

# Feuille 1 : Rappels et estimateurs

Allan Merino

Master 1 Mathématiques, UE Statistiques, Janvier 2016

---

## Quelques exercices de rappel à faire à la maison

### Exercice 1

1. (Loi faible des grands nombres) Si  $(X_n)_{n \geq 1}$  est une suite de variables aléatoires réelles indépendantes et identiquement distribuées telle que  $\mathbb{E}(X_1) < +\infty$ , alors, la suite de variables aléatoires  $\left(\frac{S_n}{n}\right)_{n \geq 1}$  converge en loi vers la variable aléatoire constante égale à  $\mathbb{E}(X_1)$ .
2. (Théorème de la Limite Centrée) Si  $(X_n)_{n \geq 1}$  est une suite de variables aléatoires réelles indépendantes et identiquement distribuées d'espérance  $\mu$  ( $\mu \in \mathbb{R}$ ) et de variance  $\sigma^2$  ( $\sigma \in \mathbb{R}_+^*$ ), alors, la suite de variables aléatoires réelles  $\left(\frac{S_n - n\mu}{\sqrt{n}\sigma}\right)_{n \geq 1}$  converge en loi vers la loi normale de paramètres 0 et 1.
3. (Théorème de Moivre-Laplace) Si  $(S_n)_{n \geq 1}$  est une suite de variables aléatoires réelles telle que pour tout  $n \geq 1$ , la variable aléatoire réelle  $S_n$  est de loi binomiale de paramètres  $n$  et  $p$  ( $p \in ]0, 1[$ ), alors, la suite de variables aléatoires réelles  $\left(\frac{S_n - np}{\sqrt{np(1-p)}}\right)_{n \geq 1}$  converge en loi vers la loi normale de paramètres 0 et 1.

---

**Rappels :** La variable aléatoire  $X$  est de loi  $\Gamma$  de paramètres  $a$  et  $\lambda$  ( $a, \lambda \in \mathbb{R}_+^*$ ) si et seulement si sa loi de probabilité est absolument continue par rapport à la mesure de Lebesgue de dérivée de Radon-Nikodym

$$\frac{d\mathbb{P}_X(x)}{dx} = \frac{\lambda^a}{\Gamma(a)} x^{a-1} e^{-\lambda x} \mathbb{1}_{]0, +\infty[}(x).$$

On montre facilement que si  $X$  et  $Y$  sont deux variables aléatoires indépendantes de loi  $\Gamma(a, \lambda)$  et  $\Gamma(b, \lambda)$ , alors, la variable aléatoire  $X + Y$  suit une loi  $\Gamma(a + b, \lambda)$ .

**Définition (loi du  $\chi_2$ ) :** Une variable aléatoire  $X$  est de loi du chi-deux à  $n$  degrés de liberté ( $n \geq 1$ ) si et seulement si  $X$  est de loi gamma de paramètres  $\frac{n}{2}$  et  $\frac{1}{2}$ . On note souvent  $X \sim \chi_{2,n}$ .

---

### Exercice 2

- Soient  $X$  et  $Y$  deux variables aléatoires définies sur  $(\Omega, \mathcal{F}, \mathbb{P})$ . Déterminer la loi de probabilité de  $X + Y$  dans les cas où
  - $X$  et  $Y$  sont indépendantes de lois respectives  $\epsilon(\alpha)$  et  $\epsilon(\beta)$ ,  $\alpha, \beta > 0$ ,
  - $X$  et  $Y$  sont indépendantes de lois respectives  $\mathcal{N}(\mu_1, \sigma_1^2)$  et  $\mathcal{N}(\mu_2, \sigma_2^2)$ ,  $\mu_1, \mu_2 \in \mathbb{R}$ ,  $\sigma_1, \sigma_2 > 0$ .
- Plus généralement, montrer que si  $X$  et  $Y$  sont deux variables aléatoires indépendantes définies sur  $(\Omega, \mathcal{F}, \mathbb{P})$ , on a

$$f_{X+Y} = f_X \star f_Y.$$

- Soit  $X \sim \mathcal{N}(0, 1)$ . Déterminer la loi de  $X^2$ .
- Montrer que si  $X_1, \dots, X_n$  sont des variables aléatoires indépendantes identiquement distribuées de loi  $\mathcal{N}(0, 1)$ , alors  $\sum_{k=1}^n X_k^2$  suit une loi du chi-deux à  $n$  degrés de liberté.

### Exercice 3 : Critère des moindres carrés

Soient  $x_j \in \mathbb{R}$  pour  $j \in \{1, \dots, n\}$  et  $D = \{x_1, \dots, x_n\}$ . Posons  $f_D : \mathbb{R} \rightarrow \mathbb{R}$  l'application définie par  $f_D(x) = \frac{1}{n} \sum_{j=1}^n (x_j - x)^2$ .

Montrer que l'unique minimum de  $f_D$  est  $\bar{x}$ , la moyenne des données  $D$ .

**Définition** Soit  $p \in ]0, 1[$ .

- Soit  $D = \{x_1, \dots, x_n\}$  un échantillon observé de taille  $n$  d'une variable statistique quantitative. On appelle  $p$ -quantile pour  $D$  un réel  $x_p$  tel que  $\text{Card}(\{x_j; j \in \{1, \dots, n\} \text{ et } x_j \leq x_p\}) \geq np$  et  $\text{Card}(\{x_j; j \in \{1, \dots, n\} \text{ et } x_j \geq x_p\}) \geq n(1 - p)$ .
- Soit  $f$  la densité d'une loi absolument continue sur  $\mathbb{R}$ . On dit que  $x_p$  est un  $p$ -quantile si  $F(x_p) = \int_{-\infty}^{x_p} f(u) du = p$ .

### Exercice 4

- Soit  $Y$  une variable aléatoire réelle de loi absolument continue, de densité  $f$  et de fonction de répartition  $F$ . Montrer que si  $F$  est strictement monotone sur  $\{0 < F < 1\}$  et si  $p \in ]0, 1[$ , alors il existe un unique  $p$ -quantile de  $Y$ .
- Soit  $Z$  une variable aléatoire réelle qui suit une loi normale centrée réduite. Soient  $z \in \mathbb{R}$  et  $\{z_p, p \in ]0, 1[\}$  l'ensemble de ses  $p$ -quantiles. Montrer que  $\Phi(z) = 1 - \Phi(-z)$  (avec  $\Phi$  la fonction de répartition de  $Z$ ) ainsi que  $z_p = -z_{1-p}$ .
- Soient  $\mu \in \mathbb{R}$ ,  $\sigma \in \mathbb{R}_+^*$  et  $X \sim \mathcal{N}(\mu, \sigma^2)$ . Soit, de plus,  $x_p$  le  $p$ -quantile de  $X$  pour  $p \in ]0, 1[$ . Montrer que  $x_p = \mu + \sigma z_p$ .
- Expliquer la règle de "68% – 95% – 99.7%" en calculant approximativement la probabilité pour que  $X$  prenne ses valeurs dans  $[\mu - k\sigma, \mu + k\sigma]$  (appelée la  $k\sigma$ -région), pour  $k \in \{1, 2, 3\}$ .

**Quelques exercices pour débiter**

### Exercice 5 - Le modèle linéaire

Le but de cette étude consiste à rechercher une relation entre le pH  $x$  de divers lacs et le pH  $y$  de carpes vivant dans ces milieux. Le tableau ci-dessous présente la valeur  $x_i$  du pH du lac  $i$  et la valeur  $y_i$  du pH d'une carpe prélevée au hasard dans ce lac.

$x_i$	4	8	9	6	3.5	7	5
$y_i$	6.4	7.2	7.3	6.7	6.2	6.9	6.6

1. Représenter graphiquement le nuage de points correspondant à ces données. Quel type de relation semble lier les  $x_i$  et les  $y_i$  ?
2. La relation n'étant pas parfaite, on introduit un terme d'erreur  $\epsilon_i$ . Nous supposons que les  $\epsilon_i$  suivent une loi normale centrée et qu'ils sont indépendants entre eux. Exprimer, en fonction de  $x_i$  et  $\epsilon_i$ , la loi de la variable aléatoire  $Y_i$  correspondant au pH d'une carpe du lac  $i$ .
3. Donner une structure statistique de cette expérience.

---

**Rappels** Une variable aléatoire absolument continue est de loi de Student à  $n$  degrés de liberté ( $n \geq 1$ ) si et seulement si :

$$f_X(x) = \frac{\Gamma(\frac{n+1}{2})}{\Gamma(\frac{n}{2})} \frac{1}{\sqrt{n\pi}} \left(1 + \frac{x^2}{n}\right)^{-\frac{n+1}{2}}.$$

---

### Exercice 6 - Loi de Student

Montrer que si  $X$  et  $Y$  sont deux variables aléatoires réelles indépendantes de lois respectives  $\mathcal{N}(0, 1)$  et  $\chi_{2,n}$ , alors,

$$T_n = \frac{\sqrt{n}X}{\sqrt{Y}}$$

est de loi de Student à  $n$  degrés de liberté.

### Exercice 7

Soient  $n \geq 2$  et  $X_1, \dots, X_n$  des variables aléatoires réelles indépendantes de moyenne  $\mu$  et de variance  $\sigma^2 > 0$ . On pose :

$$\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i, \quad \Sigma_n^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2,$$
$$\hat{S}_n^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2, \quad S_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2.$$

On appelle  $\bar{X}_n$  et  $S_n^2$  l'espérance (reps. la variance) empirique.

1. Calculer l'espérance et la variance de  $\bar{X}_n$  ainsi que l'espérance de  $S_n^2$ .  
A présent, on considère que pour tout  $j$ ,  $X_j$  suit une loi normale  $\mathcal{N}(\mu, \sigma^2)$ .
2. Quelle est la loi de  $\bar{X}_n$  ? Quelle est la loi de  $\frac{n\hat{S}_n^2}{\sigma^2}$  ?
3. Montrer que  $\frac{n\hat{S}_n^2}{\sigma^2} \sim \chi_{n-1}^2$  et que  $\bar{X}_n$  et  $\hat{S}_n^2$  sont indépendantes.

4. En déduire la loi de  $\sqrt{n} \frac{(\bar{X}_n - \mu)}{S_n}$ .

### Exercice 8

1. On effectue un comptage de population de bacilles dans cent cellules d'un individu. Les résultats sont présentés dans le tableau suivant :

Nombre x de bacilles par cellules	1	2	3	4	5	6	7	8	9	10	11
Nombre de cellules ayant x bacilles	5	15	21	20	18	10	2	3	3	1	2

L'expérimentateur suppose que la variable aléatoire représentant le nombre de bacilles par cellule suit une loi de Poisson de paramètre  $\lambda$  inconnu. Donner la structure statistique correspondante.

2. On possède un dé (à 6 faces) truqué et on souhaite découvrir comment il est déséquilibré. On note  $p_1, \dots, p_6$  les probabilités respectives d'apparition des 6 faces. On effectue  $n$  lancers indépendants de ce dé et on observe, à chaque lancer, la face supérieure. Construire le modèle statistique adapté à ce modèle.

### Estimation

**Rappels** Soit  $\mathcal{S} = \{(\Omega, \mathcal{A}, \mathbb{P}_\theta) / \theta \in \Theta\}$  un modèle statistique. Soit  $g : \theta \rightarrow \mathbb{R}^d$  une application. Soit  $S : \mathcal{S} \rightarrow (\mathbb{R}^d, \mathcal{B}(\mathbb{R}^d))$  une statistique  $d$ -dimensionnelle.

1. On dit que  $S$  est intégrable si

$$(\forall \theta \in \Theta) \quad \mathbb{E}_\theta(\|S\|) = \int_{\Omega} \|S(\omega)\| d\mathbb{P}_\theta(\omega) < +\infty. \quad (1)$$

2. On dit qu'une statistique  $S$  est un estimateur sans biais de  $g$  si

$$(\forall \theta \in \Theta), \quad \mathbb{E}_\theta(S) = g(\theta). \quad (2)$$

3. On dit qu'un estimateur sans biais de  $g$  est à dispersion minimale si pour tout  $\theta \in \Theta$  et pour tout  $T$  estimateur sans biais de  $g$ , on a :

$$\mathbb{V}_\theta(S) \leq \mathbb{V}_\theta(T). \quad (3)$$

Par la suite, on utilisera la proposition suivante : Soit  $S = (S_1, \dots, S_d)$  un estimateur sans biais de  $g$  de carré intégrable.  $S$  est un estimateur sans biais à dispersion minimale de  $g$  si et seulement si pour tout  $j = 1, \dots, d$ , pour tout  $\theta \in \Theta$  et pour toute statistique  $X$  intégrable centrée (unidimensionnelle), on a  $\mathbb{E}_\theta(S_j X) = 0$ .

Soit  $\mathcal{S} = (\Omega, \mathcal{A}, \mathbb{P}_\theta, \theta \in \Theta)$  un modèle statistique et  $g : \Theta \rightarrow \mathbb{R}^d$  une application. Soit  $T_n$  une suite de statistique à valeurs dans  $\mathbb{R}^d$ . On dit que  $(T_n)_{n \geq 1}$  est un estimateur de  $g(\theta)$  faiblement convergent si  $T_n \rightarrow g(\theta)$  en probabilité par rapport à  $\mathbb{P}_\theta$ .

De nouveau, par la suite, on utilisera le lemme suivant : Soit  $(T_n)_{n \in \mathbb{N}^*}$  une suite d'estimateurs sans biais de  $g(\theta)$  telle que  $(\forall \theta \in \Theta), \lim_{n \rightarrow +\infty} \mathbb{V}_\theta(T_n) = 0$ . Alors,  $(T_n)_{n \in \mathbb{N}^*}$  est faiblement convergent.

### Exercice 9

Soient  $X_1, \dots, X_n$  des variables aléatoires réelles indépendantes et identiquement distribuées.

1. Montrer que  $\bar{X}_n$  est un estimateur sans biais de  $g(\theta) = \mathbb{E}(X_1)$ .
2. Montrer que  $\bar{X}_n$  est un estimateur sans biais faiblement convergent de  $\mathbb{E}(X_1)$ . Est-il fortement convergent ?
3. Montrer que  $S_n^2$  est un estimateur sans biais de  $\mathbb{V}(X_1)$ .
4. Montrer que  $S_n^2$  est un estimateur sans biais faiblement convergent de  $g(\theta) = \mathbb{V}(X_1)$ .

### Exercice 10

Soient  $X_1, \dots, X_n$  des variables aléatoires indépendantes et identiquement distribuées d'espérance  $\mu$  et de variance  $\sigma^2$ .

1. Donner la condition sur les constantes réelles  $a_1, \dots, a_n$  pour que  $\sum_{i=1}^n a_i X_i$  soit un estimateur sans biais de  $\mu$ .
2. Parmi les estimateurs sans biais de cette forme, déterminer celui qui est de variance minimale et calculer sa variance.

### Exercice 11

Soient  $\Theta = ]0, +\infty[$  et  $\{\Omega, \mathcal{A}, \mathbb{P}_\theta; \theta \in \Theta\} = \{(\mathbb{N}, \mathcal{P}(\mathbb{N}), \mathbb{P}_\theta); \theta \in \Theta\}$ , avec  $\mathbb{P}_\theta = \mathcal{P}(\theta)$ , le modèle poissonien.

1. Donner un estimateur sans biais de  $\theta$ .
2. Montrer qu'il n'existe pas d'estimateur sans biais de  $\frac{1}{\theta}$ .

### Exercice 12

On considère le modèle constitué par les lois  $\mathcal{B}(n, \theta)$  avec  $\theta \in ]0, 1[$  sur  $\Omega = \{0, 1, \dots, n\}$ . On définit la variable  $X$  par  $X(\omega) = \omega, (\forall \omega \in \Omega)$ .

1. Soit  $f$  une fonction sur  $\Omega$  telle que

$$(\forall \theta \in \Theta = ]0, 1[, \mathbb{E}_\theta(f(X)) = 0.$$

Montrer que  $f$  est la fonction nulle.

2. Calculer  $\mathbb{E}_\theta \left( \frac{X(X-n)}{n(n-1)} \right)$  et en déduire un estimateur sans biais de variance minimale de  $-\theta(1-\theta)$ .
3. On pose  $n = 10$ . Existe-t-il des estimateurs sans biais de variance minimale des fonctions suivantes du paramètre  $\theta$  :
  - (a)  $\theta^2 - \theta^4$ ,
  - (b)  $\mathbb{P}_\theta(X \leq 4)$ ,
  - (c)  $\exp(\theta)$ .

### Exercice 13

Un lac contient une proportion inconnue  $\theta$  de poissons d'une certaine espèce  $E$ . On pêche des poissons dans ce lac jusqu'à obtenir  $n$  poissons de l'espèce  $E$  et on appelle  $X$  le nombre de poissons pêchés à ce moment-là. Autrement dit, le  $n^e$  poisson pêché de l'espèce  $E$  est le  $X^e$  poisson pêché. On admet que le nombre de poissons du lac est suffisamment grand pour que l'on puisse assimiler cette pêche à des tirages avec remise.

1. Calculer la loi de  $X$ .

2. Soient  $\Theta = \{\theta \in ]0, 1[ \}$  et  $n > 1$ . Montrer que  $\mathbb{E}_\theta \left( \frac{n-1}{X-1} \right) = \theta$  et que  $\mathbb{E}_\theta \left( \frac{n}{X} \right) \neq \theta$ .

3. Montrer que pour  $n > 1$ ,  $\frac{n-1}{X-1}$  est un estimateur sans biais de variance minimale de  $\theta$ .

### Exercice 14

Soit  $X_1, X_2, \dots, X_n$  un échantillon de  $n$  valeurs mutuellement indépendantes, issu d'une population suivant une loi uniforme sur un intervalle  $[a, b]$ , où les bornes  $a$  et  $b$  sont inconnues. On pose  $Z = \min(X_1, \dots, X_n)$ ,  $T = \max(X_1, \dots, X_n)$  et  $U = \frac{Z+T}{2}$ .

1. Montrer que  $Z$  est un estimateur biaisé de  $a$  et asymptotiquement sans biais.

2. Montrer que  $T$  est un estimateur biaisé de  $a$  et asymptotiquement sans biais.

3. Montrer que  $U$  est un estimateur sans biais de la moyenne  $\mu = \frac{a+b}{2}$ .

### Exercice 15

On considère un échantillon  $X_1, \dots, X_n$  de  $n$  variables aléatoires mutuellement indépendantes et suivant toutes une loi uniforme sur l'intervalle  $[0, a]$ , avec  $a > 0$ . Soit également  $X$  une variable aléatoire suivant la même loi uniforme sur  $[0, a]$ . Soit  $\bar{X} = \sqrt[n]{X_1 \dots X_n}$  la moyenne géométrique de l'échantillon.

1. Rappeler l'expression de  $E(X)$ .

2. Montrer que la fonction de densité de probabilité de la variable  $Y = \sqrt[n]{X}$ , de support  $[0, \sqrt[n]{a}]$ , est égale à  $f_Y(x) = \frac{n}{a} x^{n-1}$ .

3. Calculer  $E(\bar{X})$ .  $\bar{X}$  est-il un estimateur sans biais de  $E(X)$  ?

4. Calculer  $E(\bar{X})$  en fonction de  $a$  pour  $n = 1, 10, 100, 1000$ . Que constatez-vous ?

5. Calculer la variance  $V(\bar{X})$  de  $\bar{X}$ .

6. Dédurre des questions précédentes, et à partir de  $E(\bar{X})$ , un estimateur sans biais de  $E(X)$ .