

## PC 8 – 20 juin 2016 – Vecteurs gaussiens, estimateurs du maximum de vraisemblance, tests

Igor Kortchemski – igor.kortchemski@cmap.polytechnique.fr

### 1 Vecteurs gaussiens

*Exercice 1.* (Modèle auto-régressif d'ordre 1 AR(1)). Soit  $(Y_n)_{n \geq 1}$  une suite de variables aléatoires indépendantes et de même loi  $\mathcal{N}(m, \sigma^2)$ . Soient  $a \in \mathbb{R}$  et  $X_0$  une variable aléatoire de loi  $\mathcal{N}(m_0, \sigma_0^2)$  indépendante de  $(Y_n)_{n \geq 1}$ . Pour tout  $n \geq 1$ , on définit la suite récurrente aléatoire  $(X_n)_{n \geq 1}$  par

$$X_n = aX_{n-1} + Y_n.$$

Il s'agit d'un cas particulier de *séries temporelles*, utilisées pour modéliser l'évolution passée d'une quantité pour en prévoir le comportement futur.

- (1) Montrer que  $(X_0, \dots, X_n)$  est un vecteur gaussien.
- (2) Déterminer la loi de  $X_n$  et exprimer  $\text{Cov}(X_k, X_n)$  en fonction de  $\text{Var}(X_k)$  pour  $0 \leq k \leq n$ . Trouver la valeur de  $c$  telle que  $X_0 + cX_1$  soit indépendant de  $X_0$ .
- (3) À quelle condition sur  $a$  la suite  $(X_n)$  converge-t-elle en loi? Quelle est alors la loi limite? Quelle est la loi de  $X_n$  si  $X_0$  a cette loi limite?
- (4) Montrer que si  $a \in ]-1, 1[$ , le vecteur  $(X_n, X_{n+1})$  converge en loi vers un vecteur gaussien dont on déterminera les paramètres.
- (5) Pour  $a \in ]-1, 1[$ , étudier la convergence en loi de la moyenne empirique  $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$ .

### 2 Estimateur du maximum de vraisemblance

*Exercice 2.* On observe un échantillon  $(X_1, \dots, X_n)$  de  $n$  variables aléatoires indépendantes et de même loi exponentielle de paramètre  $\theta > 0$  inconnu.

- (1) Déterminer l'estimateur du maximum de vraisemblance  $\widehat{\theta}_n = \theta_n(X_1, \dots, X_n)$  de  $\theta$  et montrer qu'il converge presque sûrement vers  $\theta$  lorsque  $n \rightarrow \infty$ .
- (2) Cet estimateur est-il sans biais?  
On rappelle que la densité de la loi  $\Gamma(a, \lambda)$  est  $\frac{1}{\Gamma(a)} \lambda^a x^{a-1} e^{-\lambda x} \mathbb{1}_{x>0}$ .
- (3) Démontrer que  $\sqrt{n}(\widehat{\theta}_n - \theta)$  converge en loi vers une loi qu'on déterminera.  
*Indication.* On pourra utiliser la « méthode delta ».
- (4) Construire un intervalle de confiance asymptotique à 95% pour  $\theta$ .

**Exercice 3.** On reprend le modèle AR(1) de l'exercice 1 en supposant maintenant que  $(Y_n)_{n \geq 1}$  est une suite de variables aléatoires indépendantes et de même loi  $\mathcal{N}(0, \sigma^2)$  (avec  $\sigma$  connu). On fixe  $\theta \in \mathbb{R}$  (inconnu) et on définit la suite récurrente aléatoire  $(X_n)_{n \geq 1}$  par

$$X_0 = 0, \quad X_i = \theta X_{i-1} + Y_i, i \geq 1.$$

Déterminer l'estimateur du maximum de vraisemblance  $\hat{\theta}_n = \hat{\theta}_n(X_1, \dots, X_n)$  de  $\theta$ .

### 3 Tests

**Exercice 4.** Sur un échantillon représentatif de 1000 personnes, on rapporte les avis favorables pour un homme politique. En novembre, il y avait 38% d'avis favorables, et 36% en décembre. Un éditorialiste dans son journal prend très au sérieux cette chute de 2 points. Le but de cet exercice est de confirmer ou d'infirmer la position du journaliste.

On note  $p$  la proportion d'avis favorables en novembre, et  $q$  cette proportion en décembre, et on se propose de tester  $H_0 : p - q = 0$  contre  $H_1 : p - q \neq 0$  au niveau 5%. On note  $\hat{p}_n$  la proportion d'avis favorables dans un échantillon représentatif de  $n$  personnes en novembre (et de même  $\hat{q}_n$  pour décembre).

- (1) Démontrer que  $\sqrt{n}(\hat{p}_n - p, \hat{q}_n - q)$  converge en loi vers un vecteur gaussien dont on précisera la matrice de covariance. En déduire que

$$\sqrt{n}(\hat{p}_n - \hat{q}_n) \xrightarrow[n \rightarrow \infty]{\text{loi}} \mathcal{N}(0, p(1-p) + q(1-q)).$$

- (2) Conclure en prenant pour statistique de test

$$T_n = \frac{\sqrt{n}(\hat{p}_n - \hat{q}_n)}{\sqrt{\hat{p}_n(1 - \hat{p}_n) + \hat{q}_n(1 - \hat{q}_n)}}$$

et une région de rejet une région de la forme  $\{|T_n| > c\}$ .

### 4 À chercher pour la prochaine fois

**Exercice 5.** Soit  $(X_k)_{k \geq 1}$  des variables aléatoires indépendantes de même loi uniforme sur  $[0, \theta]$  (avec  $\theta$  inconnu).

- (1) Montrer que l'estimateur du maximum de vraisemblance  $\hat{\theta}_n = \hat{\theta}_n(X_1, \dots, X_n)$  de  $\theta$  est  $\hat{\theta}_n = \max(X_1, \dots, X_n)$ .
- (2) Montrer que  $W_n = n \left(1 - \frac{\hat{\theta}_n}{\theta}\right)$  converge en loi quand  $n \rightarrow \infty$  et déterminer sa limite.
- (3) Construire un intervalle de confiance asymptotique à 95% pour  $\theta$ .

## 5 Plus appliqué

*Rappel (théorème de Cochran, extension de la proposition 6.2.8 du poly).* Soit  $X$  un vecteur colonne aléatoire de  $\mathbb{R}^n$  de loi  $\mathcal{N}(m, \sigma^2 I_n)$  (avec  $m \in \mathbb{R}^n$ ,  $\sigma > 0$ ) 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  $E_k$ . Alors :

- (1) les vecteurs aléatoires  $(Y_1, \dots, Y_p)$  sont indépendants et  $Y_k$  suit la loi  $\mathcal{N}(\mathbf{P}_k m, \sigma^2 \mathbf{P}_k)$ ;
- (2) les variables aléatoires réelles  $(\|Y_i - \mathbf{P}_i m\|^2)_{1 \leq i \leq p}$  sont indépendantes et  $\|Y_k - \mathbf{P}_k m\|^2 / \sigma^2$  suit la loi  $\chi^2(d_k)$ .

**Exercice 6.** On considère que la réponse d'un appareil de mesure à un signal déterministe  $\xi$  est égale à  $a\xi$  plus un bruit gaussien centré de variance  $b$ , où  $(a, b) \in \mathbb{R} \times \mathbb{R}_+^*$ . On se propose d'étalonner l'appareil (c'est-à-dire estimer les valeurs de  $a$  et  $b$ ) en envoyant une suite  $x = (x_1, x_2, \dots, x_n)$  de signaux connus. On note  $Y_i = ax_i + \sqrt{b}U_i$  la réponse au  $i$ -ième signal où on suppose que les coordonnées du vecteur  $U = (U_1, U_2, \dots, U_n)$  sont des variables aléatoires gaussiennes centrées réduites indépendantes. On note  $Y = (Y_1, Y_2, \dots, Y_n)$ ,

$$\widehat{A}_n = \frac{\sum_{i=1}^n x_i Y_i}{\sum_{i=1}^n x_i^2} \quad \text{et} \quad \widehat{B}_n = \frac{\sum_{i=1}^n (Y_i - x_i \widehat{A}_n)^2}{n-1}.$$

- (1) Donner la loi de  $\widehat{A}_n$ . À quelle condition sur la suite  $(x_i)_{i \geq 1}$  a-t-on  $\mathbb{E}[(\widehat{A}_n - a)^2] \rightarrow 0$  lorsque  $n \rightarrow \infty$ ?

On complète  $e_1 = \frac{x}{\|x\|}$  en une base orthonormée  $(e_1, \dots, e_n)$  de  $\mathbb{R}^n$ . Notons  $P$  la projection orthogonale sur  $E_1 = \text{Vect}(e_1)$  et  $Q$  la projection orthogonale sur  $E_2 = \text{Vect}(e_2, \dots, e_n)$ .

- (2) Déterminer  $PY$  et  $QY$ . En déduire que  $\widehat{A}_n$  et  $\widehat{B}_n$  sont des variables aléatoires indépendantes. Donner l'espérance et la variance de  $\widehat{B}_n$ .
- (3) Montrer qu'il existe une constante  $c$  (dépendant de  $x$ ) telle que la variable aléatoire  $c \frac{\widehat{A}_n - a}{\sqrt{\widehat{B}_n}}$  suive une loi de Student.
- (4) Donner un intervalle de confiance à 95% pour le paramètre  $a$ , suivant que l'on connaît la valeur de  $b$  ou non.

## 6 Pour aller plus loin

**Exercice 7.** Soient  $(X_i)_{1 \leq i \leq n}$  des variables aléatoires réelles indépendantes de même loi, de carré intégrable, d'espérance  $m$  et de variance  $\sigma^2$ . On suppose que la moyenne empirique  $\bar{X}_n$  et la variance empiriques  $V_n$ , définies par

$$\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i, \quad V_n = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2,$$

sont indépendantes. Le but de cet exercice est de démontrer que la loi de  $X_i$  est une loi gaussienne  $\mathcal{N}(m, \sigma^2)$ .

(1) Calculer  $\mathbb{E}[(n-1)V_n]$  en fonction de  $\sigma^2$ . Montrer que pour tout  $t \in \mathbb{R}$  :

$$\mathbb{E}\left[(n-1)V_n e^{itn\bar{X}_n}\right] = (n-1)\psi(t)^n \sigma^2.$$

(2) En développant  $V_n$  dans l'égalité précédente, vérifier que :

$$\mathbb{E}\left[(n-1)V_n e^{itn\bar{X}_n}\right] = -(n-1)\psi''(t)\psi(t)^{n-1} + (n-1)\psi'(t)^2\psi(t)^{n-2}.$$

(3) En déduire que, sur un voisinage ouvert de 0,  $\psi$  est solution de l'équation différentielle :

$$\frac{\psi''}{\psi} - \left(\frac{\psi'}{\psi}\right)^2 = -\sigma^2, \quad \psi(0) = 1, \quad \psi'(0) = 0.$$

(4) En déduire que la loi des variables  $X_i$  est la loi gaussienne  $\mathcal{N}(0, \sigma^2)$ .

(5) Que peut-on dire si l'on ne suppose plus  $m = 0$  ?