

## PARTITIONS ALÉATOIRES D'EWENS–PITMAN

**mots-clés :** partitions aléatoires, sous-martingales et chaînes de Markov rétrogrades.

Ce texte présente un modèle de partitions aléatoires qui sont construites récursivement, et qui ont des propriétés asymptotiques intéressantes. On rappelle qu'une *partition* de l'ensemble  $[1, n] = \{1, 2, 3, \dots, n\}$  est une famille  $\pi = (\pi_1, \pi_2, \dots, \pi_\ell)$  de parties disjointes et non vides de  $[1, n]$  telles que  $[1, n] = \pi_1 \sqcup \pi_2 \sqcup \dots \sqcup \pi_\ell$ . Par exemple,

$$\pi = (\pi_1, \pi_2, \pi_3, \pi_4) = (\{1, 3, 7\}, \{2\}, \{4, 5, 8, 9\}, \{6\}) = \begin{array}{|c|c|c|} \hline 7 & 8 & 9 \\ \hline 4 & 5 & 6 \\ \hline 1 & 2 & 3 \\ \hline \end{array}$$

est une partition de taille 9. Notons  $\mathfrak{P}(n)$  l'ensemble des partitions de taille  $n$ . Si  $\pi \in \mathfrak{P}(n)$ , on ordonnera toujours ses parts  $\pi_1, \dots, \pi_\ell$  en fonction de leurs éléments minimaux :  $\min \pi_1 < \min \pi_2 < \dots < \min \pi_\ell$  (comme dans l'exemple ci-dessus). Ceci permet de définir sans ambiguïté la liste  $c(\pi) = (c_1(\pi), c_2(\pi), \dots, c_\ell(\pi))$  des tailles des parts d'une partition  $\pi \in \mathfrak{P}(n)$ . Dans l'exemple ci-dessus,  $c(\pi) = (3, 1, 4, 1)$ . Notons aussi  $\ell(\pi)$  le nombre de parts de  $\pi$ , et  $\lambda(\pi)$  le réordonnement décroissant des tailles des parts de  $\pi$ ; dans l'exemple précédent,  $\ell(\pi) = 4$  et  $\lambda(\pi) = (\lambda_1(\pi), \lambda_2(\pi), \lambda_3(\pi), \lambda_4(\pi)) = (4, 3, 1, 1)$ . On dira que  $\lambda(\pi)$  est la *signature* de  $\pi$ .

Supposons donnée une partition  $\pi \in \mathfrak{P}(n)$ . Elle représente par exemple la répartition de  $n$  personnes en autant de groupes d'opinion. Si une nouvelle personne  $n + 1$  arrive dans cette population, elle peut :

- soit rejoindre l'un des groupes  $\pi_k$  déjà existant ;
- soit créer un nouveau groupe  $\{n + 1\}$ .

La première section du texte définit des règles de transition qui construisent une partition  $\Pi$  de taille  $n + 1$  à partir de la partition  $\pi$  de taille  $n$ , en prenant en compte deux facteurs qui poussent la personne  $n + 1$  à créer un nouveau groupe. En itérant cette construction, on obtient ainsi une suite aléatoire

$$(\pi^{(1)}, \pi^{(2)}, \dots, \pi^{(n)}, \dots)$$

de partitions, chaque  $\pi^{(n)}$  étant de taille  $n$ . Cette suite est *cohérente*, au sens suivant : pour tous entiers  $n \leq N$ , les parts de  $\pi^{(n)}$  sont les intersections non vides des parts de  $\pi^{(N)}$  avec  $[1, n]$ . La seconde section du texte montre que sous une hypothèse d'*échangeabilité*, les tailles des plus grandes parts d'une suite cohérente de partitions aléatoires ont des *fréquences limites* : pour tout  $k \geq 1$ ,

$$\frac{\lambda_k(\pi^{(n)})}{n} \xrightarrow[n \xrightarrow{\text{p.s.}} \infty]{} Y_k$$

où les  $Y_k$  sont des variables aléatoires dans  $[0, 1]$ , avec  $\sum_{k=1}^{\infty} Y_k \leq 1$ . La loi de ces fréquences limites sera évoquée à la toute fin du texte.

### 1. LES PARAMÈTRES $\theta$ ET $\alpha$

Lorsqu'un nouvel individu  $n + 1$  arrive dans une population de taille  $n$  partitionnée suivant  $\pi^{(n)}$ , deux facteurs le poussent à créer un nouveau groupe :

- l'ambition *individuelle*  $\theta$  : l'individu  $n + 1$  a une propension naturelle à créer son propre groupe.

- l'ambition *induite*  $\alpha$  : chaque groupe  $\pi_k^{(n)}$  déjà présent montre à  $n+1$  que l'on peut créer sans risque son propre groupe, et ceci le pousse dans cette direction.

Si  $\pi^{(n)} = \pi = (\pi_1, \dots, \pi_\ell)$  est fixée dans  $\mathfrak{P}(n)$ , il existe  $\ell+1$  partitions  $\Pi \in \mathfrak{P}(n+1)$  telles que les parts de  $\pi$  sont les intersections non vides des parts de  $\Pi$  avec  $[1, n]$  :

- les successeurs  $\pi[k] = (\pi_1, \dots, \pi_k \sqcup \{n+1\}, \dots, \pi_\ell)$ , obtenus en rajoutant  $n+1$  à l'une des parts de  $\pi$  ;
- le successeur  $\pi[\ell+1] = (\pi_1, \dots, \pi_\ell, \{n+1\})$ , obtenu en créant un nouveau groupe  $\{n+1\}$ .

Par exemple, si  $\pi$  est la partition de l'introduction, alors  $\pi[2] = (\{1, 3, 7\}, \{2, 10\}, \{4, 5, 8, 9\}, \{6\})$ , et  $\pi[5] = (\{1, 3, 7\}, \{2\}, \{4, 5, 8, 9\}, \{6\}, \{10\})$ .

Si l'on veut prendre en compte les deux paramètres d'ambition  $\theta$  et  $\alpha$ , il est naturel de demander que la probabilité conditionnelle pour obtenir  $\pi^{(n+1)} = \pi[\ell+1]$  sachant  $\pi^{(n)} = \pi$  soit proportionnelle à  $\theta + \alpha \ell(\pi)$ . Par ailleurs, pour  $k \in [1, \ell]$ , il est naturel de demander que la probabilité conditionnelle pour obtenir  $\pi^{(n)} = \pi[k]$  sachant  $\pi^{(n)} = \pi$  soit une fonction croissante de la taille  $c_k$  de la part  $\pi_k$ . Ainsi, s'il ne crée pas son propre groupe, alors  $n+1$  a tendance à rejoindre l'un des plus grands groupes déjà existants. Ceci motive la définition suivante :

**Définition 1.** On fixe deux paramètres  $\theta > 0$  et  $\alpha \in [0, 1)$ . Soit  $\mathfrak{P} = \bigsqcup_{n=1}^{\infty} \mathfrak{P}(n)$ . La suite de partitions aléatoires  $(\pi^{(n)})_{n \geq 1}$  de paramètres  $(\theta, \alpha)$  est la chaîne de Markov sur  $\mathfrak{P}$  :

- d'état initial  $\pi^{(1)} = (\{1\})$  (l'unique élément de  $\mathfrak{P}(1)$ ) ;
- telle que  $\pi^{(n)} \in \mathfrak{P}(n)$  pour tout  $n \geq 1$  ;
- dont le noyau de transition est défini pour  $\pi$  de taille  $n$  et avec  $\ell$  parts par :

$$P(\pi, \pi[\ell+1]) = \frac{\theta + \alpha \ell}{\theta + n} \quad ; \quad P(\pi, \pi[k]) = \frac{c_k(\pi) - \alpha}{\theta + n} \quad \text{si } 1 \leq k \leq \ell.$$

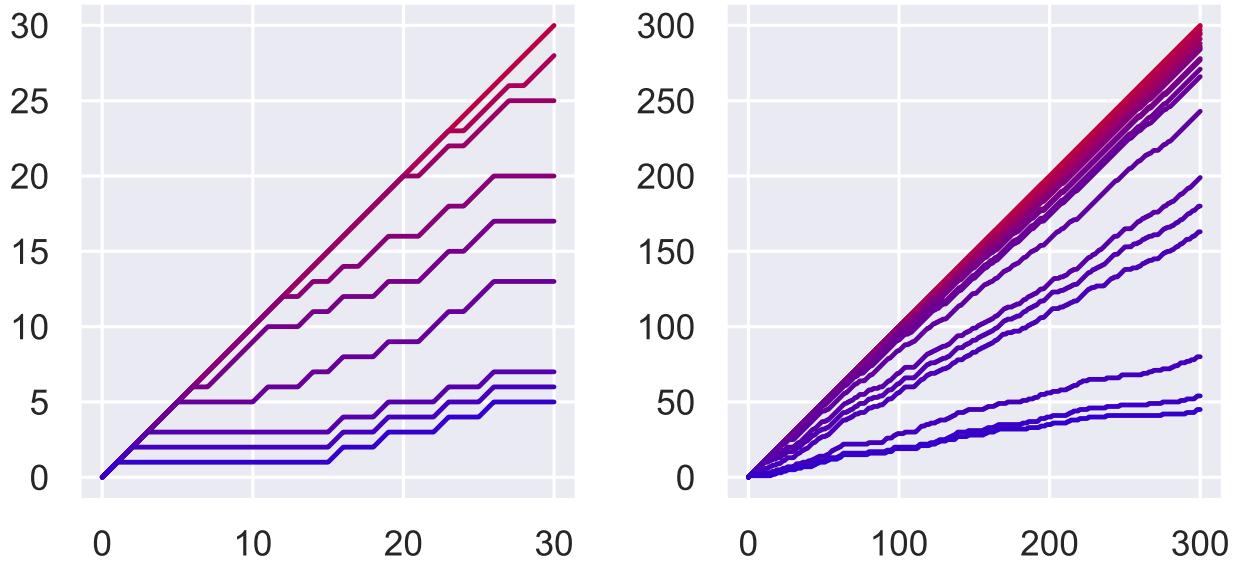


FIG. 1. Représentation graphique de deux suites cohérentes de partitions.

On peut représenter graphiquement une suite cohérente  $(\pi^{(n)})_{n \geq 1}$  comme suit. Pour tout  $k \geq 1$ , la quantité

$$c_k(\pi^{(n)}) = \begin{cases} \text{taille de la } k\text{-ième part de } \pi^{(n)} & \text{si } \ell(\pi^{(n)}) \geq k, \\ 0 & \text{si } \ell(\pi^{(n)}) < k \end{cases}$$

est croissante avec  $n$ , et pour tout  $n \geq 1$ , une unique quantité  $c_k(\pi^{(n+1)})$  est plus grande d'une unité que  $c_k(\pi^{(n)})$  (celle telle que  $n + 1$  appartient à la  $k$ -ième part de  $\pi^{(n+1)}$ ). Par conséquent, si l'on connaît toutes les suites  $(c_k(\pi^{(n)}))_{n \in [1, N]}$ , alors on connaît entièrement  $(\pi^{(n)})_{n \in [1, N]}$ . Une représentation assez intuitive de cette suite cohérente de partitions est donc donnée par le tracé de toutes les fonctions

$$n \in [1, N] \mapsto c_1(\pi^{(n)}) + c_2(\pi^{(n)}) + \cdots + c_k(\pi^{(n)})$$

pour  $k \leq \ell(\pi^{(n)})$ . L'espace entre deux courbes consécutives représente alors la taille  $c_k(\pi^{(n)})$  de la  $k$ -ième part, qui croît avec  $n$ .

On a dessiné sur la Figure 1 deux tirages de la chaîne de paramètres  $\theta = 1$  et  $\alpha = 0.3$  : l'un jusqu'à  $N = 30$ , et l'autre jusqu'à  $N = 300$ . Sur le second graphe, il apparaît assez clairement que pour tout  $k \geq 1$ , la proportion  $\frac{c_k(\pi^{(n)})}{n}$  d'individus dans le  $k$ -ième groupe créé tend vers une limite. L'objectif de la suite de ce texte est de comprendre ce résultat asymptotique.

**Remarque 2.** *Dans la suite, on ne s'intéressera pas au nombre  $\ell(\pi^{(n)})$  de groupes créé au temps  $n$ . On peut néanmoins montrer que, au sens de la convergence presque sûre :*

$$\ell(\pi^{(n)}) \underset{n \rightarrow \infty}{\simeq} \begin{cases} \theta \log n & \text{si } \alpha = 0, \\ S_{\theta, \alpha} n^{\alpha} & \text{si } \alpha > 0, \end{cases}$$

où  $S_{\theta, \alpha}$  est une certaine variable aléatoire.

## 2. FRÉQUENCES LIMITES DES PARTS DE PARTITIONS ÉCHANGEABLES

Supposons donnée une suite cohérente de partitions aléatoires  $(\pi^{(n)})_{n \geq 1}$ , définie sur un espace de probabilités  $(\Omega, \mathcal{F}, \mathbb{P})$ . On notera  $\mathbb{P}_n$  la loi de  $\pi^{(n)}$  :

$$\forall \pi \in \mathfrak{P}(n), \quad \mathbb{P}_n[\pi] = \mathbb{P}[\pi^{(n)} = \pi].$$

Si  $(\pi_1, \pi_2, \dots, \pi_\ell) = \pi \in \mathfrak{P}(n)$  et  $\sigma \in \mathfrak{S}(n)$  est une permutation de taille  $n$ , notons  $\sigma(\pi)$  la partition de taille  $n$  dont les parts sont  $(\sigma(\pi_1), \sigma(\pi_2), \dots, \sigma(\pi_\ell))$ .

**Définition 3.** *La suite cohérente  $(\pi^{(n)})_{n \geq 1}$  est dite échangeable si, pour tout  $n \geq 1$  et toute permutation  $\sigma \in \mathfrak{S}(n)$ , les deux partitions  $\pi^{(n)}$  et  $\sigma(\pi^{(n)})$  ont la même loi.*

**Théorème 4.** *La chaîne de Markov de paramètres  $(\theta, \alpha)$  donne une suite  $(\pi^{(n)})_{n \geq 1}$  qui est échangeable.*

*Démonstration.* Si  $\pi, \pi' \in \mathfrak{P}(n)$ , alors il existe une permutation  $\sigma \in \mathfrak{S}(n)$  telle que  $\sigma(\pi) = \pi'$  si et seulement si les parts de  $\pi$  et de  $\pi'$  ont les mêmes longueurs, à réordonnement près :

$$\lambda(\pi) = \lambda(\pi').$$

Une suite cohérente est donc échangeable si et seulement si  $\mathbb{P}_n[\pi]$  est une fonction de la signature  $\lambda(\pi)$ , pour tout  $n \geq 1$ . Établissons ceci pour la chaîne de Markov  $(\pi^{(n)})_{n \geq 1}$  de paramètres  $(\theta, \alpha)$ . Il suffit de voir que si  $\pi \in \mathfrak{P}(n)$  a pour liste de tailles des parts  $c(\pi) = (c_1, \dots, c_\ell)$ , alors

$$(1) \quad \mathbb{P}_n[\pi] = \frac{\alpha^\ell}{\theta^{\uparrow n}} \left( \frac{\theta}{\alpha} \right)^{\uparrow \ell} \prod_{k=1}^{\ell} (1 - \alpha)^{\uparrow c_k - 1},$$

où  $x^{\uparrow m} = x(x+1)\cdots(x+m-1)$  (avec par convention  $x^{\uparrow 0} = 1$ ). En effet, la fonction ci-dessus est symétrique en  $(c_1, \dots, c_\ell)$ , donc elle ne dépend en fait que du réordonnement décroissant  $(\lambda_1, \dots, \lambda_\ell) = \lambda(\pi)$ .  $\square$

Dans ce qui suit, on se concentre sur la suite  $(\lambda^{(n)})_{n \geq 1}$  des signatures d'une suite échangeable  $(\pi^{(n)})_{n \geq 1} : \lambda^{(n)} = \lambda(\pi^{(n)})_{n \geq 1}$ , et chaque  $\lambda^{(n)}$  est un élément de l'ensemble  $\mathfrak{Y}(n)$  des suites finies décroissantes d'entiers dont la somme est égale à  $n$ . On note

$$\mathcal{F}_{-n} = \sigma(\lambda^{(n)}, \lambda^{(n+1)}, \lambda^{(n+2)}, \dots)$$

la tribu engendrée par les signatures des partitions de taille plus grande que  $n$  dans la suite échangeable. Par construction, chaque  $\mathcal{F}_{-n}$  est une sous-tribu de  $\mathcal{F}$ , et si  $l \leq m$  sont deux entiers négatifs, alors  $\mathcal{F}_l \subset \mathcal{F}_m$ . Autrement dit,  $(\mathcal{F}_l)_{l \leq -1}$  est une *filtration rétrograde* : c'est la même définition que pour une filtration d'un espace de probabilité, à ceci près que les indices des sous-tribus sont des entiers négatifs. Dans ce qui suit, on considérera également des *chaînes de Markov rétrogrades* indiquées par les entiers négatifs : ce sont des suites de variables aléatoires  $(Y_l)_{l \leq -1}$  à valeurs dans un ensemble dénombrable  $\mathfrak{Y}$ , telles qu'il existe une matrice stochastique  $Q$  sur  $\mathfrak{Y}$  avec

$$\mathbb{P}[Y_{l+1} = y | Y_l, Y_{l-1}, \dots] = Q(Y_l, y)$$

pour tout  $l \geq -2$ . L'équation ci-dessus est la même formule que pour une chaîne de Markov standard, mais avec des indices négatifs pour les variables.

**Proposition 5.** Fixons  $k \geq 1$ , et notons

$$V_{-n,k} = \frac{\lambda_1^{(n)} + \lambda_2^{(n)} + \dots + \lambda_k^{(n)}}{n},$$

avec par convention  $\pi_j^{(n)} = \emptyset$  et  $\lambda_j^{(n)} = 0$  si  $j > \ell(\pi^{(n)})$ . La variable  $V_{-n,k}$  est la proportion d'entiers de  $[1, n]$  qui appartiennent aux  $k$  plus grandes parts de  $\pi^{(n)}$ . La suite  $(V_{l,k})_{l \leq -1}$  est une sous-martingale rétrograde pour la filtration  $(\mathcal{F}_l)_{l \leq -1}$  :

$$\forall l \leq -1, \quad \mathbb{E}[V_{l,k} | \mathcal{F}_{l-1}] \geq V_{l-1,k}.$$

Pour démontrer ceci, introduisons la notion d'*effacement aléatoire*. Si  $\Pi$  est une partition de taille  $n+1$ , son effacement aléatoire est la partition  $\pi \in \mathfrak{P}(n)$  obtenue :

- en choisissant aléatoirement  $X_{n+1} \in [1, n+1]$  de loi uniforme, indépendamment de  $\Pi$  ;
- en retirant  $X_{n+1}$  de la part de  $\Pi$  correspondante (supprimant la part si c'était  $\{X_{n+1}\}$ ) ;
- et en utilisant l'unique bijection croissante  $[1, n+1] \setminus \{X_{n+1}\} \rightarrow [1, n]$  pour transformer la liste de parts restantes en une partition de  $[1, n]$ .

Notons cette construction  $\pi = E(\Pi)$ . Par exemple, si  $\Pi = (\{1, 3, 7\}, \{2, 10\}, \{4, 5, 8, 9\}, \{6\})$  et si l'on tire  $X_{10} = 5$ , alors  $\pi = (\{1, 3, 6\}, \{2, 9\}, \{4, 7, 8\}, \{5\})$ .

**Lemme 6.** Si  $(\pi^{(n)})_{n \geq 1}$  est une suite échangeable de partitions, alors  $(\lambda^{(-l)})_{l \leq -1}$  est une chaîne de Markov rétrograde sur  $\mathfrak{Y} = \bigsqcup_{n=1}^{\infty} \mathfrak{Y}(n)$ . Son noyau de transition est

$$(2) \quad Q(\Lambda, \mu) = \mathbb{P}[\lambda(E(\Pi)) = \mu]$$

où  $\Pi$  est une partition arbitraire de signature  $\Lambda$ .

*Esquisse de preuve.* On montre d'abord que conditionnellement à  $\mathcal{F}_{-n}$ , la loi de  $\pi^{(n)}$  est uniforme sur l'ensemble des partitions de  $[1, n]$  dont la signature est  $\lambda^{(n)}$ . Autrement dit, si  $\pi$  a signature  $\Lambda$ , alors

$$(3) \quad \mathbb{P}[\pi^{(n)} = \pi | \mathcal{F}_{-n}] = \frac{1_{(\lambda^{(n)} = \Lambda)}}{B_{n,\Lambda}},$$

où  $B_{n,\Lambda}$  est le nombre de partitions de  $[1, n]$  avec signature  $\Lambda$ . Ce nombre est donné par la formule :

$$(4) \quad B_{n,\Lambda} = \frac{n!}{\prod_{i=1}^s (i!)^{m_i} (m_i!)}$$

si  $\Lambda$  est une signature avec  $m_1$  entrées égales à 1,  $m_2$  entrées égales à 2, etc. de sorte que  $n = \sum_{i=1}^s i m_i$ . Ces nombres sont également en jeu dans le noyau de transition  $Q(\lambda, \mu)$  : si  $\Lambda = (s^{m_s}, (s-1)^{m_{s-1}}, \dots, 2^{m_2}, 1^{m_1})$  est la signature d'une partition  $\Pi$  et si

$$\mu = (s^{m_s}, \dots, r^{m_r-1}, (r-1)^{m_{r-1}+1}, \dots, 1^{m_1})$$

est la signature de  $\pi = E(\Pi)$ , alors

$$(5) \quad Q(\Lambda, \mu) = \frac{(m_{r-1} + 1) B_{n-1, \mu}}{B_{n, \Lambda}}.$$

Le lemme s'en déduit, en calculant d'abord la loi conditionnelle sachant  $\mathcal{F}_{-n}$  de  $\pi^{(n-1)}$ , puis celle de  $\lambda^{(n-1)}$ .  $\square$

*Preuve de la Proposition 5.* Notons  $X_{n+1}$  une variable uniforme sur  $[1, n+1]$  et indépendante de  $\mathcal{G} = \sigma(\pi^{(n+1)}, \mathcal{F}_{-(n+1)})$ . Pour tous indices  $\rho(1) \neq \rho(2) \neq \dots \neq \rho(k)$ ,

$$(6) \quad \left( |\pi_{\rho(1)}^{(n+1)}| + \dots + |\pi_{\rho(k)}^{(n+1)}| \right) - 1_{(X_{n+1} \in \pi_{\rho(1)}^{(n+1)} \sqcup \dots \sqcup \pi_{\rho(k)}^{(n+1)})} = |E(\pi^{(n+1)})_{\rho(1)}| + \dots + |E(\pi^{(n+1)})_{\rho(k)}|.$$

On choisit la permutation  $\rho$  de sorte que les parts  $\pi_{\rho(1)}^{(n+1)}, \dots, \pi_{\rho(k)}^{(n+1)}$  soient les  $k$  plus grandes :

$$|\pi_{\rho(1)}^{(n+1)}| + \dots + |\pi_{\rho(k)}^{(n+1)}| = \lambda_1^{(n+1)} + \dots + \lambda_k^{(n+1)} = (n+1) V_{-(n+1), k}.$$

Il suffit de connaître  $\pi^{(n+1)}$  pour choisir  $\rho$ , donc on peut supposer que  $\rho$  est  $\mathcal{G}$ -mesurable, et en particulier indépendante de  $X_{n+1}$ . Par conséquent,

$$X_{n+1} \text{ et } (\pi_{\rho(1)}^{(n+1)}, \dots, \pi_{\rho(k)}^{(n+1)}) \text{ sont indépendants.}$$

En prenant l'espérance conditionnelle de (6) sachant  $\mathcal{F}_{-(n+1)}$ , on obtient donc :

$$(7) \quad n V_{-(n+1), k} = \mathbb{E}[|E(\pi^{(n+1)})_{\rho(1)}| + \dots + |E(\pi^{(n+1)})_{\rho(k)}| \mid \mathcal{F}_{-(n+1)}]$$

$$(8) \quad \leq \mathbb{E}[\lambda_1(E(\pi^{(n+1)})) + \dots + \lambda_k(E(\pi^{(n+1)})) \mid \mathcal{F}_{-(n+1)}] = \mathbb{E}[n V_{-n, k} \mid \mathcal{F}_{-(n+1)}].$$

en utilisant le Lemme 6 pour établir l'égalité sur la seconde ligne.  $\square$

L'inégalité du nombre de montées est valable pour les sous-martingales rétrogrades, avec la même preuve que dans le cas non rétrograde. Comme  $(V_{l,k})_{l \leq -1}$  est une suite bornée entre 0 et 1, elle n'a donc presque sûrement qu'un nombre fini de montées entre deux niveaux  $a$  et  $b$ , pour tous niveaux  $a < b$ . Ceci implique comme dans le cas standard la convergence presque sûre :

$$\lim_{n \rightarrow \infty} \frac{V_{-n, k}}{n} = V_k$$

pour une certaine variable aléatoire  $V_k \in [0, 1]$ . En posant  $Y_k = V_k - V_{k-1}$ , on obtient donc le résultat annoncé dans l'introduction :

**Théorème 7.** *Si  $(\lambda^{(n)})_{n \geq 1}$  est la suite des signatures d'une suite échangeable de partitions, alors pour tout  $k \geq 1$ ,*

$$\frac{\lambda_k^{(n)}}{n} \xrightarrow{\text{p.s.}} Y_k$$

pour certaines variables aléatoires  $Y_k$  avec  $\sum_{k=1}^{\infty} Y_k \leq 1$ .

En particulier, le théorème s'applique aux chaînes de Markov introduites par la Définition 1. Si l'on revient à la Figure 1, notons qu'on avait conjecturé la convergence presque sûre de  $\frac{c_k(\pi^n)}{n}$ , ce qui diffère de la convergence après réordonnement décroissant des fréquences  $\frac{\lambda_k(\pi^n)}{n}$ . Le résultat suivant, dont la démonstration est simple mais assez longue, décrit les limites des fréquences non réordonnées :

**Théorème 8.** Notons  $(W_k)_{k \geq 1}$  une suite de variables aléatoires indépendantes, avec chaque  $W_k$  qui suit une loi beta de paramètres  $(1 - \alpha, \theta + k\alpha)$  :

$$W_k \sim 1_{(x \in [0,1])} \frac{\Gamma(1 + \theta + (k - 1)\alpha)}{\Gamma(1 - \alpha) \Gamma(\theta + k\alpha)} x^{-\alpha} (1 - x)^{\theta + k\alpha - 1} dx.$$

On pose  $X_k = (1 - W_1)(1 - W_2) \cdots (1 - W_{k-1})W_k$ , et on introduit également une suite  $(U^{(n)})_{n \geq 1}$  de variables uniformes sur  $[0, 1]$  et indépendantes entre elles et de  $(W_k)_{k \geq 1}$ .

(1) Définissons une suite cohérente  $(\pi^{(n)})_{n \geq 1}$  de partitions aléatoires par la récurrence :

$$\pi^{(n+1)} = \begin{cases} \pi^{(n)}[k] & \text{si } X_1 + \cdots + X_{k-1} \leq U^{(n)} < X_1 + \cdots + X_k, \\ \pi^{(n)}[\ell(\pi^{(n)}) + 1] & \text{si } U^{(n)} \geq X_1 + \cdots + X_{\ell(\pi^{(n)})}. \end{cases}$$

Au sens de la Définition 1,  $(\pi^{(n)})_{n \geq 1}$  est une chaîne de Markov de paramètres  $(\theta, \alpha)$ .

(2) Cette chaîne vérifie  $\frac{c_k(\pi^{(n)})}{n} \rightarrow_{\text{p.s.}} X_k$ .

(3) La suite  $(Y_k)_{k \geq 1}$  est donc obtenue par réordonnement décroissant de la suite  $(X_k)_{k \geq 1}$ .

## QUESTIONS

- (1) Vérifier que le noyau de transition de la Définition 1 est bien une matrice stochastique : pour toute partition  $\pi \in \mathfrak{P}(n)$ , si  $\ell$  est le nombre de parts de  $\pi$ , alors  $\sum_{k=1}^{\ell+1} P(\pi, \pi[k]) = 1$ .
- (2) Écrire un programme `markov_partition(N, theta, alpha)` qui simule le  $N$ -ième état  $\pi^{(N)}$  de la chaîne de Markov de paramètres  $(\theta, \alpha)$ . En Python, on pourra représenter une partition  $\pi \in \mathfrak{P}(N)$  par une liste de listes  $\pi_k$  dont la somme des tailles vaut  $N$ . Expliquer pourquoi  $\pi^{(N)}$  détermine entièrement la suite  $(\pi^{(n)})_{n \in [1, N]}$ .
- (3) Écrire un autre programme `dessin_partition(pi)` qui prend en argument une partition  $\pi = \pi^{(N)}$  de taille  $N$ , et qui dessine la représentation graphique de la suite cohérente  $(\pi^{(n)})_{n \in [1, N]}$  correspondante, comme sur la Figure 1. Tester ce programme avec différentes valeurs pour les paramètres  $(\theta, \alpha)$ .
- (4) Illustrer par des programmes le résultat annoncé dans la Remarque 2.
- (5) On souhaite donner une preuve de la convergence  $\frac{\ell(\pi^{(n)})}{\log n} \rightarrow_{\text{p.s.}} \theta$  lorsque  $\alpha = 0$ .
  - Montrer que si  $\alpha = 0$ , alors  $\ell(\pi^{(n)})$  a la loi d'une somme de variables de Bernoulli indépendantes  $\sum_{k=0}^{n-1} B_k$ , avec  $\mathbb{P}[B_k = 1] = 1 - \mathbb{P}[B_k = 0] = \frac{\theta}{\theta+k}$ .
  - On considère des variables de Poisson indépendantes  $P_k$ , avec  $P_k \sim \text{Poisson}(\frac{\theta}{\theta+k})$ . Posons  $B_k = 1_{(P_k \geq 1)}$ . En utilisant le lemme de Borel–Cantelli, montrer que la suite

$$\left( \sum_{k=0}^{n-1} P_k - \sum_{k=0}^{n-1} B_k \right)_{n \geq 1}$$

reste bornée presque sûrement.

- En déduire le résultat souhaité, en considérant un processus de Poisson  $(\mathcal{P}_t)_{t \geq 0}$  d'intensité 1, qu'on regarde aux temps  $t_n = \sum_{k=0}^{n-1} \frac{\theta}{\theta+k}$ .

- (6) Montrer que deux partitions  $\pi$  et  $\pi'$  de taille  $n$  sont reliées par une permutation  $\sigma \in \mathfrak{S}(n)$  si et seulement si  $\lambda(\pi) = \lambda(\pi')$ .
- (7) Établir la Formule (1) pour la loi du  $n$ -ième état  $\pi^{(n)}$  d'une chaîne de paramètres  $(\theta, \alpha)$ . On pourra procéder par récurrence sur  $n$ , en séparant le cas où  $n + 1$  crée son propre groupe dans  $\pi^{(n+1)}$ , et le cas où  $n + 1$  rejoint une part de  $\pi^{(n)}$ .
- (8) On souhaite compléter la preuve du Lemme 6.
- Remarquons que la tribu  $\mathcal{F}_{-n}$  est engendrée par les événements  $A = A(\mu^{(n)}, \dots, \mu^{(n+k)})$  du type :
- $$\{\lambda(\pi^{(n)}) = \mu^{(n)}, \lambda(\pi^{(n+1)}) = \mu^{(n+1)}, \dots, \lambda(\pi^{(n+k)}) = \mu^{(n+k)}\},$$
- où  $\mu^{(n)}, \dots, \mu^{(n+k)}$  sont des signatures fixées de tailles  $n, \dots, n + k$ . En revenant alors à la définition de l'espérance conditionnelle, montrer que pour tout  $n \geq 1$  et toute partition  $\pi$  de signature  $\Lambda$ , l'Équation (3) est vérifiée.
- Établir la formule (4). On pourra construire une surjection de l'ensemble des permutations  $\mathfrak{S}(n)$  vers l'ensemble des partitions de  $[1, n]$  dont la signature est  $\Lambda$ .
  - Montrer que le noyau  $Q(\Lambda, \mu)$  défini par l'Équation (2) est donné par la formule explicite (5).
  - Déterminer les lois conditionnelles de  $\pi^{(n-1)}$  et de  $\lambda^{(n-1)}$  sachant  $\mathcal{F}_{-n}$ , et conclure.
- (9) Expliquer pourquoi l'espérance conditionnelle du terme de gauche de l'Équation (7) vaut  $n V_{-(n+1), k}$ , et pourquoi le Lemme 6 implique l'égalité dans l'Équation (8).
- (10) Avec les paramètres  $\theta = 1$  et  $\alpha = 0.5$ , vérifier expérimentalement que la loi de la limite  $Y_1$  de la proportion d'individus dans le plus grand groupe est la loi du maximum de la suite  $(X_k)_{k \geq 1}$  définie par le Théorème 8. On pourra utiliser `scipy.stats.beta(a, b).rvs()` pour engendrer une variable de loi beta de paramètres  $(a, b)$ .