

Contrôle continu 2

Exercice 1 Soient $n \geq 1$ et les réels x_1, \dots, x_n . Soient $\sigma^2 > 0$ et Z un vecteur gaussien de dimension d , de loi $\mathcal{N}(0, \sigma^2 I_d)$. Soient enfin $a, b \in \mathbb{R}$ et Y le vecteur gaussien de coordonnées $Y_i = ax_i + b + \sigma Z_i$.

1) Trouver les variables aléatoires $\hat{A}, \hat{B} \in \mathbb{R}$ minimisant pour tout $\omega \in \Omega$ la quantité

$$\sum_{i=1}^n (Y_i - \hat{A}x_i - \hat{B})^2.$$

2) On pose $\hat{Y}_i = \hat{A}x_i + \hat{B}$ pour $1 \leq i \leq n$. Démontrer que $\sum_{i=1}^n (Y - \bar{Y})^2 = \sum_{i=1}^n (Y - \hat{Y})^2 + \sum_{i=1}^n (\hat{Y} - \bar{Y})^2$.

3) Vérifier que $\sum_{i=1}^n (Y - \hat{Y})^2 = \sum_{i=1}^n (Y - \bar{Y})^2 - \hat{A}^2 \sum_{i=1}^n (\hat{x} - \bar{x})^2$.

4) En déduire la formule $SCE = n\sigma_Y^2(1 - \rho_{x,Y}^2)$, où SCE désigne la somme des carrés des écarts au modèle, σ_Y^2 la variance observée de $(Y_i)_i$ et $\rho_{x,Y}$ le coefficient de corrélation.

Exercice 2 Soient $n \geq 1$ et les réels x_1, \dots, x_n . Pour $n+1 \leq i \leq 2n$ on pose $x_i = x_{i-n}$. On considère les vecteurs $\vec{e}_1, \vec{e}_2 \in \mathbb{R}^{2n}$ définis par $\vec{e}_j = (e_{i,j})$ où

$$e_{i,1} = \begin{cases} x_i & \text{si } 1 \leq i \leq n \\ -x_{i-n} & \text{si } n+1 \leq i \leq 2n. \end{cases}$$

$$e_{i,2} = \begin{cases} x_i & \text{si } 1 \leq i \leq n \\ x_{i-n} & \text{si } n+1 \leq i \leq 2n. \end{cases}$$

1) Étude théorique

a) Soit B la matrice de vecteurs colonnes (\vec{e}_1, \vec{e}_2) . Calculer la matrice B^*B et la matrice $(B^*B)^{-1}B^*$.

b) Soient $\vec{\lambda} = \begin{pmatrix} a \\ b \end{pmatrix} \in \mathbb{R}^2$, et \vec{Y} un vecteur gaussien de loi $\mathcal{N}(B\vec{\lambda}, \sigma^2 I_n)$. On note $(X_i)_{1 \leq i \leq n}$ ses coordonnées. Soit $\hat{\Lambda} = \begin{pmatrix} \hat{A} \\ \hat{B} \end{pmatrix}$ défini par $\hat{\Lambda} = (B^*B)^{-1}B^*X$. Donner les expressions de \hat{A} et

\hat{B} en fonction des variables aléatoires $C_1 = \frac{1}{n} \sum_{i=1}^n x_i Y_i$ et $C_2 = \frac{1}{n} \sum_{i=n+1}^{2n} x_i Y_i$.

c) Donner les lois de \hat{A} et \hat{B} .

d) Les variables aléatoires \hat{A} et \hat{B} sont-elles indépendantes ?

e) Donner l'expression de $\hat{Y} = B\hat{\Lambda}$ en fonction des variables aléatoires C_1 et C_2 .

f) Quelle est la loi de \hat{Y} ?

g) Quelle est la loi de $\vec{Y} - \hat{Y}$? Préciser le rang de sa matrice de covariance.

h) Les vecteurs aléatoires $\vec{Y} - \hat{Y}$ et \hat{Y} sont-ils indépendants ?

i) On note $(\hat{Y}_i)_{1 \leq i \leq n}$ les coordonnées du vecteur aléatoire \hat{Y} . Les vecteurs aléatoires $((Y_i - \hat{Y}_i)^2)_{1 \leq i \leq 2n}$ et $(\hat{Y}_i^2)_{1 \leq i \leq 2n}$ sont-ils des vecteurs gaussiens ? sont-ils indépendants ?

j) Quelle est la loi de $SCE = \|\vec{Y} - \hat{Y}\|^2$?

k) Les variables aléatoires $\|\bar{Y} - \hat{Y}\|^2$ et \hat{A} sont-elles indépendantes ?

On note I l'intervalle de confiance de niveau $\alpha \in]0, 1[$ sur le paramètre a .

l) Quelle est la statistique T , de loi de Student, permettant le calcul de I .

m) Donner l'expression des bornes de I .

On note J_i l'intervalle de confiance de niveau $\alpha \in]0, 1[$ sur $E(Y_i)$, $i = 1, \dots, 2n$.

n) Quelle est la statistique T_i , de loi de Student, permettant le calcul de J_i .

o) Donner l'expression des bornes de J_i .

2) Application numérique :

Afin de comparer deux engrais \mathcal{E}_1 et \mathcal{E}_2 on relève la taille moyenne y d'une plante à 1 mois, pour différents dosages x d'engrais. Les observations sont données dans le tableau suivant

Plante i	1	2	3	4	5	6
Engrais	\mathcal{E}_1	\mathcal{E}_1	\mathcal{E}_1	\mathcal{E}_2	\mathcal{E}_2	\mathcal{E}_2
Dose x_i	1	2	3	1	2	3
Taille y_i	0,9	1,5	2,9	1	0,6	1,6

On donne

$$\sum_{i=1}^6 x_i^2 = 28, \quad \sum_{i=1}^6 y_i^2 = 15,39, \quad \sum_{i=1}^3 x_i y_i = 12,6, \quad \sum_{i=4}^6 x_i y_i = 7$$

a) Calculer la valeur \hat{a} prise par l'estimateur \hat{A} de a .

b) Calculer la valeur \hat{b} prise par l'estimateur \hat{B} de b .

c) En déduire les estimations \hat{y}_i de $E(Y_i)$, $i = 1, \dots, 6$.

d) Calculer le résidu SCE du modèle.

e) Donner son nombre de degrés de liberté.

On note $I = [c; d]$ l'intervalle de confiance au niveau $1 - \alpha = 0,95$ pour le coefficient a .

f) Déterminer le fractile de la loi de Student intervenant dans le calcul de I .

g) Déterminer c .

h) Déterminer d .

i) D'après cette étude, peut-on penser qu'un engrais favorise plus la croissance que l'autre (expliciter le critère pris utilisé).

Fractiles $t_n(p)$ de la loi de STUDENT à n degrés de liberté.

	0,6	0,7	0,8	0,9	0,95	0,975	0,99	0,995	0,999	0,9995
n= 2	0,289	0,617	1,061	1,886	2,920	4,303	6,965	9,925	22,327	31,599
n= 3	0,277	0,584	0,978	1,638	2,353	3,182	4,541	5,841	10,215	12,924
n= 4	0,271	0,569	0,941	1,533	2,132	2,776	3,747	4,604	7,173	8,610
n= 5	0,267	0,559	0,920	1,476	2,015	2,571	3,365	4,032	5,893	6,869
n= 6	0,265	0,553	0,906	1,440	1,943	2,447	3,143	3,707	5,208	5,959
n= 7	0,263	0,549	0,896	1,415	1,895	2,365	2,998	3,499	4,785	5,408
n= 8	0,262	0,546	0,889	1,397	1,860	2,306	2,896	3,355	4,501	5,041
n= 9	0,261	0,543	0,883	1,383	1,833	2,262	2,821	3,250	4,297	4,781
n= 10	0,260	0,542	0,879	1,372	1,812	2,228	2,764	3,169	4,144	4,587