

Arbres aléatoires

DS2


M2 Modélisation statistique, 2022–2023

Exercice 1 :


- a) Représenter les quatre arbres enracinés à 4 sommets.
- b) Pour chaque arbre de la question (a), combien y a-t-il de représentations planaires différentes de l'arbre ?
- c) Représenter les deux arbres enracinés binaires à 4 feuilles.
- d) Pour chaque arbre de la question (c), donner toutes les représentations planaires différentes de l'arbre.
- e) Pour chaque arbre de la question (d), combien y a-t-il de représentations ordonnées différentes de l'arbre ?

Solution de l'exercice 1.


a)




b) Seulement le troisième arbre représenté admet deux représentations planaires distinctes :




c)



d) Le premier arbre étant symétrique, il n'admet qu'une représentation planaire. Le second en admet quatre, on a donc en tout :



e) Le premier arbre admet deux représentations ordonnées :



Par leur structure, les quatre derniers arbres n'admettent chacun qu'une seule représentation ordonnée.

Exercice 2 : On définit :

- \mathcal{E}_n l'ensemble des arbres enracinés dont tous les sommets sont étiquetés (sans répétition) par $\{1, 2, \dots, n\}$.
- $\mathcal{E}_n^{\text{pl}}$ l'ensemble des arbres enracinés *planaires* dont tous les sommets sont étiquetés (sans répétition) par $\{1, 2, \dots, n\}$.
- $f : \mathcal{E}_n^{\text{pl}} \rightarrow \mathcal{E}_n$ la fonction qui "oublie" la structure planaire d'un arbre.


- Représenter chacun des quatre arbres de $\mathcal{E}_3^{\text{pl}}$ dont la racine porte l'étiquette 1.
- Des arbres précédents, lesquels ont la même image par la fonction f ?
- * Justifier que dans le cas général, pour $\mathbf{t} \in \mathcal{E}_n$, on a

$$\text{Card}(f^{-1}(\mathbf{t})) = \prod_{v \in \mathbf{t}} n_v!,$$

où comme dans le cours, n_v désigne le nombre d'enfants d'un nœud v .

Solution de l'exercice 2.

- On a



- Les deux derniers arbres représentés sont identiques quand on oublie la structure planaire, ils ont donc la même image par f .
- Dans le cas général, puisque nos arbres sont étiquetés sans répétition, pour chaque nœud de l'arbre $v \in \mathbf{t}$, chaque ordre distinct sur les enfants de v donne un arbre planaire distinct. Ainsi tous les arbres planaires $\tilde{\mathbf{t}}$ satisfaisant $f(\tilde{\mathbf{t}}) = \mathbf{t}$ s'obtiennent en fixant, pour chaque sommet $v \in \mathbf{t}$, un ordre sur les enfants de v , parmi les $n_v!$ ordres possibles.

Enfin, on a $\prod_v n_v!$ façons différentes de poser une structure planaire sur \mathbf{t} , c'est donc le cardinal de $f^{-1}(\mathbf{t})$.

Exercice 3 : On rappelle que $X \sim \text{Poi}(1)$ signifie que $\mathbb{P}(X = n) = e^{-1} \frac{1}{n!}$ pour tout $n \in \mathbb{N}$. On considère un arbre aléatoire $T \sim \text{GW}(\text{Poi}(1))$.

- L'arbre est-il sous-critique, critique ou sur-critique ? Que vaut sa probabilité d'extinction p_{ext} ?
- Soit \mathbf{t} un arbre planaire fini. Que vaut $\mathbb{P}(T = \mathbf{t})$?

c) On construit \tilde{T} un arbre aléatoire à valeur dans $\cup_n \mathcal{E}_n^{\text{pl}}$ en munissant les sommets de T d'étiquettes uniformément choisies (sans répétition) dans les entiers de 1 à $N_T =$ nombre de sommets de T .

Soit $\tilde{\mathbf{t}} \in \mathcal{E}_n^{\text{pl}}$. Que vaut $\mathbb{P}(\tilde{T} = \tilde{\mathbf{t}})$?

d) On reprend la fonction f de l'exercice 2, on fixe $\mathbf{t} \in \mathcal{E}_n$, et l'on choisit $\tilde{\mathbf{t}} \in f^{-1}(\mathbf{t})$. Montrer que

$$\mathbb{P}(f(\tilde{T}) = \mathbf{t}) = \text{Card}(f^{-1}(\mathbf{t}))\mathbb{P}(\tilde{T} = \tilde{\mathbf{t}}),$$

et en déduire que $\mathbb{P}(f(\tilde{T}) = \mathbf{t}) = \frac{e^{-n}}{n!}$.

Solution de l'exercice 3.

a) Si $\xi \sim \text{Poi}(1)$, on a $\mathbb{E}[\xi] = 1$, l'arbre est donc critique, et $p_{\text{ext}} = 1$.

b) D'après la formule du cours,

$$\mathbb{P}(T = \mathbf{t}) = \prod_{v \in \mathbf{t}} \mathbb{P}(\xi = n_v) = \prod_{v \in \mathbf{t}} \frac{e^{-1}}{n_v!}.$$

c) Étant donnée la forme d'arbre de T et conditionnellement à son nombre de sommets N_T , il y a $N_T!$ façons différentes d'attribuer les étiquettes à \tilde{T} . Notons \mathbf{t} l'arbre obtenu en oubliant les étiquettes sur les sommets de $\tilde{\mathbf{t}}$. Puisque l'étiquetage est choisi uniformément, on a (on rappelle que \mathbf{t} a n sommets)

$$\mathbb{P}(\tilde{T} = \tilde{\mathbf{t}}) = \frac{1}{n!} \mathbb{P}(T = \mathbf{t}) = \frac{1}{n!} \prod_{v \in \mathbf{t}} \frac{e^{-1}}{n_v!} = \frac{e^{-n}}{n!} \prod_{v \in \mathbf{t}} \frac{1}{n_v!}.$$

d) Toutes les représentations planaires différentes de \mathbf{t} ont la même probabilité selon le modèle de Galton–Watson, parce que l'ensemble des nombres d'enfants reste le même. Ainsi, on a

$$\mathbb{P}(f(\tilde{T}) = \mathbf{t}) = \mathbb{P}(\tilde{T} \in f^{-1}(\mathbf{t})) = \sum_{\hat{\mathbf{t}} \in f^{-1}(\mathbf{t})} \mathbb{P}(\tilde{T} = \hat{\mathbf{t}}) = \text{Card}(f^{-1}(\mathbf{t}))\mathbb{P}(\tilde{T} = \tilde{\mathbf{t}}).$$

En combinant la question précédente et la question (c) de l'exercice 2, on obtient bien $\mathbb{P}(f(\tilde{T}) = \mathbf{t}) = e^{-n}/n!$.

Exercice 4 : On modélise une population de bactéries par un arbre de Yule de paramètre λ , et on arrête l'évolution de la population quand elle atteint une taille n .

Rappel d'une loi usuelle : si $X \sim \text{Exp}(\mu)$, on a $\mathbb{E}[X] = 1/\mu$ et $\text{Var}(X) = 1/\mu^2$.

a) Construire une variable aléatoire Z qui a la loi du temps qu'on a attendu.

On pourra se donner une suite de variables indépendantes $(X_k)_{k \geq 1}$ de lois bien choisies, et construire Z à partir de celles-ci.

b) Donner l'espérance de Z .

c) Donner la variance de Z .

d) Donner la fonction de répartition de Z .

Solution de l'exercice 4.

- a) On rappelle que les temps successifs de naissance dans l'arbre de Yule sont séparés par des temps exponentiels indépendants $(X_k)_{k \geq 1}$, avec $X_k \sim \text{Exp}(k\lambda)$ pour tout k .
Ainsi, l'on a n individus au bout du temps $Z = X_1 + X_2 + \dots + X_{n-1}$ (j'accepte aussi la solution si l'on prends les n premières variables).
- b) On a donc $\mathbb{E}[Z] = \sum_{k=1}^{n-1} 1/(k\lambda) \sim \log(n)/\lambda$.
- c) Similairement, on a donc (car somme de variables deux-à-deux de covariances nulles) $\text{Var}(Z) = \sum_{k=1}^{n-1} 1/(k\lambda)^2 \rightarrow \pi^2/(6\lambda^2)$.
- d) Avec la construction CPP de l'arbre de Yule arrêté à $n - 1$ individus, on voit aussi qu'une construction de Z équivalente est $Z = \max(Y_1, \dots, Y_{n-1})$, où les Y_1, \dots, Y_{n-1} sont i.i.d. de loi $\text{Exp}(\lambda)$. Alors la fonction de répartition se calcule : pour tout $t \geq 0$,

$$\mathbb{P}(Z \leq t) = \mathbb{P}\left(\bigcap_{i=1}^{n-1} \{Y_i \leq t\}\right) = \prod_{i=1}^{n-1} \mathbb{P}(Y_i \leq t) = (1 - e^{-\lambda t})^{n-1}.$$

Exercice 5 : On considère les données de distances génétiques (fictives) suivantes :

	canard	vélociraptor	alligator	iguane	cobra
canard	0	1	2	15	12
vélociraptor	1	0	4	9	8
alligator	2	4	0	9	7
iguane	15	9	9	0	6
cobra	12	8	7	6	0

- a) Appliquer l'algorithme UPGMA pour proposer une phylogénie de ces espèces.
- b) Sur deux loci, on observe les bases suivantes :

	canard	vélociraptor	alligator	iguane	cobra
locus 1	A	A	G	A	C
locus 2	A	T	C	C	T

Proposer une décoration (c'est-à-dire placer des séquences génétiques de longueur 2 sur chaque nœud) parcimonieuse de la phylogénie trouvée à la question précédente. Combien de mutations ont été nécessaires pour aboutir aux données observées ?

Solution de l'exercice 5.


- a) Les espèces "canard" et "vélociraptor" sont plus proches (distance 1), on les fusionne, et on calcule les nouvelles distances :

$$d(\text{CV}, \text{alligator}) = \frac{2+4}{2} = 3, \quad d(\text{CV}, \text{iguane}) = \frac{15+9}{2} = 12, \quad d(\text{CV}, \text{cobra}) = \frac{12+8}{2} = 10.$$


On fusionne ensuite "CV" et "alligator" (distance 3), puis :

$$d(\text{CVA}, \text{iguane}) = \frac{2 \times 12 + 9}{3} = 11, \quad d(\text{CVA}, \text{cobra}) = \frac{2 \times 10 + 7}{3} = 9.$$


On fusionne ensuite "iguane" et "cobra" (distance 6), qui fusionnent ensuite avec "CVA" à distance $(9 + 11)/2 = 10$. On se retrouve finalement avec l'arbre phylogénétique suivant :



b) L'algorithme de Fitch nous donne, pour le locus 1 :



et pour le locus 2 :



En tout, on a donc nécessairement cinq mutations (deux pour le locus 1, trois pour le locus 2).