

# Processus de Markov en temps continu et génétique des populations.

Feuille d'exercices 3 — 2014–2015

Nicolas Champagnat

## LA FORMULE D'ÉCHANTILLONNAGE D'EWENS

### Exercice 8 : Estimateur du maximum de vraisemblance pour le taux de mutation $\theta$

Pour  $\theta > 0$  fixé, on note  $\mathbb{P}_\theta$  la loi du coalescent de Kingman avec infinité d'allèles de taux de mutation  $\theta/2$ . On note  $K_n$  le nombre d'allèles observé dans un échantillon de  $n$  individus. On rappelle que dans ce cas la loi du spectre de fréquence est donnée par la formule d'échantillonnage d'Ewens.

1. En introduisant les événements  $\{\text{coal}\}$  et  $\{\text{mut}\}$  comme dans la preuve de la formule d'échantillonnage d'Ewens, montrer que pour tout  $1 \leq k \leq n$ ,

$$\mathbb{P}_\theta(K_n = k) = \frac{n-1}{\theta+n-1} \mathbb{P}_\theta(K_{n-1} = k) + \frac{\theta}{\theta+n-1} \mathbb{P}_\theta(K_{n-1} = k-1).$$

En déduire que  $K_n = A_1 + \dots + A_n$  en loi, où  $A_1, \dots, A_n$  sont des v.a. indépendantes et  $A_i$  a pour loi la loi de Bernoulli de paramètre  $\frac{\theta}{\theta+i-1}$ .

2. Calculer  $\mathbb{E}_\theta(K_n)$  et  $\text{Var}_\theta(K_n)$ , où  $\text{Var}_\theta$  désigne la variance sous la loi  $\mathbb{P}_\theta$ . Donner un équivalent de ces deux quantités lorsque  $n \rightarrow \infty$ .
3. Montrer que  $\frac{K_n}{\ln n}$  est un estimateur de  $\theta$  qui converge en probabilité. Calculer un équivalent de sa variance. Commenter sa vitesse de convergence.
4. Montrer que  $K_n$  est une statistique suffisante pour  $\theta$ , c'est-à-dire que pour tout  $k$ , la loi du spectre de fréquence  $B_1, \dots, B_n$  sachant  $K_n = k$  ne dépend pas de  $\theta$ .
5. On note  $L_n(\theta, k) = \mathbb{P}_\theta(K_n = k)$ . Montrer que

$$L_n(\theta, k) = C \frac{\theta^k}{\theta(\theta+1) \dots (\theta+n-1)}$$

pour une certaine constante  $C$  dépendant de  $k$  et  $n$ .

6. En dérivant  $\ln L_n(\theta, k)$  par rapport à  $\theta$ , montrer que l'estimateur du maximum de vraisemblance  $\hat{\theta}$  de  $\theta$  sachant  $K_n$  est donné par la relation

$$k = \sum_{i=0}^{n-1} \frac{\hat{\theta}}{\hat{\theta} + i} = \mathbb{E}_{\hat{\theta}}(K_n)$$

et qu'il est équivalent à l'estimateur de la question 3. lorsque  $n \rightarrow +\infty$ .

7. On note  $I_n(\theta)$  l'information de Fisher de  $K_n$ , définie par  $I_n(\theta) = \mathbb{E}_{\theta} \left[ \left( \frac{\partial}{\partial \theta} \ln L_n(\theta, K_n) \right)^2 \right]$ . Calculer  $I_n(\theta)$  et donner un équivalent de  $I_n(\theta)$  lorsque  $n \rightarrow +\infty$ .
8. (**théorème de Cramer-Rao**) Soit  $\tilde{\theta}$  un estimateur sans biais de  $\theta$  mesurable par rapport à  $K_n$ . En dérivant l'expression  $\mathbb{E}_{\theta}[\tilde{\theta}]$  par rapport à  $\theta$  et en utilisant l'inégalité de Cauchy-Schwartz, montrer que  $\text{Var}_{\theta}(\tilde{\theta}) \geq \frac{1}{I_n(\theta)}$ .
9. En déduire qu'il n'existe pas d'estimateur de  $\theta$  convergeant plus vite que  $\frac{K_n}{\ln n}$ .