

Projet de sujet de Probabilités 2011

Concours d'entrée à l'ÉNS Cachan 3^e année

Les différentes parties du problème ne sont pas indépendantes

Notations

On note $\mathcal{N}(0, 1)$ la loi normale de moyenne 0 et de variance 1. Si X est une variable aléatoire, on note $\mathbb{E}(X)$ son espérance et $\text{Var}(X)$ sa variance. On rappelle que X est une variable aléatoire de Poisson de paramètre λ lorsque

$$\mathbb{P}(X = n) = e^{-\lambda} \frac{\lambda^n}{n!} \quad \text{pour tout } n \in \mathbb{N}.$$

On dit que X suit la loi de Bernoulli de paramètre $p \in [0, 1]$ lorsque

$$p = \mathbb{P}(X = 1) = 1 - \mathbb{P}(X = 0).$$

Toutes les variables aléatoires sont définies sur un espace de probabilité commun $(\Omega, \mathcal{A}, \mathbb{P})$. Si μ est une loi de probabilité sur \mathbb{N} , alors pour tout $k \in \mathbb{N}$, on note $\mu(k)$ la probabilité affectée par μ au singleton $\{k\}$. On note enfin $\mathbb{E}(X | Y)$ l'espérance conditionnelle de X sachant Y .

Si E est un ensemble fini, on note $|E|$ son cardinal. Pour tout $n \in \mathbb{N}^*$, on note \mathcal{B}_n l'ensemble des partitions de $\{1, \dots, n\}$. Pour tout $B \in \mathcal{B}_n$ et tout $b \subset \{1, \dots, n\}$ non vide, on note $b \in B$ lorsque b fait partie de la partition B , et on dit que b est un *bloc* de B . La partition B est constituée de $|B|$ blocs. Pour tous $b, b' \in B$ avec $b \neq b'$, on a $b \cap b' = \emptyset$. On a également $|b| > 0$ pour tout $b \in B$ et

$$\{1, \dots, n\} = \bigcup_{b \in B} b.$$

On note enfin B^{b+} l'élément de \mathcal{B}_{n+1} obtenu à partir de B en remplaçant le bloc $b \in B$ par $b \cup \{n+1\}$. Notons que $|B^{b+}| = |B|$.

Un modèle de croissance

Le but de ce sujet est d'étudier l'évolution au cours du temps d'une population répartie en groupes. À l'instant $n \in \mathbb{N}^*$, la population comporte n individus, numérotés de 1 à n , et les groupes qu'ils constituent sont modélisés par une variable aléatoire B_n à valeurs dans \mathcal{B}_n . Chaque bloc correspond à un groupe.

On pose $B_1 = \{\{1\}\}$. À l'instant $n+1$, un nouvel individu rejoint la population et décide **soit** de rejoindre l'un des $|B_n|$ groupes déjà constitués avec une probabilité

proportionnelle au nombre de membres du groupe (grégarisme), **soit** de créer un nouveau groupe (individualisme).

On modélise par $\theta/(n+\theta)$ la probabilité qu'à l'individu $n+1$ de créer un nouveau groupe, où $\theta > 0$ est un paramètre réel fixé et inconnu (identique pour tous). La population ne fait que croître, et comporte n individus au temps n . Le numéro d'un individu correspond exactement à son temps d'arrivée dans la population. Les individus ne meurent pas et ne quittent pas leur groupe. La suite $(B_{k+1})_{k \in \mathbb{N}}$ est une chaîne de Markov d'espace d'états $\cup_{n=1}^{\infty} \mathcal{B}_n$.

Rappels

On dit qu'une suite de variables aléatoires $(X_k)_{k \in \mathbb{N}}$ à valeurs dans un ensemble au plus dénombrable E est une *chaîne de Markov* lorsque pour tout $k \in \mathbb{N}$ et tous x_0, \dots, x_k, x_{k+1} dans E , on a

$$\mathbb{P}(X_{k+1} = x_{k+1} \mid X_0 = x_0, \dots, X_k = x_k) = \mathbb{P}(X_{k+1} = x_{k+1} \mid X_k = x_k).$$

La loi de X_0 est appelée *loi initiale* et l'ensemble E *espace d'états*. On dit que la chaîne est *homogène* lorsque pour tout $k \in \mathbb{N}$ et tous x, y dans E , la quantité $\mathbb{P}(X_{k+1} = y \mid X_k = x)$ ne dépend pas de k .

Partie I

Cette partie est consacrée à une première étude de la chaîne de Markov $(B_{k+1})_{k \in \mathbb{N}}$.

1. Montrer que pour tout $n \in \mathbb{N}^*$ et tout $B \in \mathcal{B}_n$,

$$\sum_{b \in B} |b| = n$$

2. Montrer que pour tout $n \in \mathbb{N}^*$ et tout $B \in \mathcal{B}_n$ et $B' \in \mathcal{B}_{n+1}$,

$$\mathbb{P}(B_{n+1} = B' \mid B_n = B) = \begin{cases} \frac{|b|}{\theta + n} & \text{si } B' = B^{b+} \text{ pour un } b \in B \\ \frac{\theta}{\theta + n} & \text{si } B' = B \cup \{n+1\} \\ 0 & \text{sinon} \end{cases}$$

3. La chaîne de Markov $(B_{k+1})_{k \in \mathbb{N}}$ est-elle homogène? Préciser sa loi initiale
4. Préciser l'évolution de la population dans le cas extrême où $\theta = 0$
5. Préciser l'évolution de la population dans le cas extrême où $\theta = +\infty$

Partie II

Cette partie est consacrée à la loi de la partition aléatoire B_n ainsi qu'à ses blocs.

1. Établir par récurrence que pour tout $n \geq 1$ et tout $B \in \mathcal{B}_n$,

$$\mathbb{P}(B_n = B) = \frac{\theta^{|B|}}{(\theta + 0)(\theta + 1) \cdots (\theta + n - 1)} \prod_{b \in B} (|b| - 1)!$$

2. Soit B une partition de $\{1, \dots, n\}$ en blocs $b_1, \dots, b_{|B|}$. Pour tout $1 \leq i \leq n$, soit a_i le nombre de blocs de taille i de B . Montrer que

$$a_1 + 2a_2 + \cdots + na_n = n$$

3. Avec les notations de la question précédente, établir que le nombre de partitions $B \in \mathcal{B}_n$ à nombres a_1, \dots, a_n prescrits vaut

$$\frac{n!}{\prod_{i=1}^n (i!)^{a_i} a_i!}$$

4. Pour tout $n \geq 1$ et tout $1 \leq i \leq n$, soit $C_{n,i}$ le nombre de blocs de taille i de B_n , de sorte que $n = C_{n,1} + 2C_{n,2} + \cdots + nC_{n,n}$. Dédurre des questions précédentes que pour tous entiers $0 \leq a_1, \dots, a_n \leq n$ tels que $a_1 + 2a_2 + \cdots + na_n = n$,

$$\mathbb{P}(C_{n,1} = a_1, \dots, C_{n,n} = a_n) = \frac{n!}{(\theta + 0)(\theta + 1) \cdots (\theta + n - 1)} \prod_{i=1}^n \frac{1}{a_i!} \left(\frac{\theta}{i}\right)^{a_i}$$

5. Pour tout $n \geq 1$, on pose $C_n = (C_{n,1}, \dots, C_{n,n})$ où $C_{n,i}$ est comme précédemment. Montrer que la suite de vecteurs aléatoires $(C_{k+1})_{k \in \mathbb{N}}$ est une chaîne de Markov non homogène dont on précisera l'espace d'états.

Partie III

Cette partie est consacrée à l'étude du nombre de blocs $|B_n|$ de B_n .

1. Montrer que la suite $(|B_{k+1}|)_{k \in \mathbb{N}}$ est une chaîne de Markov non homogène
2. Montrer que pour tout $n \geq 1$, $|B_n| = \xi_1 + \cdots + \xi_n$ où ξ_1, \dots, ξ_n sont des variables aléatoires indépendantes de lois de Bernoulli vérifiant pour tout $1 \leq k \leq n$

$$\mathbb{P}(\xi_k = 1) = 1 - \mathbb{P}(\xi_k = 0) = \frac{\theta}{\theta + k - 1}$$

3. Montrer que pour tout $n \geq 1$, on a

$$\mathbb{E}(|B_n|) = \sum_{k=0}^{n-1} \frac{\theta}{\theta + k} \quad \text{et} \quad \text{Var}(|B_n|) = \sum_{k=1}^{n-1} \frac{\theta k}{(\theta + k)^2}$$

La suite $(|B_{k+1}|)_{k \in \mathbb{N}}$ constitue-t-elle une martingale ?

4. Montrer que $\mathbb{E}(|B_n|) \sim \theta \ln(n)$ et $\text{Var}(|B_n|) \sim \theta \ln(n)$ quand $n \rightarrow +\infty$
5. Établir que

$$\frac{|B_n|}{\ln(n)} \xrightarrow[n \rightarrow \infty]{\mathbb{P}} \theta \quad (\star)$$

où $\xrightarrow{\mathbb{P}}$ désigne la convergence en probabilité.

Partie IV

On étudie dans cette partie le nombre de blocs de taille n de B_n , noté $C_{n,n}$.

1. Montrer que $C_{n,n}$ vaut 0 ou 1 et que $C_{n,n} = 1$ si et seulement si $|B_n| = 1$
2. Établir que

$$\mathbb{P}(C_{n,n} = 1) = \prod_{k=1}^{n-1} \frac{k}{\theta + k}$$

3. En déduire que $\lim_{n \rightarrow \infty} \mathbb{P}(C_{n,n} = 1) = 0$
4. En déduire que presque-sûrement, $C_{n,n} = 0$ à partir d'un certain rang sur n .

Partie V

Dans cette partie, on étudie le nombre de blocs de taille 1 de B_n , noté $C_{n,1}$.

1. Montrer que $(C_{k+1,1})_{k \in \mathbb{N}}$ est une chaîne de Markov d'espace d'état \mathbb{N} et que pour tout $n \geq 1$, tout $0 \leq a \leq n$ et tout $0 \leq a' \leq n+1$, on a

$$\mathbb{P}(C_{n+1,1} = a' \mid C_{n,1} = a) = \begin{cases} \frac{\theta}{\theta + n} & \text{si } a' = a + 1 \\ \frac{a}{\theta + n} & \text{si } a' = a - 1 \\ 1 - \frac{\theta}{\theta + n} - \frac{a}{\theta + n} & \text{si } a' = a \\ 0 & \text{sinon} \end{cases}$$

2. En déduire que pour tout $n \geq 1$,

$$\mathbb{E}(C_{n+1,1} \mid C_{n,1} = a) = \frac{a(\theta + n - 1) + \theta}{\theta + n}$$

3. En déduire que pour tout $n \geq 1$,

$$\mathbb{E}(C_{n,1}) = \frac{n\theta}{n + \theta - 1}$$

4. Si X et Y sont des variables aléatoires à valeurs dans \mathbb{N} avec X de carré intégrable, on définit $\text{Var}(X \mid Y) = \mathbb{E}(X^2 \mid Y) - \mathbb{E}(X \mid Y)^2$. Montrer que $\text{Var}(X \mid Y) \geq 0$ et que

$$\text{Var}(X) = \mathbb{E}(\text{Var}(X \mid Y)) + \text{Var}(\mathbb{E}(X \mid Y))$$

5. En déduire que pour tout $n \geq 1$,

$$\text{Var}(C_{n,1}) = \frac{n(n-1)(n-2+2\theta)\theta}{(n+\theta-2)(n+\theta-1)^2}$$

Partie VI

Cette partie est consacrée à l'étude d'une distance sur l'ensemble des lois de probabilités sur \mathbb{N} . Si μ et ν sont des lois de probabilité sur \mathbb{N} , on définit

$$d_V(\mu, \nu) = \sup_{A \subset \mathbb{N}} |\mu(A) - \nu(A)|.$$

Si X et Y sont des variables aléatoires sur \mathbb{N} de lois respectives μ et ν , on pose par commodité $d_V(X, Y) = d_V(\mu, \nu)$.

1. Montrer que d_V est une distance sur l'ensemble des lois de probabilité sur \mathbb{N}
2. Établir que si μ et ν sont des lois de probabilité sur \mathbb{N} alors

$$2d_V(\mu, \nu) = \sum_{k \in \mathbb{N}} |\mu(k) - \nu(k)|$$

3. Établir que si μ et ν sont des lois de probabilité sur \mathbb{N} alors

$$2d_V(\mu, \nu) = \sup_{f \in \mathcal{F}} \left| \int f d\mu - \int f d\nu \right|$$

où \mathcal{F} désigne l'ensemble des fonctions définies sur \mathbb{N} et à valeurs dans $[-1, 1]$

4. Soit $(X_n)_{n \in \mathbb{N}}$ une suite de variables aléatoires sur \mathbb{N} et μ une loi de probabilité sur \mathbb{N} . Pour tout $n \in \mathbb{N}$, on note μ_n la loi de X_n . Montrer que les propriétés suivantes sont équivalentes :

- (a) X_n converge en loi vers μ
- (b) $\lim_{n \rightarrow \infty} \mu_n(k) = \mu(k)$ pour tout $k \in \mathbb{N}$
- (c) $\lim_{n \rightarrow \infty} d_V(\mu_n, \mu) = 0$

5. Montrer que si ξ est une variable aléatoire de Bernoulli de paramètre $p \in [0, 1]$ et P une variable aléatoire de Poisson de même moyenne alors

$$d_V(\xi, P) \leq p^2$$

6. Montrer que si $(X_k)_{1 \leq k \leq n}$ et $(Y_k)_{1 \leq k \leq n}$ sont des suites de variables aléatoires indépendantes à valeurs dans \mathbb{N} alors

$$d_V(X_1 + \cdots + X_n, Y_1 + \cdots + Y_n) \leq \sum_{k=1}^n d_V(X_k, Y_k)$$

7. En déduire que si ξ_1, \dots, ξ_n sont des variables aléatoires indépendantes de loi de Bernoulli de paramètres respectifs p_1, \dots, p_n et si P_n est une variable aléatoire de Poisson de moyenne $p_1 + \cdots + p_n$ alors

$$d_V(\xi_1 + \cdots + \xi_n, P_n) \leq \sum_{k=1}^n p_k^2 \quad (**)$$

Partie VII

Cette partie est consacrée à l'étude des fluctuations asymptotiques pour la convergence en probabilité de $|B_n|/\ln(n)$ vers θ obtenue en (\star) . Elle met en œuvre la distance d_V étudiée précédemment. On admettra qu'on peut remplacer, dans le membre de droite de $(\star\star)$, la quantité $\sum_{k=1}^n p_k^2$ par la quantité plus petite

$$(1 - \exp(-p_1 - \dots - p_n)) \frac{p_1^2 + \dots + p_n^2}{p_1 + \dots + p_n}.$$

D'autre part, afin d'alléger les notations, on pose

$$\lambda_n = \mathbb{E}(|B_n|) \quad \text{et} \quad \sigma_n^2 = \text{Var}(|B_n|)$$

et on note P_n une variable aléatoire de Poisson de paramètre λ_n .

1. Établir que

$$\lim_{n \rightarrow \infty} d_V(|B_n|, P_n) = 0$$

2. Établir que pour toute fonction $f : \mathbb{R} \rightarrow \mathbb{R}$ continue et bornée,

$$\left| \mathbb{E} \left(f \left(\frac{|B_n| - \lambda_n}{\sigma_n} \right) \right) - \mathbb{E} \left(f \left(\frac{P_n - \lambda_n}{\sigma_n} \right) \right) \right| \leq 2 (\sup |f|) d_V(|B_n|, P_n)$$

3. En utilisant $\lim_{n \rightarrow \infty} \lambda_n / \sigma_n^2 = 1$, établir que

$$\frac{P_n - \lambda_n}{\sigma_n} \xrightarrow[n \rightarrow \infty]{\text{loi}} \mathcal{N}(0, 1)$$

4. Établir que

$$\frac{|B_n| - \lambda_n}{\sigma_n} \xrightarrow[n \rightarrow \infty]{\text{loi}} \mathcal{N}(0, 1)$$

5. Établir que si $(X_n)_{n \in \mathbb{N}}$ est une suite de variables aléatoires convergeant en loi vers une loi de probabilité μ et si $(a_n)_{n \in \mathbb{N}}$ et $(b_n)_{n \in \mathbb{N}}$ sont deux suites de réels convergeant vers a et b respectivement alors $(a_n X_n + b_n)_{n \in \mathbb{N}}$ converge en loi vers la loi de $aX + b$ où X suit la loi μ

6. En déduire que

$$\frac{|B_n| - \theta \ln(n)}{\sqrt{\theta \ln(n)}} \xrightarrow[n \rightarrow \infty]{\text{loi}} \mathcal{N}(0, 1)$$

7. Soit $\alpha \in]0, 1[$. Déduire de la question précédente un intervalle de confiance asymptotique pour θ au niveau de confiance $1 - \alpha$, en fonction d'un quantile de la loi $\mathcal{N}(0, 1)$.

– **Fin de l'épreuve** –