

## Devoir de Statistiques

*Les questions notées (\*) sont facultatives*

### Exercice 1.

On considère  $\beta \in \mathbb{R}^d$  et  $\Sigma$  une matrice de covariance de taille  $d$ . Pour tout vecteur  $v \in \mathbb{R}^d$ , on note  $\|v\|^2 = \sum_{k=1}^d v_k^2$ . Soit  $Q$  une matrice carrée telle que  $Q^t Q = \Sigma$ .

- (1) Rappeler brièvement pourquoi une telle matrice  $Q$  existe.
- (2) Soit  $Z$  un vecteur gaussien de loi  $\mathcal{N}(0, I_d)$ . Quelle est la loi de  $QZ + \beta$ ? En déduire une méthode de simulation de la loi  $\mathcal{N}(\beta, \Sigma)$  à partir d'un  $d$ -échantillon de loi  $\mathcal{N}(0, 1)$ .
- (3) Quel est le support de la loi  $\mathcal{N}(0, \Sigma)$ ? Que peut-on dire quand  $\Sigma$  n'est pas inversible?
- (4) On suppose désormais que  $\Sigma$  est inversible. Soit  $X \sim \mathcal{N}(\beta, \Sigma)$ . Montrer que  $Q$  est inversible, et donner la loi de  $\|Q^{-1}(X - \beta)\|^2$ .
- (5) Soit maintenant  $M$  une matrice (non nécessairement carrée) telle que  ${}^t M M = \Sigma^{-1}$ . En utilisant la question précédente, trouver la loi de  $\|M(X - \beta)\|^2$ .
- (6) Soit  $X^{(1)}, \dots, X^{(n)}$   $n$  tirages indépendants de même loi que  $X$ . Simulez avec **Scilab** un tel tirage pour  $d = 2$ ,  $\Sigma = [5, 1; 1, 1]$ ,  $n = 1000$ , et  $\beta$  à votre guise. Quelle est la forme du nuage de points? Essayer également avec  $\Sigma$  non inversible.
- (7) Quand  $n$  est grand, quel  $k$  faut-il prendre pour qu'environ 95% des points soient dans la région  $\mathcal{E} = \{x \in \mathbb{R}^d, \|M(x - \beta)\|^2 \leq k\}$ ?
- (8) On va montrer que  $\mathcal{E}$  est (l'intérieur d') un ellipsoïde (une ellipse quand  $d = 2$ ). La matrice  $\Sigma^{-1}$  peut se diagonaliser de la façon suivante :  $\Sigma^{-1} = {}^t P D P$ , avec  $P$  orthogonale et  $D$  diagonale. Écrire  $\|M(x - \beta)\|^2$  en fonction de  $P, D, x$  et  $\beta$ .
- (9) Quelle équation vérifie  $u$  quand  $\beta + P^{-1}u$  appartient à  $\mathcal{E}$ ? Conclure.
- (10\*) Dans le cas  $d = 2$ , quels sont les paramètres (demi grand axe et demi petit axe) de l'ellipse, en fonction des valeurs propres de  $\Sigma$ ?
- (11\*) Dans le cas  $d = 2$  donner un paramétrage de la frontière de  $\mathcal{E}$ , c'est à dire l'écrire comme une courbe paramétrée.
- (12\*) Tracer l'ellipse dans l'exemple de la question (6). On pourra utiliser la fonction **spec**.
- (13) Donner la densité de la loi  $\mathcal{N}(\beta, \Sigma)$ . Quelles en sont les lignes de niveau? Utiliser la fonction **contour** pour les tracer dans l'exemple de la question (6).

**Exercice 2.**

On considère le modèle de régression linéaire simple suivant : soit  $x \in \mathbb{R}^n$  un vecteur, et  $Y \in \mathbb{R}^n$  un vecteur aléatoire tel que  $Y_i$  suit une loi normale  $\mathcal{N}(\beta_1 x_i + \beta_2, \sigma^2)$ , où  $\beta_1$ ,  $\beta_2$  et  $\sigma^2$  sont des paramètres inconnus à estimer. On observe les variables indépendantes  $Y_1, \dots, Y_n$ .

On note  $\beta = {}^t(\beta_1, \beta_2)$ ,  $x = {}^t(x_1, \dots, x_n)$ ,  $Y = {}^t(Y_1, \dots, Y_n)$ ,  $\mathbf{1} = {}^t(1, \dots, 1)$ . Pour tous vecteurs  $v, w \in \mathbb{R}^n$ , on note  $\text{var}(v) = \overline{v^2} - \bar{v}^2$ ,  $\text{cov}(v, w) = \overline{vw} - \bar{v} \bar{w}$ , où

$$\bar{v} = n^{-1} \sum_{i=1}^n v_i, \quad \overline{vw} = n^{-1} \sum_{i=1}^n v_i w_i, \quad \text{et } \|v\|^2 = \sum_{i=1}^n v_i^2.$$

On suppose que  $\text{var}(x) \neq 0$ .

- (1) Donner le modèle statistique.
- (2) Écrire la log vraisemblance associée  $L(\beta_1, \beta_2, \sigma^2)$
- (3) Maximiser  $(\beta_1, \beta_2) \mapsto L(\beta_1, \beta_2, \sigma^2)$  et en déduire des estimateurs  $\hat{\beta}_1$  et  $\hat{\beta}_2$  de  $\beta_1$  et  $\beta_2$ .  
On note  $\hat{\beta} = {}^t(\hat{\beta}_1, \hat{\beta}_2)$ .
- (4) Par dérivation de  $\sigma^2 \mapsto L(\beta_1, \beta_2, \sigma^2)$ , trouver l'estimateur du maximum de vraisemblance de  $\sigma^2$ , qu'on notera  $S$ .

Pour la suite, on admettra que  $S$  est indépendant de  $\hat{\beta}$ , et que  $nS/\sigma^2 \sim \chi^2(n-2)$ .

- (5) Donner la loi de  $\hat{\beta}$  (on pourra trouver une matrice  $A$  telle que  $\hat{\beta} = AY$ ), et celle de  $\hat{\beta}_1$ .
- (6) Calculer le biais de  $\hat{\beta}$ .
- (7) Quel est le biais de  $S$ ? Pourquoi choisit-on plutôt  $\hat{\sigma}^2 = \frac{1}{n-2} \sum_{i=1}^n (Y_i - \hat{\beta}_1 x_i - \hat{\beta}_2)^2$ ?
- (8) Donner un intervalle de confiance de niveau  $1 - \alpha$  pour  $\sigma^2$ .
- (9\*) Dans cette question, on suppose que pour  $n = 100$ , on a obtenu comme réalisation de l'estimateur  $\hat{\sigma}^2$  la valeur 1.2. Tester au niveau 5% que  $\sigma^2 = 1$ .
- (10) Donner un intervalle de confiance de niveau  $1 - \alpha$  pour  $\beta_1$ . On rappelle que si  $Z$  suit une loi  $\mathcal{N}(0, 1)$  et  $V$  une loi  $\chi^2(d)$  indépendante de  $Z$ , alors  $Z/\sqrt{V/d}$  suit une loi de Student  $\mathcal{T}(d)$ .
- (11) En utilisant la méthode de Bonferroni, trouver une région de confiance pour  $\beta$ .
- (12) En utilisant l'exercice 1, donner la loi de  $\|M(\hat{\beta} - \beta)\|^2$ , pour  $M = \sigma^{-1}(x \mathbf{1})$  (matrice de taille  $n \times 2$ ).
- (13) En déduire une région de confiance elliptique pour  $\beta$ . On rappelle que si  $Z$  suit une loi  $\chi^2(d_1)$  et  $V$  une loi  $\chi^2(d_2)$  indépendante de  $Z$ , alors  $(Z/d_1)/(V/d_2)$  suit une loi de Fisher  $\mathcal{F}(d_1, d_2)$ .
- (14) Quelle est la meilleure région de confiance pour  $\beta$  entre celle de la question (11) et celle de la question (13)?
- (15) Trouvez une fonction de la Stixbox qui permet d'estimer  $\beta$  et donne des intervalles de confiance sur  $\beta_1$  et  $\beta_2$ .