

## TD 06 – Graphes aléatoires et partiel de l'an dernier (corrigé)

**Exercice 1.** $K_4$ 

Soit  $G$  un graphe aléatoire de loi  $G_{n,p}$ . L'objectif de cet exercice est de montrer qu'il y a un seuil  $p_0 := n^{-2/3}$  tel que pour  $p = o(p_0)$ , le graphe  $G$  n'a pas de clique de taille 4 avec bonne probabilité, et que pour  $p = \omega(p_0)$ , le graphe  $G$  a au moins une clique de taille 4 avec bonne probabilité.

**Rappels / définitions :**

- Un graphe aléatoire  $G$  suit la loi  $G_{n,p}$  s'il a  $n$  sommets et que chaque arête est présente dans  $G$  avec probabilité  $p$ ;
- une clique de taille 4 est un ensemble de 4 sommets tous reliés deux à deux par des arêtes;
- $p = o(p_0)$  signifie  $\frac{p}{p_0} \rightarrow 0$  quand  $n \rightarrow +\infty$ ;
- $p = \omega(p_0)$  signifie  $\frac{p_0}{p} \rightarrow 0$  quand  $n \rightarrow +\infty$ .

1. Pour  $p$  quelconque, calculer  $\mathbf{E}[X]$ , où  $X$  est le nombre de cliques du graphe  $G$ .

$\text{☞}$  On a  $\binom{n}{4}$  ensembles possibles de 4 sommets. Pour chacun de ces ensembles, on définit  $X_i$  qui vaut 1 si c'est une clique et zéro sinon. On a  $X = \sum_i X_i$ . Et  $\mathbf{E}[X_i] = \mathbf{P}\{X_i = 1\} = p^6$ . D'où

$$\mathbf{E}[X] = \binom{n}{4} p^6.$$

2. Soit  $p = o(p_0)$ , montrer que  $\Pr(X \neq 0) \rightarrow 0$  quand  $n$  tend vers l'infini.

$\text{☞}$  On a  $\mathbf{E}[X] \leq n^4 p^6 = o(n^{4-6 \times 2/3}) = o(1)$ . Donc  $\mathbf{E}[X]$  tend vers zéro quand  $n$  tend vers l'infini. Comme  $X$  est une valeur entière, positives ou nulle, on conclut que  $\mathbf{P}\{X \neq 0\} = \Pr(X \geq 1) \leq \mathbf{E}[X]$  tend aussi vers 0.

On suppose maintenant  $p = \omega(p_0)$ , et on veut montrer que  $\mathbf{P}\{X = 0\} \rightarrow 0$  quand  $n$  tend vers l'infini.

3. Montrer que  $\mathbf{P}\{X = 0\} \leq \frac{\mathbf{Var}[X]}{\mathbf{E}[X]^2}$ . Il suffira donc de montrer que  $\frac{\mathbf{Var}[X]}{\mathbf{E}[X]^2} \rightarrow 0$ .

$\text{☞}$  On utilise l'inégalité de Chebychev

$$\Pr(X = 0) \leq \mathbf{P}\{|X - \mathbf{E}[X]| \geq \mathbf{E}[X]\} \leq \frac{\mathbf{Var}[X]}{\mathbf{E}[X]^2}.$$

4. Soit  $X_i$  des variables aléatoires à valeur dans  $0,1$  (et non indépendantes). Montrer que

$$\mathbf{Var}\left[\sum_i X_i\right] \leq \mathbf{E}\left[\sum_i X_i\right] + \sum_{i \neq j} \mathbf{E}\left[(X_i - \mathbf{E}[X_i])(X_j - \mathbf{E}[X_j])\right].$$

$\text{☞}$  On a

$$\begin{aligned} \mathbf{Var}\left[\sum_i X_i\right] &= \mathbf{E}\left[\left(\sum_i (X_i - \mathbf{E}[X_i])\right)^2\right] \\ &= \mathbf{E}\left[\sum_{i,j} (X_i - \mathbf{E}[X_i]) \cdot (X_j - \mathbf{E}[X_j])\right] \\ &= \sum_i \mathbf{E}\left[(X_i - \mathbf{E}[X_i])^2\right] + \sum_{i \neq j} \mathbf{E}\left[(X_i - \mathbf{E}[X_i])(X_j - \mathbf{E}[X_j])\right]. \end{aligned}$$

On observe ensuite que  $\mathbf{E}\left[(X_i - \mathbf{E}[X_i])^2\right] = \mathbf{E}[X_i^2] - \mathbf{E}[X_i]^2 \leq \mathbf{E}[X_i^2]$ . Mais comme  $X_i$  est à valeur dans  $0,1$ , on a  $\mathbf{E}[X_i^2] = \mathbf{E}[X_i]$ . D'où l'inégalité.

5. En déduire que  $\mathbf{Var}[X] = o(\mathbf{E}[X]^2)$  et conclure.

$\text{☞}$  On note  $C_i$  les ensembles de 4 sommets du graphe  $G$ , et on définit  $X_i$  la variable aléatoire qui vaut 1 si  $C_i$  forme une clique et 0 sinon. On a  $X = \sum_i X_i$  et d'après la question précédente  $\mathbf{Var}[X] \leq \mathbf{E}[X] + \sum_{i \neq j} \mathbf{E}\left[(X_i - \mathbf{E}[X_i])(X_j - \mathbf{E}[X_j])\right]$ . Fixons  $i \neq j$  et considérons  $\mathbf{E}\left[(X_i - \mathbf{E}[X_i])(X_j - \mathbf{E}[X_j])\right] = \mathbf{E}[X_i X_j] - \mathbf{E}[X_i] \mathbf{E}[X_j]$ . On a  $\mathbf{E}[X_i X_j] = \mathbf{P}\{C_i \text{ et } C_j \text{ sont des cliques}\} = p^k$ , où  $k$  est le nombre d'arêtes nécessaires pour que  $C_i$  et  $C_j$  soient des cliques. Ce nombre d'arêtes va dépendre du nombre de sommets communs entre  $C_i$  et  $C_j$ . On distingue donc les cas suivants

- Si  $|C_i \cap C_j| = 0$  ou  $|C_i \cap C_j| = 1$ , alors  $k = 12$  et  $\mathbf{E}\left[(X_i - \mathbf{E}[X_i])(X_j - \mathbf{E}[X_j])\right] = 0$ .

— Si  $|C_i \cap C_j| = 2$ , alors  $k = 11$  et  $\mathbb{E}[(X_i - \mathbb{E}[X_i])(X_j - \mathbb{E}[X_j])] = p^{11}(1-p)$ . Il y a  $\binom{n}{4} \cdot \binom{4}{2} \cdot \binom{n-4}{2}$  tels couples  $(C_i, C_j)$ .  
 — Si  $|C_i \cap C_j| = 3$ , alors  $k = 9$  et  $\mathbb{E}[(X_i - \mathbb{E}[X_i])(X_j - \mathbb{E}[X_j])] = p^9(1-p^3)$ . Il y a  $\binom{n}{4} \cdot \binom{4}{3} \cdot \binom{n-4}{1}$  tels couples  $(C_i, C_j)$ .  
 — Le cas  $|C_i \cap C_j| = 4$  est impossible car  $C_i \neq C_j$ .  
 On a donc  $\text{Var}[X] \leq \mathbb{E}[X] + \binom{n}{4} \cdot \binom{4}{2} \cdot \binom{n-4}{2} p^{11}(1-p) + \binom{n}{4} \cdot \binom{4}{3} \cdot \binom{n-4}{1} p^9(1-p^3)$ . Chacun des trois termes de cette somme est un  $o(\mathbb{E}[X]^2)$  (car  $p = \omega(p_0)$ ), d'où la réponse à la question. On conclut grâce aux questions précédentes que  $\Pr(X \neq 0) \rightarrow 0$  quand  $n$  tend vers l'infini.

### Exercice 2.

*Grphe Aléatoire Bipartite*

Soit  $0 < p < 1$  et  $n \in \mathbb{N}^*$ . On définit un graphe aléatoire non orienté  $H_{2n,p}$  de la manière suivante. On se donne une famille  $\{X_{i,j} : 1 \leq i \leq n, n+1 \leq j \leq 2n\}$  de v.a. i.i.d. de loi de Bernoulli de paramètre  $p$ . On pose alors  $H_{2n,p} = (V, E)$ , avec  $V = \{1, \dots, 2n\}$  et

$$E = \{(i, j) : X_{i,j} = 1\} \subset \{1, \dots, n\} \times \{n+1, \dots, 2n\}.$$

1. Quelle est la loi du nombre d'arêtes de  $H_{2n,p}$  ?

$\mathbb{E}$  Le nombre d'arêtes de  $H_{2n,p}$  suit la loi  $B(n^2, p)$ .

2. Quelle est l'espérance du nombre de sommets isolés de  $H_{2n,p}$  ?

$\mathbb{E}$  Soit  $N$  le nombre de sommets isolés. Si  $A_i$  est l'événement « le sommet  $i$  est isolé », on a par linéarité de l'espérance, on a  $\mathbb{E}[N] = \sum \mathbb{P}(A_i) = 2n(1-p)^n$ .

3. Dans cette question on pose  $p = c \log(n)/n$  pour un nombre réel  $c > 0$ .

1. Montrer que si  $c > 1$ , alors

$$\lim_{n \rightarrow \infty} \mathbb{P}(H_{2n,p} \text{ a un sommet isolé}) = 0.$$

2. Montrer que si  $c < 1$ , alors

$$\lim_{n \rightarrow \infty} \mathbb{P}(H_{2n,p} \text{ a un sommet isolé}) = 1.$$

$\mathbb{E}$

1. Si  $c > 1$ , on a  $\mathbb{E}[N] = 2n \exp(n \log(1 - \frac{c \log n}{n})) \rightarrow 0$  et donc  $\mathbb{P}(N \geq 1) \leq \mathbb{E}[N] \rightarrow 0$ .
2. Si  $c < 1$ , on calcule

$$\mathbb{E}[N^2] = \sum_{i,j=1}^{2n} \mathbb{P}(A_i \cap A_j) = 2n(1-p)^n + 2n(n-1)(1-p)^{2n} + 2n^2(1-p)^{2n-1}$$

d'où il vient que  $\mathbb{E}[N^2]/\mathbb{E}[N]^2$  tend vers 1. On utilise l'inégalité de Tchebychev pour conclure que

$$\mathbb{P}(N = 0) = \mathbb{P}(\mathbb{E}[N] - N \geq \mathbb{E}[N]) \leq \mathbb{P}(|N - \mathbb{E}[N]| \geq \mathbb{E}[N]) \leq \frac{\text{Var}[N]}{\mathbb{E}[N]^2} = \frac{\mathbb{E}[N^2]}{\mathbb{E}[N]^2} - 1 \rightarrow 0.$$

4. Dans cette question on pose  $p = 1/2$ . Montrer qu'il existe une constante  $C > 0$  telle que

$$\lim_{n \rightarrow \infty} \mathbb{P} \left( \text{tous les sommets de } H_{2n,p} \text{ ont un degré inférieur à } \frac{n}{2} + C\sqrt{n \log n} \right) = 1.$$

$\mathbb{E}$  Le degré  $d_i$  du sommet  $i$  suit la loi  $B(n, 1/2)$ . Par l'inégalité de Chernoff I, on a donc

$$\mathbb{P}(d_i \geq \frac{n}{2} + a) \leq \exp(-2a^2/n).$$

Ainsi, par la borne de l'union,

$$\mathbb{P}(\max_i d_i \geq \frac{n}{2} + a) \leq 2n \exp(-2a^2/n).$$

Cette quantité tend vers 0 si  $a = C\sqrt{n \log n}$  avec  $2C^2 > 1$ .

### Exercice 3.

*Clique Number*

Le clique number  $\omega(G)$  d'un graphe  $G$  est l'entier  $k$  maximal tel que  $G$  contient une clique de taille  $k$  (c'est-à-dire un ensemble de  $k$  sommets tous reliés deux à deux par des arêtes). Soit  $G$  un graphe aléatoire de loi  $G_{n,1/2}$  (i.e.  $G$  a  $n$  sommets et chaque arête de  $G$  est présente avec probabilité  $1/2$ ). L'objectif de cet exercice est de montrer que pour tout  $\varepsilon > 0$ ,

$$\lim_{n \rightarrow +\infty} \mathbf{P} \{ (2 - \varepsilon) \log n \leq \omega(G) \leq (2 + \varepsilon) \log n \} = 1.$$

Asymptotiquement,  $\omega(G)$  est donc de l'ordre de  $2 \log n$ .

Remarque : La méthode utilisée pour montrer ce résultat ressemble beaucoup à celle utilisée dans l'exercice K4.

1. Pour un entier  $k$  quelconque, on définit  $X_k$  la variable aléatoire comptant le nombre de cliques de taille  $k$  dans  $G$ . Calculer  $\mathbf{E}[X_k]$

☞ Une solution pour l'exercice peut être trouvée ici : [https://www.win.tue.nl/~nikhil/courses/2015/2W008/probabilistic\\_method-2.pdf](https://www.win.tue.nl/~nikhil/courses/2015/2W008/probabilistic_method-2.pdf), section 3.2.

2. Soit  $\varepsilon > 0$ . Montrer que  $\lim_{n \rightarrow +\infty} \mathbf{P}\{\omega(G) \geq (2 + \varepsilon) \log n\} = 0$  (pour simplifier, on pourra supposer que  $k = (2 + \varepsilon) \log n$  est un entier).
3. On considère maintenant  $k = (2 - \varepsilon) \log n$  (encore une fois, on le suppose entier). Montrer que  $\lim_{n \rightarrow +\infty} \mathbf{P}\{\omega(G) \leq (2 - \varepsilon) \log n\} = 0$ . *Indice : on pourra utiliser les questions 3 et 4 de l'exercice K4.*

#### Exercice 4.

*Estimer l'intersection avec un rectangle*

Let  $P \subset \mathbb{Z}^2$  of size  $n$ . Our objective is to be able to answer quickly queries of the form what is the fraction of points in  $P$  that are in the rectangle  $r = [a_1, b_1] \times [a_2, b_2]$ ? We write  $r[P] = \frac{|P \cap r|}{n}$  for this fraction. We consider a simple data structure to approximate  $r[P]$  efficiently for any query  $r$ . The data structure is just a random subset  $S \subset P$  of size  $m$ . On query  $r$ , the estimate for  $r[P]$  we output is  $\frac{|S \cap r|}{m}$ . The structure  $S$  defines an  $\varepsilon$ -approximation if for all queries  $r$ , we have  $|r[P] - \frac{|S \cap r|}{m}| \leq \varepsilon$ .

1. What  $m$  should we take to obtain an  $\varepsilon$ -approximation with probability  $1 - \delta$ ?

☞ On va prendre un sample  $S$  dont l'espérance de la taille est  $m$  (plutôt que taille exactement  $m$ ).

Pour  $p \in P$ , soit  $X_p$  une variable aléatoire de Bernoulli de paramètre  $m/n$ , et l'on définit  $S$  par la relation suivante : si  $X_p = 1$  alors  $p \in S$ , et si  $X_p = 0$  alors  $p \notin S$ . Fixons un rectangle  $r$  et soit  $X(r) = \sum_{p \in R} X_p = |S \cap R|$  de telle sorte que  $X(r)/m$  soit notre estimateur. Alors  $\mathbf{E}[X(r)] = \sum_{p \in R} \mathbf{P}\{p \in S\} = \sum_{p \in R} \mathbf{P}\{m/n\} = mr[P]$ . On peut donc appliquer Chernoff à  $X(r)$  car :

$$\mathbf{P}\{|X(r)/m - r[P]| \geq \varepsilon\} = \mathbf{P}\{|X(r) - mr[P]| \geq \varepsilon m\} = \mathbf{P}\{|X(r) - \mathbf{E}[X(r)]| \geq \varepsilon/r[P] \cdot \mathbf{E}[X(r)]\} \leq 2e^{-\frac{\varepsilon^2}{2+\varepsilon} \mathbf{E}[X(r)]}.$$

avec  $\varepsilon' = \varepsilon/r[P]$ , ce qui donne (en utilisant  $r[P] \leq 1$  pour la dernière inégalité) :

$$2e^{-\frac{\varepsilon^2}{2+\varepsilon} \mathbf{E}[X(r)]} \leq 2e^{-\frac{\varepsilon^2}{2r[P]+\varepsilon} m} \leq 2e^{-\frac{\varepsilon^2}{2+\varepsilon} m}.$$

Cette inégalité est vraie pour un rectangle  $r$  fixé, mais nous avons besoin d'une Union-Bound sur tous les rectangles. Or, il y a une infinité de rectangles possibles dans  $\mathbb{Z}^2$ , donc nous devons être un peu plus malin. Il faut remarquer que si  $r$  et  $r'$  sont des rectangles pour lesquels  $P \cap r = P \cap r'$ , alors  $r[P] = r'[P]$  et l'estimation sera la même, donc l'erreur sur l'un sera exactement la même que l'erreur sur l'autre. En d'autres termes, on veut trouver un certain nombre de rectangle  $r_1, r_2, \dots, r_k$  tels que pour tout rectangle  $r$  de  $\mathbb{Z}^2$ , il existe  $i$  tel que  $P \cap r = P \cap r_i$ . Ainsi,

$$\mathbf{P}\{\exists r \text{ s.t. } |r[P] - X(r)| \geq \varepsilon\} \leq \sum_{i=1}^k \mathbf{P}\{|r_i[P] - X(r_i)| \geq \varepsilon\} \leq k2e^{-\frac{\varepsilon^2}{2+\varepsilon} m}.$$

Montrons maintenant qu'on peut obtenir  $k = n^4$  : pour chaque 4-uplet des points de  $P$   $((x_1, y_1), (x_2, y_2), (x_3, y_3), (x_4, y_4))$ , on définit un rectangle  $r_i = [x_1, x_2] \times [y_3, y_4]$ . Cet ensemble de  $n^4$  rectangles a bien la propriété demandée car si  $r$  est un rectangle quelconque, on peut "pousser" sa limite verticale gauche le plus à droite possible jusqu'à rencontrer un point de  $P$ , auquel cas on s'arrête de "pousser". On fait de même pour les quatre côtés du rectangle (on "pousse" vers l'intérieur jusqu'à rencontrer un point de  $P$ ), et on tombe sur un  $r_i$  pour lequel  $r \cap P = r_i \cap P$ .

En résumé, nous voulons  $m$  tel que

$$n^4 2e^{-\frac{\varepsilon^2}{2+\varepsilon} m} \leq \delta,$$

ce qui est possible pour

$$m \geq \frac{2+\varepsilon}{\varepsilon^2} (4 \ln n + \ln 2 - \ln \delta) = \Omega(\ln n).$$

#### Exercice 5.

*Algorithme probabiliste pour calculer la médiane*


On étudie un algorithme probabiliste<sup>1</sup> pour déterminer la médiane d'un ensemble  $E = \{x_1, \dots, x_n\}$  de  $n$  nombres réels en temps  $O(n)$ . On rappelle que  $m$  est une médiane de  $E$  si au moins  $\lceil n/2 \rceil$  des éléments de  $E$  sont inférieurs ou égaux à  $m$ , et au moins  $\lfloor n/2 \rfloor$  des éléments de  $E$  sont supérieurs ou égaux à  $m$ . Pour simplifier on suppose  $n$  impair (ce qui fait que la médiane est unique) et on suppose aussi que les éléments de  $E$  sont tous distincts.

Voici comment fonctionne l'algorithme

1. Remarque : il existe un algorithme déterministe de même performance

- (a) Soit  $(Y_i)_{1 \leq i \leq n}$  une suite de v.a. i.i.d. de loi de Bernoulli de paramètre  $n^{-1/4}$ . On considère le sous-ensemble aléatoire de  $E$  défini par  $F = \{x_i : Y_i = 1\}$ . Si  $\text{card } F \leq \frac{2}{3}n^{3/4}$  ou  $\text{card } F \geq 2n^{3/4}$  on répond «ERREUR 1».
- (b) On trie  $F$  et on appelle  $d$  le  $\lfloor \frac{1}{2}n^{3/4} - \sqrt{n} \rfloor$ ème plus petit élément de  $F$ , et  $u$  le  $\lfloor \frac{1}{2}n^{3/4} - \sqrt{n} \rfloor$ ème plus grand élément de  $F$ .
- (c) On détermine le rang de  $d$  et de  $u$  dans  $E$  (l'élément minimal a rang 1, l'élément maximal a rang  $n$ ), que l'on note respectivement  $r_d$  et  $r_u$ . Si  $r_d > n/2$  ou  $r_u < n/2$  on répond «ERREUR 2».
- (d) On note  $G = \{x_i \in E : d < x_i < u\}$ . Si  $\text{card } G \geq 4n^{3/4}$  on répond «ERREUR 3».
- (e) On trie  $G$  et on renvoie le  $(\lceil n/2 \rceil - r_d)$ ème élément de  $G$ .

1. Justifier pourquoi l'algorithme retourne la médiane en temps  $O(n)$  lorsqu'il ne répond pas de message d'erreur.

 Si aucun message d'erreur n'est renvoyé, l'algorithme s'exécute en temps  $O(n)$ ; en effet la génération des  $(Y_i)$  prend un temps  $O(n)$ , le tri de  $F$  et  $G$  prend un temps  $O(m \log m)$  pour  $m = O(n^{3/4})$ , et la détermination de  $r_d$ , de  $r_u$  et de  $G$  nécessite  $O(n)$  comparaisons. De plus, l'absence de message d'erreur numéro 2 garantit que la médiane est dans l'intervalle  $[d, u]$ , donc dans  $G$ .

2. Montrer que pour  $i \in \{1, 2, 3\}$ , on a

$$\lim_{n \rightarrow \infty} \Pr(\text{l'algorithme retourne «ERREUR } i\text{») = 0.$$

Pour simplifier l'analyse et éviter d'écrire des symboles  $\lfloor \cdot \rfloor$  ou  $\lceil \cdot \rceil$ , on pourra supposer implicitement que des nombres tels que  $\sqrt{n}$ ,  $\frac{1}{2}n^{3/4}$ , ... sont des entiers



1. Pour l'erreur 1 : comme  $\text{card } F = Y_1 + \dots + Y_n$  a la loi  $B(n, n^{-1/4})$ , on a par l'inégalité de Chernoff II

$$\mathbb{P}(\text{card } F \geq 2n^{3/4}) \leq \exp(-n^{3/4}/3), \quad \mathbb{P}(\text{card } F \leq \frac{2}{3}n^{3/4}) \leq \exp(-n^{3/4}/18).$$

2. Pour l'erreur 2 : on note  $E^-$  l'ensemble des éléments de  $E$  inférieurs ou égaux à la médiane, et on remarque que  $r_d > n/2$  équivaut à  $\text{card}(F \cap E^-) < \frac{1}{2}n^{3/4} - \sqrt{n}$ . La v.a.  $\text{card}(F \cap E^-)$  suit la loi  $B(\lceil n/2 \rceil, n^{-1/4})$  (notons  $\mu$  sa moyenne) donc par l'inégalité de Chernoff II

$$\mathbb{P}(\text{card}(F \cap E^-) < \frac{1}{2}n^{3/4} - \sqrt{n}) \leq \mathbb{P}(\text{card}(F \cap E^-) \leq (1 - 2n^{-1/4})\mu) \leq \exp(-\mu\sqrt{n}) \rightarrow 0$$

Un argument symétrique traite le cas de  $r_u > n/2$  et considérant  $E^+$  l'ensemble des éléments de  $E$  supérieurs ou égaux à la médiane

3. Pour l'erreur 3 : si  $\text{card } G \geq 4n^{3/4}$ , alors ou bien  $\text{card}(G \cap E^-) \geq 2n^{3/4}$  ou bien  $\text{card}(G \cap E^+) \geq 2n^{3/4}$ ; ces deux événements ayant même probabilité, il suffit de montrer que  $\mathbb{P}(\text{card}(G \cap E^-) \geq 2n^{3/4}) \rightarrow 0$ . On remarque que si  $\text{card}(G \cap E^-) \geq 2n^{3/4}$ , alors  $r_d \leq \frac{n}{2} - 2n^{3/4}$  et donc l'ensemble  $F$  contient au moins  $\frac{1}{2}n^{3/4} - \sqrt{n}$  parmi les  $\frac{n}{2} - 2n^{3/4}$  plus petits éléments de  $E$ . La probabilité de ce dernier événement est  $\mathbb{P}(X \geq (1 + \varepsilon)X)$ , où  $X \sim B(\frac{n}{2} - 2n^{3/4}, n^{-1/4})$  et  $\varepsilon = \frac{\sqrt{n}}{n^{3/4}/2 - 2\sqrt{n}} = O(n^{-1/4})$ . Une dernière application de l'inégalité de Chernoff II permet de conclure que la probabilité considérée tend vers 0.