

Graphes aléatoires d'Erdős-Renyi
Distance en variation et couplage

Exercice 1 (Graphes aléatoires d'Erdős-Renyi)


On considère un espace probabilisé (Ω, \mathcal{A}, P) .

Pour définir un graphe aléatoire non orienté G , on se donne :

- $S = \{s_1, \dots, s_n\}$ un ensemble fini de $n \geq 2$ sommets ;
- pour toute paire de sommets $\{s_i, s_j\}$ avec $i < j$, $T_{i,j}$ une variable de Bernoulli de paramètre p sur (Ω, \mathcal{A}, P) .

Les arêtes du graphe sont les paires $\{s_i, s_j\}$ telles que $T_{i,j} = 1$ avec $i < j$. Les variables $T_{i,j}$ sont supposées indépendantes.

Voici un exemple de graphe aléatoire avec $S = \{a, b, c, d, e\}$ et $p = 0.4$:



1. Quel est le nombre maximal d'arêtes de G ?
2. Écrire une fonction Python d'entête `listAdj(S,p)` qui génère la liste des listes d'adjacence d'un tel graphe aléatoire ayant S pour liste de sommets.

Le graphe dessiné ci-dessus correspond par exemple à la liste des listes d'adjacence suivante :

`[['c', 'e'], ['d', 'e'], ['a', 'e'], ['b', 'e'], ['a', 'b', 'c', 'd']]`

avec la liste des sommets qui est $S = 'abcde'$.

3. Pour tout $k \in \llbracket 1, n \rrbracket$, on considère la variable aléatoire D_k égale au degré du sommet s_k . Déterminer la loi de D_k .
4. On dit que s_k est isolé si $D_k = 0$ est réalisé. On note Z_n la variable aléatoire comptant les sommets isolés de G et X_k la variable aléatoire de Bernoulli qui vaut 1 si s_k est isolé et 0 sinon.

(a) Montrer que : $Z_n = \sum_{k=1}^n X_k$. En déduire que : $E(Z_n) = n(1 - p)^{n-1}$.

(b) Montrer que : $Z_n^2 = \sum_{k=1}^n X_k + 2 \sum_{1 \leq i < j \leq n} X_i X_j$.

(c) Justifier que : $P([X_i = 1] \cap [X_j = 1]) = (1 - p)^{2n-3}$.

En déduire que : $E(Z_n^2) = n(1 - p)^{n-1} + n(n - 1)(1 - p)^{2n-3}$.

On suppose désormais que $p = p_n = c \frac{\ln(n)}{n}$, avec $c > 0$, $c \neq 1$.

5. (a) Écrire une fonction Python Z qui renvoie le nombre de sommets isolés d'un graphe donné par sa liste de listes d'adjacence lst . On importera les bibliothèques `numpy` as `np` et `numpy.random` as `rd`.
- (b) On souhaite estimer l'influence de la valeur de c sur le nombre de sommets isolés. En exécutant le script suivant :

```

1 | list2c = [0.3, 0.5, 0.7, 1.3, 1.5, 1.7]
2 | n = 1000
3 | res = []
4 |
5 | for c in list2c:
6 |     s = 0
7 |     for k in range(200):
8 |         if Z(listAdj(range(1,n+1), c*np.log(n)/n))==0:
9 |             s += 1
10 |        res.append(s/200)
11 | print(res)

```

on obtient $[0.0, 0.0, 0.0, 0.91, 0.975, 0.99]$ après de longues minutes.

Quelle conjecture sur la valeur d'une probabilité pouvez-vous faire lorsque $c < 1$ et $c > 1$? Justifier.

6. (a) Montrer que $(1 - p_n)^{n-1} \underset{n \rightarrow +\infty}{\sim} (1 - p_n)^n$ puis que $(1 - p_n)^{n-1} \underset{n \rightarrow +\infty}{\sim} n^{-c}$.
- (b) On rappelle que l'inégalité de Markov affirme que si X est une variable aléatoire positive admettant une espérance et $a > 0$,

$$P(X \geq a) \leq \frac{E(X)}{a}.$$

Si $c > 1$, en déduire la limite de $P(Z_n \geq 1)$ puis de $P(Z_n = 0)$, lorsque $n \rightarrow +\infty$.

- (c) On rappelle que l'inégalité de Bienaymé-Tchébichev affirme que si X est une variable aléatoire admettant une variance et $\varepsilon > 0$,

$$P(|X - E(X)| \geq \varepsilon) \leq \frac{V(X)}{\varepsilon^2}.$$

Montrer que $P(Z_n = 0) \leq \frac{V(Z_n)}{E(Z_n)^2}$. En déduire que si $c < 1$, $P(Z_n = 0) \xrightarrow[n \rightarrow +\infty]{} 0$?

- (d) Votre conjecture est-elle correcte ?

Exercice 2 (Distance en variation et couplage)

Tout au long du sujet $(\Omega, \mathcal{F}, \mathbf{P})$ désignera un espace probabilisé et les variables aléatoires utilisées plus bas seront toutes définies sur cet espace probabilisé. Sous réserve de son existence, l'espérance mathématique d'une variable aléatoire réelle X sera notée $E(X)$.

Partie 1 : Distance en variation

Dans cette première partie, on considère un ensemble discret \mathcal{K} dont on suppose qu'il est soit fini soit égal à l'ensemble des entiers naturels \mathbb{N} . \mathcal{A} désigne l'ensemble de toutes les parties de \mathcal{K} et pour tout $A \in \mathcal{A}$, on note \bar{A} le complémentaire de A dans \mathcal{K} .

Soient P et Q deux probabilités sur \mathcal{K} . Pour tout $k \in \mathcal{K}$, on pose $p_k = P(\{k\})$ et $q_k = Q(\{k\})$. On rappelle que pour tout $k \in \mathcal{K}$, $p_k \geq 0$, avec $\sum_{k \in \mathcal{K}} p_k = 1$. De plus, toute probabilité P est entièrement déterminée par la donnée de $(p_k)_{k \in \mathcal{K}}$ puisque pour tout $A \in \mathcal{A}$, $P(A) = \sum_{k \in A} p_k$.

Lorsque \mathcal{K} est fini, on définit la distance en variation entre les probabilités P et Q par

$$D(P, Q) = \frac{1}{2} \sum_{k \in \mathcal{K}} |p_k - q_k| \tag{i}$$

1. Lorsque $\mathcal{K} = \{0; 1\}$ exprimer $D(P, Q)$ en fonction de p_1 et q_1 .
2. Lorsque $\mathcal{K} = \mathbb{N}$, vérifier que la série de terme général $(|p_k - q_k|)_{k \in \mathbb{N}}$ est convergente.

On étend donc la définition de la distance en variation donnée par (i) au cas où $\mathcal{K} = \mathbb{N}$.

3. Vérifier que pour tout $A \in \mathcal{A}$, $|P(A) - Q(A)| \in [0, 1]$.

4. Montrer que pour tout $A \in \mathcal{A}$, $2|P(A) - Q(A)| = \left| \sum_{k \in A} (p_k - q_k) \right| + \left| \sum_{k \in \bar{A}} (p_k - q_k) \right|$.

5. En déduire que pour tout $A \in \mathcal{A}$,

$$|P(A) - Q(A)| \leq D(P, Q) \tag{ii}$$

6. Montrer que la partie $A = \{k \in \mathcal{K} \mid q_k \geq p_k\}$ réalise l'égalité dans (ii), c'est-à-dire que

$$|P(A) - Q(A)| = D(P, Q)$$

7. Démontrer la formule $D(P, Q) = 1 - \sum_{k \in \mathcal{K}} \min(p_k, q_k)$.

8. On considère un couple de variables aléatoires (X, Y) tel que X soit de loi P et Y soit de loi Q . Autrement dit, pour tout $k \in \mathcal{K}$,

$$\mathbf{P}(X = k) = p_k \quad \text{et} \quad \mathbf{P}(Y = k) = q_k$$

Montrer que $D(P, Q) \leq \mathbf{P}(X \neq Y)$.

Partie 2 : Couplage binomiale - Poisson

Soit $n \in \mathbb{N}^*$ et $\lambda \in \mathbb{R}_+^*$ tels que $\lambda < n$.

L'objet de cette deuxième partie est d'étudier un exemple, l'approximation de la loi binomiale par la loi de Poisson en terme de distance en variation.

Plus précisément, si d'une part $\mathcal{B}(n, \lambda/n)$ désigne la loi binomiale de paramètres n et λ/n et si d'autre part on note $\mathcal{P}(\lambda)$ la loi de Poisson de paramètre λ , le but est de prouver la majoration suivante :

$$D(\mathcal{B}(n, \lambda/n), \mathcal{P}(\lambda)) \leq \frac{\lambda^2}{n} \tag{iii}$$

où D est définie au (i).

9. Soit Y_1, \dots, Y_n des variables aléatoires indépendantes et de même loi de Poisson $\mathcal{P}(\lambda/n)$.

Donner sans démonstration la loi de $\sum_{i=1}^n Y_i$.

10. Vérifier que pour tout $x \in [0, 1]$,

$$f(x) = 1 - (1 - x) \exp(x).$$

appartient à $[0, 1]$.

Soit U_1, \dots, U_n des variables aléatoires indépendantes de même loi de Bernoulli de paramètre $f(\lambda/n)$. On suppose que les variables U_1, \dots, U_n sont indépendantes des variables Y_1, \dots, Y_n de la question 9. Pour $i \in \llbracket 1, n \rrbracket$, on pose $X_i = 0$ si $U_i = Y_i = 0$ et $X_i = 1$ sinon.

11. Vérifier que, pour tout $i \in \llbracket 1, n \rrbracket$, X_i suit une loi de Bernoulli de paramètre λ/n .

Donner la loi de $\sum_{i=1}^n X_i$.

12. Montrer que pour tout $i \in \llbracket 1, n \rrbracket$,

$$\mathbf{P}(X_i \neq Y_i) \leq \frac{\lambda^2}{n^2}$$

On pourra établir que pour tout réel x , $1 + x \leq \exp(x)$.

13. Montrer que :

$$\mathbf{P}\left(\sum_{i=1}^n X_i \neq \sum_{i=1}^n Y_i\right) \leq \mathbf{P}\left(\bigcup_{i=1}^n (X_i \neq Y_i)\right).$$

14. En déduire que :

$$\mathbf{P}\left(\sum_{i=1}^n X_i \neq \sum_{i=1}^n Y_i\right) \leq \frac{\lambda^2}{n}.$$

Conclure quant à (iii).

15. Quel résultat connu peut-on déduire de (iii) lorsque n tend vers l'infini ?