

DS 12 (B)

Devoir surveillé du Samedi 29 Mars

La calculatrice est interdite. Durée : 4h

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 (Ω, \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 (Ω, \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 φ_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 φ_n est dérivable sur $]0, 1[$, de dérivée φ'_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

$$q \in [0, 1[, \quad h_n(q) = \int_0^{q/p} \frac{y^{n-1}}{1+y} dy.$$

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 α 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_α 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.