



RESUME DU COURS DE MATHEMATIQUES



**ESTIMATION**

**ESTIMATION**

**ECHANTILLONS**

**DEFINITION-1 :** Soit  $\mathcal{L}$  une loi de probabilité définie sur un espace probabilisé  $(\Omega, \mathcal{T}, P)$ . On appelle échantillon aléatoire de taille  $n$  (ou  $n$ -échantillon) de la loi  $\mathcal{L}$  toute suite  $\varepsilon_n = (X_1, \dots, X_n)$  définie sur  $(\Omega)$  et à valeurs dans  $\mathbb{R}^n$  où  $X_1, \dots, X_n$  sont  $n$  variables aléatoires, mutuellement indépendantes définies sur l'espace probabilisé  $(\Omega, \mathcal{T}, P)$  et qui suivent la même loi de probabilité  $\mathcal{L}$ .

Pour tout  $\omega \in \Omega$  tel que  $\{\omega\} \in \mathcal{T}$  la réalisation de  $\varepsilon_n$ , c'est-à-dire  $(X_1(\omega), \dots, X_n(\omega))$ , notée  $(x_1, \dots, x_n)$ , s'appellera un échantillon observé.

**DEFINITION-2 :** On appelle statistique sur un échantillon  $\varepsilon_n = (X_1, \dots, X_n)$  d'une loi de probabilité  $\mathcal{L}$  toute variable aléatoire  $Y = \varphi(X_1, \dots, X_n)$  sur  $(\Omega, \mathcal{T}, P)$  où  $\varphi$  est une application de  $\mathbb{R}^n$  dans  $\mathbb{R}$

**DEFINITION-3 :** Soit  $\varepsilon_n = (X_1, \dots, X_n)$  un  $n$ -échantillon de la loi  $\mathcal{L}$ . La statistique  $\bar{X}_n = \frac{1}{n} \sum_{k=1}^n X_k$  s'appelle moyenne empirique de la loi  $\mathcal{L}$  associée à l'échantillon  $\varepsilon_n$

**THEOREME :** Soit  $\bar{X}_n$  la moyenne empirique associée à un  $n$ -échantillon d'une loi  $\mathcal{L}$  d'espérance  $m$  et de variance  $\sigma^2$ , alors

$$E(\bar{X}_n) = m \text{ et } V(\bar{X}_n) = \frac{\sigma^2}{n}$$

**THEOREME :** La moyenne empirique  $\bar{X}_n$  associée à un  $n$ -échantillon d'une loi  $\mathcal{L}$  d'espérance  $m$  converge en probabilité (donc en loi) vers une variable certaine égale à  $m$ .

**THEOREME :** Soit  $\bar{X}_n$  la moyenne empirique associée à un  $n$ -échantillon d'une loi  $\mathcal{L}$  d'espérance  $m$  et de variance  $\sigma^2$ , alors la variable centrée réduite associée à  $\bar{X}_n$  converge en loi vers une variable  $Y$  qui suit la loi normale  $\mathcal{N}(0, 1)$ .

$$\frac{\bar{X}_n - m}{\frac{\sigma}{\sqrt{n}}} \text{ converge en loi vers } Y$$

---

ESTIMATEURS

---

**Position du problème**

On suppose que les résultats observés sur l'échantillon  $(x_1, \dots, x_n)$  sont les réalisations d'une variable  $X$ , dont la loi est inconnue. On veut, à partir de l'échantillon observé, rechercher quelle loi théorique on peut prendre pour  $X$ . Dans certains cas, on ne connaît rien a priori sur la loi de  $X$ . Mais, très souvent, on est dans la situation où la loi cherchée appartient à une certaine famille de lois (classique ou pas) dépendant d'un paramètre  $\theta$ , que nous noterons  $\mathcal{L}_\theta$ , et on suppose que l'on connaît l'ensemble  $\Theta$  dans lequel varie le paramètre  $\theta$ . Par exemple, pour une famille de lois de Bernoulli, le paramètre  $p$  varie dans  $[0, 1]$ , pour une famille de lois de Poisson, comme pour une famille de lois exponentielles le paramètre  $\lambda$  varie dans  $\mathbb{R}^{+*}$ .

La loi que l'on cherche à évaluer est alors déterminée par son paramètre  $\theta_0$  et on suppose raisonnablement qu'à deux valeurs distinctes du paramètre correspondent deux lois différentes.

**En résumé :** on veut estimer la valeur  $\theta_0$  du paramètre d'une loi à partir d'un échantillon aléatoire d'une variable  $X$  qui suit cette loi inconnue, valeur  $\theta_0$  qui permet de déterminer sans ambiguïté la loi des variables  $X_1, \dots, X_n$  qui constituent l'échantillon, qui sont mutuellement indépendantes et qui suivent la même loi que  $X$ . Dans la pratique, on est souvent amené à estimer non pas directement  $\theta_0$  mais une fonction de  $\theta_0$

**DEFINITION :** Soit  $g : \Theta \rightarrow \mathbb{R}$  et  $\varepsilon_n = (X_1, \dots, X_n)$  un  $n$ -échantillon d'une loi  $\mu_{\theta_0}$ . On appelle estimateur de  $g(\theta_0)$  toute statistique (toute fonction de  $X_1, \dots, X_n$ ) qui prend ses valeurs dans  $g(\Theta)$ , ensemble des valeurs possibles de  $g(\theta_0)$

On notera  $T_n = \varphi(X_1, \dots, X_n)$  un estimateur de  $g(\theta_0)$

Toutes les variables  $X_i$  ( $1 \leq i \leq n$ ) suivent la même loi  $\mu_\theta$ , donc  $T_n$  dépend de  $\theta$ . Les valeurs observées de l'échantillon, grâce auxquelles on cherchera à évaluer  $g(\theta_0)$  sont des réalisations de  $T_n$

**DEFINITION :** Soit  $T_n = \varphi(X_1, \dots, X_n)$  un estimateur de  $g(\theta_0)$ . Une estimation de  $g(\theta_0)$  est une réalisation de  $T_n$ , donc la valeur  $\varphi(x_1, \dots, x_n)$  où  $(x_1, \dots, x_n)$  est une réalisation de l'échantillon  $(X_1, \dots, X_n)$ .

En pratique on désignera par la même lettre  $\theta$  la variable et la vraie valeur  $\theta_0$  que l'on cherche à estimer.

**Exemples :**

1) on dispose d'un dé dont ne sait pas s'il est équilibré. On le lance  $n$  fois de manière indépendante et on choisit une fois pour toutes  $i \in \llbracket 1, 6 \rrbracket$  (on cherche donc à estimer la probabilité d'apparition du numéro  $i$ )

On considère la variable de Bernoulli  $X_k$  qui prend la valeur 1 si au  $k^{\text{ème}}$  lancer le numéro  $i$  est apparu et qui prend la valeur 0 sinon. Le paramètre de  $X_k$  est  $p = P(\text{numéro } i \text{ apparaisse})$ . Ici  $\theta = p$ , la famille de loi est la famille de loi de Bernoulli, de paramètre  $p$  inconnu et  $\Theta = [0, 1]$ . On pourra

page 2

Jean MALLET et Michel MITERNIQUE

© EDUKLUB SA

Tous droits de l'auteur des oeuvres réservés. Sauf autorisation, la reproduction ainsi que toute utilisation des oeuvres autre que la consultation individuelle et privée sont interdites.