

## TD2 : Modèle linéaire gaussien

- Exercice 1** (Quelques éléments d'algèbre linéaire). 1. Soit  $M$  une matrice carrée  $n \times n$  telle que  ${}^tM = M = M^2$ . Soit  $W = \text{Im}(M)$ .
- Soit  $u \in W$ , montrer que  $Mu = u$ .
  - Soit  $v \in \mathbb{R}^n$ , et  $w \in W$ , montrer que  $v - Mv \perp w$ .
  - Conclure que  $M$  est la matrice de projection sur  $\text{Im}(M)$ .
- Calculer la projection du vecteur  $u = (1, 1, 0)$  sur le plan  $\{x + y - z = 0\}$ .
  - Déterminer la matrice de projection orthogonale  $Q$  de  $\mathbb{R}^4$  sur le sous-espace vectoriel engendré par  $(1, 2, 0, 0)$  et  $(1, 0, 1, 1)$ . Quelle est la projection de  $(1, -2, 2, 2)$  sur cet espace? Qu'en déduisez-vous?

**Exercice 2.** On souhaite vérifier si le taux de sucre d'un soda respecte les recommandations d'un organisme de santé indépendant, à savoir une valeur inférieure à 0.100 g/ml. Dans des conditions expérimentales garantissant l'indépendance des observations, on mesure le taux de sucre de 10 bouteilles différentes. Sur ces observations, on observe un taux moyen de 0.103 g/ml de sucre et un écart-type de 0.010 g/ml. On suppose que les 10 observations suivent une même loi gaussienne.

- Préciser le modèle statistique.
- Construire un test en se plaçant du point de vue du directeur de l'usine de fabrication du soda. Quelle est sa conclusion au niveau 5%?
- Construire le test en se plaçant du point de vue de l'organisme de santé, quelle sera sa conclusion au niveau 5%?

**Exercice 3.** Soit le modèle statistique

$$\left(\mathbb{R}^{n+p}, \{\mathcal{N}(m_1, \sigma^2)^{\otimes n} \otimes \mathcal{N}(m_2, \sigma^2)^{\otimes p}\}_{m_1, m_2 \in \mathbb{R}, \sigma^2 > 0}\right).$$

L'objectif de cet exercice est de construire un test pour  $H_0 : m_1 = m_2$  contre  $H_1 : m_1 \neq m_2$ . Dans la suite, pour  $m_1, m_2 \in \mathbb{R}$  et  $\sigma^2 > 0$ , on note  $X = (X_1, \dots, X_n)$  de loi  $\mathcal{N}(m_1, \sigma^2)$  et  $Y = (Y_1, \dots, Y_p)$  de loi  $\mathcal{N}(m_2, \sigma^2)$ .

- Déterminer les lois des statistiques

$$Q = \frac{\bar{X}_n - \bar{Y}_p}{\sqrt{1/n + 1/p}} \quad \text{et} \quad W^2 = \sum_{i=1}^n (X_i - \bar{X}_n)^2 + \sum_{j=1}^p (Y_j - \bar{Y}_p)^2.$$

- En déduire la loi sous  $H_0$  de la statistique  $\sqrt{n+p-2} \frac{Q}{W}$ .
- Construire un test de niveau  $\alpha \in (0, 1)$  pour  $H_0$  contre  $H_1$ .
- Les résultats d'un examen noté sur 20 sont répertoriés dans le tableau suivant.

Filles	2	12	4	4	2	15	10	17	11	12	2			
Garçons	7	3	6	8	9	10	9	11	17	16	14	12	2	6

On suppose que les notes sont indépendantes et issues de lois gaussiennes dont seule la moyenne dépend du genre de l'élève, la variance étant identique. Montrer qu'au niveau 5%, on ne peut déduire à l'existence d'une différence entre les moyennes des notes des filles et des garçons.

**Exercice 4.** Soit  $(t_1, \dots, t_n)$  des réels tels que  $t_i \neq t_j$  pour deux indices  $i \neq j$ . On considère le modèle statistique

$$\left( \mathbb{R}^n, \{ \mathcal{N}(\theta_1 + t_i \theta_2, \sigma^2)^{\otimes n} \otimes \mathcal{N}(m_2, \sigma^2)^{\otimes p} \}_{\theta_1, \theta_2 \in \mathbb{R}, \sigma^2 > 0} \right),$$

et on note  $\mathbf{1}$  et  $\mathbf{t}$  les vecteurs définis par  ${}^t(1, \dots, 1)$  et  ${}^t(t_1, \dots, t_n)$  respectivement. On posera

$$\bar{\mathbf{t}} = \frac{1}{n} \sum t_i \quad \text{et} \quad s = \frac{1}{n} \|\mathbf{t}\|^2 - (\bar{\mathbf{t}})^2.$$

1. Montrer que  $s \neq 0$ .
2. Déterminer les estimateurs du maximum de vraisemblance de  $(\theta_1, \theta_2, \sigma^2)$ .
3. Quelle est la loi de  $(\hat{\theta}_1, \hat{\theta}_2)$ ? Montrer que ces deux vecteurs sont linéairement indépendants si et seulement si  $\bar{\mathbf{t}} = 0$ .
4. Construire un test au niveau  $\alpha$  pour  $H_0 : \theta_2 = 0$  contre  $H_1 : \theta_2 \neq 0$ .
5. Des prélèvements ont lieu dans la rivière aux jours  $t_1 = 1, \dots, t_5 = 5$  et ont donné les valeurs suivantes pour la concentration d'un polluant

Jour	1	2	3	4	5
[C] ( $\mu/l$ )	11	10	12	12	14

Peut-on rejeter au niveau 5% l'hypothèse que la concentration en polluant n'évolue pas au cours du temps?

**Exercice 5** (Régression polynomiale). On s'intéresse au modèle statistique  $Y = P(X) + \epsilon$ , où  $P$  est un polynôme de degré  $d$  et  $\epsilon$  un vecteur gaussien centré de matrice de covariance  $\sigma^2 I_n$ .

1. Poser ce modèle statistique sous la forme d'un modèle linéaire gaussien sous forme matricielle. Rappeler la formule donnant les estimateurs du maximum de vraisemblance de  $a_d, \dots, a_0$  de  $P$  ainsi que  $\sigma^2$ .
2. Donner un estimateur non-biaisé de  $\sigma^2$  noté  $\hat{\sigma}_n^2$ , ainsi que sa loi.
3. Déterminer un intervalle de confiance à 95% de  $\sigma^2$ . Commentez.
4. Que se passe-t-il dans le cas particulier  $n = d$ ?
5. On note  $H_0^{(k)} := P \in \mathbb{R}_{k-1}[X]$  et  $H_1^{(k)} := P \in \mathbb{R}_k[X]$ . Déterminer un test de niveau  $\alpha$  de  $H_0^{(k)}$  contre  $H_1^{(k)}$ .