

## Exercices, 3

### Correction Exo 12

1. On peut prendre

- $\mathcal{X} = \{1, \dots, d\}^{\mathbb{N}}$  (suites à valeurs dans  $\{1, \dots, d\}$ ).
- $\mathcal{A} = \sigma\left(\bigcup_{i=1}^{+\infty} \mathcal{P}(\{1, \dots, d\}^i) \times \{1, \dots, d\}^{\mathbb{N}-i}\right)$  (plus petite tribu rendant observable les réalisations de  $(X_1, \dots, X_N) = \pi_{1:N}(X_1, \dots, X_\infty)$ ).
- Loi de  $(X_{1:N}, N)$  donnée par  $N \sim \mathcal{P}(n)$ , et

$$\mathbb{P}(X_{1:N} = x_{1:k} \mid N = j) = \begin{cases} \prod_{i=1}^k p_{x_i} & \text{si } k = j \\ 0 & \text{sinon.} \end{cases}$$

2. Soit  $k \in \mathbb{N}$ ,  $E \mid N = k$  suit une loi multinomiale  $\mathcal{M}(k, \mathbf{p})$ , c'est à dire

$$\mathbb{P}(E = e_{1:d} \mid N = k) = \frac{k!}{e_1! \times \dots \times e_d!} \prod_{j=1}^d p_j^{e_j} \mathbb{1}_{\sum_{j=1}^d e_j = k}.$$

On en déduit

$$\begin{aligned} \mathbb{P}(E = e_{1:d}) &= \sum_{k=1}^{+\infty} e^{-n} \frac{n^k}{k!} \frac{k!}{e_1! \times \dots \times e_d!} \prod_{j=1}^d p_j^{e_j} \mathbb{1}_{\sum_{j=1}^d e_j = k} \\ &= \sum_{k=0}^{+\infty} \prod_{j=1}^d \frac{(np_j)^{e_j}}{e_j!} e^{-np_j} \mathbb{1}_{\sum_{j=1}^d e_j = k} \\ &= \prod_{j=1}^d \frac{(np_j)^{e_j}}{e_j!} e^{-np_j}. \end{aligned}$$

On en déduit que les  $E_j$  sont indépendantes, de loi de Poisson  $\mathcal{P}(np_j)$ .

3. Soit  $u \in \mathbb{R}^d$ .

$$\Phi_{Z_n}(u) = \mathbb{E}(e^{i\langle u, Z_n \rangle}) = \mathbb{E}\left(\prod_{j=1}^d e^{iu_j Z_{n,j}}\right) = \prod_{j=1}^d \mathbb{E}(e^{iu_j Z_{n,j}}) \rightarrow \prod_{j=1}^d \mathbb{E}e^{iu_j Z_j} = \mathbb{E}e^{i\langle u, Z \rangle},$$

où  $Z = (Z_1, \dots, Z_d)^T$ , avec les  $Z_j$  indépendantes.

4. On se place sous  $H_0$ . Soit  $j \in \{1, \dots, d\}$ , on peut écrire

$$E_j = \sum_{i=1}^n Y_i,$$

pour des  $Y_i$  i.i.d. de loi  $\mathcal{P}(p_{0,j})$ . Le théorème central limite donne alors (on a bien  $\mathbb{E}Y_1^2 = p_1 + p_1^2 < +\infty$ ),

$$\frac{\sqrt{n}}{\sqrt{p_{0,j}}} \left( \frac{E_j}{n} - p_{0,j} \right) \rightsquigarrow \mathcal{N}(0, 1),$$

ce dont on déduit que, pour tout  $j$ ,

$$Z_{n,j} := \frac{(E_j - np_{0,j})^2}{np_{0,j}} \rightsquigarrow \chi^2(1).$$

Les  $(Z_{n,j})_j$  étant indépendantes, de la partie précédente on déduit que

$$S := \sum_{j=1}^d \frac{(E_j - np_{0,j})^2}{np_{0,j}} \rightsquigarrow \chi^2(d).$$

Un test de niveau  $\alpha$  pour  $H_0 : \mathbf{p} = \mathbf{p}_0$  est alors

$$\mathbb{1}_{S \geq q_{1-\alpha}},$$

où  $q_{1-\alpha}$  est le  $1 - \alpha$ -quantile d'une  $\chi^2(d)$ .

5. Dans le cas où  $n$  est inconnu (mais supposé tendant vers  $+\infty$ ), on va essayer de remplacer  $n$  par  $N$ . On se place encore sous  $H_0$ , et commence par regarder

$$Z = (E_j - Np_{0,j})_{j=1,\dots,d} = (I_d - \mathbf{p}_0 \mathbf{1}^T)E,$$

où  $E$  est le vecteur des effectifs. En remarquant que  $(I_d - \mathbf{p}_0 \mathbf{1}^T)\mathbb{E}(E) = (I_d - \mathbf{p}_0 \mathbf{1}^T)((np_{0,j})_{j=1,\dots,d}) = 0$ , on en déduit que

$$\frac{1}{\sqrt{n}}Z = \frac{1}{\sqrt{n}}(I_d - \mathbf{p}_0 \mathbf{1}^T)(E - \mathbb{E}(E)) \rightsquigarrow (I_d - \mathbf{p}_0 \mathbf{1}^T)\mathcal{N}(0, \text{Diag}(\mathbf{p}_0)).$$

Un calcul matriciel donne

$$\begin{aligned} (I_d - \mathbf{p}_0 \mathbf{1}^T)\text{Diag}(\mathbf{p}_0)(I_d - \mathbf{1}\mathbf{p}_0^T) &= (\text{Diag}(\mathbf{p}_0) - \mathbf{p}_0 \mathbf{p}_0^T)(I_d - \mathbf{1}\mathbf{p}_0^T) \\ &= \text{Diag}(\mathbf{p}_0) - \mathbf{p}_0 \mathbf{p}_0^T - \mathbf{p}_0 \mathbf{p}_0^T + \mathbf{p}_0 \mathbf{p}_0^T \mathbf{1}\mathbf{p}_0^T \\ &= \text{Diag}(\mathbf{p}_0) - \mathbf{p}_0 \mathbf{p}_0^T. \end{aligned}$$

Comme pour un test du Chi-deux d'adéquation classique, on en déduit alors que

$$\text{Diag}((\mathbf{p}_0)^{-1/2})\frac{1}{\sqrt{n}}Z \rightsquigarrow \mathcal{N}(0, \pi_{\sqrt{\mathbf{p}_0^\perp}}),$$

et donc

$$\frac{1}{n} \left\| \text{Diag}((\mathbf{p}_0)^{-1/2})Z \right\|^2 \rightsquigarrow \chi^2(d-1),$$

en utilisant Cochran. Reste un dernier terme en  $n$  à faire disparaître. Pour cela on remarque que  $\frac{N}{n} \rightarrow 1$  en probabilité (loi des grands nombres), et une application du Lemme de Slutsky donne

$$\frac{1}{N} \left\| \text{Diag}((\mathbf{p}_0)^{-1/2})Z \right\|^2 \rightsquigarrow \chi^2(d-1).$$

En prenant comme statistique de test

$$\tilde{S} = \sum_{j=1}^d \frac{(E_j - Np_{0,j})^2}{Np_{0,j}},$$

un test de niveau asymptotique  $\alpha$  est alors  $\mathbb{1}_{\tilde{S} \geq q_{1-\alpha}}$ , où  $q_{1-\alpha}$  est le  $1 - \alpha$  quantile d'une  $\chi^2(d-1)$ .

### Correction Exo 13

Comme  $\text{Cov}(AX) = AA^T$ , si  $A \in O_d(\mathbb{R})$ ,  $AX \sim X$ . Il suffit alors d'appliquer le résultat de l'exercice 2 (un peu plus général), en prenant pour  $A$  des rotations pour deux coordonnées laissant invariant les autres coordonnées.

### Correction Exo 14

On commence par le cas  $d = 2$ . On prend alors comme vecteurs orthogonaux  $a = (1, 1)$  et  $b = (1, -1)$ , et on peut alors écrire, pour tous  $t_1, t_2 \in \mathbb{R}$ ,

$$\begin{aligned}\mathbb{E}(\exp(i(t_1X_1 + t_1X_2 + t_2X_1 - t_2X_2))) &= \mathbb{E}(\exp(i(t_1X_1 + t_1X_2))) \mathbb{E}(\exp(i(t_2X_1 - t_2X_2))) \\ &= \varphi_1(t_1)\varphi_2(t_1)\varphi_1(t_2)\varphi_2(-t_2),\end{aligned}$$

où  $\varphi_j$  est la fonction caractéristique de  $X_j$ . Par ailleurs, en exploitant directement l'indépendance des  $X_j$ , on a

$$\mathbb{E}(\exp(i(t_1X_1 + t_1X_2 + t_2X_1 - t_2X_2))) = \varphi_1(t_1 + t_2)\varphi_2(t_1 - t_2),$$

ce dont on déduit l'équation

$$\varphi_1(t_1 + t_2)\varphi_2(t_1 - t_2) = \varphi_1(t_1)\varphi_2(t_1)\varphi_1(t_2)\varphi_2(-t_2). \quad (1)$$

Les choix  $t_1 = t_2 = t$  et  $t = t_1 = -t_2$  donnent le système

$$\begin{aligned}\varphi_1(2t) &= \varphi_1(t)^2\varphi_2(t)\varphi_2(-t), \\ \varphi_2(2t) &= \varphi_2(t)^2\varphi_1(t)\varphi_1(-t).\end{aligned}$$

Par une récurrence immédiate, on en déduit que, pour tout  $n \geq 1$  et  $t \in \mathbb{R}$ ,

$$\varphi_1(t) = \prod_{j=1}^{4^n} \varphi_{\varepsilon_j}(\sigma_j 2^{-n}t),$$

où  $\varepsilon$  et  $\sigma$  sont des suites de  $4^n$  éléments à valeurs dans  $\{1, 2\}$  et  $\{-1, 1\}$ . Par continuité de  $\varphi_1$  en 0, on peut trouver  $r > 0$  tel que, pour tout  $|t| < r$ ,  $|\varphi(t) - 1| < 1$ . Pour de tels  $t$  on peut prendre les log (complexes), qu'on note  $\ell_j$ . Cela donne

$$\ell_1(t) = \sum_{j=1}^{4^n} \ell_{\varepsilon_j}(\sigma_j 2^{-n}t).$$

Or, pour  $j \in \llbracket 1; 4^n \rrbracket$ ,

$$\ell_{\varepsilon_j}(\sigma_j 2^{-n}t) = \log\left(1 - \frac{t^2}{2}4^{-n} + o_n(4^{-n})\right) = -\frac{t^2}{2}4^{-n} + o_n(4^{-n}),$$

en utilisant le fait que  $X$  est centrée et de variance 1. On en déduit que

$$\ell_1(t) = -\frac{t^2}{2} + o_n(1) = -\frac{t^2}{2}.$$

On a donc montré que pour tout  $t$  dans  $] -r, r[$ ,  $\varphi_1(t) = \exp(-t^2/2)$ . Notons  $R$  le rayon maximal pour lequel cela arrive, c'est à dire  $R = \sup \{r > 0 \mid \forall t \in ] -r; r[ \quad |\varphi_1(t) - 1| < 1\}$ . Si  $R < +\infty$ , comme  $|\exp(-R^2/2) - 1| < 1$ , par continuité de  $\varphi_1$  autour de  $\pm R$  on peut trouver  $\varepsilon$  tel que  $\forall |t| < R + \varepsilon \quad |\varphi_1(t) - 1| < 1$ , ce qui contredit la définition de  $R$ . On en déduit que  $R = +\infty$ , et donc que  $X_1 \sim \mathcal{N}(0, 1)$ . Pareillement on déduit  $X_2 \sim \mathcal{N}(0, 1)$ .

Pour le cas  $d$  quelconque, il suffit de regarder les vecteurs de type  $e_i + e_j$  et  $e_i - e_j$ , où les  $e_i$  sont les vecteurs de la base canonique.

**Remarque:** On peut prouver le Théorème de Darmois Skitovitch comme ceci, en remarquant que  $\varphi_1(t)$  se met sous la forme  $\varphi_1(t) = \prod_{j=1}^4 \varphi_{\varepsilon_j}(\sigma_j a_j t)$ , avec  $\sum_{j=1}^4 a_j^2 = 1$ .