

## MAP 311: Aléatoire PC 8

Marc Lelarge

20 juin 2016

### Exercice 1

Soit  $(X_n)_{n \geq 1}$  une suite de v.a. indépendantes et de même loi. On suppose que  $X_1$  est de carré intégrable, de moyenne  $m$  et de variance  $\sigma^2 > 0$ . On définit:

$$\hat{m}_n = \frac{X_1 + \dots + X_n}{n}, \quad \hat{\sigma}_n^2 = \frac{1}{n-1} \sum_{k=1}^n (X_k - \hat{m}_n)^2.$$

1. Justifier que  $\sqrt{n} \frac{\hat{m}_n - m}{\sigma}$  converge en loi vers  $\mathcal{N}(0, 1)$ .
2. En déduire un intervalle de confiance asymptotique pour  $m$  au niveau 95% (en supposant  $\sigma$  connu).
3. Montrer que  $\hat{\sigma}_n$  converge presque sûrement vers  $\sigma$ . L'estimateur  $\hat{\sigma}_n^2$  est-il sans biais? On pourra montrer que  $\frac{n-1}{n} \hat{\sigma}_n^2 = \frac{1}{n} \sum_{k=1}^n X_k^2 - \hat{m}_n^2$ .
4. Montrer que

$$\sqrt{n} \frac{\hat{m}_n - m}{\hat{\sigma}_n} \xrightarrow{\mathcal{L}} \mathcal{N}(0, 1).$$

5. En déduire un intervalle de confiance asymptotique pour  $m$  au niveau 95%.

### Solution.

1. TCL.
2. Soit  $z_{\alpha/2}$  le quantile d'ordre  $1 - \alpha/2$  de la loi normale  $\mathbb{P}(Z \geq z_{\alpha/2}) = \alpha/2$ . On a alors

$$\mathbb{P} \left( -z_{\alpha/2} \leq \sqrt{n} \frac{\hat{m}_n - m}{\sigma} \leq z_{\alpha/2} \right) \rightarrow \mathbb{P}(|Z| \leq z_{\alpha/2}) = 1 - \alpha.$$

L'intervalle  $\left[ \hat{m}_n - \frac{\sigma z_{\alpha/2}}{\sqrt{n}}, \hat{m}_n + \frac{\sigma z_{\alpha/2}}{\sqrt{n}} \right]$  est un intervalle de confiance asymptotique au niveau  $1 - \alpha$ . Pour  $\alpha = 0.005$ , on prend  $z_{\alpha/2} \approx 1.96$ .

3. On a

$$\hat{\sigma}_n^2 = \frac{1}{n} \sum_{k=1}^n X_k^2 - 2\hat{m}_n^2 + \hat{m}_n^2 = \frac{1}{n} \sum_{k=1}^n X_k^2 - \hat{m}_n^2.$$

Par la loi forte des grands nombres,  $\frac{1}{n} \sum_{k=1}^n X_k^2$  c.v. p.s. vers  $\mathbb{E}[X_1^2] = \sigma^2 + m^2$  et  $\hat{m}_n$  c.v. p.s. vers  $m$  donc  $\hat{\sigma}_n$  c.v. p.s. vers  $\sigma$ .

On a

$$\mathbb{E}[\hat{m}_n^2] = \frac{\sigma^2}{n} + m^2,$$

donc

$$\mathbb{E} \left[ \frac{n-1}{n} \hat{\sigma}_n^2 \right] = \sigma^2 + m^2 - (\sigma^2/n + m^2) = \frac{n-1}{n} \sigma^2,$$

donc  $\hat{\sigma}_n^2$  est un estimateur sans biais de la variance.

- Comme  $\hat{\sigma}_n$  converge en probabilité vers  $\sigma$ , on obtient le résultat en appliquant le théorème de Slutsky.
- Comme dans la question 2, l'intervalle  $\left[ \hat{m}_n - \frac{\hat{\sigma}_n z_{\alpha/2}}{\sqrt{n}}, \hat{m}_n + \frac{\hat{\sigma}_n z_{\alpha/2}}{\sqrt{n}} \right]$  est un intervalle de confiance asymptotique au niveau  $1 - \alpha$ .

### Exercice 2:

Le but de cet exercice est d'estimer un temps d'attente qui suit une loi exponentielle de paramètre  $\lambda > 0$  inconnu. Soit  $(E_i)_{i \geq 1}$  une suite de v.a.r. i.i.d. de loi exponentielle de paramètre  $\lambda > 0$  inconnu. On pose  $\hat{m}_n = \frac{E_1 + \dots + E_n}{n}$  et

$$\hat{\sigma}_n^2 = \frac{1}{n-1} \sum_{k=1}^n (E_k - \hat{m}_n)^2.$$

- Donner un intervalle de confiance asymptotique pour  $\frac{1}{\lambda}$  au niveau 95%. En déduire un intervalle de confiance asymptotique pour  $\lambda$  au niveau 95%.
- Appliquer la méthode delta avec la fonction  $f(x) = 1/x$ .

### Solution.

- Comme  $\mathbb{E}[E_1] = \frac{1}{\lambda}$ , par l'exercice précédent  $\left[ \hat{m}_n - \frac{\hat{\sigma}_n z_{\alpha/2}}{\sqrt{n}}, \hat{m}_n + \frac{\hat{\sigma}_n z_{\alpha/2}}{\sqrt{n}} \right]$  est un intervalle de confiance asymptotique pour  $\frac{1}{\lambda}$  au niveau  $1 - \alpha$ . On en déduit que

$$\left[ \frac{1}{\hat{m}_n + \frac{\hat{\sigma}_n z_{\alpha/2}}{\sqrt{n}}}, \frac{1}{\hat{m}_n - \frac{\hat{\sigma}_n z_{\alpha/2}}{\sqrt{n}}} \right]$$

est un intervalle de confiance pour  $\lambda$ .

- en appliquant la méthode delta avec la fonction  $f(x) = 1/x$ , on a  $\sqrt{n}(f(\hat{m}_n) - f(1/\lambda))$  qui converge en loi vers  $\mathcal{N}(0, (f'(1/\lambda))^2 \sigma^2)$ . Comme la variance de  $E_1$   $\sigma^2 = \frac{1}{\lambda^2}$  et  $f'(1/\lambda) = -\lambda^2$  pour  $\lambda > 0$ , on obtient:

$$\sigma \sqrt{n} \left( \frac{1}{\hat{m}_n} - \lambda \right) \xrightarrow{\mathcal{L}} \mathcal{N}(0, 1).$$

En appliquant le lemme de Slutsky, on en déduit que

$$\left[ \frac{1}{\hat{m}_n - \frac{z_{\alpha/2}}{\hat{\sigma}_n \sqrt{n}}}, \frac{1}{\hat{m}_n + \frac{z_{\alpha/2}}{\hat{\sigma}_n \sqrt{n}}} \right]$$

est un intervalle de confiance asymptotique pour  $\lambda$  au niveau  $1 - \alpha$ .

**Exercice 3:** Soit  $(X_n)_{n \geq 1}$  des v.a.r. i.i.d. de loi uniforme sur  $[0, \theta]$ .

1. Étudier la convergence, le biais, la variance, l'écart quadratique moyen, et la fluctuation asymptotique de l'estimateur  $m_n = 2(X_1 + \dots + X_n)/n$  de  $\theta$ . Construire un intervalle de confiance asymptotique;
2. Montrer que l'estimateur  $M_n = \max(X_1, \dots, X_n)$  de  $\theta$  a pour densité  $(n/\theta)(x/\theta)^{n-1}\mathbf{1}_{[0,\theta]}(x)$  puis calculer  $\mathbb{E}(M_n)$  et  $\text{Var}(M_n)$ . Comparer avec l'estimateur moyenne empirique  $m_n$ ;
3. Montrer que  $M_n \xrightarrow{\mathbb{P}} \theta$ . Montrer de deux manières différentes que la convergence est p.s.;
4. Montrer que  $W_n = n(M_n/\theta - 1)$  converge en loi quand  $n \rightarrow \infty$ , et déterminer la limite. Construire un intervalle de confiance asymptotique.
5. Montrer que  $M_n$  est l'estimateur de maximum de vraisemblance de  $\theta$ .

**Solution.** Pour un estimateur  $\hat{\theta}_n$  de  $\theta$ , l'écart quadratique moyen possède toujours une décomposition (carré-du-)biais-variance :  $\mathbb{E}((\hat{\theta}_n - \theta)^2) = (\mathbb{E}(\hat{\theta}_n) - \theta)^2 + \text{Var}(\hat{\theta}_n)$ . Cela découle du théorème de Pythagore dans  $L^2$ :  $\mathbb{E}((Z - \theta)^2) = \text{Var}(Z) + (\mathbb{E}(Z) - \theta)^2$ . Note:  $\text{Var}(Z) = \arg \min_{c \in \mathbb{R}} \mathbb{E}((Z - c)^2)$ .

1. La LGN entraîne que  $m_n \rightarrow \theta$  p.s. L'estimateur n'est pas biaisé :  $\mathbb{E}(m_n) = \theta$ . La variance est égale à l'écart quadratique moyen, et vaut  $\frac{4}{n}\text{Var}(X_1) = \frac{\theta^2}{3n} = \mathcal{O}(\frac{1}{n})$ . La fluctuation asymptotique est gaussienne, de vitesse  $\sqrt{n}$ , car par le TCL,  $\sqrt{n}(m_n - \theta) \xrightarrow{\text{loi}} \mathcal{N}(0, \frac{\theta^2}{3})$ . L'intervalle de confiance asymptotique s'obtient avec le résultat de fluctuation. Nul besoin du lemme de Slutsky car l'inversion en  $\theta$  est facile ici: si  $Z \sim \mathcal{N}(0, 1)$  et  $J \subset \mathbb{R}$ ,

$$\mathbb{P}(Z \in J) \approx \mathbb{P}\left(\frac{\sqrt{3n}}{\theta}(m_n - \theta) \in J\right) = \mathbb{P}(\theta \in m_n/(1 + (3n)^{-1/2}J))$$

Tout intervalle  $J$  tel que  $\mathbb{P}(Z \in J) = 1 - \alpha$  fournit l'intervalle de confiance  $I = m_n/(1 + (3n)^{-1/2}J)$  de niveau  $1 - \alpha$  pour  $\theta$ . On peut chercher à choisir  $J$  de sorte que  $I$  soit petit;

2.  $F_{M_n}(x) = (x/\theta)^n \mathbf{1}_{[0,\theta]} + \mathbf{1}_{] \theta, \infty[}$  et  $f_{M_n}(x) = F'_{M_n}(x) = (n/\theta)(x/\theta)^{n-1} \mathbf{1}_{[0,\theta]}(x)$ . Par conséquent,  $\mathbb{E}(M_n) = \frac{n}{n+1}\theta$  et  $\text{Var}(M_n) = \frac{n}{(n+1)^2(n+2)}\theta^2 = \mathcal{O}(\frac{1}{n^2})$ . L'estimateur  $M_n$  est biaisé (et asymptotiquement sans biais), mais il est plus rapide que  $m_n$ . L'écart quadratique moyen de  $M_n$  vaut  $(\mathbb{E}(M_n) - \theta)^2 + \text{Var}(M_n) = \frac{\theta^2}{(n+1)^2} + \frac{n\theta^2}{(n+1)^2(n+2)} = \frac{2}{(n+1)(n+2)}\theta^2 = \mathcal{O}(\frac{1}{n^2})$ ;
3. Pour tout  $\varepsilon > 0$  assez petit,  $\mathbb{P}(|M_n - \theta| > \varepsilon) = \mathbb{P}(M_n < \theta - \varepsilon) = ((\theta - \varepsilon)/\theta)^n$ . Cela donne la convergence en probabilité de  $M_n$  vers  $\theta$ , et même la convergence p.s. en utilisant le lemme de Borel-Cantelli pour  $\varepsilon$  fixé (il faut ensuite poser  $\varepsilon = 1/k$  et faire  $\cap_k$ ). Alternativement, comme p.s.  $(M_n)_{n \geq 1}$  est positive croissante et majorée par  $\theta$ , elle converge p.s. et dans  $L^1$  vers une v.a.r.  $\leq \theta$  de moyenne  $\lim_{n \rightarrow \infty} \mathbb{E}(M_n) = \theta$ , qui est forcément égale p.s. à  $\theta$ ;
4.  $F_{W_n}(x) = \mathbb{P}(M_n \leq \theta(1 + x/n))$ . Ainsi,  $F_{W_n}(x) \rightarrow 1$  si  $x > 0$ , tandis que si  $x \leq 0$  alors, pour  $n \gg 1$ ,  $F_{W_n}(x) = (1 + x/n)^n \rightarrow e^x$ . Ainsi,  $W_n \rightarrow -W$  en loi quand  $n \rightarrow \infty$ , o  $W \sim \text{Exp}(1)$ . L'intervalle de confiance asymptotique s'obtient avec la fluctuation: Pour tout  $J \subset \mathbb{R}$ , on a

$$\mathbb{P}(-W \in J) \approx \mathbb{P}(W_n \in J) = \mathbb{P}(\theta \in M_n/(1 + J/n)).$$

N'importe quel intervalle  $J$  tel que  $\mathbb{P}(-W \in J) = 1 - \alpha$  fournit l'intervalle de confiance asymptotique  $I = M_n/(1 + J/n)$  pour  $\theta$ . On peut choisir  $J$  tel que  $I$  soit petit.

5. Pour tout réel  $\theta \geq 0$ , on a  $L(\theta; X_1, \dots, X_n) = \theta^{-n} \prod_{k=1}^n \mathbf{1}_{[0, \theta]}(X_k)$ , qui vaut 0 si  $\theta < M_n$  et qui décroît comme  $\theta^{-n}$  si  $\theta \geq M_n$ . Donc  $M_n = \arg \max_{\theta \geq 0} L(\theta; X_1, \dots, X_n)$ .

**Exercice 4: Théorème de Cochran**

Soit  $X$  un vecteur colonne aléatoire de  $\mathbb{R}^n$  de loi  $\mathcal{N}(m, \sigma^2 I_n)$ , et  $\mathbb{R}^n = E_1 \oplus \dots \oplus E_p$  une décomposition de  $\mathbb{R}^n$  en somme directe de  $p$  sous-espaces vectoriels orthogonaux de dimensions  $d_1, \dots, d_p$  avec  $d_1 + \dots + d_p = n$ . Soit  $\mathbf{P}_k$  la matrice du projecteur orthogonal sur  $E_k$  et  $Y_k := \mathbf{P}_k X$  la projection orthogonale de  $X$  sur  $E_k$ .

1. Montrer que les projections  $(Y_1, \dots, Y_p)$  sont indépendantes et  $Y_k \sim \mathcal{N}(\mathbf{P}_k m, \sigma^2 \mathbf{P}_k)$ ;
2. Montrer que  $\|Y_1 - \mathbf{P}_1 m\|^2, \dots, \|Y_p - \mathbf{P}_p m\|^2$  sont indépendantes et  $\sigma^{-2} \|Y_k - \mathbf{P}_k m\|^2 \sim \chi^2(d_k)$ .

**Solution.**

1. On se ramène tout d'abord au cas où  $m = 0$  par translation. Le vecteur aléatoire  $Y = (Y_1, \dots, Y_p)^\top$  de  $\mathbb{R}^{np}$  s'écrit  $Y = AX$  où  $A$  est la matrice de dimension  $np \times n$

$$A = \begin{pmatrix} \mathbf{P}_1 \\ \vdots \\ \mathbf{P}_p \end{pmatrix}.$$

Il en découle que  $Y$  suit la loi  $\mathcal{N}(0, \sigma^2 AA^\top)$ . Pour tout  $1 \leq i \leq p$ , on a  $\mathbf{P}_i = \mathbf{P}_i^\top = \mathbf{P}_i^2$ . De plus,  $\mathbf{P}_i \mathbf{P}_j = 0$  si  $1 \leq i \neq j \leq p$  car  $E_i \perp E_j$ . Par conséquent,  $AA^\top = \text{Diag}(\mathbf{P}_1, \dots, \mathbf{P}_p)$  est diagonale par blocs. Il en découle que  $Y_1, \dots, Y_p$  sont des vecteurs gaussiens indépendants avec  $Y_k \sim \mathcal{N}(0, \sigma^2 \mathbf{P}_k)$  pour tout  $1 \leq k \leq p$ .

2. Les variables aléatoires  $\|Y_1\|^2, \dots, \|Y_p\|^2$  sont indépendantes. Il reste à déterminer leur loi. Pour tout  $1 \leq k \leq p$ , soit  $B_k = \{e_{k,1}, \dots, e_{k,d_k}\}$  une base orthonormée de  $E_k$ . La réunion  $B_1 \cup \dots \cup B_p$  constitue une base orthonormée de  $\mathbb{R}^n$ . Le vecteur  $X$  s'écrit dans cette base  $X = Y_1 + \dots + Y_p$  avec  $Y_k = a_{k,1}e_{k,1} + \dots + a_{k,d_k}e_{k,d_k}$  où  $a_{k,i} = \langle X, e_{k,i} \rangle$ . L'invariance par transformation orthogonale de la loi  $\mathcal{N}(0, \sigma^2 I_n)$  implique que les variables aléatoires  $a_{k,i}$  sont indépendantes et de même loi  $\mathcal{N}(0, \sigma^2)$ . Il en découle que  $\sigma^{-2} \|Y_k\|^2 = \sigma^{-2} (a_{k,1}^2 + \dots + a_{k,d_k}^2) \sim \chi^2(d_k)$  pour tout  $1 \leq k \leq p$ , ce qui achève la preuve du théorème de Cochran.

**Exercice 5: Échantillons gaussiens**

Soit  $(X_1, \dots, X_n)$  un échantillon de loi  $\mathcal{N}(m, \sigma^2)$ . On lui associe la *moyenne empirique* et la *variance empirique* définies respectivement par

$$\bar{X}_n = \frac{1}{n} \sum_{k=1}^n X_k \quad \text{et} \quad \sigma_n^2 = \frac{1}{n-1} \sum_{k=1}^n (X_k - \bar{X}_n)^2.$$

Montrer que les variables aléatoires  $\bar{X}_n$  et  $\sigma_n^2$  sont indépendantes avec

$$\bar{X}_n \sim \mathcal{N}\left(m, \frac{\sigma^2}{n}\right) \quad \text{et} \quad \frac{(n-1)}{\sigma^2} \sigma_n^2 \sim \chi^2(n-1).$$

**Solution.** Soit  $\mathbf{1}_n$  le vecteur de  $\mathbb{R}^n$  dont toutes les coordonnées sont égales à 1, et soit  $E_1 = \{a\mathbf{1}_n; a \in \mathbb{R}\}$  le sous-espace vectoriel de  $\mathbb{R}^n$  engendré par  $\mathbf{1}_n$ . La matrice de la projection orthogonale sur  $E_1$  est donnée par

$$\mathbf{P}_1 = \frac{\mathbf{1}_n \mathbf{1}_n^\top}{\|\mathbf{1}_n\|^2} = \frac{1}{n} \mathbf{1}_n \mathbf{1}_n^\top.$$

Le sous-espace  $E_2 = E_1^\perp$  est de dimension  $n - 1$  et la matrice de la projection orthogonale sur  $E_2$  est  $\mathbf{P}_2 = \mathbf{I}_n - \mathbf{P}_1$ . On a  $Y_1 = \mathbf{P}_1 X = \bar{X}_n \mathbf{1}_n$  et  $Y_2 = \mathbf{P}_2 X = (X_1 - \bar{X}_n, \dots, X_n - \bar{X}_n)^\top$ , ce qui entraîne  $\|Y_2\|^2 = (n - 1)\sigma_n^2$ . Le théorème de Cochran permet de conclure.

### Exercice 6: Test d'aquéquation du chi-deux

Il s'agit d'un test non-paramétrique classique.

- Soient  $p = (p_1, \dots, p_k)$ ,  $q = (q_1, \dots, q_k)$  des lois discrètes avec  $p_i > 0$  pour tout  $1 \leq i \leq k$ , et

$$D(p, q) := \sum_{i=1}^k \frac{(p_i - q_i)^2}{p_i}.$$

Montrer que  $D(p, q) \geq 0$  avec égalité ssi  $p = q$ . S'agit-il d'une distance?

- Soit  $X_1, \dots, X_n$  un échantillon d'une loi discrète inconnue  $q = (q_1, \dots, q_k)$  sur  $\{1, \dots, k\}$ . On souhaite savoir si cette loi  $q$  est égale à une loi discrète de référence  $p = (p_1, \dots, p_k)$  (qui est connue). Pour cela, on introduit les hypothèses statistiques antagonistes:

$$H_0 : p = q, \quad H_1 : p \neq q.$$

On introduit la statistique de test  $S_n = S(X_1, \dots, X_n)$  définie par

$$S_n := nD(p, \hat{q}) = n \sum_{i=1}^k \frac{(p_i - \hat{q}_i)^2}{p_i} = n \sum_{i=1}^k \frac{(n_i - N_i)^2}{n_i}$$

où

- $\hat{q} = (N_1/n, \dots, N_k/n)$  est l'estimateur empirique de  $q$ ;
- $N_i := \text{card}\{1 \leq m \leq n : X_m = i\} = \sum_{m=1}^n \mathbf{1}_{\{X_m=i\}}$  est l'effectif de  $i$  dans l'échantillon;
- $n_i := np_i$  est l'effectif théorique sous  $H_0$ .

En pratique, on calcule les  $n_i$  et les  $N_i$  (comptage) puis  $S_n$ . Montrer que

- si  $H_0$  est fautive alors  $S_n \rightarrow +\infty$  presque sûrement quand  $n \rightarrow \infty$ ;
- si  $H_0$  est vraie alors  $S_n \rightarrow \chi^2(k - 1)$  en loi quand  $n \rightarrow \infty$ .

Indication: établir que

$$S_n = \left\| \frac{1}{\sqrt{n}} \sum_{m=1}^n V_m \right\|_2^2 \quad \text{où} \quad V_{m,i} := \frac{\mathbf{1}_{\{X_m=i\}} - p_i}{\sqrt{p_i}}.$$

3. Fixons un seuil de tolérance  $0 < \alpha < 1$ , typiquement  $\alpha = 5/100$ , appelé *niveau du test*, et considérons la région  $\mathcal{R}_\alpha = [0, a]$  où  $a$  est le quantile  $1 - \alpha$  de la loi  $\chi^2(k - 1)$ , appelée *région d'acceptation du test*. Au vu de  $X_1, \dots, X_n$ , on décide comme suit:

- Si  $S_n \in \mathcal{R}_\alpha$ , on accepte l'hypothèse  $H_0$ ;
- Si  $S_n \notin \mathcal{R}_\alpha$ , on rejette l'hypothèse  $H_0$ .

De manière résumée la décision prise avec le test est  $T_n := H_{\mathbf{1}_{S_n \notin \mathcal{R}_\alpha}}$ . Montrer que

- Si  $H_0$  est vraie alors la probabilité de rejeter à tort  $H_0$  tend vers  $\alpha$  quand  $n \rightarrow \infty$ ;
- Si  $H_0$  est fausse, alors la probabilité d'accepter à tort  $H_0$  tend vers 0 quand  $n \rightarrow \infty$ .

On parle d'*erreurs de première et de seconde espèce du test* ( $\rightarrow$  niveau et puissance).

### Solution.

1. Évident. Ce n'est pas une distance, car elle n'est pas symétrique. Cependant,  $\sqrt{D(p, q)}$  est la distance euclidienne de  $p$  à  $q$  pondérée par  $p$ ;
2. D'après la loi forte des grands nombres,

$$\frac{S_n}{n} \xrightarrow[n \rightarrow \infty]{\text{p.s.}} \sum_{i=1}^k \frac{(p_i - q_i)^2}{p_i} = D(p, q).$$

Si  $H_0$  est fausse alors  $D(p, q) > 0$  et donc  $S_n = n(S_n/n) \sim_{n \rightarrow \infty} nD(p, q) \rightarrow +\infty$  presque sûrement quand  $n \rightarrow \infty$ . Si  $H_0$  est vraie, alors  $q = p$  et  $D(p, q) = 0$ , et comportement de  $S_n$  quand  $n \rightarrow \infty$  peut-être décrit par le théorème central limite multivarié. On a

$$S_n = n \sum_{i=1}^k \frac{(p_i - \frac{1}{n} \sum_{m=1}^n \mathbf{1}_{\{X_m=i\}})^2}{p_i} = \left\| \frac{V_1 + \dots + V_n}{\sqrt{n}} \right\|_2^2$$

où  $V_1, \dots, V_n$  sont les vecteurs aléatoires de  $\mathbb{R}^k$  définis par

$$V_{m,i} := \frac{1}{\sqrt{p_i}} (\mathbf{1}_{\{X_m=i\}} - p_i)$$

pour tout  $1 \leq m \leq n$  et  $1 \leq i \leq k$ . Or les vecteurs aléatoires  $V_1, \dots, V_n$  sont i.i.d. de matrice de covariance  $\Sigma = I_k - \sqrt{p}\sqrt{p}^\top$  où  $\sqrt{p}^\top := (\sqrt{p_1}, \dots, \sqrt{p_k})$ . Par conséquent, le TCL donne

$$\frac{1}{\sqrt{n}} \sum_{m=1}^n V_m \xrightarrow[n \rightarrow \infty]{\text{loi}} \mathcal{N}(0, \Sigma).$$

Comme la norme est continue, on obtient que

$$S_n = \left\| \frac{1}{\sqrt{n}} \sum_{m=1}^n V_m \right\|_2^2 \xrightarrow[n \rightarrow \infty]{\text{loi}} \|Z\|_2^2$$

où  $Z \sim \mathcal{N}(0, \Sigma)$ . La matrice  $\Sigma$  est de rang  $k - 1$ . La matrice  $\sqrt{p}\sqrt{p}^\top$  est la matrice de projection orthogonale sur  $\text{Vect}(\sqrt{p})$ , tandis que  $\Sigma = I_k - \sqrt{p}\sqrt{p}^\top$  est la matrice de projection orthogonale sur  $\text{vect}(\sqrt{p})^\perp$  dans  $\mathbb{R}^k$ . Le théorème de Cochran donne  $Z \sim \chi^2(k - 1)$ .

3. Si  $H_0$  est vraie alors  $\mathbb{P}(T_n = 1) = \mathbb{P}(S_n > a) = 1 - \mathbb{P}(S_n \leq a) \rightarrow 1 - (1 - \alpha) = \alpha$  car  $S_n \rightarrow \chi^2(k - 1)$ . Si  $H_0$  est fausse, alors  $\mathbb{P}(T_n = 0) = \mathbb{P}(S_n \leq a) \rightarrow 0$  car  $S_n \rightarrow +\infty$  p.s.