

Feuille d'exercices

Convergences et approximations ; statistiques inférentielles

Exercice 1

Edhec 2006

Si Φ est la fonction de répartition de la loi normale centrée réduite, on donne les valeurs approchées suivantes : $\Phi(1,96) \cong 0,975$ et $\Phi(0,90) \cong 0,816$.

1. a. Montrer que pour tout entier $k \geq 3$, l'intégrale $A_k = \int_1^{+\infty} \frac{\ln t}{t^k} dt$ est convergente.

b. À l'aide d'une intégration par parties, montrer que $A_k = \frac{1}{(k-1)^2}$.

2. a. Montrer que la fonction f définie sur \mathbb{R} par : $f(t) = \frac{16 \ln t}{t^5}$ si $t > 1$, $f(t) = 0$ si $t \leq 1$, définit une densité de variable aléatoire X .

b. Montrer que la variable aléatoire X admet une espérance, et la calculer.

c. Montrer que la variable aléatoire X admet une variance, et la calculer.

3. On considère une suite (X_n) de variables aléatoires indépendantes suivant la loi définie par la densité f définie au 2° a. Pour tout entier $n \geq 1$, on définit la variable aléatoire Y_n par $Y_n = \frac{X_1 + \dots + X_n}{n}$.

a. Quelle est la limite de la suite de variables aléatoires (Y_n) quand n tend vers $+\infty$?

b. Calculer une valeur approchée de la probabilité de l'évènement $\left(\left| Y_{68} - \frac{16}{9} \right| \leq 0,1 \right)$.

c. Évaluer un entier n_0 tel que pour tout entier $n \geq n_0$ on ait $P\left(\left| Y_n - \frac{16}{9} \right| \leq 0,1 \right) \geq 0,95$.

Exercice 2

Edhec 2012

On considère une variable aléatoire de Bernoulli X de paramètre p ($0 < p < 1$) inconnu et un

n -échantillon (X_1, \dots, X_n) de la loi de X . On pose $S_n = \sum_{i=1}^n X_i$ et $F_n = \frac{S_n}{n}$.

On souhaite estimer p en donnant un intervalle de confiance.

1) a) Donner la loi de S_n ainsi que son espérance et sa variance.

b) Montrer que F_n est un estimateur sans biais de p . Donner son risque quadratique.

2) On note Φ la fonction de répartition de la loi normale centrée réduite et on note t le réel tel que $\Phi(t) = 0,975$.

a) Justifier que, pour n assez grand, on peut approcher la loi de $\frac{S_n - np}{\sqrt{np(1-p)}}$ par la loi normale centrée réduite.

b) En utilisant cette approximation, montrer que : $P(-t \leq \frac{S_n - np}{\sqrt{np(1-p)}} \leq t) = 2\Phi(t) - 1$.

c) En déduire : $P(F_n - \frac{t\sqrt{p(1-p)}}{\sqrt{n}} \leq p \leq F_n + \frac{t\sqrt{p(1-p)}}{\sqrt{n}}) = 0,95$.

3) a) Montrer que : $p(1-p) \leq \frac{1}{4}$.

b) On admet que $t = 1,96$. Établir que : $P\left(F_n - \frac{0,98}{\sqrt{n}} \leq p \leq F_n + \frac{0,98}{\sqrt{n}}\right) \geq 0,95$.

4) Lors d'élections, deux sondages sont effectués, chacun par un institut, et indépendamment l'un de l'autre.

Le premier sondage est effectué auprès de 625 personnes : 325 d'entre elles déclarent vouloir voter pour le président sortant.

Le deuxième sondage est effectué auprès de 400 autres personnes : 180 d'entre elles déclarent vouloir voter pour le président sortant.

On note p la proportion théorique d'électeurs souhaitant reconduire le président sortant.

a) Utiliser la première partie pour déterminer un intervalle de confiance pour p au risque 5% en utilisant le premier sondage.

b) Déterminer de même un intervalle de confiance pour p au risque 5% en utilisant le deuxième sondage.

Exercice 3

Edhec 2013

Dans cet exercice, n désigne un entier naturel supérieur ou égal à 2.

On considère une variable aléatoire réelle X dont une densité de probabilité est donnée par :

$$f(x) = \begin{cases} e^{-(x-\theta)} & \text{si } x \geq \theta \\ 0 & \text{si } x < \theta \end{cases}, \theta \text{ désignant un réel strictement positif inconnu.}$$

Soit (X_1, \dots, X_n) un n -échantillon de la loi de X . On pose :

$$Y_n = \frac{1}{n} \sum_{i=1}^n X_i \text{ et } Z_n = \text{Inf}(X_1, X_2, \dots, X_n).$$

1) a) Déterminer la fonction de répartition F de X puis reconnaître la loi de $X - \theta$. En déduire l'espérance et la variance de X .

b) Montrer que $T_{1,n} = Y_n - 1$ est un estimateur sans biais de θ .

2) a) Déterminer la fonction de répartition de Z_n puis reconnaître la loi de $Z_n - \theta$.

b) Montrer que $T_{2,n} = Z_n - \frac{1}{n}$ est un estimateur sans biais de θ .

3) Calculer les variances de $T_{1,n}$ et $T_{2,n}$. Que peut-on en conclure ?

4) On veut construire un estimateur T_n sans biais et convergent de θ , comme combinaison linéaire de $T_{1,n}$ et $T_{2,n}$. On souhaite, de plus, que la variance de T_n soit la plus petite possible.

On note ρ le coefficient de corrélation linéaire de $T_{1,n}$ et $T_{2,n}$, supposé constant, et on pose :

$$T_n = a_{1,n}T_{1,n} + a_{2,n}T_{2,n}$$

- Donner la valeur de $a_{1,n} + a_{2,n}$.
- Écrire la variance de T_n comme une fonction f de $a_{1,n}$, puis déterminer $a_{1,n}$ et $a_{2,n}$ (en fonction de n et de ρ) afin que cette fonction soit minimale.
- Vérifier que la variance de T_n est inférieure ou égale à celles de $T_{1,n}$ et $T_{2,n}$.

Exercice 4

Edhec 2014

Dans cet exercice, n et N désignent deux entiers naturels supérieurs ou égaux à 2.

1) a) Montrer que, pour tout entier naturel k de $\llbracket 0, N-1 \rrbracket$, on a :

$$\frac{1}{N} \left(\frac{k}{N} \right)^n \leq \int_{\frac{k}{N}}^{\frac{k+1}{N}} t^n dt \leq \frac{1}{N} \left(\frac{k+1}{N} \right)^n$$

b) En déduire que :

$$\frac{1}{N} \sum_{k=0}^{N-1} \left(\frac{k}{N} \right)^n \leq \frac{1}{n+1}$$

2) Soit Y une variable aléatoire à valeurs dans $\llbracket 1, N \rrbracket$.

a) Justifier que, pour tout k de $\llbracket 1, N \rrbracket$, on a : $P(Y = k) = P(Y > k-1) - P(Y > k)$.

En déduire que :

$$E(Y) = \sum_{k=0}^{N-1} P(Y > k)$$

b) Montrer de même que :

$$E(Y(Y-1)) = 2 \sum_{k=0}^{N-1} k P(Y > k)$$

Une urne contient des boules numérotées de 1 à N . On effectue n tirages au hasard d'une boule avec remise à chaque fois de la boule tirée et on note X_i le numéro de la boule obtenue au $i^{\text{ème}}$ tirage. On admet que les variables X_1, \dots, X_n sont mutuellement indépendantes.

On suppose N inconnu et on cherche à l'estimer grâce à deux estimateurs différents

3) On considère la variable aléatoire M_n , égale à la moyenne empirique de l'échantillon (X_1, \dots, X_n) . On a donc : $M_n = \frac{1}{n} \sum_{i=1}^n X_i$.

a) Calculer l'espérance de M_n et en déduire un estimateur sans biais M_n' de N .

b) Calculer le risque quadratique de M_n' . Quelle est sa limite lorsque n tend vers $+\infty$?

4) On considère maintenant la variable aléatoire Z_n définie par : $Z_n = \text{Max}(X_1, \dots, X_n)$.

a) On note F_n la fonction de répartition de Z_n .

Donner la valeur de $F_n(k)$ pour tout k de $Z_n(\Omega)$.

b) Utiliser les questions précédentes pour en déduire que : $E(Z_n) \geq N - \frac{N}{n+1}$. Établir alors que Z_n est un estimateur asymptotiquement sans biais de N .

c) Déterminer $E(Z_n(Z_n - 1))$ et vérifier que : $\lim_{n \rightarrow +\infty} E(Z_n(Z_n - 1)) = N(N - 1)$.

En déduire que le risque quadratique de Z_n tend vers 0 lorsque n tend vers $+\infty$.

Exercice 5

Soit $a \in \mathbb{R}_+^*$, X une VAR définie sur un probabilisé $(\Omega, \mathcal{T}, \mathbb{P})$, suivant la loi uniforme

$\mathcal{U}_{[0, a]}$, et (X_1, \dots, X_n) un n -échantillon *i.i.d.* de la loi de X sur $(\Omega, \mathcal{T}, \mathbb{P})$.

On cherche à construire un « bon » estimateur de a . On note \overline{X}_n la moyenne empirique.

Q1_ Soit $T_n = 2 \overline{X}_n$. Montrer que T_n est sans biais et déterminer son risque quadratique.

Q2_ Soit $S_n = \max(X_1, \dots, X_n)$. Déterminer les fonctions de répartition de X et de S_n .

En déduire une densité de S_n , puis son biais et son risque quadratique.

Q3_ Soit $U_n = \frac{n+1}{n} S_n$. Déterminer son biais et son risque quadratique.

Q4_ Quel est le meilleur de ces trois estimateurs de a pour de grandes valeurs de n ?

Exercice 6

Soit $a \in]0, 1[$, et X une VAR définie sur $(\Omega, \mathcal{T}, \mathbb{P})$, à valeurs dans $[0, 1]$.

On suppose que la loi conditionnelle de X sachant l'événement $[X \leq a]$ est la loi uniforme

sur $[0, a]$, et que sa loi conditionnelle sachant $[X > a]$ est la loi uniforme sur $[a, 1]$.

On suppose de plus que $\mathbb{P}([X \leq a]) = \frac{1}{2}$.

Q1_ Montrer que X est une VAR à densité.

Déterminer une densité de X , son espérance et sa variance.

On cherche maintenant à estimer le paramètre inconnu a .

Q2_ Soit (X_1, \dots, X_n) un n – échantillon *i.i.d.* de la loi de X . On pose :

$$M_n = \frac{1}{n} \sum_{k=1}^n X_k.$$

a_ Déterminer l'espérance $\mathbb{E}(M_n)$, et la variance $\mathbb{V}(M_n)$.

b_ En déduire un estimateur sans biais T_n de a .

c_ La suite d'estimateurs $(T_n)_{n \in \mathbb{N}^*}$ est-elle consistante ?

Q3_ Donner une majoration de $\mathbb{V}(T_n)$ quand $a \in]0, 1[$.

Pour n et α donnés, préciser, en utilisant l'inégalité de Bienaymé – Cebycev, les valeurs de ε pour lesquelles $[T_n - \varepsilon, T_n + \varepsilon]$ est un intervalle de confiance I_1 pour a au seuil de risque α .

Q4_ Quelle est la limite en loi de la suite $\left(\frac{T_n - a}{\sqrt{\mathbb{V}(T_n)}} \right)_{n \in \mathbb{N}^*}$?

On suppose n suffisamment grand pour identifier la loi de $\frac{T_n - a}{\sqrt{\mathbb{V}(T_n)}}$ à cette loi limite.

Q5_ En déduire un intervalle de confiance I_2 pour a au niveau de risque 5 % .

Q6_ Au seuil de risque 5 % , comparer les longueurs des intervalles de confiance I_1 et I_2 .

Exercice 7

A l'issue d'un scrutin de type uninominal permettant à plusieurs centaines de milliers d'électeurs de départager deux candidats A et B d'importance comparable, on se propose,

avant le dépouillement, de procéder à une estimation de la proportion p des voix obtenues par le candidat A . A cet effet, on répète n fois ($n \in \mathbb{N}^*$) l'expérience suivante : on retire au hasard un bulletin des urnes ; on note s'il est ou non en faveur de A et on le remet dans les urnes. On note X_n la VAR indiquant le nombre de suffrages favorables à A parmi les n bulletins dépouillés. Le quotient $Y_n = \frac{X_n}{n}$ indique donc la proportion des suffrages favorables à A parmi ces n bulletins. On pose enfin : $u_n = \mathbb{P} \left(|Y_n - p| > 0,01 \right)$. Soit $\varepsilon \in]0, 1[$. On veut déterminer le nombre n de bulletins qu'il suffit de dépouiller pour avoir $u_n \leq \varepsilon$, *i.e.* pour connaître p à 0,01 près avec un risque d'erreur inférieur à ε .

Q1_ Déterminer la loi de X_n . Calculer les espérances et les variances de X_n et Y_n .

Q2_ Montrer que : $\forall n \in \mathbb{N}^*, \mathbb{V}(X_n) \leq \frac{n}{4}$.

Q3_ Soit $\alpha \in \mathbb{R}_+$. En appliquant à Y_n l'inégalité de Bienaymé – Cebycev, donner une majoration de $\mathbb{P} \left(|Y_n - p| > \alpha \right)$. En déduire que $u_n \leq \frac{2500}{n}$.

Q4_ Comment suffit-il de choisir n pour que $u_n \leq \varepsilon$? Examiner le cas où $\varepsilon = 0,1$.

Q5_ En approchant X_n par une loi normale (*on justifiera l'approximation*), montrer que

$$u_n = 2 \left(1 - \Phi \left(\frac{0,01 \sqrt{n}}{\sqrt{p(1-p)}} \right) \right), \text{ puis que } u_n \leq 2 \left(1 - \Phi \left(0,02 \sqrt{n} \right) \right).$$

Q6_ Justifier l'existence de la réciproque Φ^{-1} de Φ . Préciser son domaine de définition.

Déduire de ce qui précède que $u_n \leq \varepsilon$ dès que $n \geq 2500 \left(\Phi^{-1} \left(1 - \frac{\varepsilon}{2} \right) \right)^2$.

Examiner le cas où $\varepsilon = 0,1$.

Q7_ Comparer la qualité de l'approximation fournie par l'inégalité de Bienaymé – Cebycev à celle fournie par l'approximation en loi (*i.e.* par le théorème central limite).

Exercice 8

Soit $(X_n)_{n \in \mathbb{N}^*}$ une suite de VAR définies sur un même univers probabilisé $(\Omega, \mathcal{T}, \mathbb{P})$.

On suppose les $(X_n)_{n \in \mathbb{N}^*}$ mutuellement indépendantes, à valeurs dans $\mathbb{N} \cup \{-1\}$, et

de loi donnée par : $\forall n \in \mathbb{N}^*, \forall k \in X_n(\Omega), \mathbb{P}(X_n = k) = \frac{1}{e(k+1)!}$.

Q1_ Déterminer, pour tout entier $n \in \mathbb{N}^*$, la loi de $S_n = \sum_{k=1}^n X_k$.

hint Pour $k \in \mathbb{N}^*$, on introduira la VAR $Y_k = X_k + 1$.

Q2_ A l'aide de la formule de Taylor avec reste intégrale, établir que :

$$\forall n \in \mathbb{N}^*, \mathbb{P}(S_n \leq 0) = 1 - \frac{1}{n!} \int_0^n t^n e^{-t} dt.$$

Q3_ A l'aide du théorème central limite, montrer que : $\lim_{n \rightarrow +\infty} \frac{1}{n!} \int_0^n t^n e^{-t} dt = \frac{1}{2}$.

Exercice 9

Q1_ Montrer que $f : t \mapsto \frac{1}{a t^{1+\frac{1}{a}}} \mathbf{1}_{[1, +\infty[}(t)$ est une densité de probabilité ($a > 0$).

Soit X une VAR à densité définie sur un espace probabilisé $(\Omega, \mathcal{T}, \mathbb{P})$, de densité f .

Q2_ Donner une CNS sur a pour que X admette une espérance. Calculer alors $\mathbb{E}(X)$.

Q3_ On suppose que X admet une espérance. On pose : $\forall n \in \mathbb{N}^*, \overline{X}_n = \frac{1}{n} \sum_{k=1}^n X_k$,
où (X_1, \dots, X_n) est n -échantillon *i.i.d.* de la loi de X .

Quelle fonction de a est-elle estimée sans biais par \overline{X} ?

Q4_ Déterminer la loi de probabilité de la VAR Y définie par : $Y = \frac{1}{a} \ln(X)$.

Q5_ Si (x_1, \dots, x_n) est une réalisation de l'échantillon, on appelle **vraisemblance** de cette réalisation la fonction $\Lambda : a \mapsto L(x_1, \dots, x_n, a) = \prod_{i=1}^n f(x_i)$.

a_ Calculer en fonction de x_1, \dots, x_n la valeur $t(x_1, \dots, x_n)$ de a qui maximise Λ .

L'estimateur $a = t(X_1, \dots, X_n)$ est dit **estimateur du maximum de vraisemblance**.

b_ Montrer que a suit une loi Gamma. En déduire son espérance et sa variance.

c_ Calculer la dérivée seconde de $\ln \Lambda$, et donner sa valeur pour $a = t(x_1, \dots, x_n)$.

d_ Montrer que a est un estimateur sans biais et convergent de a .