

## Contrôle Continu

*Durée 2h00. Les documents, les téléphones portables, tablettes, ordinateurs ne sont pas autorisés. La calculatrice est autorisée. Les exercices sont indépendants. La qualité de la rédaction sera prise en compte. Tous les résultats numériques seront donnés avec une précision de deux chiffres après la virgule.*

**Exercice 1. QCM.** On se place dans le cadre du modèle de régression linéaire multiple gaussien :  $Y = X\beta + \epsilon$ , avec  $Y$  un vecteur de taille  $n$ ,  $\beta$  un vecteur de taille  $p$ ,  $X$  une matrice de rang  $p$ , et  $\epsilon \sim \mathcal{N}(0_n, \sigma^2 I_n)$ . Répondez aux questions suivantes. Une seule réponse est acceptée par question.

- La matrice  $X$  est de taille :
  - $n \times p$
  - $p \times n$
- Dans ce modèle, les  $Y_i$ ,  $1 \leq i \leq n$ , sont aléatoires, indépendants et identiquement distribués (i.i.d.).
  - Vrai
  - Faux
- Dans ce modèle, les  $\epsilon_i$ ,  $1 \leq i \leq n$ , sont aléatoires i.i.d.
  - Vrai
  - Faux
- Dans ce modèle, les  $\beta_k$ ,  $1 \leq k \leq p$ , sont aléatoires i.i.d.
  - Vrai
  - Faux
- L'estimateur des moindres carrés  $\hat{\beta}$  est la projection de  $Y$  sur l'espace engendré par les colonnes de  $X$ .
  - Vrai
  - Faux
- L'estimateur des moindres carrés  $\hat{\beta}$  est l'estimateur de  $\beta$  qui a la plus petite variance (au sens matriciel).
  - Vrai
  - Faux
- L'estimateur du maximum de vraisemblance de  $\beta$  est non biaisé.
  - Vrai
  - Faux
- L'estimateur du maximum de vraisemblance de  $\sigma^2$  est non biaisé.
  - Vrai
  - Faux
- Les estimateurs des moindres carrés  $\hat{\beta}$  et  $\hat{\sigma}^2$  sont indépendants.
  - Vrai
  - Faux
- Les estimateurs des moindres carrés  $\hat{\beta}_k$ ,  $1 \leq k \leq p$ , sont indépendants.
  - Vrai
  - Faux

**Exercice 2.** On souhaite faire la régression simple d'une variable  $Y$  en fonction d'une variable explicative  $X$  (avec intercept). Pour cela, on dispose de  $n$  observations  $(x_i, y_i)$ ,  $1 \leq i \leq n$ , et des statistiques résumées suivantes :

$$\begin{aligned} \bar{x} &= \frac{1}{n} \sum_{i=1}^n x_i = 1 & \bar{y} &= \frac{1}{n} \sum_{i=1}^n y_i = 2.07 \\ s_x^2 &= \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 = 0.35 & s_y^2 &= \frac{1}{n-1} \sum_{i=1}^n (y_i - \bar{y})^2 = 15.93 \\ s_{xy}^2 &= \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) = 2.22 \\ \bar{x^2} &= \frac{1}{n} \sum_{i=1}^n x_i^2 = 1.34 & s_{x^2}^2 &= \frac{1}{n-1} \sum_{i=1}^n (x_i^2 - \bar{x^2})^2 = 1.56 \\ s_{x^2y}^2 &= \frac{1}{n-1} \sum_{i=1}^n (x_i^2 - \bar{x^2})(y_i - \bar{y}) = 4.85 \end{aligned}$$

1. Posez un modèle de régression en précisant les hypothèses, et donnez l'expression des estimateurs des coefficients.
2. Calculez les coefficients en utilisant les données fournies.
3. Rappelez la définition du  $R^2$  du modèle et son interprétation.
4. On rappelle que, dans le cas d'une régression simple, on a  $R^2 = \rho_{x,y}^2$ , avec  $\rho_{x,y}$  le coefficient de corrélation entre  $x$  et  $y$ . Calculez le  $R^2$  du modèle.
5. On souhaite maintenant faire la régression de  $Y$  contre  $X^2$ . Posez le modèle associé, calculez les estimateurs de ses coefficients et le  $R^2$  de ce modèle.
6. D'après ces résultats, pouvez-vous préférer un modèle plutôt qu'un autre ?

**Exercice 3.** On examine l'évolution d'une variable  $Y$  en fonction de deux variables  $x$  et  $z$ . On dispose de  $n = 50$  observations de ces variables. On note  $X = \begin{pmatrix} \mathbf{1} & x & z \end{pmatrix}$  où  $\mathbf{1}$  est le vecteur constant et  $x, z$  sont les vecteurs des variables explicatives. On suppose que l'on a calculé :

$$X^T X = \begin{pmatrix} ? & 0 & 0 \\ ? & 4.28 & 5.41 \\ ? & ? & 103.86 \end{pmatrix}, \quad Y^T Y = \|Y\|^2 = 147.24, \quad \hat{\beta} = \begin{pmatrix} 0.1 \\ -2 \\ 1 \end{pmatrix}.$$

1. Donnez les valeurs manquantes dans la matrice.
2. Donnez l'expression de  $\hat{\beta}$  et calculez  $X^T Y$ .
3. Calculez les moyennes empiriques  $\bar{x}$ ,  $\bar{z}$  et  $\bar{y}$ .
4. Donnez l'expression de  $\hat{Y}$  et calculez  $\|\hat{Y}\|^2$ .
5. Donnez l'estimateur sans biais de la variance, et calculez-le.
6. Sous quelles hypothèses peut-on connaître la loi de  $\hat{\sigma}^2$  ? Donnez l'expression de cette loi (normalisée).
7. Construisez un intervalle de confiance à 95% pour  $\sigma^2$ .  
On donne les quantiles à 2.5%, 5%, 95% et 97.5% de la loi du  $\chi^2$  à 49, 48, et 47 degrés de liberté dans la table suivante :

	2.5%	5%	95%	97.5%
47	30	32.3	64	67.8
48	30.8	33.1	65.2	69
49	31.6	33.9	66.3	70.2

**Exercice 4.** On dispose des vecteurs  $\mathbf{x}_1$ ,  $\mathbf{x}_2$  et  $\mathbf{y}$  décrivant les valeurs prises par trois variables  $X_1$ ,  $X_2$  et  $Y$ . On exécute les commandes suivantes dans R :

```
fit_1 <- lm(y ~ x_1 + x_2)
summary(fit_1)

##
## Call:
## lm(formula = y ~ x_1 + x_2)
##
## Residuals:
##   Min     1Q  Median     3Q    Max
## -2.558 -0.807 -0.417  0.397  3.671
##
## Coefficients:
##             Estimate Std. Error t value Pr(>|t|)
## (Intercept)  -1.888     0.354   -5.34  5.4e-05 ***
## x_1           -0.290     0.375   -0.78   0.45
## x_2            2.960     0.251   11.78  1.3e-09 ***
## ---
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## Residual standard error: 1.58 on 17 degrees of freedom
## Multiple R-squared:  0.891, Adjusted R-squared:  0.878
## F-statistic: 69.4 on 2 and 17 DF,  p-value: 6.66e-09

fit_2 <- lm(y ~ x_2)
summary(fit_2)

##
## Call:
## lm(formula = y ~ x_2)
##
## Residuals:
##   Min     1Q  Median     3Q    Max
## -2.383 -0.873 -0.276  0.424  3.407
##
## Coefficients:
##             Estimate Std. Error t value Pr(>|t|)
## (Intercept)  -1.891     0.350   -5.41  3.9e-05 ***
## x_2            2.951     0.248   11.89  5.9e-10 ***
## ---
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## Residual standard error: 1.56 on 18 degrees of freedom
## Multiple R-squared:  0.887, Adjusted R-squared:  0.881
## F-statistic: 141 on 1 and 18 DF,  p-value: 5.88e-10
```

1. Donnez les équations (numériques) des deux droites de régression estimées.
2. Quelle est la longueur des vecteurs  $\mathbf{x}_1$ ,  $\mathbf{x}_2$  et  $\mathbf{y}$  ?
3. On s'intéresse au premier modèle. Que dire de la significativité des coefficients ? Justifiez. On décrira en détails le test associé, avec ses hypothèses.
4. Dans le premier modèle, les intervalles de confiance pour coefficient associé à  $\mathbf{x}_2$  aux niveaux, respectivement, de 90%, 95% et 99% contiennent-ils zéro ?
5. Lequel des deux modèles a le  $R^2$  le plus grand ? Est-ce surprenant ?
6. Lequel des deux modèles préféreriez-vous ? Justifiez.