

## TD 08 – Convergence de variables aléatoires

---

**Exercice 1.***Second théorème de Borel-Cantelli*

L'objectif de cet exercice est de montrer le second théorème de Borel-Cantelli. Il donne une réciproque du théorème de Borel-Cantelli vu en cours, dans le cas où les événements sont indépendants. Soit  $(A_n)_{n \in \mathbb{N}}$  une suite d'événements *indépendants* de probabilité  $p_n$ . On suppose que la somme  $\sum_n p_n$  diverge. L'objectif de cet exercice est de montrer qu'alors, presque sûrement, une infinité d'événements  $A_n$  se réalisent.

1. Exprimer l'événement "une infinité d'événements  $A_n$  se réalisent" en terme d'unions et d'intersections des événements  $A_n$ .
2. Soit  $B_{k,\ell}$  l'événement  $\bigcap_{k \leq n \leq \ell} \overline{A_n}$ . Montrer que pour tout  $k$  fixé,  $\lim_{\ell \rightarrow \infty} \mathbf{P}\{B_{k,\ell}\} = 0$ . *Indice : on pourra utiliser l'inégalité  $1 + x \leq e^x$  pour tout  $x \in \mathbb{R}$ .*
3. On note  $B_k = \bigcap_{n \geq k} \overline{A_n}$ . En déduire que  $\mathbf{P}\{\bigcup_k B_k\} = 0$ .
4. Conclure que  $\mathbf{P}\{\text{"une infinité d'événements } A_n \text{ se réalisent"}\} = 1$ .
5. *Application.* Soit  $(X_n)_{n \in \mathbb{N}}$  une suite de variables de Bernoulli indépendantes de paramètre  $\mathbf{P}\{X_n = 1\} = p_n = 1/n$ . Montrer que presque sûrement la suite  $X_n$  contient un nombre infini de '1', mais seulement un nombre fini de '11'.

**Exercice 2.***Conditions de convergence*

Soit  $X_n$  une suite infinie de variables de Bernoulli indépendantes de paramètres  $1 - p_n$ , avec  $0 \leq p_n \leq 1/2$  (i.e.  $\mathbf{P}\{X_n = 1\} = 1 - p_n$  et  $\mathbf{P}\{X_n = 0\} = p_n$ ).

1. Donner une condition nécessaire et suffisante pour que la suite  $X_n$  converge en distribution.
2. Donner une condition nécessaire et suffisante pour que la suite  $X_n$  converge en probabilité.
3. Donner une condition nécessaire et suffisante pour que la suite  $X_n$  converge presque sûrement.

**Exercice 3.***Calcul de limite*

L'objectif de cet exercice est de montrer l'égalité suivante :

$$\lim_n \exp(-n) \sum_{k=0}^n \frac{n^k}{k!} = \frac{1}{2}$$

On considère  $(X_n)_{n \geq 1}$  une suite de variables aléatoires indépendantes de loi de Poisson de paramètre

1. On note  $S_n = \sum_{k=1}^n X_k$ .

1. Montrer que pour tout  $n \geq 1$ ,  $\mathbf{P}\{S_n \leq n\} = \exp(-n) \sum_{k=0}^n \frac{n^k}{k!}$ .
2. Conclure en utilisant le Théorème Central Limite.

**Exercice 4.**

Théorème de Mycielski

Recall that the *chromatic number*  $\chi(G)$  is the smallest number of colors needed to color the vertices of  $G$  such that any two adjacent vertices have different colors. Clearly, graphs with large cliques have a high chromatic number, but the opposite is not true. The goal of this exercise is to prove Mycielski's theorem, which states that for any integer  $k \geq 2$ , there exists a graph  $G$  such that  $G$  contains no triangles and  $\chi(G) \geq k$ .

1. Fix  $0 < \varepsilon < \frac{1}{3}$  and let  $G$  be a random graph on  $n$  vertices where each edge appears independently with probability  $p = n^{\varepsilon-1}$ . Show that when  $n$  tends to infinity, the probability that  $G$  has more than  $n/2$  triangles tends to 0.
2. Let  $\alpha(G)$  be the size of the largest *independent set* of  $G$  (A set of vertices  $X$  is *independent* if there is no edge between any two vertices of  $X$  in  $G$ ). Show that  $\chi(G) \geq n/\alpha(G)$ .
3. Let  $a = 3n^{1-\varepsilon} \ln n$ . Show that when  $n$  tends to infinity,

$$\mathbb{P}(\alpha(G) < a) \rightarrow 1.$$

Deduce that there exists  $n$  and  $G$  of size  $n$  such that  $G$  has at most  $n/2$  triangles and  $\alpha(G) < a$ .

4. Let  $G$  be such a graph. Let  $G'$  be a graph obtained from  $G$  by removing a minimum number of vertices so that  $G'$  does not contain any triangle. Show that

$$\chi(G') > \frac{n^\varepsilon}{6 \ln n}$$

and conclude the proof of Mycielski's Theorem.

**Exercice 5.**

Filtres de Bloom

[Disclaimer : l'exercice parle de choses vues en cours que vous n'avez en fait pas vues. Mais ça n'a aucune importance.]

Rappelez-vous les tables de hachage vues en cours et reprenons l'exemple de l'interdiction des mots de passe trop simples. On dispose d'un ensemble  $F$  de mots de passe interdits, et l'on veut stocker  $F$  de manière intelligente pour pouvoir, à chaque fois qu'un utilisateur choisit un nouveau mot de passe, vérifier si ce mot de passe est admissible. Dans le premier exemple du cours (*Chain Hashing*), on cherche à minimiser le temps d'une requête pour savoir si  $x \in F$ . Dans le deuxième exemple du cours (*Bit Strings/Fingerprints*), on cherche à minimiser l'espace de stockage de  $F$ , quitte à ce que certaines requêtes produisent un faux positif (i.e. répond que  $x \in F$  alors que  $x \notin F$ ).

On va s'intéresser ici à un troisième exemple appelé *filtre de Bloom* qui permet d'obtenir un meilleur compromis entre espace de stockage et taux de faux positifs. Un filtre de Bloom est un tableau  $A$  à  $n$  cases, initialement remplies à 0. On dispose de  $k$  fonctions de hachage indépendantes  $h_1, \dots, h_k$  à valeurs dans  $\{1, \dots, n\}$ . On suppose comme à l'accoutumée pour les fonctions de hachage, que chaque  $h_i$  associe à n'importe quel élément de l'univers un nombre choisi uniformément au hasard dans  $\{1, \dots, n\}$ . Soit  $F = \{f_1, \dots, f_m\}$  l'ensemble des  $m$  mots interdits. L'étape de pré-processing est la suivante : pour chaque  $f \in F$ , et pour chaque  $i \leq k$ , on met  $A[h_i(f)]$  à 1 (si cette case était déjà à 1, on ne la touche pas). Supposons maintenant que l'on ait une requête du type  $s \in F$ . On répond de la manière suivante : si tous les  $A[h_i(s)]$  valent 1 pour  $1 \leq i \leq k$ , alors on répond  $s \in F$ . Sinon, on répond  $s \notin F$ . On vérifie facilement qu'il est impossible d'obtenir un faux-négatif.

1. Soit  $X$  le nombre de cases de  $A$  dans lesquelles il reste un 0 après le pré-processing. Quelle est l'espérance de  $X/n$  ?
2. Soit  $p = e^{-km/n}$ . Dans cette question, on suppose pour simplifier que  $X$  est égal à  $pn$ . Quelle est la probabilité  $P$  d'un faux positif ? Comment choisir  $k$  pour minimiser  $P$ , et qu'obtient-on comme valeur de  $P$  ?
3. Justifier pourquoi il a semblé raisonnable de supposer, par simplification, que  $X = pn$ . Plus exactement, utiliser l'approximation de Poisson pour borner  $\mathbf{P}\{|X - np| \geq \varepsilon n\}$ , et commenter.