

Examen du 4 mai 2018

Durée : 2 heures. Tous documents interdits.

Exercice 1. Soit $f : [0, 1] \rightarrow [0, \infty)$ et $0 < T_\infty \leq \infty$ tels que $\{f \neq 0\}$ est dénombrable et

$$\#\{x : f(x) \in (0, t]\} < \infty \iff t < T_\infty.$$

Soit (U_i) une suite de v.a. i.i.d. uniformes dans $[0, 1]$. Pour tout $t > 0$, on définit $F(t)$ la partition de \mathbb{N} telle que

$$i \stackrel{F(t)}{\sim} j \iff \forall x \in [U_i \wedge U_j, U_i \vee U_j], f(x) \notin (0, t].$$

Pour $k \geq 1$, on définit $F_k(t)$ la restriction de $F(t)$ à $[k] := \{1, \dots, k\}$.

- Rappeler la topologie usuelle sur l'espace des partitions de \mathbb{N} .
- Que vaut $F(0+)$? Pour $t < T_\infty$ fixé, que peut-on dire de la loi de la partition $F(t)$? Dire pourquoi la limite $F(T_\infty-)$ existe. Cette partition peut-elle avoir des singletons?

Soient $\beta > -1$ et $\alpha \in \mathbb{R}$. On définit $\mathcal{R}(t) := \{(x, f(x)) : f(x) \in (0, t]\}$. On suppose que $(\mathcal{R}(t); t \geq 0)$ est un processus de Markov et que conditionnellement à $\mathcal{R}(t) = \{(x_1, f(x_1)), \dots, (x_n, f(x_n))\}$, où $x_1 < \dots < x_n$, chaque intervalle (x_{i-1}, x_i) pour $i \in \{1, \dots, n+1\}$ (notant $x_0 = 0$ et $x_{n+1} = 1$) se fragmente indépendamment à taux Δ_i^α avec $\Delta_i := x_i - x_{i-1}$. Plus précisément, indépendamment pour chaque i , on ajoute un point à $\mathcal{R}(t)$ égal à $(x_{i-1} + Z_i \Delta_i, t + Y_i)$, où les variables aléatoires

$$Y_i \sim \text{Exp}(\Delta_i^\alpha) \quad \text{et} \quad Z_i \sim \text{Beta}(\beta + 1, \beta + 1)$$

sont toutes indépendantes.

- Quelle est la loi du processus $(\#\mathcal{R}(t); t > 0)$ lorsque $\alpha = 0$?
- Lorsque $\alpha < 0$, montrer que

$$\mathbb{E}(T_\infty) \leq \frac{1}{1 - \mathbb{E}(Z_1^{-\alpha})}$$

En déduire que $\mathbb{P}(T_\infty < \infty) = 0$ ou 1 selon que $\alpha \geq 0$ ou $\alpha < 0$.

- Soient $((V_i, X_i); i \geq 0)$ les atomes d'un processus de Poisson ponctuel sur $[0, 1] \times [0, \infty)$ d'intensité la mesure de Lebesgue sur $[0, 1] \times [0, \infty)$. Soit $f : [0, 1] \rightarrow [0, \infty)$ définie par $f(t) = \sum_{i \geq 1} X_i \mathbb{1}_{\{V_i\}}$. Montrer que f peut être générée par la procédure décrite précédemment pour certaines valeurs de α et β que l'on précisera.

Solution de l'exercice 1.

- La topologie usuelle est la topologie générée par la distance ultramétrique

$$d(\pi, \pi') = (\min\{k : \pi_{[k]} \neq \pi'_{[k]}\})^{-1}$$

- b) On voit facilement que $F(0+)$ est la partition grossière réduite au seul élément \mathbb{N} . Pour tout $t < T_\infty$, $F(t)$ est bien sûr échangeable. La limite $F(T_\infty-)$ existe car le processus $(F(t); t \in (0, T_\infty))$ est monotone (partitions de plus en plus fines). En effet, cela implique que $F_k(t)$ est stationnaire (constante pour $t \in (t_k, T_\infty)$ pour un certain t_k), ce qui donne la convergence dans la topologie usuelle. La partition $F(T_\infty-)$ a des singletons dès qu'il existe un intervalle ouvert I tel que $\{x \in I : f(x) \in (0, T_\infty)\}$ est dense dans I . Il est facile de voir qu'alors pour tout $i \in \mathbb{N}$ tel que $U_i \in I$, $\{i\} \in F(T_\infty-)$.
- c) Lorsque $\alpha = 0$, le processus $(\#\mathcal{R}(t); t > 0)$ est un processus de Yule de paramètre 1.
- d) On suppose que $\alpha < 0$. Pour $t \in (0, T_\infty)$, on définit $I_t := \min\{x : f(x) \in (0, t]\}$. On voit alors que conditionnellement à $I_t = x$, à taux x^α , I_t saute de x à Zx , où Z est comme dans l'énoncé. Ainsi, si T_n désigne le n -ième temps de saut de (I_t) (avec $T_0 = 0$),

$$I_{T_n} = \prod_{i=1}^n Z_i,$$

où les Z_i sont iid, et conditionnellement à $I_{T_n} = x$, $T_{n+1} - T_n$ suit la loi exponentielle de paramètre x^α , dont l'espérance est $x^{-\alpha}$. Or $T_\infty \leq \lim_n T_n = \sum_{n \geq 0} (T_{n+1} - T_n)$, donc

$$\mathbb{E}(T_\infty) \leq \sum_{n \geq 0} \mathbb{E}(T_{n+1} - T_n) = \sum_{n \geq 0} \mathbb{E}(I_{T_n}^{-\alpha}) = \sum_{n \geq 0} \mathbb{E}\left(\prod_{i=1}^n Z_i^{-\alpha}\right) = \sum_{n \geq 0} \mathbb{E}(Z_1^{-\alpha})^n = \frac{1}{1 - \mathbb{E}(Z_1^{-\alpha})}.$$

On peut donc en déduire que $\mathbb{P}(T_\infty < \infty) = 1$ dès que $\alpha < 0$. Pour $\alpha = 0$, nous savons que $\mathbb{P}(T_\infty = \infty) = 1$ puisqu'il s'agit du processus de Yule. Lorsque $\alpha > 0$, les temps d'attente sont plus longs que pour le processus de Yule, donc T_∞ croît stochastiquement avec α , ce qui donne le résultat.

- e) Ici chaque intervalle (x, y) à temps t est fragmenté indépendamment par l'atome (V_J, X_J) , où

$$J := \arg \min\{X_i : X_i > t, V_i \in (x, y)\}.$$

Ainsi, X_J et V_J sont indépendantes, $X_J - t$ suit la loi exponentielle de paramètre $(y - x)$ et V_J est uniformément distribuée dans (x, y) , ce qui donne la bonne description avec $\alpha = 1$ et $\beta = 0$.

Exercice 2. Soit $A \subset \mathbb{N}$ un ensemble aléatoire supposé échangeable, au sens où sa loi est invariante par toute permutation de \mathbb{N} .

- a) Que vaut $\mathbb{P}(A = \{1\})$? Donner la probabilité que A soit fini.
- b) Caractériser la loi de A .
- c) À présent on se donne (A, B) un couple de sous-ensembles de \mathbb{N} , supposé échangeable. Caractériser la loi de (A, B) .

Solution de l'exercice 2.

- a) Comme $\mathbb{P}(A = \{1\}) = \mathbb{P}(A = \{j\})$ pour tout j et que $\sum_j \mathbb{P}(A = \{j\}) \leq 1$, on a forcément $\mathbb{P}(A = \{1\}) = 0$. Le même raisonnement montre que A est fini avec probabilité 0.
- b) Comme (A, A^c) forment une partition échangeable de \mathbb{N} , le théorème de de Finetti assure que A a une fréquence asymptotique $p \in [0, 1]$ et que conditionnellement à p la suite $(\mathbb{1}_A(i))$ est une suite de v.a. de Bernoulli indépendantes de paramètre p .
- c) De la même manière, $(A \setminus B, B \setminus A, A \cap B, (A \cup B)^c)$ forment une partition échangeable de \mathbb{N} . Il existe donc un triplet (p_A, p_B, p_{AB}) aléatoire de réels de $[0, 1]$ de somme ≤ 1 tel que conditionnellement à ce triplet, chaque entier i choisit indépendamment d'appartenir à $(A \setminus B, B \setminus A, A \cap B, (A \cup B)^c)$ avec probabilités respectives $p_A, p_B, p_{AB}, 1 - p_A - p_B - p_{AB}$.

Exercice 3. Soit \mathcal{X} un ensemble fini, de cardinal n . On appelle \mathcal{X} -arbre un arbre (non nécessairement binaire) enraciné à n feuilles dont les feuilles sont étiquetées par \mathcal{X} (de manière bijective). Une collection $\mathcal{H} \subset \mathcal{P}(\mathcal{X})$ de parties de \mathcal{X} est appelée \mathcal{X} -hiérarchie si : (i) $\mathcal{X} \in \mathcal{H}$; (ii) pour tout $x \in \mathcal{X}$, $\{x\} \in \mathcal{H}$; et

(iii) pour tous $A, B \in \mathcal{H}$, $A \cap B \in \{A, B, \emptyset\}$.

- a) Montrer qu'il existe une bijection naturelle φ entre les \mathcal{X} -arbres et les \mathcal{X} -hiérarchies. Piste : le cardinal d'une \mathcal{X} -hiérarchie est toujours inférieur ou égal à $2n - 1$.
- b) Montrer que pour tous \mathcal{X} -arbres T et T'

$$d(T, T') = \#(\varphi(T) \Delta \varphi(T'))$$

définit une distance (ici Δ désigne la différence symétrique : $C \Delta C' = (C \cup C') \setminus (C \cap C') = (C \setminus C') \cup (C' \setminus C)$). Elle est appelée *distance de Robinson-Foulds*.

- c) Expliquer pourquoi si T et T' sont deux \mathcal{X} -arbres *binaires* distincts, $d(T, T') \geq 2$.

On se donne maintenant k \mathcal{X} -arbres T_1, \dots, T_k .

- d) On définit

$$\mathcal{H}^{>\frac{1}{2}} = \{A \subset \mathcal{X} : \#\{j : A \in \varphi(T_j)\} > k/2\}.$$

Montrer que $\mathcal{H}^{>\frac{1}{2}}$ est une \mathcal{X} -hiérarchie. On appelle $T^{>\frac{1}{2}} = \varphi^{-1}(\mathcal{H}^{>\frac{1}{2}})$ l'*arbre consensus majoritaire*.

- e) Montrer que

$$\sum_{i=1}^k d(T_i, T^{>\frac{1}{2}}) \leq \frac{k}{2} \#(\cup_{i=1}^k \varphi(T_i)) \leq \frac{k}{2}(n+1+k(n-2)).$$

Solution de l'exercice 3.

- a) À chaque nœud de l'arbre T on peut associer la partie de \mathcal{X} qui est l'ensemble des étiquettes des feuilles qu'il sous-tend. On voit facilement que pour tout arbre T , la collection des parties ainsi associées à ses nœuds est une hiérarchie. En effet soient A et B deux telles parties et ν_A et ν_B les nœuds associés. Si $\nu_A \prec \nu_B$, alors $B \subset A$; bien sûr si $\nu_B \prec \nu_A$, alors $A \subset B$; sinon, $A \cap B = \emptyset$ (sans quoi il existerait une feuille qui descend à la fois de ν_A et de ν_B).

L'inverse de φ peut être définie de la manière suivante. Soit \mathcal{H} une hiérarchie. On construit récursivement $T = \varphi^{-1}(\mathcal{H})$ à l'aide d'une correspondance entre les éléments de \mathcal{H} et les nœuds de T en partant de la racine, qui est associée à $\{\mathcal{X}\}$. Pour tout nœud ν de T déjà construit, associé à $A \in \mathcal{H}$, soit A est un singleton et ν est une feuille, soit A n'est pas un singleton, et chaque fille de ν est associée à chaque $B \in \mathcal{H}$ tel que $B \subset A$ qui est maximal (pour tout $C \in \mathcal{H}$, si $C \subset A$ alors $B \not\subset A$).

- b) L'inégalité triangulaire vient du simple fait que de manière générale

$$C \Delta C'' \subset (C \Delta C') \cup (C' \Delta C'').$$

- c) Si $T \neq T'$, sans perte de généralité (par symétrie), il existe $A \in \varphi(T) \setminus \varphi(T')$. Soit alors B le plus petit élément de $\varphi(T)$ contenant strictement A . Comme T est binaire, $B = A \sqcup A'$, où $A' \in \varphi(T)$. Si on avait simultanément $B \in \varphi(T')$ et $A' \in \varphi(T')$, alors comme T' est aussi binaire, on aurait $A \in \varphi(T')$. Donc on peut trouver au moins deux éléments dans $\varphi(T') \setminus \varphi(T)$, A d'une part, et d'autre part B ou A' . Donc

$$d(T, T') \geq \#(\varphi(T') \setminus \varphi(T)) \geq 2.$$

- d) Comme $\mathcal{X} \in \varphi(T_j)$ pour tous j , on a $\#\{j : \mathcal{X} \in \varphi(T_j)\} = k > k/2$ et donc $\mathcal{X} \in \mathcal{H}^{>\frac{1}{2}}$. De la même manière $\mathcal{H}^{>\frac{1}{2}}$ contient tous les singletons.
 Soient maintenant $A, B \in \mathcal{H}^{>\frac{1}{2}}$. Alors $\#\{j : A \in \varphi(T_j)\} > k/2$ et $\#\{j : B \in \varphi(T_j)\} > k/2$. Donc il existe i tel que $A \in \varphi(T_i)$ et $B \in \varphi(T_i)$. Comme $\varphi(T_i)$ est une hiérarchie, $A \cap B \in \{A, B, \emptyset\}$.

- e) Pour tout i ,

$$d(T_i, T^{>\frac{1}{2}}) = \#(\varphi(T_i) \Delta \mathcal{H}^{>\frac{1}{2}}) = \sum_{A \subset \mathcal{X}} \mathbb{1}(A \in \varphi(T_i) \Delta \mathcal{H}^{>\frac{1}{2}}).$$

Donc

$$\sum_{i=1}^k d(T_i, T^{>\frac{1}{2}}) = \sum_{A \subset \mathcal{X}} \sum_{i=1}^k \mathbb{1}(A \in \varphi(T_i) \Delta \mathcal{H}^{>\frac{1}{2}}).$$

Or

$$\begin{aligned} \sum_{i=1}^k \mathbb{1}(A \in \varphi(T_i) \Delta \mathcal{H}^{>\frac{1}{2}}) &= \sum_{i=1}^k \mathbb{1}(A \in \varphi(T_i) \setminus \mathcal{H}^{>\frac{1}{2}}) + \sum_{i=1}^k \mathbb{1}(A \in \mathcal{H}^{>\frac{1}{2}} \setminus \varphi(T_i)) \\ &\leq \frac{k}{2} \mathbb{1}(A \in (\cup_i \varphi(T_i) \setminus \mathcal{H}^{>\frac{1}{2}})) + \frac{k}{2} \mathbb{1}(A \in \mathcal{H}^{>\frac{1}{2}}) \\ &= \frac{k}{2} \mathbb{1}(A \in (\cup_i \varphi(T_i))). \end{aligned}$$

On obtient la première égalité en sommant sur A . La deuxième égalité est due au fait que chaque $\varphi(T_j)$ contient les mêmes $n+1$ éléments (n feuilles et racine) et additionnellement au plus $n-2$ éléments qui ne sont pas partagés par les autres hiérarchies.