



## TD 6 : Vecteurs gaussiens

**Exercice 1.** Soit  $r \geq 1$  et  $n_1, \dots, n_r$  des entiers strictement positifs. Soient  $Y_1, \dots, Y_r$  des vecteurs gaussiens indépendants à valeurs respectivement dans  $\mathbb{R}^{n_1}, \dots, \mathbb{R}^{n_r}$ . Montrer que le vecteur aléatoire  $Y = {}^t(Y_1, \dots, Y_r)$ , de dimension  $n_1 + \dots + n_r$ , est gaussien et expliciter sa matrice de covariance en fonction de celles des  $Y_i$ ,  $1 \leq i \leq r$ .

**Exercice 2.** Soit  $X$  un vecteur gaussien centré de matrice de covariance

$$\Sigma = \begin{pmatrix} 3 & -1 & 0 \\ -1 & 3 & 0 \\ 0 & 0 & 2 \end{pmatrix}.$$

Trouver un endomorphisme  $U$  de  $\mathbb{R}^3$  tel que les composantes de  $Y = UX$  soient indépendantes. Préciser la loi de  $Y$ .

**Exercice 3.** Soient  $U_1, \dots, U_n$  des v.a. réelles i.i.d. de loi  $\mathcal{N}(0, 1)$  et  $\theta \in \mathbb{R}$ . On pose  $X_1 = U_1$  et pour tout  $2 \leq k \leq n$ ,  $X_k = \theta X_{k-1} + U_k$ .

- a) Montrer que le vecteur aléatoire  $X = {}^t(X_1, \dots, X_n)$  peut s'exprimer sous la forme  $X = AU$ , pour une matrice  $A$  à déterminer. Montrer que  $X$  est un vecteur gaussien.
- b) Dédire de l'expression précédente l'espérance  $\vec{m}$  et la matrice de covariance  $\Sigma$  de  $X$ .
- c) Montrer que  $X$  admet une densité, que l'on calculera en fonction de  $\Sigma$ .
- d) Quelle est la loi de  $X_n$ ? Discuter en fonction de  $\theta$  le comportement de  $X_n$  lorsque  $n \rightarrow \infty$ .

**Exercice 4.** On souhaite étudier le rendement d'une certaine variété de pommes. On dispose de  $p$  pommiers et on note  $X_j$  le rendement observé du  $j$ ème arbre,  $j \in \{1, \dots, p\}$ . On suppose que chaque  $X_j$  est la somme d'une moyenne théorique  $m$  ne dépendant que de la variété, et d'une erreur  $\epsilon_j$  :

$$X_j = m + \epsilon_j, \quad \epsilon_j \stackrel{\text{i.i.d.}}{\sim} \mathcal{N}(0, \sigma^2), \quad j \in \{1, \dots, p\}.$$

On ne connaît ni  $m$  ni  $\sigma^2$ , on considère donc le modèle paramétrique  $\{\mathbb{P}_{m,\sigma}, m > 0, \sigma > 0\}$ .

- a) Proposer un estimateur pour  $m$  et donner ses propriétés (biais, consistance, vitesse).
- b) On cherche à présent à estimer  $\sigma^2$ . Pour ce faire, on pose

$$S_p = \frac{1}{p} \sum_{j=1}^p X_j^2 - (\bar{X}_p)^2 = \frac{1}{p} \sum_{j=1}^p (X_j - \bar{X}_p)^2.$$

Pour tout  $j \in \{1, \dots, p\}$ , on définit

$$Z_j = \begin{pmatrix} X_j^2 \\ X_j \end{pmatrix}.$$

Donner l'espérance et la matrice de covariance de  $Z_1$  sous  $\mathbb{P}_{m,\sigma}$ . En déduire le comportement asymptotique du vecteur aléatoire  $\sqrt{p}(\bar{Z}_p - \mathbb{E}_{m,\sigma}[Z_1])$ , lorsque  $p \rightarrow \infty$ .

c) En utilisant la méthode delta avec une fonction adéquate, montrer que

$$\sqrt{p}(S_p - \sigma^2) \xrightarrow{\mathcal{L}} \mathcal{N}(0, V(\sigma)) \quad \text{lorsque } p \rightarrow \infty,$$

pour une fonction  $V(\sigma)$  indépendante de  $m$  à déterminer.

**Exercice 5.** A l'aide de la transformée de Fourier et du résultat en dimension 1, démontrer le théorème central limite vectoriel.

**Exercice 6.** Soit  $Y$  un vecteur de  $\mathbb{R}^n$ . On dit que  $Y$  suit un modèle linéaire Gaussien lorsque

$$Y = \mu + \varepsilon \quad \text{où } \varepsilon \text{ est un vecteur Gaussien de loi } \mathcal{N}_n(0, \sigma^2 I_n)$$

pour deux paramètres  $\mu \in \mathbb{R}^n$  et  $\sigma^2 > 0$  inconnus. Nous faisons de plus l'hypothèse que  $\mu$  appartient à un sous espace vectoriel  $V$  de  $\mathbb{R}^n$ .

*Remarque :* Il s'agit de la donnée du 1-échantillon  $Y$  de loi  $\mathbb{P}_{(\mu,\sigma^2)} = \mathcal{N}_n(\mu, \sigma^2 I_n)$  avec  $(\mu, \sigma^2) \in V \times ]0, +\infty[$ . Il s'agit aussi de la donnée de  $Y = {}^t(Y_1, \dots, Y_n)$ , où  $Y_i$  suit la loi  $\mathcal{N}(\mu_i, \sigma^2)$  pour tout  $i \in \{1, \dots, n\}$ , mais attention ce n'est pas a priori un  $n$ -échantillon : ici les  $Y_i$  sont indépendantes mais pas de même loi.

1) Quelle est la densité du vecteur Gaussien  $Y$  de loi  $\mathbb{P}_{(\mu,\sigma^2)} = \mathcal{N}_n(\mu, \sigma^2 I_n)$  avec  $(\mu, \sigma^2) \in V \times ]0, +\infty[$ ?

2)a) Notons  $\Pi_V$  la projection orthogonale sur  $V$ . Montrer que

$$\forall x \in \mathbb{R}^n \quad \inf_{m \in V} \|x - m\| = \|x - \Pi_V x\|$$

b) En déduire que l'estimateur du maximum de vraisemblance de  $(\mu, \sigma^2)$  est  $(\hat{\mu}, \hat{s}_n^2)$  avec

$$\hat{\mu} = \Pi_V Y \quad \text{et} \quad \hat{s}_n^2 = \frac{1}{n} \|Y - \Pi_V Y\|^2$$

3) Notons  $p = \dim V$ . Montrer que  $\hat{\mu}$  et  $\hat{s}_n^2$  sont indépendants et que

$$\hat{\mu} \sim \mathcal{N}_n(\mu, \sigma^2 \Pi_V) \quad \text{et} \quad \frac{n \hat{s}_n^2}{\sigma^2} \sim \chi^2(n - p)$$

4) Posons

$$\hat{\sigma}_n^2 = \frac{1}{n - p} \|Y - \Pi_V Y\|^2 = \frac{n \hat{s}_n^2}{n - p}$$

Soit  $x \in \mathbb{R}^n$  tel que  $\langle \Pi_V x, x \rangle = {}^t x \Pi_V x \neq 0$ . Donner la loi de la variable aléatoire

$$\frac{{}^t x \hat{\mu} - {}^t x \mu}{\sqrt{\hat{\sigma}_n^2 {}^t x \Pi_V x}}$$

En déduire un test de  $H_0 : {}^t x \mu = 0$  contre  $H_1 : {}^t x \mu \neq 0$  au niveau  $\alpha$ .

*A quoi ça sert tout ça ? Supposons qu'une certaine quantité  $y$  est une fonction affine des quantités  $x_1, \dots, x_p$  :*

$$y = \beta_1 x_1 + \dots + \beta_p x_p \quad \text{avec } \beta_1, \dots, \beta_p \text{ inconnus}$$

*Observons alors  $n$  réalisations indépendantes de  $(y, x_1, \dots, x_p)$  :*

$$(Y_1, X_{1,1}, \dots, X_{1,p}), \quad \dots \quad (Y_n, X_{n,1}, \dots, X_{n,p})$$

*Nous pouvons alors supposer que  $Y = \mu + \varepsilon$  avec  $\varepsilon \sim \mathcal{N}_n(0, \sigma^2 I_n)$  et  $\mu_j = \beta_1 X_{j,1} + \dots + \beta_p X_{j,p}$  pour tout  $j \in \{1, \dots, n\}$ . Le variable aléatoire  $\varepsilon$  représente le bruit, c'est-à-dire l'impact de toutes les variables aléatoires d'environnement non explicitement prises en compte dans la relation linéaire. Nous pouvons donc estimer  $\mu$ , déterminer un intervalles de confiance, faire des tests... Et, sous des hypothèses d'inversibilité, nous en déduisons l'estimation de  $(\beta_1, \dots, \beta_p)$ , des intervalles de confiance, des tests...*

