travail.

Nous remercions tous ceux qui ont participé à la réalisation de ce travail qui est le fruit de notre dur labeur. Nous citons avec respect notre encadrant maitre assistanat **Zerari AMEL** pour sa disponibilité et ses judicieuses orientations ainsi que l'intérêt qu'il a manifesté à notre projet.

De même , nous tenons à remercier tous ceux qui ont contribué de près ou de loin à la réalisation de ce travail.

# Table des matières

|   |           |
|---|-----------|
| <b>Introduction Générale</b>  | <b>2</b>  |
| <b>1 statistique inférentielle et échantillon</b>                     | <b>4</b>  |
| 1.1 statistique descriptive . . . . .                                 | 4         |
| 1.1.1 Séries statistiques associées à un caractère discret . . . . .  | 5         |
| 1.1.2 Séries statistiques associées à un caractère continue . . . . . | 9         |
| 1.1.3 Variable aléatoire . . . . .                                    | 10        |
| 1.2 L'échantillon . . . . .   | 18        |
| 1.2.1 Méthodes de sondage . . . . .                                   | 18        |
| 1.3 Statistique inférentielle . . . . .                               | 22        |
| 1.3.1 Objectif . . . . .  | 22        |
| 1.3.2 Estimation . . . . .  | 23        |
| 1.3.3 Estimateur . . . . .  | 23        |
| 1.3.4 Test d'hypothèse . . . . .                                      | 28        |
| <b>2 Caractéristiques d'un échantillon</b>                            | <b>31</b> |
| 2.0.5 Caractéristiques d'un échantillon aléatoire . . . . .           | 32        |
| 2.0.6 Distribution du chi-deux . . . . .                              | 34        |
| 2.0.7 Distribution de Fisher-Snédecor . . . . .                       | 36        |
| 2.0.8 Distribution de Student . . . . .                               | 37        |
| 2.0.9 Cas particulier d'échantillons gaussiens . . . . .              | 39        |
| <b>Conclusion Générale</b>  | <b>41</b> |
| <b>Bibliographie</b>  | <b>41</b> |

# Introduction Générale

La statistique connut, au début des  $XX^e$  siècle, une véritable révolution, celle de l'inférence. Il s'agit, à partir de résultats statistiques limités, observés sur un échantillon, d'inférer à toute une population pour laquelle on induira des estimations, à partir des observations. Cette démarche trouve sa motivation dans des domaines appliqués spécifiques essentiellement en Grande Bretagne et aux Etats-Unis mais les outils ainsi créés trouveront, de part leur efficacité, des applications quasi universelles. La France restera à l'écart de ce mouvement. A l'époque du bourbakisme montant, si de grands noms comme Emile Borel, Maurice Fréchet, Paul Levy, s'illustrent dans la théorie (formelle) des probabilités, les méthodes statistiques ont mauvaise presse dans les milieux universitaires. Il faudra attendre les années cinquante (et encore plus tard dans l'enseignement) pour que, face à la pression économique des applications et à l'efficacité des nouvelles méthodes statistiques, la France commence à rattraper son retard dans ce domaine.

Depuis le  $XVIII^e$  siècle, deux approches des probabilités coexistent : le point de vue subjectif (représenté par Bayes et Laplace), où l'on considère la probabilité en termes de "raisons de croire", d'estimation du degré de confiance dans la réalisation d'un événement aléatoire et le point de vue fréquentiste, s'appuyant sur la loi des grands nombres de Bernoulli et les théorèmes limites (Laplace), où l'on conçoit la probabilité comme stabilisation limite de la fréquence lors de la répétition, un grand nombre de fois, de l'évènement. Au  $XIX^e$  siècle, Quételet et ses successeurs ne retiendront de la synthèse de Laplace que l'aspect fréquentiste, laissant en sommeil les techniques d'estimations amorcées au  $XVIII^e$ .

Dans un article publié en 1935 dans la "Revue de l'Institut International de la Statistique", Willcox dénombreait 115 définitions de la statistique. En étant plus raisonnable, voici quelques exemples :

1. Dans le style dénigrement (par ignorance?), celle attribuée à Bismarck : "Il y a trois formes de mensonge, le mensonge ordinaire, le damné mensonge et la statistique."
2. Achenwall (1749) : "La statistique est la connaissance approfondie de la situation

respective et comparative des Etats."

Définition correspondant à l'origine de la statistique, liée à la notion d'Etat.

3. Sinclair (1785) : "La statistique a pour but de constater la somme de bonheur dont jouit une population et les moyens de l'augmenter".

Ce mémoire est réparti sur l'introduction générale et deux chapitres .Dans le premier chapitre, nous avons présenté statistique inférentielle et échantillon celle qui contient statistique descriptive, l'échantillon et statistique inférentielle.

Dans le deuxième chapitre on s'est intéressé de échantillon aléatoire, caractéristique d'un échantillon aléatoire, distribution du chi deux, distribution de fisher snédecor ,distribution de student et cas particulier d'échantillons gaussiens.

# Chapitre 1

## statistique inférentielle et échantillon

La synthèse entre les observations et la population étudiée s'obtient à l'aide des procédés d'inférence statistique, c'est à dire d'estimation de tests statistiques. L'inférence utilise les modèles mathématiques et le calcul des probabilités.

### 1.1 statistique descriptive

**Définition 1.1.1** 1. *Statistique descriptive* est la branche des statistiques qui regroupe les nombreuses techniques utilisées pour décrire un ensemble relativement important de données.

2. *La population statistique* est le groupe formé par toutes les personnes ou tous les objets à propos desquels on souhaite obtenir de l'information .

3. *La taille de la population statistique* est l'effectif de cette population c'est-à-dire le nombre d'individus statistiques dont elle est constituée. Une population finie est une population dont la taille est finie. Une population infinie est une population dont la taille est infinie. Dans la pratique, on peut considérer une population finie comme étant infinie si elle est d'effectif très grand.

4. *Les individus statistiques* ( ou unités statistiques ) sont les éléments de la population.

5. *L'ensemble fondamental*  $\Omega$  appelé l'univers définissant l'ensemble des résultats possibles de  $\varepsilon$  appelés événements élémentaires.

6. *Effectif total* c'est le nombre total d'individus.

7. *Caractère* c'est la propriété étudiée. On distingue les caractères discrets qui ne peuvent prendre qu'un nombre fini de valeurs et les caractères continus dont on regroupe les valeurs par intervalles .

8. **Les modalités** ce sont les différentes valeurs qui peut prendre un caractère et on noté  $x_i$ .

### 1.1.1 Séries statistiques associées à un caractère discret

**Définition 1.1.2** On appelle série statistique la donnée simultanée (dans un tableau) des valeurs du caractère étudié (noté  $x_i$ ), rangées dans l'ordre croissant, et des effectifs (notés  $n_i$ ) de ces valeurs.

**Remarque 1.1.3** A la place des effectifs ( $n_i$ ), on peut aussi utiliser les fréquences

$$f_i = \frac{n_i}{N} \quad (N \text{ représente l'effectif total}) \text{ et les fréquences en pourcentages } f_i = \frac{n_i}{N} \times 100.$$

**Exemple 1.1.4** Les notes sur 20 obtenues lors d'un devoir de mathématiques dans une classe de seconde sont les suivantes :

10, 8, 11, 9, 12, 10, 8, 10, 7, 9, 10, 11, 12, 10, 8, 9, 10, 9, 10, 11.

La population étudiée est la classe et les individus sont les élèves. L'effectif total est égal à 20 et la note obtenue au devoir est le caractère discret que l'on étudie.

La série statistique définie par les effectifs est la suivante :

|   |   |   |   |    |    |    |
|---|---|---|---|----|----|----|
| Valeurs du caractère (notes) $x_i$          | 7 | 8 | 9 | 10 | 11 | 12 |
| Effectifs (nb d'élèves ayant la note) $n_i$ | 1 | 3 | 4 | 7  | 3  | 2  |

La série statistique définie par les fréquences en pourcentage est la suivante :

### Définition 1.1.5

|  |    |     |     |     |    |     |
|--|----|-----|-----|-----|----|-----|
| Valeurs du caractère (notes) $x_i$               | 7  | 8   | 9   | 10  | 11 | 12  |
| Fréquences en % $f_i = \frac{n_i}{N} \times 100$ | 5% | 15% | 20% | 35% | 15 | 10% |

### Effectifs cumulés

**Définition 1.1.6** 1. L'effectifs cumulés croissante ( $n_i \nearrow$ ) est le nombre d'individus ayant la valeur de la modalité  $\leq x_i$  et définie par :

$$n_i \nearrow = n_1 + n_2 + \dots + n_i = \sum_{s=1}^i n_s$$

2. L'effectives cumulés décroissante ( $n_i \searrow$ ) est le nombre d'individus ayant la valeur de la modalité  $\succeq x_2$  et définie par :

$$n_i \searrow = N - (n_1 + n_2 + \dots + n_{i-1}) = N - \sum_{s=1}^i n_s$$

### Fréquences cumulés

**Définition 1.1.7** 1. Fréquences cumulé croissant est la fréquence d'individus ayant la valeur de la modalité ( $f_i \nearrow$ ) et définie par :

$$f_i \nearrow = f_1 + f_2 + \dots + f_i = \sum_{j=1}^i f_j$$

2. Fréquences cumulé décroissant est la fréquence d'individus ayant la valeur de la modalité ( $f_i \searrow$ ) et définie par :

$$f_i \searrow = 1 - (f_1 + f_2 + \dots + f_{i-1}) = 1 - \sum_{j=1}^{i-1} f_j$$

**Exemple 1.1.8** Avec l'exemple (1.1.3) on a :

|                             |    |    |    |    |    |    |
|-----------------------------|----|----|----|----|----|----|
| Valeurs $x_i$               | 7  | 8  | 9  | 10 | 11 | 12 |
| Effectif cumulé croissant   | 1  | 4  | 8  | 15 | 18 | 20 |
| Effectif cumulé décroissant | 19 | 16 | 12 | 5  | 2  | 0  |

### Paramètres de position

Les paramètres de position, aussi appelés valeurs centrales, servent à caractériser l'ordre de grandeur des données.

**Définition 1.1.9 (Moyenne arithmétique)** On appelle moyenne d'une série statistique d'effectif total  $N$ , le réel :

$$\bar{X} = \frac{1}{N} \sum_{i=1}^k n_i x_i = \sum_{i=1}^k f_i x_i$$

tel que  $k$  représente le nombre de valeurs prises par le caractère.

**Exemple 1.1.10** Avec l'exemple (1.1.3), on a  $\bar{X} = 9,7$

1. Si on ajouté à toutes les valeurs d'une série statistique le même nombre  $b$ , on augmente la moyenne de cette série par  $b$ .

2. Si les valeurs d'une série statistique sont multipliées ou divisées par un même nombre  $a$ , la moyenne de cette série est aussi multipliée ou divisée par  $a$ .

**Proposition 1.1.11** *Si une population d'effectif  $N$  est composée d'une partie d'effectif  $N_1$  et de moyenne  $(\bar{x}_1)$  et d'une autre partie d'effectif  $N_2$  et de moyenne  $\bar{x}_2$  alors la moyenne  $\bar{X}$  de la population totale est telle que :  $\bar{X} = \frac{N_1\bar{x}_1 + N_2\bar{x}_2}{N}$ .*

**Exemple 1.1.12** *Si dans une classe, les 15 garçons d'une classe mesurent en moyenne 182cm et si les 20 filles mesurent en moyenne 168cm, alors la taille moyenne d'un élève de cette classe est égale à  $\frac{15 \times 182 + 20 \times 168}{15 + 20} = 174$ cm.*

**Définition 1.1.13 (Médiane)** *La médiane  $M_e$  d'une série statistiques est la valeur qui permet de partager le groupe étudié en deux sous groupe de même effectif tel que, tous les éléments du premier groupe (resp. second groupe) ont des valeurs inférieures (resp. supérieures) ou égales à  $M_e$ .*

1. Si  $n_i$  est paire ( $N = 2l$ ) alors :

$$M_e = \frac{x_l + x_{l+1}}{2}$$

2. Si  $n_i$  est impaire ( $N = 2l + 1$ ) alors :

$$M_e = x_{l+1}$$

**Exemple 1.1.14** *On considère la série statistique suivante :*

|                            |   |   |   |    |    |    |    |
|----------------------------|---|---|---|----|----|----|----|
| Valeurs du caractère $x_i$ | 7 | 8 | 9 | 10 | 11 | 14 | 16 |
| effectifs $n_i$            | 2 | 1 | 1 | 1  | 2  | 1  | 2  |

*L'effectif total est pair : la médiane  $M_e$  est la demi-somme des 2 valeurs situées au milieu.*

$$D'où : M_e = \frac{10+11}{2} = 10,5.$$

**Exemple 1.1.15** *On considère la série statistique suivante :*

|                            |   |   |   |    |    |    |
|----------------------------|---|---|---|----|----|----|
| Valeurs du caractère $x_i$ | 6 | 8 | 9 | 12 | 13 | 17 |
| effectifs $n_i$            | 3 | 1 | 2 | 1  | 3  | 3  |

*L'effectif total est impair : la médiane  $M_e$  est la valeur située au milieu.*

$$D'où : M_e = 12.$$

**Définition 1.1.16 ( Mode)** *On appelle le mode d'une série statistique la modalité la plus fréquente c'est-à-dire celle dont l'effectif est le plus grand.*

**population étudiée** : hommes français.

**caractère étudié** : âge en 2005.

|          |        |        |        |        |        |        |        |
|----------|--------|--------|--------|--------|--------|--------|--------|
| âge      | 37     | 38     | 39     | 40     | 41     | 42     | 43     |
| effectif | 436554 | 437247 | 449879 | 449881 | 456985 | 450554 | 435859 |

mode ( $M_o$ ) : 41ans.

### Paramètres de dispersion

Les paramètres de dispersion (étendue, variance,...) sont calculés pour les variables statistiques quantitatives.

**Définition 1.1.17 (L'entendue)** *L'entendue d'une série statistique est la différence entre la plus grande valeur et la plus petite valeur des caractères étudiés.*

**Exemple 1.1.18** *d'après l'exemple (1.1.8), l'entendue est :6*

**Définition 1.1.19 ( Variance)** *Elle est définie par la formule suivante :*

$$var(x) = \frac{1}{N} \sum_{i=1}^k n_i (x_i - \bar{x})^2 = \sum_{i=1}^k f_i (x_i - \bar{x})^2$$

**Définition 1.1.20 (L'ecart type)** *Est la racine carrée de la variance ,définie par la formule suivante :*

$$\sigma_x = \sqrt{var(x)}$$

### La fonction de répartition

**Définition 1.1.21** *La fonction de répartition d'une série statistique discrète est l'application  $F$  définie par :*

$$F : \mathbb{R} \rightarrow [0; 1]$$

$$x \longmapsto F(x) = \sum_{x_i \leq x} f_i$$

Tel que :

$$F(X) = \begin{cases} 0 & x < x_1 \\ \sum_{j=1}^i f_j & x_i \leq x < x_{i+1} \\ 1 & x \leq x_k \end{cases}$$

### 1.1.2 Séries statistiques associées à un caractère continue

**Définition 1.1.22** Soit la classe  $[e_i, e_{i+1}[$ .

1. Les nombre  $e_i, e_{i+1}$  s'appellent les bornes de la classe.
2. La demi somme  $c_i = \frac{e_i + e_{i+1}}{2}$  s'appelle le centre de la classe.
3. La différence  $e_{i+1} - e_i$  s'appelle l'entendue.
4. L'effectifs  $n_i$  de la classe est la somme des effectifs partiels des valeurs de la série appartenant a la classe.
5. La fréquence  $f_i$  de la classe est la rapport :  $f_i = \frac{n_i}{N}$ .

#### Paramètres d'une série statistique continue

**Définition 1.1.23 (La classe modale)** C'est la classe dont les effectif le plus grand.

**Définition 1.1.24 (Le mode)** On déterminer la classe modale  $[e_i, e_{i+1}[$ , on pose  $h_i = n_i - n_{i-1}$  et  $h_{i+1} = n_{i+1} - n_i$ .

$$M_o = \frac{h_i e_{i+1} + h_{i+1} e_i}{h_i + h_{i+1}}$$

**Définition 1.1.25 (Médiane)** Graphéquement on définit par la formule suivante :

$$\tan \alpha = \frac{f_i \nearrow - f_{i-1} \nearrow}{e_{i+1} - e_i} = \frac{\frac{1}{2} - f_{i-1} \nearrow}{M_e - e_i}$$

**Définition 1.1.26 (La moyenne)**  $\bar{X}$  se calculer par la formule suivant :

$$\bar{X} = \frac{1}{N} \sum_{i=1}^k n_i c_i$$

**Remarque 1.1.27**  $Var(x)$  et  $\sigma_x$  sont les même dans le cas discrète, on remplacer les modalité  $x_i$  par  $c_i$ .

## La fonction de répartition

**Définition 1.1.28** La fonction de répartition d'une série statistique continue est définie par :

$$\begin{aligned} F & : \mathbb{R} \longrightarrow [0; 1] \\ x & \longmapsto F(x) \end{aligned}$$

Telle que :

$$F(x) = \begin{cases} 0 & \text{si } x \prec e_1 \\ \sum_{j=1}^{i-1} f_j + \frac{x-e_i}{e_{i+1}-e_i} f_i & \text{si } x \in [e_i, e_{i+1}[ \\ 1 & \text{si } x \succeq e_{i+1} \end{cases}$$

**Exemple 1.1.29** Soit la distribution :

|                |         |          |          |          |          |          |
|----------------|---------|----------|----------|----------|----------|----------|
| Classe         | [8, 10[ | [10, 12[ | [12, 14[ | [14, 16[ | [16, 18[ | [18, 20[ |
| $c_i$          | 9       | 11       | 13       | 15       | 17       | 19       |
| $n_i$          | 1       | 2        | 4        | 6        | 5        | 2        |
| $f_i$          | 0,05    | 0,1      | 0,2      | 0,3      | 0,25     | 0,1      |
| $f_i \nearrow$ | 0,05    | 0,15     | 0,35     | 0,65     | 0,9      | 1        |
| $n_i c_i$      | 9       | 2        | 52       | 90       | 85       | 38       |

La classe modale est : [14, 16[.

La classe médiane est : [14, 16[.

$$M_o = 15,33 \quad M_e = 15 \quad \bar{X} = 14,8 \quad \text{var}(x) = 6,76 \quad \sigma_x = 2,6$$

### 1.1.3 Variable aléatoire

**Définition 1.1.30** Une variable statistique  $X$  est une application de  $\Omega$  dans un ensemble  $E$ .

#### Types des variables aléatoires

Il ya deux types des variables aléatoires :

#### Quantitative

**Définition 1.1.31** Une variable aléatoire  $X$  est dite quantitative si elle prend des valeurs dans  $\mathbb{R}$ , il s'agit d'une variable représentée par une quantité (une valeur).

**Exemple 1.1.32** *L'âge, le poids et la taille,... etc.*

- Il existe deux types de variables quantitatives : variables discrètes et variables continues.

### **Variables discrètes**

**Définition 1.1.33** *Une variable aléatoire est dite discrète si elle ne prend que des valeurs discontinues dans un intervalle fini ou dénombrable.*

**Exemple 1.1.34** *Le résultat du jet d'un dé, le nombre d'enfants dans une famille...*

### **Variables continues**

**Définition 1.1.35** *Une variable aléatoire est dite continue si elle ne prend ses valeurs dans  $\mathbb{R}$  ou une partie ou un ensemble de parties de  $\mathbb{R}$ .*

**Exemple 1.1.36** *La moyenne des étudiants, la taille...*

### **Qualitative**

**Définition 1.1.37** *Une variable qualitative est quant à elle une variable représentée par une qualité, (modalité plutôt que d'une valeur).*

**Exemple 1.1.38** *Le sexe, encore l'état civil, le degré de satisfaction d'un service quelconque...*

- Il existe également deux type de variables : variables nominales et variables ordinales.

### **Variables nominales**


**Définition 1.1.39** *Une variable aléatoire qualitative nominale est une variable qui correspondent à des noms, il n'y a aucun ordre précis sur les modalités. Ce sont seulement des mots dans le désordre.*

**Exemple 1.1.40** *La variable sexe est une variable qualitative nominale qui a deux modalités possibles : féminin ou masculin et dont l'ordre n'importe pas.*

## Variabes ordinales

**Définition 1.1.41** Une variable aléatoire qualitative ordinale est une variable qui correspond à un ordre. Il y a un ordre sur les modalités.

**Exemple 1.1.42** Le degré de satisfaction par rapport à un service : très satisfait, satisfait, insatisfait...



les types de variable aléatoire

## Fonction de densité de probabilité

**Définition 1.1.43** On appelle fonction de densité de probabilité toute fonction continue par morceaux (intégrable) vérifiant les deux conditions suivantes :

1.  $\forall x \in \mathbb{R} \quad f(x) \geq 0$ .
2.  $\int_{-\infty}^{+\infty} f(x) dx = 1$ .

## Fonction de répartition

**Définition 1.1.44** La fonction de répartition d'une variable aléatoire réelle  $X$ , notée  $F_X(x)$ , caractérise la loi de probabilité de cette variable. Elle représente la probabilité que la variable aléatoire réelle  $X$  prenne une valeur inférieure ou égale à  $x$  :

$$F_X(x) = P(X \leq x)$$

Telle que :

$$F_X(x) = \int_{-\infty}^x f_X(u) du$$

La fonction de répartition  $F_X(x)$  est donc l'une des primitives de la fonction de densité de probabilités.

## Paramètre de variable aléatoire

### cas discrète

**Définition 1.1.45 (L'espérance)** Soit  $X$  une variable aléatoire discrète sur  $\Omega$  telle que :  $X(\Omega) = \{x_1, \dots, x_n\}$ , avec  $x_1 < \dots < x_n$ . On appelle espérance mathématique de  $X$  le réel :

$$E(X) = \sum_{i=1}^n x_i p_i = \sum_{i=1}^n x_i p(X = x_i)$$

**Définition 1.1.46 (La variance)** Soit  $X$  une variable aléatoire discrète sur  $\Omega$  telle que :  $X(\Omega) = \{x_1, \dots, x_n\}$ , avec  $x_1 < \dots < x_n$ . On appelle variance de  $X$  le réel :

$$\text{var}(X) = E((X - E(X))^2) = E(X^2) - E^2(X)$$

**Définition 1.1.47 (L'écart type)** On appelle écart type le réel :

$$\sigma_X = \sqrt{\text{var}(X)}$$

**Définition 1.1.48 (Covariance)** Soient  $X$  et  $Y$  deux variables aléatoires. La covariance de  $X$  et  $Y$  est le réel :

$$\text{Cov}(X, Y) = E[(X - E(X))(Y - E(Y))]$$

**cas continu** Soit  $X$  une variable aléatoire continue admettant pour densité la fonction  $f$ . Sous réserve de convergence des intégrales, on définit :

– **L'espérance mathématique** de  $X$  par :

$$E(X) = \int_{-\infty}^{+\infty} x f(x) dx$$

– **La variance** de  $X$  par :

$$\text{var}(X) = \int_{-\infty}^{+\infty} x^2 f(x) dx - E^2(X)$$

– **l'écart type** de  $X$  par :

$$\sigma(X) = \sqrt{\text{var}(X)}$$

## Lois de probabilité

### lois discrète

## Loi uniforme

**Définition 1.1.49** Une distribution de probabilité suit une loi uniforme lorsque toutes les valeurs prises par la variable aléatoire sont équiprobables. Si  $n$  est le nombre de valeurs différentes prises par la variable aléatoire.

$$\forall i, P(X = x_i) = \frac{1}{n}$$

**Exemple 1.1.50** La distribution des chiffres obtenus au lancer de dé suit une loi uniforme dont la loi de probabilité est la suivante :

|              |               |               |               |               |               |               |
|--------------|---------------|---------------|---------------|---------------|---------------|---------------|
| $X$          | 1             | 2             | 3             | 4             | 5             | 6             |
| $P(X = x_i)$ | $\frac{1}{6}$ | $\frac{1}{6}$ | $\frac{1}{6}$ | $\frac{1}{6}$ | $\frac{1}{6}$ | $\frac{1}{6}$ |

$E(x) = 3,5$                        $Var(x) = 2,92$

## Loi de Bernoulli

**Définition 1.1.51** On effectue un tirage avec remise dans une urne contenant des boules blanches et noires, les premières en proportion  $p$ , les secondes en proportion  $q = 1 - p$ . Soit  $X$  le nombre des boules blanches tirées.

**Notation 1.1.52**  $X \sim B(1, p)$ .

**Proposition 1.1.53** 1. L'espérance de la variable de Bernoulli est :

$$E(X) = p$$

avec  $p = P(X = 1)$ .

2. La variance de la variable de Bernoulli est :

$$V(X) = pq$$

avec  $q = P(X = 0) = 1 - p$ .

## Loi binomiale

**Définition 1.1.54** On effectue  $n$  tirage avec remise dans une urne contenant des boules blanches et noires, les premières en proportion  $p$ , les secondes en proportion  $q = 1 - p$ . Soit  $X$  le nombre des boules blanches tirées. Elle définie par :

$$P(X = k) = C_n^k P^k (1 - P)^{n-k}$$

pour  $k \in \{0, 1, \dots, n\}$ .

**Notation 1.1.55**  $X \sim B(n; p)$ .

**Proposition 1.1.56** 1.  $E(X) = np$ .

2.  $Var(X) = npq$ .

## Loi de Poisson

**Définition 1.1.57** Soit  $X$  le nombre d'apparitions d'un événement rare sur un intervalle de temps donné .

$$P(X = k) = \frac{\lambda^k}{k!} \exp(-\lambda)$$

**Notation 1.1.58**  $X \sim P(\lambda)$ .

**Proposition 1.1.59** 1.  $E(X) = \lambda$ .

2.  $Var(X) = \lambda$ .

## Loi géométrique

**Définition 1.1.60** On effectue des tirages avec remise dans une urne contenant des boules blanches et noire , les premières en proportion  $p$ , les secondes en proportion  $q = 1 - p$ . Soit  $X$  le nombre des tirages nécessaires pour obtenir une boule blanche .

$$p(X = k) = pq^{k-1}$$

avec :  $k \in \mathbb{N}^*$

**Notation 1.1.61**  $X \sim G(p)$ .

**Proposition 1.1.62** 1.  $E(X) = \frac{1}{p}$ .

2.  $Var = \frac{q}{p^2}$ .

## lois continues

### loi exponentielle

**Définition 1.1.63** Une variable aléatoire continue  $X$  suit la loi exponentielle de paramètre  $\lambda$  ( $\lambda > 0$ ) si elle admet pour densité la fonction  $f$  définie sur  $\mathbb{R}$  par :

$$f(x) = \begin{cases} \lambda \exp(-\lambda x) & \text{si } x \geq 0 \\ 0 & \text{sinon} \end{cases}$$

**Notation 1.1.64**  $X \sim \exp(\lambda)$ .

**Proposition 1.1.65** 1.  $E(X) = \frac{1}{\lambda}$ .

2.  $Var(X) = \frac{1}{\lambda^2}$ .

### Loi uniforme

**Définition 1.1.66** Une variable aléatoire continue  $X$  suit la loi uniforme sur l'intervalle  $[a; b]$  si elle admet pour densité la fonction  $f$  définie sur  $\mathbb{R}$  par :

$$f(x) = \begin{cases} \frac{1}{b-a} & \text{si } x \in [a; b] \\ 0 & \text{sinon} \end{cases}$$

**Notation 1.1.67**  $X \sim U(a, b)$ .

**Proposition 1.1.68** 1.  $E(X) = \frac{a+b}{2}$ .

2.  $Var(X) = \frac{(b-a)^2}{12}$ .

### Loi normale

**Définition 1.1.69** Une variable aléatoire continue  $X$  suit la loi normale de paramètre  $\mu$  et  $\sigma$  ( $\sigma > 0$ ) si elle admet pour densité la fonction  $f$  définie sur  $\mathbb{R}$  par :

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{1}{2} \left(\frac{x-\mu}{\sigma}\right)^2\right)$$

**Notation 1.1.70**  $X \sim N(\mu, \sigma)$ .

**Proposition 1.1.71** 1.  $E(X) = \mu$ .

2.  $Var(X) = \sigma^2$ .

## Loi du khi-deux

**Définition 1.1.72** Si  $(X_1, \dots, X_n)$  sont un v.a indépendantes suivant toutes la loi normale centrée réduite, alors la quantité  $X = X_1^2 + \dots + X_n^2$  est une variable aléatoire qui suit une loi de khi-deux à  $n$  degrés de liberté.

**Notation 1.1.73**  $X \sim \chi_n^2$ .

**Proposition 1.1.74** 1.  $\chi_n^2 \succeq 0$ , cette loi n'est donc pas symétrique.

2.  $\chi_n^2$  admet une densité (difficile a retenir).

3.

$$\begin{aligned} E[\chi_n^2] &= n \\ \text{Var}(\chi_n^2) &= 2n. \end{aligned}$$

4. Pour  $n \succeq 30$  :

$$\sqrt{2\chi_n^2} - \sqrt{2n-1} \sim N(0;1)$$

## Loi de Student

**Définition 1.1.75** Si  $X$  et  $Y$  sont deux variables aléatoires indépendantes,  $X \sim N(0,1)$  et  $Y \sim \chi_n^2$ , alors la quantité  $T = \frac{X\sqrt{n}}{Y}$  est une variable aléatoire qui suit la loi de student à  $n$  degrés de liberté.

**Notation 1.1.76**  $T \sim T_n$ .

**Proposition 1.1.77** 1.  $T(n)$  admet une densité paire, cette loi est donc symétrique

2.

$$E(T) = 0 \text{ si } n \succ 1$$

3.

$$\text{Var}(T) = \frac{n}{n-2} \text{ si } n \succ 2$$

## Loi de fisher-Snédecor

**Définition 1.1.78** Si  $X_1 \sim \chi_{n_1}^2$ ,  $X_2 \sim \chi_{n_2}^2$ , et si  $X_1$  et  $X_2$  sont indépendantes, alors la quantité  $F = \frac{X_1/n_1}{X_2/n_2}$  est une variable aléatoire qui suit la loi de fisher -Snédecor à  $n_1$  et  $n_2$  degrés de libertés.

**Notation 1.1.79**  $X \sim F_{n_1, n_2}$ .

## Loi normale réduite

**Définition 1.1.80** Il s'agit de la loi normale obtenue pour  $\mu = 0$  et  $\sigma = 1$ . Sa densité  $f$  est alors définie par :

$$f(x) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{1}{2}x^2\right)$$

**Notation 1.1.81**  $X \sim N(0; 1)$ .

## 1.2 L'échantillon

**Définition 1.2.1** On considère une population  $\Omega$  de taille  $N$ . On appelle échantillon un sous ensemble de cette population. . L'objectif est d'obtenir une meilleure connaissance de la population par l'étude du seul échantillon. Le recours à un échantillon répond en général à une contrainte pratique (manque de temps, de place, évaluation destructive d'une production, coût financier...) interdisant l'étude exhaustive de la population.

– L'échantillon satisfait les deux conditions suivantes :

1. Tous les individus sont sélectionnés dans la même population.
2. Les individus sont sélectionnés de façon indépendante.

**Définition 1.2.2 (La taille de l'échantillon)** La taille de l'échantillon est l'effectif de cet échantillon c'est-à-dire le nombre d'individus statistiques observés dans la population statistique.

**Définition 1.2.3 (Sondage)** On appelle sondage toute observation partielle d'une population statistique c'est-à-dire l'observation d'une partie de cette population.

**Définition 1.2.4 (Fluctuation d'échantillonnage)** On appelle fluctuation d'échantillonnage la variation de la distribution des fréquences d'un échantillon à l'autre.

### 1.2.1 Méthodes de sondage

**Définition 1.2.5** Une méthode de sondages (ou d'échantillonnage) décrit la façon dont la population statistique sera observée partiellement à travers un de ses sous-ensembles appelé échantillon. Et il ya deux méthodes :

## Méthode probabiliste :

**Définition 1.2.6** *Sélection de l'échantillon par tirage aléatoire dans la population-mère. Chaque individu statistique doit avoir exactement la même chance que les autres de participer à l'enquête.*

*On distingue quatre méthodes :*

### Échantillonnage aléatoire simple

**Définition 1.2.7** *Dans un échantillon aléatoire simple, les éléments constituant l'échantillon sont extraits au hasard*

*(à l'aide d'une table de nombres au hasard, par exemple) d'une liste de la population.*


*On extrait ainsi  $n$  individus d'une population de taille  $N$ .*

*Le tirage peut s'effectuer avec ou sans remise, renvoyant ainsi généralement à un modèle de loi binomiale (avec remise), ou hypergéométrique (sans remise).*

**Remarque 1.2.8** *Si le tirage s'effectue avec remise, l'échantillon aléatoire simple est dit indépendant*

*(EASI = Echantillon Aléatoire Simple et Indépendant).*

**Exemple 1.2.9** *Dans une urne, on place autant de boules que d'individus dans la population. Chaque boule correspond à un individu de la population, on mélange les boules et on en tire une au hasard. On sélectionne ainsi un individu. On ne remet pas la boule dans l'urne (tirage sans remise) ; Retour à l'étape 2 jusqu'à ce que l'échantillon soit complet.*



*Échantillonnage aléatoire simple*

## Echantillonnage aléatoire systématique

**Définition 1.2.10** Les individus de la population  $\Omega$  sont numérotés de 1 à  $N$ . Pour sélectionner  $n$  individus, nous partageons la population en  $k = \frac{N}{n}$  groupes :  $\{1, \dots, k\}$ ,  $\{1 + k, \dots, 2k\}$ , ... ,  $\{1 + (n - 1)k, \dots, N\}$ .

Nous choisissons au hasard l'individu  $i$  par les individus numérotés de 1 à  $k$ .

Nous constituons notre échantillon des individus  $\{i, i + k, i + 2k, \dots, i + (n - 1)k\}$ .

Le choix de l'individu  $i$  détermine entièrement la constitution de l'échantillon.

**Exemple 1.2.11**  $\Omega = \{1, \dots, 20\}$ ,  $k = 4$ .

Les échantillons possibles sont :  $\{1, 5, 9, 13, 17\}$ ,  $\{2, 6, 10, 14, 18\}$ ,  $\{3, 7, 11, 15, 19\}$ ,  $\{4, 8, 12, 16, 20\}$


## Echantillonnage stratifié

**Définition 1.2.12** La population étudiée  $\Omega$  est partitionnée en  $q$  sous-populations  $\Omega_1, \Omega_2, \dots, \Omega_q$ , appelées "strates". L'échantillon est constitué de la réunion de  $q$  échantillons choisis au hasard, un par strate : nous effectuons dans chaque strate un échantillonnage simple.

**Exemple 1.2.13**  $\Omega = \{1, 2, 3, 4, 5\}$ ,  $\Omega_1 = \{1, 2\}$ ,  $\Omega_2 = \{3, 4, 5\}$ .

Nous sélectionnons deux individus, dans  $\Omega_1$  et trois dans  $\Omega_2$ .

Nous obtenons l'un des six échantillons possibles.




*Echantillonnage stratifié*

## Echantillonnage en grappes et à plusieurs degrés

**Définition 1.2.14** La population  $\Omega$  est divisée en sous-populations appelées unités primaires. Chaque unité primaire est divisée en unités secondaires, etc.

Nous effectuons des tirages au hasard en cascade : nous tirons des unités primaires, dans chaque unité primaire, nous tirons une unité secondaire, etc.

**Exemple 1.2.15** *L'INSEE effectue des échantillonnages à quatre niveaux : départements, cantons, communes, ménages*



*Echantillonnage en grappes et à plusieurs degrés*

**Méthode non-probabiliste :**

**Définition 1.2.16** *Identifier dans la population-mère, quelques critères de répartition significatifs puis d'essayer de respecter cette répartition, dans l'échantillon d'individus interrogés. On utilise cette méthode lorsqu'il n'est pas possible de constituer une liste exhaustive de toutes les unités du sondage.*

**Echantillonnage par quotas**

**Définition 1.2.17** *C'est une méthode d'échantillonnage qui consiste à s'assurer de la représentativité d'un échantillon, en lui affectant une structure similaire à celle de la population mère, au titre de plusieurs critères que sont, dans le cas d'une étude grand public, le sexe, l'âge, la profession, la région et la catégorie d'agglomération (critères détaillés dans la rubrique échantillon) puis à calculer le pourcentage de personnes appartenant à chaque catégorie selon les données du recensement de l'INSEE.*

**Exemple 1.2.18** *Si les ouvriers hommes, âgés de 30 à 40 ans et urbains, représentent 2% de la population des électeurs, un échantillon de 1000 individus établis selon la méthode des quotas doit comprendre 20 personnes appartenant à cette catégorie. Lors d'une enquête téléphonique par quotas, un logiciel est utilisé pour décompter les individus déjà interrogés pour chaque catégorie de répondants. Des questions d'identification sont préalablement posées par les sondeurs pour savoir si l'individu peut être interrogé en fonction de l'état d'avancement de l'obtention des quotas. Lorsqu'une catégorie de répondants est*

*difficile à obtenir, les instituts de sondages utilisent parfois des techniques de redressement d'échantillon.*

## **La méthode des itinéraires**

**Définition 1.2.19** *On impose à l'enquêteur :*

1. *Un point de départ dans une commune.*
  2. *Un itinéraire à suivre avec tirage systématique des logements dans lesquels effectuer les interviews.*
- Le but est reproduire un certain tirage aléatoire des enquêtés, sans donner explicitement des noms et adresses à l'enquêteur.

## **Échantillonnage de convenance ou au jugé**

**Définition 1.2.20** *On prélève un échantillon en se fondant sur certains jugements au sujet de l'ensemble de la population.*

## **Échantillonnage sur place**

**Définition 1.2.21** *L'échantillon étudié est définie par un lieu. Cette méthode est utilisé dans l'échantillonnage de populations mobiles, rares ou spécifiques. Avec cette méthode il faut faire attention à :*

1. *Ne pas sur-représenter les individus passant + de temps sur place.*
2. *Les périodes d'enquête.*
3. *Les pondérations a posteriori pour tenir compte de la probabilité de présence.*

# **1.3 Statistique inférentielle**

**Définition 1.3.1** *Statistique inférentielle est l'ensemble des méthodes permettant de tirer des conclusions sur un groupe détermine a partir des données provenant d'un échantillon choisi dans cette population.*

## **1.3.1 Objectif**

L'objectif de la statistique inférentielle est :

1. Fournir des résultats relatifs à une population à partir de mesures statistiques réalisées sur d'échantillons.

2. Dédire des renseignements sur un échantillon à partir de la connaissance de la population (échantillonnage).
3. Dédire des renseignements sur une population à partir de la connaissance d'un échantillon (estimation).
  - Le but de statistique inférentielle est de faire des prévisions et prendre des décisions au vu des données.

Nous avons vu deux grandes catégories de méthodes :

L'estimation ponctuelle et par intervalles de confiance, avec la méthode des moments, la méthode du maximum de vraisemblance et les tests d'hypothèses.

### 1.3.2 Estimation


**Définition 1.3.2** *L'estimation statistique consiste à donner une valeur approchée à une caractéristique d'une population, à partir d'un échantillon d'observations issues de cette population.*

### 1.3.3 Estimateur

**Définition 1.3.3** *Un estimateur est une variable aléatoire (c'est une fonction de variable aléatoire). Ou bien est un paramètre d'échantillon utilisé pour "estimer" la valeur d'un paramètre statistique de la population.*

**Proposition 1.3.4** 1. *Si l'estimateur a même moyenne que le paramètre à estimer, on dit que cet estimateur est non biaisé. Dans le cas contraire, on dit qu'il est dit biaisé.*

2. *Si l'on prend la moyenne d'échantillon  $X_i$  comme estimateur de  $\mu$ , on dira que c'est un estimateur non biaisé puisque la moyenne des  $X_i$  est égale à  $\mu$  (théorème des moyennes). par contre, si on utilise l'écart type d'échantillon.*



### estimation ponctuelle d'un paramètre

**Moyenne** La valeur moyenne  $m_e$  d'un paramètre observé sur un échantillon de population, dont la taille est fixée, fournit une estimation  $\bar{x}$  de la moyenne réelle de ce paramètre sur la population considérée.

**Exemple 1.3.5** Une usine produit des vis cruciformes. On souhaite estimer la moyenne des longueurs des vis dans la production de la journée qui s'élève à 10000 pièces.

On choisit un échantillon de 150 vis et on obtient une moyenne de  $m_e = 4.57\text{cm}$ . On en déduit donc que la longueur moyenne des vis de la production journalière est  $\bar{x} = 4.57\text{cm}$ .

**Écart-type** Le problème est toujours le même, mais cette fois-ci, l'estimation de l'écart-type est moins intuitive

**Proposition 1.3.6** L'écart-type  $\sigma_e$  d'un paramètre observé sur un échantillon de population, dont la taille est fixée, fournit une estimation faussée de l'écart-type de ce paramètre dans toute la population considérée.

Une meilleure estimation de l'écart-type réel est obtenue en considérant le nombre

$$\sigma = \sigma_e \sqrt{\frac{n}{n-1}}$$

où  $n$  est la taille de l'échantillon servant au calcul de  $\sigma_e$ .

**Remarque 1.3.7** La correction devient assez rapidement minime lorsque la taille de l'échantillon augmente car :

$$\lim_{n \rightarrow +\infty} \sqrt{\frac{n}{n-1}} = 1$$

La correction est ainsi de l'ordre de 0.5% pour des échantillons de taille 100, et de l'ordre de 0.05% pour des échantillons de taille 1000.

**Exemple 1.3.8** La mesure de la longueur des vis produites dans l'échantillon précédent de 150 pièces conduit à relever un écart-type de 3mm.

La meilleure estimation possible de l'écart-type de la production journalière n'est pas de 3mm comme dans le cas précédent pour la moyenne, mais de  $\sigma = 3\sqrt{\frac{150}{149}} \simeq 3.01$

**Fréquence** La fréquence d'apparition  $f_e$  d'un paramètre observé sur un échantillon de population, dont la taille est fixée, fournit une estimation  $f$  de la fréquence réelle d'apparition de ce paramètre sur la population considérée.

**Exemple 1.3.9** Dans l'exemple précédent, On prélève un échantillon de 150 vis et on relève 3 pièces défectueuses. On peut alors donner une estimation de la fréquence de vis défectueuses dans la production journalière : on a  $f_e = \frac{3}{150} = 0.02$  donc  $f = 0.02$ .

### Estimation par intervalle de confiance d'un paramètre

**Définition 1.3.10** Les estimations ponctuelles dépendent directement de l'échantillon prélevé au hasard. Dans de très nombreux cas, l'importance attribuée au hasard est grande, cela conduit à s'interroger avant d'utiliser ces estimations pour prendre des décisions dont les conséquences peuvent être lourdes ! Aussi, sans rejeter les informations fournies par l'étude d'un échantillon, est on amené à chercher un nouveau type d'estimation de la fréquence et de la moyenne d'une population, en utilisant le calcul de probabilités qui permet de « contrôler » l'influence d'un échantillon particulier.

**Moyenne** On souhaite, à partir des observations faites sur un échantillon, déterminer un intervalle de confiance contenant la valeur moyenne avec un risque d'erreur décidé à l'avance.

On suppose que les conditions sont réunies pour faire l'approximation que la loi d'échantillonnage de la moyenne  $\bar{x}$  est la loi normale  $N(m, \frac{\sigma}{\sqrt{n}})$

On pose :

$$T = \frac{\bar{x} - m}{\frac{\sigma}{\sqrt{n}}}$$

$$T \sim N(0; 1)$$

Soit la probabilité fixée à l'avance, pour que  $T$  n'appartienne pas à l'intervalle  $[-t; t]$ . On peut écrire :

$$\begin{aligned} p(|T| > t) &= \alpha \Leftrightarrow 1 - p(|T| \leq t) = \alpha \\ &\Leftrightarrow p(|T| \leq t) = 1 - \alpha \\ &\Leftrightarrow p(-t \leq T \leq t) = 1 - \alpha \\ &\Leftrightarrow p\left(-t \leq \frac{\bar{x} - m}{\frac{\sigma}{\sqrt{n}}} \leq t\right) = 1 - \alpha \\ &\Leftrightarrow p\left(\bar{x} - t \frac{\sigma}{\sqrt{n}} \leq m \leq \bar{x} + t \frac{\sigma}{\sqrt{n}}\right) = 1 - \alpha \end{aligned}$$

Autrement dit,  $m$  appartient à l'intervalle  $\left[\bar{x} - t \frac{\sigma}{\sqrt{n}}; \bar{x} + t \frac{\sigma}{\sqrt{n}}\right]$ , pour  $100(1 - \alpha)\%$  d'échantillons.

- Cet intervalle est appelé intervalle de confiance.
- $\alpha$  est le risque d'erreur ou le seuil de risque.
- $1 - \alpha$  est le coefficient de confiance.

**Proposition 1.3.11** *L'intervalle  $\left[\bar{x} - t\frac{\sigma}{\sqrt{n}}; \bar{x} + t\frac{\sigma}{\sqrt{n}}\right]$  est l'intervalle de confiance de la moyenne  $m$  de la population avec le coefficient de confiance  $2\pi(t) - 1 = 1 - \alpha$ .*

**Fréquence** A l'aide d'un échantillon, nous allons définir, avec un coefficient de confiance choisi à l'avance, un intervalle de confiance de la fréquence  $p$  des éléments de la population possédant une certaine propriété.

On se place dans le cas où on peut approximer la loi par la loi normale  $N(p; \sqrt{\frac{p(1-p)}{n}})$ .

**Proposition 1.3.12** *L'intervalle  $\left[f - t\sqrt{\frac{f(1-f)}{n-1}}; f + t\sqrt{\frac{f(1-f)}{n-1}}\right]$  est l'intervalle de confiance d'une fréquence  $p$  de la population avec le coefficient de confiance  $2\pi(t) - 1 = 1 - \alpha$ . ayant pour centre la fréquence  $f$  de l'échantillon considéré.*

**Exemple 1.3.13** *Un sondage dans une commune révèle que sur les 500 personnes interrogées, 42% sont mécontentes de l'organisation des transports. On veut déterminer, au seuil de risque 1%, un intervalle de confiance du pourcentage  $p$  de personnes mécontentes dans la commune on a :*

$$f = 0.42.$$

$$n = 500.$$

$$\alpha = 1\% \text{ donc } : t = 2.575.$$

*Un intervalle de confiance du pourcentage  $p$  est :*

$$\left[0.42 - 2.58\sqrt{\frac{0.42 * 0.58}{499}}; 0.42 + 2.575\sqrt{\frac{0.42 * 0.58}{499}}\right] = [0.36; 0.48] = [36\%; 48\%]$$

- Le tableau ci-dessous regroupe toutes les situations dans lesquelles on doit savoir fournir une estimation ponctuelle ou par intervalle de confiance :

| Paramètre de la population totale à estimer | Valeur du paramètre dans l'échantillon de taille $n$ | Estimation ponctuelle pour la population totale | Estimation par intervalle de confiance au niveau de confiance $2\Pi(t) - 1$ pour la population totale |
|---|--|---|---|
| Moyenne                                     | $m_e$  | $m = m_e$                                       | $\left[ m_e - t \frac{\sigma}{\sqrt{n}}; m_e + t \frac{\sigma}{\sqrt{n}} \right]$                     |
| Écart-type                                  | $\sigma_e$   | $\sigma = \sigma_e \sqrt{\frac{n}{n-1}}$        |   |
| Fréquence                                   | $f_e$  | $f = f_e$                                       | $\left[ f_e - t \sqrt{\frac{f_e(1-f_e)}{n-1}}; f_e + t \sqrt{\frac{f_e(1-f_e)}{n-1}} \right]$         |

## Méthodes d'estimation

**Méthode empirique** On sélectionne un estimateur naturel et on étudie ses propriétés. On le modifie éventuellement pour que le nouvel estimateur ait de meilleures propriétés (par exemple, la variance corrigée).

**Méthode des moments** Si on a  $M$  paramètres à estimer  $(\theta_m)$ , tel que :  $m = (1, \dots, M)$ . On résout un système de  $M$  équations à  $M$  inconnues (les  $M$  paramètres) en égalant pour  $m = (1, \dots, M)$  le moment d'ordre  $m$  de la population  $m$  et le moment d'ordre  $m$  de l'échantillon :

$$\frac{1}{n} \sum_{i=1}^n (x_i)^m$$

**Exemple 1.3.14** L'estimateur du moment de  $\sigma^2$  est alors la variance non corrigée de l'échantillon.

**Méthode du maximum de vraisemblance** Les meilleures valeurs du paramètre inconnu  $\theta$  sont celles qui donnent à l'évènement observé  $(x_1, \dots, x_n)$  la plus grande probabilité.

On a vu que cette probabilité peut être représentée par la vraisemblance :

$$\theta L(x; \theta) = f(x_1; \theta); \dots; f(x_n; \theta)$$

L'estimation "maximum de vraisemblance" de  $\theta$  sera une fonction des observations qui rend  $L(x; \theta)$  maximum.

**Remarque 1.3.15** L'estimateur de maximum de vraisemblance n'existe pas toujours et n'est pas toujours unique.

### 1.3.4 Test d'hypothèse

**Définition 1.3.16** Une hypothèse est un ensemble des valeurs des paramètres inconnus (paramètres de population).

**Proposition 1.3.17** Une hypothèse est dite simple si elle ne contient qu'un seul élément, ce qui est généralement le cas pour

$$H_0 : \theta = \theta_0$$

tel que :  $H_0$  test d'hypothèse nulle et  $\Theta_0$  est l'ensemble de valeurs supposée du paramètre  $\theta$  selon  $H_0$ . sinon elle est composite.

$$H_1 : \theta \in \Theta_1$$

avec :  $\Theta_1$  un sous ensemble de l'ensemble des paramètres disjoint de  $\theta_0$ .

#### Proposition 1.3.18

$H_1$  se ramène souvent aux trois cas suivants :

1.  $H_1 : \theta < \theta_0$ .
2.  $H_1 : \theta > \theta_0$ .
3.  $H_1 : \theta \neq \theta_0$ .

– Dans les deux premiers cas, le test est dit unilatéral et dans le dernier le test est dit bilatéral .

### Types du test d'ypothèses

#### test paramétrique

**Définition 1.3.19** Un test paramétrique est un test pour lequel d'hypothèses sur la distribution des populations sont requises.

**test non paramétrique** On qualifie les test non paramétriques les méthodes statistiques qui sont applicables dans les conditions générales quant aux distributions des populations.

## Région de rejet d'un test et erreurs

**Définition 1.3.20** Soit  $X$  une variable aléatoire et  $\chi$  l'ensemble de ses valeurs. le test s'effectue en trouvant un sous ensemble  $R \subseteq \chi$  appelé la région de rejet.

Ainsi, si  $X \in R$ , l'hypothèse nulle ( $H_0$ ) est rejetée, sinon, elle est retenue.

Cette région se définit sous la forme suivante :

$$R = \{x : T(x) > s\}$$

avec :  $T$  est une statistique de test et  $s$  un seuil.

- En effectuant un test d'hypothèses, on peut se tromper en rejetant l'hypothèse nulle ou en l'acceptant.

## Erreurs de test hypothèse

Il existe deux types d'erreur : l'erreur de première espèce (dite aussi erreur de type  $I$ ) et l'erreur de deuxième espèce (dite aussi erreur de type  $II$ ).

### Erreur de première espèce

**Définition 1.3.21** L'erreur de première espèce correspond au cas où l'on rejette  $H_0$  (décider  $H_1$ ) alors que celle-ci est vraie.

### Erreur de deuxième espèce

**Définition 1.3.22** L'erreur de deuxième espèce correspond quant à elle au cas où l'on rejette  $H_1$  (décider  $H_0$ ) alors que celle-ci est vraie.

| Décision \ Vérité | $H_0$                     | $H_1$                     |
|-------------------|---------------------------|---------------------------|
| $H_0$             | décision correcte         | erreur de deuxième espèce |
| $H_1$             | erreur de première espèce | décision correcte         |

*Récapitulatif des décisions en test d'hypothèse*

### risque du test hypothèse

### risque de première espèce

**Définition 1.3.23** *Le risque de première espèce est notée  $\alpha$ . Il représente le risque de rejeter  $H_0$  à tort. des valeurs de ce risque sont 1% , 5% , 10% qui correspondent aux niveaux de confiance 99% , 95% et 90%.*

### risque de deuxième espèce

**Définition 1.3.24** *Le risque de deuxième espèce représente quant à lui le risque de retenir  $H_0$  à tort. Il est noté  $\beta$ .*

### niveau de confiance du test

**Définition 1.3.25** *Le niveau de confiance du test est donc  $1 - \alpha$  qui correspond à retenir  $H_0$  à raison.*

### puissance d'un test

**Définition 1.3.26** *La puissance d'un test est la probabilité de rejeter l'hypothèse nulle à raison la puissance du test est donc le complément de l'erreur de deuxième espèce et est donc égale à  $1 - \beta$*

| Décision \ Vérité | $H_0$                            | $H_1$                         |
|-------------------|----------------------------------|-------------------------------|
| $H_0$             | niveau de confiance $1 - \alpha$ | risque $\beta$                |
| $H_1$             | risque $\alpha$                  | puissance de test $1 - \beta$ |

*Récapitulatif sur les risques associés à un test d'hypothèses*

# Chapitre 2

## Caractéristiques d'un échantillon

Etude statistique portant sur tous les éléments d'une population étant, soit impossible à réaliser (trop grand nombre d'individus à étudier), soit trop onéreuse, il faut obtenir des résultats fiables sur les caractéristiques d'une population en se limitant à l'étude des éléments ou unités d'un échantillon. Cet échantillon doit non seulement donner des estimations non biaisées des paramètres mais permettre, de plus, d'évaluer la marge d'erreurs dues aux fluctuations d'échantillonnage.

L'échantillon doit être représentatif de la population ; il en résulte, en particulier, que chaque unité doit avoir une probabilité non nulle d'être tirée, un tel échantillon est qualifié d'aléatoire.

**Définition 2.0.27** *On étudie une caractéristique mesurable  $X$  d'une population de taille finie ou infinie. La composition de la population, vis à vis du caractère  $X$ , est entièrement définie par la connaissance des quantités  $F(x)$  tel que :  $F(x) =$  Proportion des individus tels que  $X < x$ , pour toutes les valeurs de  $x \in R$ . Soit  $E$  l'expérience consistant à choisir au hasard un élément de la population. Avant le tirage, on se propose de prévoir la valeur du caractère  $X$  que l'on obtiendra. Ce caractère est une variable aléatoire  $X$  telle que  $Pr(X < x) = F(x)$  pour toute valeur  $x \in R$ . À l'expérience  $E$  est associée une variable aléatoire  $X$  dont la fonction de répartition est  $F(x)$ . On réalise  $n$  fois la même expérience  $E$ , dans des conditions indépendantes.*

**Définition 2.0.28** *Un échantillon aléatoire de taille  $n$  de la variable aléatoire  $X$  est une suite de variables aléatoires indépendantes  $X_1; X_2; \dots; X_n$  ayant toutes la même distribution que  $X$ .*

*Une suite  $x_1; x_2; \dots; x_n$  de valeurs prises par les v.a.  $X_i$  est une réalisation de l'échantillon.*

## 2.0.5 Caractéristiques d'un échantillon aléatoire

Une statistique définie sur un échantillon aléatoire  $X$  de taille  $n$  est une fonction mesurable des variables  $X_i$ . Les principales caractéristiques d'un échantillon sont les statistiques  $\bar{X}$  et  $S^2$ .

On suppose que les moments d'ordre 1 et 2 de la variable aléatoire parente  $X$  existent et on pose

$$\begin{aligned} E(X) &= m \\ \text{Var}(X) &= \sigma^2 \end{aligned}$$

**Remarque 2.0.29** 1. *moment centré empirique d'ordre  $r$  est définie par :*

$$\mu_r = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^r$$

2. *moment non centré empirique d'ordre  $r$  est définie par :*

$$m_r = \frac{1}{n} \sum_{i=1}^n X_i^r$$

### Étude de la statistique $\bar{X}$

**Définition 2.0.30** *La statistique  $\bar{X}$  est la fonction mesurable des variables  $X_i$ , définie par :*

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

**Proposition 2.0.31** 1. *Cas d'une population infinie : Un calcul rapide donne les résultats suivants :*

$$E(\bar{X}) = m, \text{Var}(\bar{X}) = \frac{\sigma^2}{n}$$

2. *Cas d'une population finie : L'échantillon de taille  $n$  est extrait d'une population finie de taille  $N$  par un tirage sans remise, On obtient les résultats suivants :*

$$E(\bar{X}) = m, \text{Var}(\bar{X}) = \frac{N-n}{N-1} \frac{\sigma^2}{n} \simeq \left(1 - \frac{n}{N}\right) \frac{\sigma^2}{n}$$

Le coefficient  $\frac{n}{N}$  représente la fraction de la population constituant l'échantillon.

3. *Comportement asymptotique :*

– Loi faible des grands nombres

$\bar{X}$  converge en probabilité vers  $m$  quand  $n$  tend vers l'infini.

– Loi forte des grands nombres

$\bar{X}$  converge presque sûrement vers  $m$  quand  $n$  tend vers l'infini, car la série :

$$\sum_{i=1}^n \frac{\sigma_i^2}{i^2} = \sigma^2 \sum_{i=1}^n \frac{1}{i^2}$$

est une série convergente.

Appliquons le théorème central limite à la variable aléatoire  $Y_n$  :

$$Y_n = \frac{\sum_{i=1}^n X_i - nm}{\sigma\sqrt{n}} = \frac{\bar{X} - m}{\frac{\sigma}{\sqrt{n}}}$$

La variable  $Y_n$  converge en loi vers une variable suivant la loi normale  $N(0; 1)$  quand  $n$  tend vers l'infini.

**Remarque 2.0.32** Pour appliquer le théorème central limite, il faut que les moments d'ordre 1 et 2 existent.

### Étude de la statistique $S^2$ ou variance empirique

**Définition 2.0.33** La variance empirique  $S^2$  d'un échantillon de taille  $n$  est définie par :

$$S^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$$

**Proposition 2.0.34** 1. *Espérance mathématique de  $S^2$*

$$E(S^2) = \frac{n-1}{n} \sigma^2 = \left(1 - \frac{1}{n}\right) \sigma^2$$

Si la taille  $n$  de l'échantillon est grande, l'espérance de  $S^2$  a pour valeur limite  $\sigma^2$ .

2. *Variance de  $S^2$*  (Calcul un peu plus long mais non difficile).

$$\text{Var}(S^2) = \frac{n-1}{n^3} [(n-1)\mu_4 - (n-3)\sigma^4]$$

avec  $\mu_4$  étant le moment centré d'ordre 4 de la variable  $X$ .

Si la taille  $n$  de l'échantillon est grande, la variance de  $S^2$  a pour valeur limite :

$$\frac{\mu_4 - \sigma^4}{n}$$

**Théorème central limite pour  $S^2$**  La variable aléatoire :

$$\frac{S^2 - \left(1 - \frac{1}{n}\right) \sigma^2}{\sqrt{\text{Var } S^2}}$$

converge en loi vers une variable suivant la loi normale  $N(0; 1)$  quand  $n$  tend vers l'infini.

En prenant les limites de l'espérance et de la variance pour  $n$  grand, on obtient le résultat suivant. La variable aléatoire :

$$\frac{S^2 - \sigma^2}{\sqrt{\frac{\mu_4 - \sigma^4}{n}}}$$

converge en loi vers la loi  $N(0; 1)$ .

### Corrélation entre $\bar{X}$ et $S^2$

Pour définir la corrélation entre  $\bar{X}$  et  $S^2$ , on calcule la covariance entre ces deux variables aléatoires :

$$\text{Cov}(\bar{X}, S^2) = \frac{n-1}{n^2} \mu^3$$

$\mu_3$  étant le moment centré d'ordre 3 de la variable  $X$ .

**Proposition 2.0.35** *Si  $n$  tend vers l'infini, la covariance entre ces variables tend vers 0, les statistiques  $\bar{X}$  et  $S^2$  sont donc asymptotiquement non corrélées.*

*Si la distribution de la variable  $X$  est symétrique, le moment centré  $\mu_3$  est égal à 0, les statistiques  $\bar{X}$  et  $S^2$  sont donc non corrélées quelle que soit la valeur de  $n$ .*

*Si de plus,  $X$  suit une loi normale, les statistiques  $\bar{X}$  et  $S^2$  sont indépendantes quelle que soit la valeur de  $n$ .*

## 2.0.6 Distribution du chi-deux

**Définition 2.0.36** *La variable aléatoire, égale à la somme des carrés de  $\nu$  variables aléatoires indépendantes, centrées, réduites, gaussiennes, suit la loi du chi-deux  $\chi^2$  à  $\nu$  degrés de liberté :*

$$\chi^2(\nu) = \sum_{i=1}^{\nu} U_i^2 = \sum_{i=1}^{\nu} \left( \frac{X_i - m}{\sigma} \right)^2$$

*Cette distribution a été introduite par Karl Pearson en 1900.*

**Proposition 2.0.37** 1. *La variable aléatoire  $\chi^2(\nu)$  varie de 0 à  $+\infty$ .*

2. Le paramètre  $\nu$  est le nombre de degrés de liberté de la variable, il représente la dimension de l'espace dans lequel se trouve le point représentatif de l'échantillon  $X$ . Si les variables aléatoires  $X_i$  vérifient  $k$  relations linéaires, le nombre de degrés de liberté diminue de  $k$ .
3. La loi suivie par la somme de variables aléatoires indépendantes, suivant chacune des lois du chi-deux, est une loi du chi-deux dont le degré de liberté est la somme des degrés de liberté de chaque loi.
4. Moments :

$$\begin{aligned} E(\chi^2(\nu)) &= \nu \\ \text{Var}(\chi^2(\nu)) &= 2\nu \end{aligned}$$

5. Mode :

$$M_0 = \nu - 2 \quad \text{si } \nu > 2.$$


### Fonction de densité

**Définition 2.0.38** La densité de probabilité de la variable aléatoire  $\chi^2(\nu)$  est une expression mathématique compliquée et peu maniable :

$$f(\chi^2(\nu)) = \frac{1}{2^{\nu/2} \Gamma(\nu/2)} \exp(-\chi^2/2) (\chi^2)^{\nu/2-1}.$$

$\Gamma$  est la fonction eulérienne définie par :

$$\Gamma(x) = \int_0^{\infty} \exp(-t) t^{x-1} dt \quad \text{Pour } x > 0$$



Densité de la loi du chi – deux pour différentes valeurs du paramètre  $\nu$ .

**Exemple 2.0.39** on prend une valeur de degré de liberté par exemple ( $\nu = 4$ )  
donc  $f(\chi^2(\nu)) = \frac{1}{2^2\Gamma(2)} \exp(-\chi^2/2) (\chi^2)^{4/2-1}$  avec  $\Gamma(2) = \int_0^\infty \exp(-t) t dt = 1$ .  
 $E(\chi^2(4)) = 4$ .  
 $Var(\chi^2(4)) = 8$ .

## 2.0.7 Distribution de Fisher-Snédecor

**Définition 2.0.40** La distribution  $F$  de Fisher-Snédecor (ou plus simplement distribution  $F$  de Fisher) a été étudiée en 1924 par Fisher (statisticien anglais né en 1890) et calculée en 1934 par Snédecor ; elle joue un rôle important en analyse de la variance et en analyse de la régression.

On considère deux variables aléatoires indépendantes suivant des lois du chi-deux à  $\nu_1$  et  $\nu_2$  degrés de liberté respectivement.

La variable aléatoire  $F$  de Fisher est définie par :

$$F(\nu_1; \nu_2) = \frac{\chi^2(\nu_1)/\nu_1}{\chi^2(\nu_2)/\nu_2}$$

**Proposition 2.0.41** Propriété évidente :  $F(\nu_1; \nu_2) = \frac{1}{F(\nu_2; \nu_1)}$

1. La variable  $F(\nu_1; \nu_2)$  varie de 0 à  $+\infty$ .
2. La loi de probabilité de la variable  $F$  dépend de deux paramètres, les degrés de liberté,

$\nu_1$  et  $\nu_2$ .

3. Moment :

$$E(F) = \frac{\nu_2}{\nu_2 - 2} \quad \text{si } \nu_2 \succ 2$$

$$Var(F) = \left(\frac{\nu_2}{\nu_2 - 2}\right)^2 \frac{2(\nu_1 - \nu_2 - 2)}{\nu_1(\nu_2 - 4)} \quad \text{si } \nu_2 \succ 4$$

4. Mode :

$$M_0 = \frac{\nu_2(\nu_1 - 2)}{\nu_1(\nu_2 - 2)} \quad \text{si } \nu_1 > 2.$$

## Fonction de densité

**Définition 2.0.42** La densité de probabilité de la variable aléatoire  $F(\nu_1; \nu_2)$  est une expression mathématique compliquée et peu maniable :

$$g(f) = \begin{cases} 0 & \text{si } f \leq 0 \\ \frac{(\nu_1/\nu_2)^{\nu_1/2}}{\beta(\nu_1/2; \nu_2/2)} \times \frac{f^{\nu_1/2-1}}{\left(1 + \frac{\nu_1}{\nu_2} f\right)^{(\nu_1+\nu_2)/2}} & \text{sinon} \end{cases}$$

avec  $\beta$  est la fonction eulérienne définie par :

$$\beta(p; q) = \int_0^1 t^{p-1} (1-t)^{q-1} dt.$$

Densité de la loi de Fisher – Snedecor pour différentes valeurs du paramètre  $\nu_1, \nu_2$

**Exemple 2.0.43** on prend  $\nu_1 = 4$  et  $\nu_2 = 6$ .

$$\text{donc } g(f) \begin{cases} 0 & \text{si } f \leq 0 \\ \frac{(4/6)^{4/2}}{\beta(4/2; 6/2)} \times \frac{f^{4/2-1}}{\left(1 + \frac{4}{6} f\right)^{(4+6)/2}} & \text{sinon} \end{cases}$$

$$\text{avec } \beta(2; 3) = \int_0^1 t(1-t)^2 = 1/12$$

$$E(F) = \frac{6}{6-2} = 3/2 \quad \text{si } \nu_2 \succ 2$$

$$Var(F) = \left(\frac{6}{6-2}\right)^2 \frac{2(4-6-2)}{4(6-4)} = -36/16 \quad \text{si } \nu_2 \succ 4$$

## 2.0.8 Distribution de Student

**Définition 2.0.44** La distribution  $T$  de Student, pseudonyme du statisticien anglais W.S. Gosset (1876-1937), joue un rôle important dans l'étude de la statistique  $X$  pour une distribution normale dont on ne connaît pas la variance.

La loi de Student est la loi de la variable aléatoire  $T$  définie par :

$$T^2(\nu) = \frac{U^2}{\chi^2(\nu)/\nu} = F(1; \nu) \text{ ou } T(\nu) = \frac{U}{\sqrt{\chi^2(\nu)/\nu}}$$

où  $U$  est une variable aléatoire centrée réduite normale.

**Proposition 2.0.45** 1. La variable  $T(\nu)$  varie de  $-\infty$  à  $+\infty$ .

2. La loi de probabilité de la variable  $T(\nu)$  dépend d'un paramètre, le degré de liberté  $\nu$  de la variable  $\chi^2(\nu)$ .

3. Moments :

$$\begin{aligned} E[T(\nu)] &= 0 \\ \text{Var}[T(\nu)] &= \frac{\nu}{\nu - 2} \quad \text{si } \nu > 2 \end{aligned}$$

4. Mode :


$$M_0 = 0$$

## Fonction de densité

**Définition 2.0.46** La densité de probabilité de la variable aléatoire  $T$  est une expression mathématique compliquée et peu maniable :

$$\begin{aligned} f(t) &= \frac{1}{\sqrt{\pi\nu}} \frac{\Gamma((\nu+1)/2)}{\Gamma(\nu/2)} \times \left(1 + \frac{t^2}{\nu}\right)^{-(\nu+1)/2} \\ &= \frac{1}{\sqrt{\nu}} \frac{1}{\beta\left(\frac{1}{2}; \frac{\nu}{2}\right)} \left(1 + \left(1 + \frac{t^2}{\nu}\right)^{-(\nu+1)/2}\right) \end{aligned}$$

$\Gamma$  fonction eulérienne .



Densité de la loi de Student.

**Exemple 2.0.47** on prend  $\nu = 2$

$$\text{donc } f(t) = \frac{1}{\sqrt{2}} \frac{1}{\beta(\frac{1}{2}; \frac{2}{2})} \left( 1 + \left( 1 + \frac{t^2}{2} \right)^{-(2+1)/2} \right) \text{ avec } \beta\left(\frac{1}{2}; \frac{1}{2}\right) = \int_0^1 t^{-\frac{1}{2}} (1-t)^0 = 2$$

## 2.0.9 Cas particulier d'échantillons gaussiens

L'échantillons considérés dans ce paragraphe sont issus d'une population suivant la loi normale  $N(m; \sigma)$  et les propriétés démontrées ne sont valables que sous cette hypothèse.

### Étude de la statistique $\bar{X}$

La variable  $\bar{X}$ , combinaison linéaire de  $n$  variables aléatoires indépendantes gaussiennes, est une variable gaussienne.

Donc,  $\forall n$  : la loi de la variable  $X$  est la loi  $N\left(m; \frac{\sigma}{\sqrt{n}}\right)$ .

### Étude de la statistique $S^2$

La décomposition de la statistique  $S^2$

$$nS^2 = \left[ \sum_{i=1}^n (X_i - m)^2 \right] - n(m - \bar{X})^2$$

et le théorème de Cochran sur la décomposition d'une forme quadratique conduisent au résultat suivant :

$$\sum_{i=1}^n \left( \frac{X_i - m}{\sigma} \right)^2 = \frac{n S^2}{\sigma^2} + \left( \frac{\bar{X} - m}{\frac{\sigma}{\sqrt{n}}} \right)^2$$

- Le premier membre, somme de  $n$  carrés de variables aléatoires centrées réduites, indépendantes, gaussiennes est une variable  $\chi^2(n)$ .
- Le deuxième membre est une somme de deux formes quadratiques :
  - la première est de rang  $(n - 1)$ , car les variables vérifient la relation :

$$\sum_{i=1}^n (X_i - \bar{X}) = 0$$

- la deuxième est de rang 1.

On en déduit les deux résultats suivants :

1.  $\frac{n S^2}{\sigma^2}$  est une variable  $\chi^2(n - 1)$ .
2.  $\bar{X}$  et  $S^2$  sont deux variables indépendantes.

On démontre la réciproque suivante, qui est une propriété caractéristique des variables aléatoires gaussiennes

Si les statistiques  $\bar{X}$  et  $S^2$  sont indépendantes, la variable aléatoire  $X$  est une variable aléatoire gaussienne.

# Conclusion Générale

En fin toute démarche statistique consiste :

A prélever un échantillon aléatoire de la population par des techniques appropriées. Les différentes méthodes utilisées pour obtenir un tel échantillon relèvent de la théorie de l'échantillonnage, quelques méthodes seront expliquées.

A étudier les principales caractéristiques d'un échantillon, issu d'une population dont on connaît la loi de probabilité, le cas particulier des échantillons issus d'une population normale . Les lois du chi-deux, de Fisher-Snedecor, de Student, lois dérivées de la loi normale, ayant de nombreuses applications dans la théorie de l'estimation et des tests.

# Bibliographie

- [1] **B. Fayolle** : (2010) Statistique inférentielle version complète , 7, 24, 26.
- [2] **B. JOURDAIN** : (2013) Probabilités et statistique , 49.
- [3] **D. Concordet** : Introduction a la statistique inferentielle , 7-35.
- [4] **F. Chamroukhi** : (2013) Éléments de statistique inférentielle, 8-13, 144-150.
- [5] **F. Gilbert et S. Digabel** : (2013) Distributions d'échantillonnage, 5.
- [6] **I. Lyon** : (2010) Cours de probabilités et statistiques, 15, 23, 24, 27-34.
- [7] **J.-Christophe Breton** : (2008) Statistiques IUT Biotechnologie , 10, 12-13.
- [8] **J.JACQUES** : Statistiques inférentielles département, 19-22, 25.
- [9] **J. Vaillant** : (2005) Initiation a la théorie de l'échantillonnage , 1-3.
- [10] **M. Gentes** : (2010) Cours de Probabilités et Statistiques , 13-28.
- [11] **P.Brachet** : Statistique : Résumé de cours et méthodes , 1-6.
- [12] **R. Veysseyre** : Statistique et probabilités pour l'ingénieur , 179-192.
- [13] **S. Geffray** : (2009) Statistique descriptive et inferentielle.
- [14] **S. Robin** : (2007) éléments de la théorie de l'échantillonnage , 7, 11, 17, 18.