

## Sujet ESSEC

Sujet HEC 2005 E2

L'objet du problème est d'étudier quelques propriétés d'un estimateur du paramètre  $p$  d'une loi géométrique.

### Partie I. Formule du binôme négatif.

Pour tout couple  $(n, r)$  d'entiers naturels tels que  $1 \leq r \leq n - 1$ , on rappelle la formule du triangle de Pascal :

$$\binom{n}{r} = \binom{n-1}{r-1} + \binom{n-1}{r}.$$

1. Montrer que, pour tout entier  $r \in \llbracket 1, n \rrbracket$ , on a :  $\binom{n}{r} = \sum_{k=r}^n \binom{k-1}{r-1}$ .

2. Soit  $(n, r)$  un couple d'entiers naturels, tels que  $1 \leq r \leq n$ .

Pour tout réel  $x \in ]0, 1[$ , on définit la fonction  $f_{r,n}$  par :  $f_{r,n}(x) = \sum_{k=r}^n \binom{k}{r} x^k$ .

(a) Montrer, pour tout réel  $x \in ]0, 1[$ , que :

$$(1-x)f_{r,n}(x) = xf_{r-1,n-1}(x) - \binom{n}{r}x^{n+1}.$$

(b) On suppose l'entier  $r$  fixé.

Montrer que, lorsque  $n$  tend vers  $+\infty$  :  $\binom{n}{r} \underset{n \rightarrow +\infty}{\sim} \frac{n^r}{r!}$ .

3. Soit  $x$  un réel fixé de  $]0, 1[$  et soit  $r$  un entier naturel fixé.

On veut établir l'existence de la limite de  $f_{r,n}(x)$  lorsque  $n$  tend vers  $+\infty$ , et déterminer la valeur de cette limite.

(a) Justifier l'existence et donner la valeur de  $\lim_{n \rightarrow +\infty} f_{0,n}(x)$  et  $\lim_{n \rightarrow +\infty} f_{1,n}(x)$ .

(b) Soit  $r$  un entier naturel non nul. On suppose que, pour tout réel  $x \in ]0, 1[$ , on a :

$$\lim_{n \rightarrow +\infty} f_{r-1,n}(x) = \frac{x^{r-1}}{(1-x)^r}.$$

Montrer que, pour tout réel  $x \in ]0, 1[$ ,  $\lim_{n \rightarrow +\infty} f_{r,n}(x) = \frac{x^r}{(1-x)^{r+1}}$ .

(c) Conclure que, pour tout  $r \in \mathbb{N}$ ,  $\sum_{k=r}^{+\infty} \binom{k}{r} x^k = \frac{x^r}{(1-x)^{r+1}}$ .

### Partie II. Développement en série de $\ln(1-x)$ .

Soit  $x$  un réel de  $]0, 1[$ .

4. Montrer, pour tout entier  $n \in \mathbb{N}^*$ , l'égalité :  $\int_0^x \frac{1-t^n}{1-t} dt = \sum_{k=1}^n \frac{x^k}{k}$ .

5. À l'aide d'un encadrement simple, montrer que :  $\lim_{n \rightarrow +\infty} \int_0^x \frac{t^n}{1-t} dt = 0$ .
6. En déduire la convergence de la série de terme général  $\frac{x^k}{k}$  ainsi que l'égalité :  $\sum_{k=1}^{+\infty} \frac{x^k}{k} = -\ln(1-x)$ .

### Partie III. Loi binomiale négative.

Toutes les variables aléatoires qui interviennent dans cette partie sont définies sur un même espace probabilisé  $(\Omega, \mathcal{A}, P)$ .

Soit  $p$  un réel de  $]0, 1[$  et  $q = 1 - p$ . On considère une variable aléatoire  $X$  à valeurs dans  $\mathbb{N}^*$ , qui suit la loi géométrique de paramètre  $p$ . On rappelle que pour tout entier  $k \in \mathbb{N}^*$ ,  $P(X = k) = pq^{k-1}$ .

7. Calculer la valeur de l'espérance  $E(X)$  et de la variance  $V(X)$  de la variable aléatoire  $X$ .
8. On considère la variable aléatoire  $Y$  définie par  $Y = \frac{1}{X}$ .
- Déterminer l'ensemble des valeurs prises par  $Y$  ainsi que la loi de probabilité de  $Y$ .
  - Montrer que  $Y$  admet une espérance  $E(Y)$ , que l'on calculera en fonction de  $p$  et  $q$ .
  - Pour tout entier  $i \geq 2$ , établir l'existence du moment  $E(Y^i)$  d'ordre  $i$  de  $Y$ .
9. Soient  $X_1$  et  $X_2$  deux variables aléatoires indépendantes, à valeurs dans  $\mathbb{N}^*$ , qui suivent la même loi géométrique de paramètre  $p$ . On pose :  $S_1 = X_1$ ,  $S_2 = X_1 + X_2$  et  $Y_2 = \frac{2}{S_2}$ .
- Déterminer la loi de probabilité de chacune des variables aléatoires  $S_2$  et  $Y_2$ .
  - Établir l'existence de l'espérance  $E(Y_2)$  de la variable aléatoire  $Y_2$ .
  - Calculer cette espérance en fonction de  $p$  et  $q$ .
10. On considère une suite  $(X_n)_{n \in \mathbb{N}^*}$  de variables aléatoires à valeurs dans  $\mathbb{N}^*$ , indépendantes et de même loi géométrique de paramètre  $p$ . Pour tout entier  $n \in \mathbb{N}^*$ , on pose :  $S_n = \sum_{k=1}^n X_k$ .
- Calculer l'espérance  $E(S_n)$  et la variance  $V(S_n)$  de la variable aléatoire  $S_n$ .
  - Montrer que la loi de probabilité de la variable aléatoire  $S_n$  est donnée, pour tout entier  $s \in \mathbb{N}^*$  par :
    - si  $s < n$ ,  $P(S_n = s) = 0$ ,
    - si  $s \geq n$ ,  $P(S_n = s) = \binom{s-1}{n-1} p^n q^{s-n}$ .
11. Pour tout entier  $n \in \mathbb{N}^*$ , on pose :  $Y_n = \frac{n}{S_n}$ .
- Préciser l'ensemble des valeurs prises par la variable aléatoire  $Y_n$  ainsi que la loi de probabilité de  $Y_n$ .
  - Soit  $t$  un réel quelconque de  $[0, 1[$ .  
Montrer que, pour tout  $m \in \mathbb{Z}$ , la série  $\sum_{s \geq 1} s^m t^s$  est convergente.  
En déduire l'existence des moments d'ordre 1 et 2 de la variable aléatoire  $Y_n$ .

## Partie IV. Une estimation ponctuelle du paramètre $p$ .

Soit  $p$  un réel de  $]0, 1[$  et  $q = 1 - p$ .

Dans cette partie, on considère une variable aléatoire réelle  $X$  à valeurs dans  $\mathbb{N}^*$ , qui suit une loi géométrique de paramètre  $p$  inconnu.

Pour tout entier naturel non nul  $n$ , on considère un  $n$ -échantillon  $(X_1, X_2, \dots, X_n)$  de variables aléatoires à valeurs dans  $\mathbb{N}^*$  indépendantes et de même loi que  $X$ .

Les variables aléatoires  $X, X_1, X_2, \dots, X_n$  sont définies sur un même espace probabilisé  $(\Omega, \mathcal{A}, P)$ .

On pose  $\bar{X}_n = \frac{S_n}{n} = \frac{1}{Y_n}$ .

12. Montrer que  $\bar{X}_n$  est un estimateur sans biais pour le paramètre  $\frac{1}{p}$  (c'est-à-dire tel que  $E(\bar{X}_n) = \frac{1}{p}$ ).

Quel est la variance de  $\bar{X}_n$  ?

13. Pour tout entier  $n \in \mathbb{N}^*$ , on note  $h_n$  et  $\varphi_n$  les applications définies sur  $[0, 1[$  à valeurs dans  $\mathbb{R}$  telles que :

$$\forall t \in [0, 1[, \quad h_n(t) = \sum_{s=n}^{+\infty} \frac{1}{s} \binom{s-1}{n-1} t^s \quad \text{et} \quad \varphi_n(t) = \sum_{s=n}^{+\infty} \frac{1}{s^2} \binom{s-1}{n-1} t^s.$$

On admet dans toute la suite du problème, que  $h_n$  est de classe  $C^1$  et que pour tout réel  $t \in [0, 1[$ , la dérivée  $h'_n$  de  $h_n$  vérifie :  $h'_n(t) = \sum_{s=n}^{+\infty} \binom{s-1}{n-1} t^{s-1}$ .

On admet également que la fonction  $\varphi_n$  est dérivable sur  $]0, 1[$ , de dérivée  $\varphi'_n$ , et que pour tout  $t \in ]0, 1[$ ,  $\varphi'_n(t) = \frac{1}{t} h_n(t)$ .

- (a) Montrer que :  $E(Y_n) = n \left(\frac{p}{q}\right)^n h_n(q)$ .

Établir que, pour tout  $q \in [0, 1[$ , on a :  $h_n(q) = \int_0^q \frac{t^{n-1}}{(1-t)^n} dt$ .

- (b) À l'aide du changement de variable  $y = \frac{t}{1-t}$  (que l'on justifiera), montrer que pour tout  $q \in [0, 1[$ ,  $h_n(q) = \int_0^{q/p} \frac{y^{n-1}}{1+y} dy$ .

En déduire, en utilisant une intégration par parties, que l'on peut écrire pour tout  $q \in [0, 1[$ ,

$$h_n(q) = \frac{q^n}{n p^{n-1}} + \frac{1}{n} \int_0^{q/p} \frac{y^n}{(1+y)^2} dy.$$

14. Pour tout entier  $n \in \mathbb{N}^*$ , soit  $b_n$  la fonction définie sur  $]0, 1[$  à valeurs réelles qui, à tout réel  $p \in ]0, 1[$  associe  $b_n(p) = E(Y_n) - p$  ( $b_n$  représente le biais de  $Y_n$  pour estimer  $p$ ).

- (a) Montrer que :  $b_n(p) = \left(\frac{p}{q}\right)^n \int_0^{q/p} \frac{y^n}{(1+y)^2} dy$ .

- (b) En déduire que la suite  $(b_n(p))_{n \in \mathbb{N}^*}$  est convergente et préciser sa limite.

Calculer  $\lim_{n \rightarrow +\infty} E(Y_n)$ .

- (c) À l'aide d'une intégration par parties, montrer l'égalité :

$$b_n(p) = \frac{pq}{n} + o\left(\frac{1}{n}\right).$$

## Partie V. Un intervalle de confiance du paramètre $p$ .

Dans cette partie, le contexte est identique à la partie précédente

15. (a) En utilisant le résultat de la question 14.(c), montrer que, lorsque  $n$  tend vers  $+\infty$  :

$$(E(Y_n))^2 = p^2 + \frac{2p^2 q}{n} + o\left(\frac{1}{n}\right).$$

- (b) On admet que, lorsque  $n$  tend vers  $+\infty$  :  $E(Y_n^2) = p^2 + \frac{3p^2 q}{n} + o\left(\frac{1}{n}\right)$ .

Établir que, lorsque  $n$  tend vers  $+\infty$ ,  $V(Y_n) \sim \frac{p^2 q}{n}$ .

16. Pour tout entier  $n \in \mathbb{N}^*$ , on pose :  $T_n = \frac{Y_n - p}{\sqrt{\frac{p^2 q}{n}}}$ .

On admet que la suite de variables aléatoires  $(T_n)_{n \in \mathbb{N}^*}$  converge en loi vers une variable aléatoire  $T$  qui suit la loi normale centrée réduite.

Cette question a pour objectif la détermination, pour  $n$  assez grand, d'un intervalle de confiance du paramètre inconnu  $p$  au risque  $\alpha$  donné. Autrement dit, il s'agit de trouver des variables aléatoires  $I_n$  et  $J_n$ , fonctions de  $Y_n$ , telles que  $P(I_n \leq p \leq J_n) = 1 - \alpha$ .

- (a) Soit  $a_\alpha$  le réel strictement positif tel que  $P(T \geq a_\alpha) = \frac{\alpha}{2}$ .

Pour  $n$  assez grand, on peut considérer que :  $P(-a_\alpha \leq T_n \leq a_\alpha) = 1 - \alpha$ .

En déduire l'égalité :

$$P\left(Y_n - a_\alpha p \sqrt{\frac{q}{n}} \leq p \leq Y_n + a_\alpha p \sqrt{\frac{q}{n}}\right) = 1 - \alpha.$$

- (b) Montrer que l'on peut choisir les "statistiques"  $I_n$  et  $J_n$  de la façon suivante :

$$I_n = Y_n - \frac{2a_\alpha}{3\sqrt{3}} \frac{1}{\sqrt{n}} \quad \text{et} \quad J_n = Y_n + \frac{2a_\alpha}{3\sqrt{3}} \frac{1}{\sqrt{n}}.$$

- (c) On suppose que  $n = 900$ . Un échantillon observé  $x_1, x_2, \dots, x_{900}$  de réalisations des variables aléatoires  $X_1, X_2, \dots, X_{900}$  a fourni le résultat suivant :  $\bar{x}_{900} = \frac{1}{900} \sum_{i=1}^{900} x_i = 4$ .

Calculer la réalisation  $y_{900}$  de la variable aléatoire  $Y_{900}$ .

On se donne un niveau de risque  $\alpha = 0,05$ . Le nombre  $a_{0,05}$  est à peu près égal à 2.

Sachant que  $\frac{2}{45\sqrt{3}} \approx 0,026$ , trouver un intervalle de confiance réalisé qui contienne le paramètre inconnu  $p$  avec un niveau de confiance au moins égal à 0,95.