

## Estimation

### Exercice 1

On procède à une série de mesures avec un même appareil. On suppose que le résultat d'une mesure est une v.a.  $X$  suivant une loi normale de moyenne inconnue  $m$  et d'écart-type 0.5. On a observé la série de valeurs suivantes :

12.5 15.8 14.7 15.3 15.2 15.1 15.6 14.9 14.9

1. Construire un intervalle de confiance  $I_1$  de niveau 90 % pour  $m$ .
  2. Construire un intervalle de confiance  $I_2$  de niveau 98 % pour  $m$ .
  3. Comment obtenir un intervalle de confiance qui ait même longueur que  $I_1$  et même niveau de confiance que  $I_2$  ?
- 

### Exercice 2

Une usine fabrique des câbles. On suppose que la charge maximale supportée par un câble, exprimée en tonnes, est une v.a. normale de moyenne  $m$  inconnue et d'écart-type 0.3). Une étude portant sur 50 câbles a donné une moyenne des charges maximales supportées égale à 12.2 tonnes.

1. Déterminer un intervalle de confiance à 99 % de la charge maximale moyenne de tous les câbles fabriqués par l'usine.
  2. Quelle doit être la taille minimale de l'échantillon étudié pour que la longueur de l'intervalle de confiance à 99 % soit inférieure ou égale à 0.2 ?
- 

### Exercice 3

Une entreprise fabrique une pièce de moteurs industriels. Parfois ces pièces se révèlent immédiatement défectueuses après la vente. Le taux de défaillance doit être limité à 0.04. Sur 500 pièces contrôlées, 28 sont défectueuses.

1. Donner un intervalle de confiance pour le taux en question (avec le risque de 5 %).
  2. La norme de qualité de production est-elle respectée ?
- 

### Exercice 4

On dit qu'une v.a.  $Y$  suit la loi « log-normale » de paramètres  $(m, \sigma)$  si  $X = \ln Y$  suit la loi normale paramètres  $(m, \sigma^2)$ . On dispose d'un échantillon de neuf observations d'une loi log-normale de paramètres  $(m, \sigma)$  inconnus :

11.3 2.1 1.1 8.9 4.6 5.7 13.5 24.5 16.4

1. Construire un intervalle de confiance de niveau 90 % pour  $m$ .
  2. Même question pour  $\sigma$ .
- 

### Exercice 5

Une chaîne de fabrication produit un pourcentage  $p$  d'appareils défectueux. Le paramètre  $p$  est inconnu mais on sait que  $p \leq 0.08$ . On voudrait construire un estimateur sans biais de  $p$  de précision supérieure à  $1/0.002$ . Quelle doit être la taille de l'échantillon à prélever ?

---

### Exercice 6

Une machine fabrique des pièces dont la longueur est une v.a.  $X$  acceptable si elle est comprise entre 28.18 et 28.22 mm.

1. Dans un premier temps, on estime que  $X$  suit la loi normale de moyenne 28.20 et d'écart-type 0.012. Calculer le pourcentage de pièces acceptables auquel il faut s'attendre.
2. Sans mettre en cause l'écart-type estimé  $\sigma = 0.012$ , on désire vérifier la valeur moyenne de la longueur des pièces produites  $m$  par l'analyse d'un échantillon. Quelle doit être la taille de l'échantillon qui placera  $m$  dans un intervalle d'amplitude 0.01mm centré sur  $\hat{m}$ , moyenne de l'échantillon au risque de 1 % ?
3. On prélève un échantillon de 50 pièces qui donne le résultat suivant : moyenne de l'échantillon 28.195, écart-type de l'échantillon 0.015. Déterminer l'intervalle centré sur  $\hat{m}$  où se trouve  $m$  au risque 1 %.
4. On complète l'analyse par une étude des retours de l'atelier de montage pour non-conformité. Sur 250 pièces expédiées, 21 sont retournées. Déterminer la probabilité qu'une pièce soit hors tolérance, dans un intervalle de confiance de niveau 95 %.

### Exercice 7

Soit  $(X_1, \dots, X_n)$  un échantillon de la loi normale de paramètres  $(m, \sigma^2)$  où  $m$  et  $\sigma$  sont inconnus et soit  $k > 0$ . On pose  $\widehat{m}_n = \frac{1}{n} \sum_{i=1}^n X_i$  et  $\widehat{s}_n^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \widehat{m}_n)^2$ .

1. En se rappelant que  $n\widehat{s}_n^2/\sigma^2$  suit la loi du Khi-Deux à  $(n-1)$  d.d.l., calculer le moment d'ordre  $k$  de  $\widehat{s}_n^2$ ,  $\mathbb{E}[(\widehat{s}_n^2)^k]$ .
  2. Trouver la constante  $\alpha_{k,n}$  telle que  $\widehat{\sigma}_n^{2k} = \alpha_{k,n}(\widehat{s}_n^2)^k$  soit un estimateur sans biais de  $\sigma^{2k}$ . Examiner les cas particuliers  $k=1$  et  $k=\frac{1}{2}$ .
  3. Montrer que  $\widehat{\sigma}_n^{2k}$  est un estimateur correct.
- On donne  $\frac{\Gamma(x+a)}{\Gamma(x+b)} = x^{a-b} \left[ 1 + \frac{(a-b)(a+b-1)}{2x} + o\left(\frac{1}{x}\right) \right]$  lorsque  $x \rightarrow +\infty$ .
- 

### Exercice 8

Le nombre d'appels téléphoniques entre 9 h et 10 h est une v.a.  $X$  suivant une loi de Poisson de paramètre inconnu  $\lambda$ . On cherche à évaluer la probabilité  $\mathbb{P}(X=0) = e^{-\lambda} = \mu$  qu'il n'y ait pas d'appel pendant ce laps de temps. On note  $X_1, \dots, X_n$  les nombres d'appels (aléatoires) sur  $n$  jours durant cet intervalle de temps.

$(X_1, \dots, X_n)$  est un échantillon de  $X$ . Désignons la moyenne de ces appels par  $\widehat{m} = \frac{1}{n} \sum_{i=1}^n X_i$  et le nombre de

jours sans appel par  $n\widehat{F} = \sum_{i=1}^n \mathbb{1}_{\{X_i=0\}}$ .

On propose trois estimateurs différents pour  $\mu$  :  $\widehat{\mu}_1 = \widehat{F}$  ;  $\widehat{\mu}_2 = e^{-\widehat{m}}$  ;  $\widehat{\mu}_3 = \left(1 - \frac{1}{n}\right)^{n\widehat{m}}$ .

1. Déterminer le biais et la variance de chacun de ces estimateurs.
  2. Etudier la convergence de chacun de ces estimateurs, puis comparer leur précision.
- 

### Exercice 9

La hauteur maximale  $H$  de la crue annuelle d'un fleuve est soigneusement observée, car une crue supérieure à 6 mètres serait catastrophique. On a modélisé la loi de la v.a.  $H$  comme étant de Rayleigh, i.e. de densité

$$f_H(x) = \frac{x}{\theta} e^{-\frac{x^2}{2\theta}} \mathbb{1}_{[0, +\infty[}(x),$$

où  $\theta$  est un paramètre inconnu. Pendant 8 ans on a observé les hauteurs de crues suivantes en mètres :

2.5   2.9   1.8   0.9   1.7   2.1   2.2   2.8

1. Donner l'estimateur du maximum de vraisemblance de  $\theta$ .
  2. Une compagnie d'assurance estime qu'une catastrophe n'arrive en moyenne qu'au plus une fois tous les mille ans. Cette estimation peut-elle être justifiée par les observations ?
- 

### Exercice 10

On considère une v.a.  $X$  de densité  $f_X(x) = e^{-(x-\theta)} \mathbb{1}_{[\theta, +\infty[}(x)$ , où  $\theta > 0$  est un paramètre inconnu. Soit  $(X_1, \dots, X_n)$  un échantillon de  $X$ .

1. (a) Donner les valeurs de  $\mathbb{E}(X)$  et  $\text{var}(X)$ .  
(b) Trouver un estimateur sans biais simple  $T_n$  de  $\theta$ . Etudier sa convergence.  
(c) Donner une loi approchée de  $T_n$  pour  $n \geq 100$ . En déduire un intervalle de confiance pour  $\theta$  de crédibilité 0.9.
2. On se propose maintenant d'étudier l'estimateur du maximum de vraisemblance  $U_n$  de  $\theta$ .  
(a) Exprimer  $U_n$  en fonction de  $X_1, \dots, X_n$ .  
(b) Déterminer la fonction de répartition  $F_{U_n}$  ainsi que la densité  $f_{U_n}$  de  $U_n$ .  
(c) Calculer la précision de  $U_n$ .
3. Comparer les estimateurs  $T_n$  et  $U_n$ . Lequel est préférable ?

### Exercice 11

Soient  $X_1, \dots, X_n$  des v.a. indépendantes issues d'une loi normale centrée de variance  $\theta$ . On note  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$  et on définit deux statistiques  $U$  et  $V$  par :

$$U = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2 = \frac{1}{n-1} \left[ \sum_{i=1}^n X_i^2 - n\bar{X}^2 \right] \quad \text{et} \quad V = \frac{1}{n(n-1)} \left[ (n-2) \sum_{i=1}^n X_i^2 + (n\bar{X})^2 \right].$$

1. Montrer que  $U$  et  $V$  sont des estimateurs sans biais de  $\theta$ .
  2. Calculer leur variance. (On a  $\mathbb{E} \left[ \left( \sum_{i=1}^n X_i^2 \right)^2 \right] = n(n+2)\theta^2$ ,  $\mathbb{E} \left[ \bar{X}^2 \sum_{i=1}^n X_i^2 \right] = \frac{n+2}{n} \theta^2$ ,  $\mathbb{E}(\bar{X}^4) = \frac{3}{n^2} \theta^2$ .)
  3. Soit  $T_a = aU + (1-a)V$  avec  $a \in \mathbb{R}$ . Montrer que  $T_a$  est un estimateur sans biais de  $\theta$  et donner la valeur de  $a$  qui minimise  $\text{var}(T_a)$ .
- 

### Exercice 12

L'organisateur d'une exposition picturale s'intéresse au rythme d'arrivée des groupes de visiteurs à partir des observations faites au cours des premières journées. Il constate que le temps séparant l'arrivée de deux groupes successifs peut être assimilé à une v.a. uniforme sur  $[0, \theta]$  et que les temps inter-arrivées sont indépendants. Pour l'organisation ultérieure des caisses réservées aux entrées des groupes, il souhaite estimer avec précision le paramètre  $\theta$ , ayant à sa disposition un échantillon  $(X_1, \dots, X_n)$  de  $X$ .

1. (a) Donner les valeurs de  $\mathbb{E}(X)$  et  $\text{var}(X)$ .  
(b) En déduire la valeur de  $\alpha$  telle que  $T_n = \alpha \hat{m}_n$  soit un estimateur sans biais du paramètre  $\theta$ , où 
$$\hat{m}_n = \frac{1}{n} \sum_{i=1}^n X_i.$$
  
(c) Montrer que  $T_n$  est un estimateur correct.
  2. On se propose maintenant d'étudier l'estimateur du maximum de vraisemblance  $U_n$  de  $\theta$ .  
(a) Exprimer  $U_n$  en fonction de  $X_1, \dots, X_n$ .  
(b) Déterminer la fonction de répartition  $F_{U_n}$  ainsi que la densité  $f_{U_n}$  de  $U_n$ , puis calculer  $\mathbb{E}(U_n)$  et  $\text{var}(U_n)$ .  
(c) Déterminer  $\beta_n$  tel que  $V_n = \beta_n U_n$  soit un estimateur sans biais de  $\theta$ .  
(d) Montrer que  $V_n$  est correct.
  3. (a) Comparer les estimateurs  $T_n$  et  $V_n$ .  
(b) Calculer les valeurs numériques de  $T_n$  et  $V_n$  observées pour  $n = 75$ ,  $\sum_{i=1}^n x_i = 28$  h et  $\max(x_1, \dots, x_n) = 0.71$  h.
- 

### Exercice 13

Soit  $X_1, \dots, X_n$  des v.a. indépendantes issues d'une loi uniforme sur  $[k\theta, (k+1)\theta]$  où  $k > 0$  est connu et  $\theta > 0$  est inconnu. On note  $X_{(1)} = \min(X_1, \dots, X_n)$  et  $X_{(n)} = \max(X_1, \dots, X_n)$ .

1. (a) Trouver l'estimateur du maximum de vraisemblance de  $\theta$  que l'on notera  $U$ .  
(b) Déterminer la fonction de répartition  $F_U$  ainsi que la densité  $f_U$  de  $U$ .  
(c) Calculer  $\mathbb{E}(U)$  et  $\text{var}(U)$ .  
(d) En déduire le risque  $\mathbb{E}[(U - \theta)^2]$ .
2. Soit  $V = \frac{1}{k} X_{(1)}$  un autre estimateur de  $\theta$ .  
(a) Déterminer la fonction de répartition  $F_V$  ainsi que la densité  $f_V$  de  $V$ .  
(b) Calculer  $\mathbb{E}(V)$  et  $\text{var}(V)$ .  
(c) En déduire le risque  $\mathbb{E}[(V - \theta)^2]$ .
3. Soit  $T_a = aU + (1-a)V$  avec  $a \in \mathbb{R}$  une famille d'estimateurs de  $\theta$ . Trouver la valeur de  $a$  qui minimise le risque  $\mathbb{E}[(T_a - \theta)^2]$ . On donne  $\mathbb{E}[X_{(1)}X_{(n)}] = \left[ k(k+1) + \frac{1}{n+2} \right] \frac{\theta^2}{k(k+1)}$ .

### Exercice 14

Prouver le résultat suivant :

Il existe presque-sûrement au plus un estimateur d'un paramètre  $\theta$  sans biais et de variance minimale.

(Indication : si  $\hat{\theta}_1$  et  $\hat{\theta}_2$  sont deux tel estimateurs, introduire  $\hat{\theta}_3 = \frac{1}{2}(\hat{\theta}_1 + \hat{\theta}_2)$ . Calculer  $\mathbb{E}(\hat{\theta}_3)$  et  $\text{var}(\hat{\theta}_3)$ , puis remarquer que l'on doit nécessairement avoir  $\text{var}(\hat{\theta}_3) \geq V$  où  $V = \text{var}(\hat{\theta}_1) = \text{var}(\hat{\theta}_2)$  est la variance minimale. Conclure.)

---

### Exercice 15 (Statistiques exhaustives)

Soit  $X$  une v.a. continue (resp. discrète) de densité  $x \mapsto f_X(x; \theta)$  (resp. de loi  $x \mapsto p_X(x; \theta) = \mathbb{P}(X = x)$ ) et  $(X_1, \dots, X_n)$  un échantillon de  $X$ . On introduit la vraisemblance de  $(X_1, \dots, X_n)$  :  $L(x_1, \dots, x_n; \theta) = f_X(x_1; \theta) \dots f_X(x_n; \theta)$  (resp.  $p_X(x_1; \theta) \dots p_X(x_n; \theta)$ ).

On dit qu'une statistique de  $(X_1, \dots, X_n)$ ,  $T = \varphi(X_1, \dots, X_n)$ , de densité  $t \mapsto f_T(t; \theta)$  (resp. de loi discrète  $t \mapsto p_T(t; \theta) = \mathbb{P}(T = t)$ ) est exhaustive pour  $\theta$  s'il existe une fonction  $h$  indépendante de  $\theta$  telle que :

$$L(x_1, \dots, x_n; \theta) = f_T(t; \theta)h(x_1, \dots, x_n) \quad (\text{resp. } p_T(t; \theta)h(x_1, \dots, x_n))$$

où  $t = \varphi(x_1, \dots, x_n)$ . La densité conditionnelle de  $(X_2, \dots, X_n)$  sachant  $T = t$  est alors donnée par

$$f_{(X_2, \dots, X_n) | T=t}(x_2, \dots, x_n) = \frac{h(x_1, \dots, x_n)}{\frac{\partial \varphi}{\partial x_1}(x_1, \dots, x_n)}$$

expression indépendante de  $\theta$ . Cette remarque signifie, qu'une fois  $T$  connue, l'échantillon n'apporte plus d'information concernant  $\theta$  et donc que  $T$  porte toute l'information disponible sur  $\theta$ .

1. Vérifier que  $T$  est exhaustive pour  $\theta$  dans chacun des cas suivants :

(a)  $X$  suit la loi de Poisson de paramètre  $\theta$  et  $T = \sum_{i=1}^n X_i$ ;

(b)  $X$  suit la loi exponentielle de paramètre  $\theta$  et  $T = \sum_{i=1}^n X_i$ ;

(c)  $X$  suit la loi normale de paramètres  $(\theta, \sigma^2)$  où  $\sigma$  est connu et  $T = \sum_{i=1}^n X_i$ ;

(d)  $X$  suit la loi normale de paramètres  $(m, \theta)$  où  $m$  est connu et  $T = \sum_{i=1}^n (X_i - m)^2$ ;

(e)  $X$  suit la loi uniforme sur  $[0, \theta]$  et  $T = \max(X_1, \dots, X_n)$ .

2. Démontrer le résultat suivant (théorème de Darmois) :

On suppose les hypothèses suivantes vérifiées :

le support de  $f_X$ ,  $S_\theta = \{x \in \mathbb{R} : f_X(x; \theta) > 0\}$ , est indépendant de  $\theta$ ;

la densité  $f_X$  est de la forme  $f_X(x; \theta) = \exp[a(x)\alpha(\theta) + b(x) + \beta(\theta)]$ ;

la fonction  $x_1 \mapsto \sum_{i=1}^n a(x_i)$  est une bijection de classe  $C^1$  pour tout  $(x_2, \dots, x_n)$ .

Dans ces conditions, la statistique  $T = \sum_{i=1}^n a(X_i)$  est exhaustive.

Retrouver les résultats précédents (excepté le dernier) à partir de ce théorème.

---

### Exercice 16 (Information de Fisher, inégalité de Cramér-Rao)

Soit  $X$  une v.a. de densité  $x \mapsto f_X(x; \theta)$ . On introduit l'information de Fisher fournie par  $X$  sur le paramètre  $\theta$  :

$$I_X(\theta) = \mathbb{E} \left[ \left( \frac{\partial}{\partial \theta} \ln f_X(X; \theta) \right)^2 \right] = \int_{-\infty}^{+\infty} \left[ \frac{\partial}{\partial \theta} \ln f_X(x; \theta) \right]^2 f_X(x; \theta) dx.$$

Si le support de  $f_X$ ,  $S_\theta = \{x \in \mathbb{R} : f_X(x; \theta) > 0\}$ , est indépendant de  $\theta$ , alors sous certaines conditions de régularité pour  $f$ , on a :

$$I_X(\theta) = \text{var} \left[ \frac{\partial}{\partial \theta} \ln f_X(X; \theta) \right] = -\mathbb{E} \left[ \frac{\partial^2}{\partial \theta^2} \ln f_X(X; \theta) \right].$$

(Dans le cas où  $X$  est une v.a. discrète, remplacer  $f_X$  par  $x \mapsto p_X(x; \theta) = \mathbb{P}(X = x)$  ainsi que l'intégrale par une somme.)

1. Calculer  $I_X$  dans les cas suivants :

- (a)  $X$  suit la loi de Poisson de paramètre  $\theta$  ;
- (b)  $X$  suit la loi exponentielle de paramètre  $\theta$  ;
- (c)  $X$  suit la loi normale de paramètres  $(\theta, \sigma^2)$  où  $\sigma$  est connu ;
- (d)  $X$  suit la loi normale de paramètres  $(m, \theta^2)$  où  $m$  est connu ;
- (e)  $X$  suit la loi uniforme sur  $[0, \theta]$ .

2. On suppose maintenant que  $S_\theta$  est indépendant de  $\theta$ . Soit  $(X_1, \dots, X_n)$  un échantillon de  $X$ , et  $I_n = I_{(X_1, \dots, X_n)}$ .

- (a) Montrer que  $I_n = nI_X$ .
- (b) Montrer que pour toute statistique exhaustive  $T$  de  $(X_1, \dots, X_n)$ , on a  $I_T = I_n$ .

3. On a le résultat suivant (inégalité de Cramér-Rao) :

*On suppose que  $S_\theta$  est indépendant de  $\theta$ . Soit  $T = \phi(X_1, \dots, X_n)$  une statistique de  $X_1, \dots, X_n$ . Alors,*

$$\text{var } T \geq \frac{\left[ \frac{\partial}{\partial \theta} \mathbb{E}(T) \right]^2}{I_n(\theta)}.$$

*En particulier, si  $T$  est un estimateur sans biais de  $\theta$ , on a  $\text{var } T \geq \frac{1}{I_n(\theta)}$ , ce qui donne une borne supérieure pour la précision d'un tel estimateur.*

Tester l'efficacité de  $T$  dans les cas suivants :

- (a)  $X$  suit la loi de Poisson de paramètre  $\theta$  et  $T = \frac{1}{n} \sum_{i=1}^n X_i$  ;
- (b)  $X$  suit la loi exponentielle de paramètre  $\theta$  et  $T = (n-1) / \sum_{i=1}^n X_i$  ;
- (c)  $X$  suit la loi normale de paramètres  $(\theta, \sigma^2)$  où  $\sigma$  est connu et  $T = \frac{1}{n} \sum_{i=1}^n X_i$  ;
- (d)  $X$  suit la loi normale de paramètres  $(m, \theta)$  où  $m$  est connu et  $T = \frac{1}{n} \sum_{i=1}^n (X_i - m)^2$  ;
- (e)  $X$  suit la loi uniforme sur  $[0, \theta]$  et  $T = \frac{n+1}{n} \max(X_1, \dots, X_n)$ .