

**Exercice 1****Chose promise chose due****4 points**

1. On observe  $x_i, i = 1, \dots, n$ , le département de naissance des  $n$  élèves de la classe. Donnez la formule mathématique permettant de calculer la moyenne de ces observations ?
2. Après calcul, on a trouvé un coefficient de corrélation de -1,23. Comment interpréter ce résultat ?
3. Soient  $(x_i, y_i), i = 1, \dots, n$ ,  $n$  observation d'un couple de variables quantitatives. Montrez que

$$\text{cov}(x, y) = \frac{1}{n} \sum_{i=1}^n x_i y_i - \left( \frac{1}{n} \sum_{i=1}^n x_i \right) \left( \frac{1}{n} \sum_{i=1}^n y_i \right)$$

4. Qu'est-ce qu'une statistique ?
5. Donner un exemple d'OPM
6. En quoi est-ce intéressant qu'un échantillon soit i.i.d. ?
7. Comment comparer deux estimateurs ?
8. A quoi sert la borne de Cramer Rao ?

**Exercice 2****La danse si Ted joue int****3 points**

On considère la densité de la loi jointe

$$f_{X,Y}(x, y) = \lambda^2 \exp^{-\lambda y} \text{ pour } 0 \leq x \leq y \text{ et } 0 \text{ sinon}$$

1. Montrez que la densité de la loi marginale en  $y$  est

$$f_Y(y) = \lambda^2 y \exp^{-\lambda y} \text{ pour } 0 \leq y \text{ et } 0 \text{ sinon}$$

2. Calculez la densité conditionnelle  $f_{X|Y}(x)$  de  $x$  sachant  $y$ . Vérifiez qu'il s'agit bien d'une densité de probabilité.
3. Calculez l'espérance conditionnelle  $\mathbb{E}_{X|Y}(x)$  de  $x$  sachant  $y$ .

**Exercice 3****L'équilibre de Hardy-Weinberg****3 points**

En faisant l'hypothèse que les fréquences d'apparition des gènes sont en équilibre, les génotypes MM, MN et NN apparaissent dans une population avec des probabilités  $(1 - \theta)^2$ ,  $2\theta(1 - \theta)$  et  $\theta^2$  (et ce conformément au principe de Hardy-Weinberg) où  $\theta$  est un paramètre inconnu à déterminer (qui modélise la probabilité de trouver l'allèle  $M$  dans la population). Dans un échantillon de la population chinoise de Hong Kong en 1937, les groupes sanguins se présentaient avec les fréquences suivantes, où  $M$  et  $N$  sont des antigènes érythrocytaires

Groupe sanguin	MM	MN	NN	Total
Nombre d'individu	342	500	187	1029

Donner l'estimateur max de vraisemblance de  $\theta$  et l'estimation associée. Cet estimateur est-il efficace ?

---

**Exercice 4****L'avarie en ce début de médian****10 points**

Soit  $X$  une variable aléatoire réelle suivant une loi normale de paramètres  $\mu$  et  $\sigma^2$  tous deux inconnus, et donc de densité :

$$f_X(x) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp^{-\frac{(x-\mu)^2}{2\sigma^2}} .$$

Nous allons dans cet exercice étudier une classe d'estimateurs du paramètre  $\sigma^2$ .

1. Dans cette première partie, on suppose  $\mu$  connu
  - a) Donner l'estimateur max de vraisemblance de  $\sigma^2$
  - b) Cet estimateur est-il efficace ?
  - c) Quelle est sa variance ?
2. Dans cette deuxième partie, on suppose  $\mu$  inconnu On pose

$$\hat{\sigma}_a^2 = \frac{a}{n} \sum_{i=1}^n (X_i - \bar{X})^2,$$

où  $a$  est un coefficient positif. On rappelle que  $\bar{X} \sim \mathcal{N}(\mu, \sigma^2/n)$ .

- a) Montrer que

$$\hat{\sigma}_a^2 = \frac{a}{n} \sum_{i=1}^n (X_i - \mu)^2 - a(\bar{X} - \mu)^2,$$

- b) Exprimer le biais de cet estimateur  $\hat{\sigma}_a^2$  comme une fonction du coefficient  $a$ .
  - c) Comment choisir  $a$  pour que soit sans biais ?
3. Le choix de  $a$ . On admettra que

$$S^2 = \frac{n \hat{\sigma}_a^2}{a \sigma^2}$$

suit une loi du chi2 à  $n - 1$  degrés de liberté et donc que  $\mathbb{E}(S^2) = n - 1$  et  $Var(S^2) = 2(n - 1)$ .

- a) Exprimer la variance de  $\hat{\sigma}_a^2$  comme une fonction du coefficient  $a$ .
- b) En déduire le risque de cet estimateur  $\hat{\sigma}_a^2$  comme une fonction du coefficient  $a$ .
- c) Montrez que  $a_{opt}$  la valeur de  $a$  qui minimise ce risque est

$$a_{opt} = \frac{n}{n + 1}.$$

4. Conclusion

- a) À la vue de ces résultats, quel est à votre sens le meilleur estimateur du paramètre  $\sigma^2$  et pourquoi ?
  - b) Quel est ici l'intérêt de la borne de Crame Rao ?
-

## Formulaire

- fréquences  $\hat{f}_i = \frac{n_i}{n}$  où  $n$  est le nombre total d'observations et  $n_i$  le nombre d'observation de la modalité  $i$
- moyenne :  $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = \sum_{i=1}^n \hat{f}_i x_i$
- variance empirique :  $\hat{\sigma}_x^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$
- espérance d'une variable aléatoire discrète :  $\mathbb{E}(X) = \sum_i x_i \mathbb{P}(x_i)$ .
- espérance d'une variable aléatoire continue de densité  $f(x)$  :  $\mathbb{E}(X) = \int x f(x) dx$ .
- variance d'une variable aléatoire  $X$  :  $Var(X) = \mathbb{E}\left((X - \mathbb{E}(X))^2\right)$ .
- médiane :  $\mathbb{P}(X < M) = 0,5$
- mode :  $Argmax_{x \in \Omega} \{\mathbb{P}(x)\}$
- fractiles à l'ordre  $p$ ,  $\forall p \in [0, 1]$ ,  $\hat{\Phi}_p$  telle que  $\hat{\mathbb{P}}(X \leq \hat{\Phi}_p) = p$
- les quartiles :
  - $\hat{\Phi}_{\frac{1}{4}} = \hat{Q}_1$ , telle que  $\hat{F}(\hat{Q}_1) = \frac{1}{4}$ ,
  - $\hat{\Phi}_{\frac{1}{2}} = \hat{Q}_2 = \hat{M}$ , telle que  $\hat{F}(\hat{M}) = \frac{1}{2}$ ,
  - $\hat{\Phi}_{\frac{3}{4}} = \hat{Q}_3$ , telle que  $\hat{F}(\hat{Q}_2) = \frac{3}{4}$ .
- covariance :  $c_{xy} = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})$
- corrélation :  $cor(x, y) = \frac{c_{xy}}{\sqrt{\hat{\sigma}_x^2 \hat{\sigma}_y^2}}$
- probabilité conditionnelle :  $\mathbb{P}(X = x_i | Y = y_j) = \frac{\mathbb{P}(X = x_i, Y = y_j)}{\mathbb{P}(Y = y_j)}$
- densité conditionnelle :  $f_{X|Y}(x|y) = \frac{f_{(X,Y)}(x, y)}{f_Y(y)}$
- espérance conditionnelle (v.a. discrète) :  $\mathbb{E}[Y|X = a] = \sum_{i=1}^n y_i \mathbb{P}(Y = y_i | X = a)$
- La loi des grands nombres :  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i \xrightarrow{n \rightarrow \infty} \mathbb{E}(X)$
- Le théorème central limite :  $\sqrt{n} \left( \frac{1}{n} \sum_{i=1}^n X_i - \mathbb{E}(X) \right) \xrightarrow[n \rightarrow \infty]{(d)} \mathcal{N}(0, \sigma^2)$

Estimateurs :

- Le risque :  $R_{\hat{\theta}}(\theta) = \mathbb{E}\left((\hat{\theta}(X_1, \dots, X_n) - \theta)^2\right)$ 
  - Le biais d'un estimateur :  $\mathbb{E}(\hat{\theta}) - \theta$
  - La variance d'un estimateur :  $\mathbb{E}\left((\hat{\theta} - \mathbb{E}(\hat{\theta}))^2\right)$
- Soit  $X$  une variable aléatoire de distribution  $f_{\theta}(x)$  et  $(X_1, \dots, X_n)$  une famille de  $n$  variables aléatoires i.i.d. ayant pour loi parente la loi de  $X$  dépendant d'un paramètre  $\theta \in \mathbb{R}$ .
- Vraisemblance :

$$L(\theta, X_1, \dots, X_n) = \prod_{i=1}^n f_{\theta}(X_i)$$

Log vraisemblance :

$$\ell(\theta, X_1, \dots, X_n) = \log L(\theta, X_1, \dots, X_n) = \sum_{i=1}^n \log f_{\theta}(X_i)$$

Le score :

$$s(\theta, X_1, \dots, X_n) = \frac{\partial \ell(\theta, X_1, \dots, X_n)}{\partial \theta}$$

- L'information de Fisher :  $I_n(\theta) = \text{Var}\left(\frac{\partial \ell(\theta, X_1, \dots, X_n)}{\partial \theta}\right) = -\mathbb{E}\left(\frac{\partial^2 \ell(\theta, X_1, \dots, X_n)}{\partial \theta^2}\right)$
- Pour  $\theta \in \mathbb{R}^p$ , L'information de Fisher est la matrice  $p \times p$

$$I_n(\theta) = \mathbb{E}(\nabla \ell(\theta, X_1, \dots, X_n) \nabla \ell(\theta, X_1, \dots, X_n)^\top)$$

- Borne de Cramer Rao
  - pour un estimateur sans biais de  $\theta$

$$BCR(\theta) = \frac{1}{I_n(\theta)} \leq \text{Var}(\hat{\theta}(X_1, \dots, X_n))$$

- Pour un estimateur sans biais d'une fonction de  $\theta$  :  $\mathbb{E}(\hat{u}(\theta)) = u(\theta)$

$$BCR(\theta) = \frac{u'(\theta)}{I_n(\theta)} \leq \text{Var}(\hat{u}(\theta(X_1, \dots, X_n)))$$

- pour un estimateur biaisé de biais  $B$

$$BCR(\theta) = \frac{1 + B'(\theta)}{I_n(\theta)} \leq \text{Var}(\hat{\theta}(X_1, \dots, X_n))$$

Variables aléatoires et lois

- Soit  $Y \sim \mathcal{N}(0, 1)$  une variable aléatoire normale centrée réduite.
- Soit  $Y_1, Y_2, \dots, Y_n$  un échantillon i.i.d. de taille  $n$  de loi parente  $\mathcal{N}(0, 1)$ .
- On appelle loi du  $\chi^2$  à  $n$  degrés de libertés la loi de la variable aléatoire  $Z_n = \sum_{i=1}^n Y_i^2$ .  
L'espérance et la variance de cette loi sont  $\mathbb{E}(Z_n) = n$  et  $\text{Var}(Z_n) = 2n$
- On appelle loi de student à  $n$  degrés de libertés la loi de la variable aléatoire  $T_n$

$$T_n = \frac{N}{\sqrt{\frac{X_n}{n}}} \quad \begin{array}{l} N \sim \mathcal{N}(0, 1) \\ X_n \sim \chi_n^2 \end{array}$$