

## Première Année Master M.A.E.F. 2015 – 2016

## Econométrie II

Contrôle continu n°2, avril 2016

Examen de 1h30. Tout document ou calculatrice est interdit.

1. (**Sur 29 points**) Pour  $n$  et  $p$  deux entiers tels que  $n \geq p + 1$ , soit  $Y = {}^t(Y_i)_{1 \leq i \leq n}$  défini par:

$$Y_i = \theta_0 + \theta_1 X_i^{(1)} + \dots + \theta_p X_i^{(p)} + \varepsilon_i \quad \text{pour tout } i = 1, \dots, n, \quad (1)$$

avec:

- $(X_i^{(j)})_{1 \leq i \leq n, 1 \leq j \leq p}$  étant connues et telles que  $X = \begin{pmatrix} 1 & X_1^{(1)} & \dots & X_1^{(p)} \\ \vdots & \vdots & & \vdots \\ 1 & X_n^{(1)} & \dots & X_n^{(p)} \end{pmatrix}$  soit une matrice de rang  $p + 1$ ;
- $\theta = {}^t(\theta_j)_{0 \leq j \leq p}$  un vecteur de nombres réels inconnus;
- $\varepsilon = {}^t(\varepsilon_i)_{1 \leq i \leq n}$  un vecteur d'erreur non observé tel que  $\mathbb{E}(\varepsilon) = 0$  et  $\text{cov}(\varepsilon) = \Sigma$ , où  $\Sigma$  est une matrice définie positive inconnue de valeurs propres  $0 < \lambda_1 \leq \dots \leq \lambda_n$  (inconnues).

- (a) On effectue une régression par moindres carrés ordinaires pour obtenir un estimateur  $\hat{\theta}$ . Montrer que  $\hat{\theta}$  est un estimateur sans biais de  $\theta$  et  $\text{cov}(\hat{\theta}) = ({}^t X X)^{-1} {}^t X \Sigma X ({}^t X X)^{-1}$  (**1pt**).
- (b) Pour une matrice carrée  $A = (a_{ij})_{1 \leq i, j \leq m}$  où  $m \in \mathbf{N}^*$ , soit la norme matricielle définie par

$$\|A\|_2 = \sup_{U \in \mathbf{R}^m, U \neq 0} \frac{\|AU\|_2}{\|U\|_2} \quad \text{où } \|Z\|_2^2 = {}^t Z Z \quad \text{pour tout } Z \in \mathbf{R}^m.$$

Montrer que si  $A$  est une matrice symétrique, alors  $\|A\|_2 = \max(|\text{Valeurs propres de } A|)$  (**2pts**).

- (c) Montrer que  ${}^t X X$  est une matrice définie positive et on notera  $0 < \mu_1 \leq \dots \leq \mu_{p+1}$  ses valeurs propres (**1.5pts**). Montrer que  ${}^t V \Sigma V \leq \lambda_n \|V\|_2^2$  pour tout  $V \in \mathbf{R}^n$  (**2pts**), et en déduire que  ${}^t W \text{cov}(\hat{\theta}) W \leq \lambda_n \|X ({}^t X X)^{-1} W\|_2^2$  pour tout  $W \in \mathbf{R}^{p+1}$  (**1.5pts**), puis que  ${}^t W \text{cov}(\hat{\theta}) W \leq \frac{\lambda_n}{\mu_1} \|W\|_2^2$  (**2pts**). En déduire une condition suffisante de convergence de  $\hat{\theta}$  vers  $\theta$  quand  $n \rightarrow \infty$  (**1pt**).
- (d) On se place désormais dans le cadre d'hétéroscédasticité suivant: les  $(\varepsilon_i)$  sont indépendantes et  $\text{var}(\varepsilon_i) = \sigma_i^2$ , avec  $\underline{\sigma}^2 \leq \sigma_i^2 \leq \bar{\sigma}^2$  pour tout  $i = 1, \dots, n$  et  $\frac{1}{n} \sum_{i=1}^n \sigma_i^2 \xrightarrow{n \rightarrow \infty} \sigma^2$  où  $0 < \underline{\sigma}^2 \leq \sigma^2 \leq \bar{\sigma}^2$  sont trois réels fixés inconnus. Montrer que  $\hat{\theta} \xrightarrow[n \rightarrow +\infty]{\mathcal{P}} \theta$  si  $\mu_1 \xrightarrow{n \rightarrow \infty} +\infty$  (**1pt**).
- (e) On considère l'estimateur de la variance par MCO  $\hat{\sigma}^2 = \frac{1}{n-(p+1)} {}^t(Y - X \hat{\theta})(Y - X \hat{\theta})$ . Montrer que  $\mathbb{E}(\hat{\sigma}^2) = \frac{1}{n-(p+1)} (\text{Tr}(\Sigma) - \text{Tr}(H \Sigma))$  où vous exprimerez  $H = (H_{ij})_{1 \leq i, j \leq n}$  en fonction  $X$  (**2pts**). Montrer que pour tout  $i = 1, \dots, n$ ,  $H_{ii} = \sum_{k=1}^n H_{ik}^2 \geq 0$  (**1pt**), puis que  $\underline{\sigma}^2(p+1) \leq \text{Tr}(H \Sigma) \leq \bar{\sigma}^2(p+1)$  (**2pts**). En déduire que  $\mathbb{E}(\hat{\sigma}^2) \xrightarrow{n \rightarrow \infty} \sigma^2$  (**1pt**).
- (f) Montrer que  $\frac{1}{n-(p+1)} \sum_{i=1}^n \varepsilon_i^2 - \hat{\sigma}^2 \geq 0$  (**1.5pts**), et  $\frac{1}{n-(p+1)} \sum_{i=1}^n \varepsilon_i^2 \xrightarrow[n \rightarrow +\infty]{\mathcal{P}} \sigma^2$  (**2.5pts**). En déduire que  $\hat{\sigma}^2 \xrightarrow[n \rightarrow +\infty]{\mathcal{P}} \sigma^2$  (**2pts**).
- (g) On va montrer que les tests de Student peuvent être valables dans un tel cadre. On suppose que  $p = 1$ ,  $n$  pair, et  $X_i^{(1)} = 1$ ,  $\sigma_i^2 = \bar{\sigma}^2$  pour  $i = 1, \dots, n/2$ ,  $X_i^{(1)} = 0$ ,  $\sigma_i^2 = \underline{\sigma}^2$  pour  $i = n/2 + 1, \dots, n$ , avec  $\underline{\sigma}^2 < \bar{\sigma}^2$ . Donner l'expression exacte de  $\hat{\theta}$ , de  $\text{cov}(\hat{\theta})$ , de  $\sigma^2$  (**3.5pts**). Rappeler l'expression matricielle du test de Student  $\hat{T}_1$  relatif à la significativité de  $X^{(1)}$  (**0.5pts**). En déduire que  $\hat{T}_1 = \sqrt{n} \frac{\hat{\theta}_1}{2\sigma}$  (**1pt**), puis montrer que  $\hat{T}_1 \xrightarrow[n \rightarrow \infty]{\mathcal{L}} \mathcal{N}(0, 1)$  (**1pt**).

*Proof.* (a) On a  $\hat{\theta} = ({}^t X X)^{-1} {}^t X Y = \theta + ({}^t X X)^{-1} {}^t X \varepsilon$ . Comme  $\mathbb{E}(\varepsilon) = 0$ , on a bien  $\mathbb{E}(\hat{\theta}) = \theta$ .

On a  $\text{cov}(\hat{\theta}) = \mathbb{E}(({}^t X X)^{-1} {}^t X \varepsilon \varepsilon {}^t X ({}^t X X)^{-1}) = ({}^t X X)^{-1} {}^t X \mathbb{E}(\varepsilon \varepsilon {}^t) X ({}^t X X)^{-1} = ({}^t X X)^{-1} {}^t X \Sigma X ({}^t X X)^{-1}$ .

- (b)  $A$  est symétrique donc diagonalisable. Il en est de même pour  $A^2$ , dont les valeurs propres sont le carré de celles de  $A$ . Ainsi  $\|AU\|_2^2 = {}^tUA^2U = {}^t(PU)D^2(PU)$  où  $P$  est une matrice orthogonale et  $D$  une matrice diagonale. D'où  $\sup_{U \in \mathbf{R}^m, U \neq 0} \frac{\|AU\|_2^2}{\|U\|_2^2} = \sup_{U' \in \mathbf{R}^m, U' \neq 0} \frac{\|DU'\|_2^2}{\|U'\|_2^2} = \sup_{(u_i)_i} \frac{\sum_{i=1}^m v p_i^2 u_i^2}{\sum_{i=1}^m u_i^2} \leq \max(v p_i^2)$  (où  $v p_i$  désigne les valeurs propres de  $A$ ).
- (c)  ${}^tXX$  est une matrice symétrique donc diagonalisable. De plus  ${}^tU^tXXU = \|XU\|_2^2$ , donc la forme quadratique  $U \rightarrow {}^tU^tXXU$  est positive. Comme  ${}^tXX$  est inversible, elle ne peut pas avoir 0 pour valeur propre, donc elle est définie positive. Comme précédemment, on écrit  ${}^tV\Sigma V = {}^t(PV)D(PV)$  où  $P$  est diagonale et  $D$  la matrice diagonale constituée des  $\lambda_i$ . D'où le résultat.  
On a également  ${}^tW \text{cov}(\hat{\theta}) W = {}^tW \text{cov}(\hat{\theta}) W = ({}^tXX)^{-1} {}^tX \Sigma X ({}^tXX)^{-1} W = {}^tW' \Sigma W'$  avec  $W' = X ({}^tXX)^{-1} W$ . En utilisant ce qui précède, on a bien  ${}^tW' \Sigma W' \leq \lambda_n \|W'\|_2^2$ . Mais  $\|W'\|_2^2 = {}^tW ({}^tXX)^{-1} {}^tX \Sigma X ({}^tXX)^{-1} W = {}^tW ({}^tXX)^{-1} W \leq \max(|\text{Valeur propre de } ({}^tXX)^{-1}|) \|W\|_2^2 = 1/\mu_1 \|W\|_2^2$ . D'où le résultat.  
On a donc  $\|(\text{cov}(\hat{\theta}))^{1/2}\|_2^2 \leq \frac{\lambda_n}{\mu_1}$ , d'où  $\|\text{cov}(\hat{\theta})\|_2 \leq \frac{\lambda_n}{\mu_1}$ . Une condition suffisante de convergence est donc  $\frac{\lambda_n}{\mu_1} \xrightarrow{n \rightarrow \infty} 0$ .
- (d) Dans ce cas,  $\lambda_n \leq \bar{\sigma}^2$  donc la condition précédente devient bien  $\mu_1 \rightarrow \infty$ .
- (e) On a  $\mathbb{E}(\hat{\sigma}^2) = \frac{1}{n-(p+1)} \mathbb{E}[\text{Tr}({}^t(P_{[X]^\perp} \varepsilon) P_{[X]^\perp} \varepsilon)] = \frac{1}{n-(p+1)} \mathbb{E}[\text{Tr}(P_{[X]^\perp} P_{[X]^\perp} \varepsilon \varepsilon^t \varepsilon)]$  du fait que  $\text{Tr}(AB) = \text{Tr}(BA)$ . Avec le fait que  $P_{[X]^\perp} P_{[X]^\perp} = P_{[X]^\perp} = I_n - P_{[X]}$  et  $\mathbb{E}(\varepsilon \varepsilon^t) = \Sigma$ , on en déduit que  $\mathbb{E}(\hat{\sigma}^2) = \frac{1}{n-(p+1)} \text{Tr}((I_n - P_{[X]})\Sigma) = \frac{1}{n-(p+1)} (\text{Tr}(\Sigma) - \text{Tr}(H\Sigma))$  avec  $H = P_{[X]} = X ({}^tXX)^{-1} X$ .  
Comme  $H = {}^tH$  et  $H^2 = H = {}^tHH$ , la matrice  ${}^tHH$  a pour terme général  $\sum_{k=1}^n H_{ki} H_{kj}$ , donc sur la diagonale, pour  $i = j$ , on obtient  $H_{ii} = \sum_{k=1}^n H_{ki} H_{ki}$ .  
On a  $\text{Tr}(H\Sigma) = \sum_{i=1}^n \sigma_i^2 H_{ii}$ . Comme d'après ce qui précède,  $H_{ii} \geq 0$ , et  $\sigma^2 \leq \sigma_i^2 \leq \bar{\sigma}^2$ , on a  $\sigma^2 \sum_{i=1}^n H_{ii} \leq \text{Tr}(H\Sigma) \leq \bar{\sigma}^2 \sum_{i=1}^n H_{ii}$ . Mais on sait que  $\sum_{i=1}^n H_{ii} = \text{Tr}(H) = p + 1$  (matrice de projection orthogonale sur un sous-espace vectoriel de dimension  $p + 1$ ), d'où le résultat.
- (f) On sait que  $\|\varepsilon\|_2^2 \geq \|P_{[X]^\perp} \varepsilon\|_2^2 = {}^t(Y - X\hat{\theta})(Y - X\hat{\theta})$ , d'où le résultat.  
Soit  $Z_n = \frac{1}{n} \sum_{k=1}^n \varepsilon_k^2$ . Alors pour  $u \in \mathbf{R}$ ,  $\mathbb{E}(e^{iuZ_n}) = \prod_{k=1}^n \mathbb{E}(e^{iu\varepsilon_k^2/n})$ , du fait de l'indépendance des  $(\varepsilon_k)$ . On en déduit que  $\log(\mathbb{E}(e^{iuZ_n})) = \sum_{k=1}^n \log(\mathbb{E}(e^{iu\varepsilon_k^2/n}))$ . Mais grâce à un DL en 0,  $\mathbb{E}(e^{iu\varepsilon_k^2/n}) = 1 + iu\sigma_k^2/n(1 + o(1))$ , d'où  $\sum_{k=1}^n \log(\mathbb{E}(e^{iu\varepsilon_k^2/n})) = \sum_{k=1}^n \log(1 + iu\sigma_k^2/n(1 + o(1))) = iu \frac{1+o(1)}{n} \sum_{k=1}^n \sigma_k^2 \xrightarrow{n \rightarrow \infty} iu\sigma^2$ . Par suite,  $\mathbb{E}(e^{iuZ_n}) \xrightarrow{n \rightarrow \infty} e^{iu\sigma^2}$ , qui est la fonction caractéristique de la masse de Dirac en  $\sigma^2$ . D'où  $Z_n \xrightarrow{\mathcal{L}} \sigma^2$ , soit  $Z_n \xrightarrow{\mathcal{P}} \sigma^2$ , et avec Slutsky,  $\frac{1}{n-(p+1)} \sum_{k=1}^n \varepsilon_k^2 \xrightarrow{\mathcal{P}} \sigma^2$ .  
La variable  $S_n = \frac{1}{n-(p+1)} \sum_{i=1}^n \varepsilon_i^2 - \hat{\sigma}^2$  est positive, et son espérance est  $\frac{1}{n-(p+1)} \text{Tr}(H\Sigma) \xrightarrow{n \rightarrow \infty} 0$ . Donc d'après l'Inégalité de Markov,  $S_n \xrightarrow{\mathcal{P}} 0$  et comme  $\frac{1}{n-(p+1)} \sum_{i=1}^n \varepsilon_i^2 \xrightarrow{\mathcal{P}} \sigma^2$ , on en déduit que  $\hat{\sigma}^2 \xrightarrow{\mathcal{P}} \sigma^2$ .
- (g) Dans ce cas,  ${}^tXX = \frac{n}{2} \begin{pmatrix} 2 & 1 \\ 1 & 1 \end{pmatrix}$ , d'où  $({}^tXX)^{-1} = \frac{2}{n} \begin{pmatrix} 1 & -1 \\ -1 & 2 \end{pmatrix}$ .  
On en déduit que  $\hat{\theta} = ({}^tXX)^{-1} {}^tXY = \frac{2}{n} \begin{pmatrix} 1 & -1 \\ -1 & 2 \end{pmatrix} \begin{pmatrix} \sum_{i=1}^n Y_i \\ \sum_{i=1}^{n/2} Y_i \end{pmatrix} = \begin{pmatrix} \frac{2}{n} \sum_{i=n/2+1}^n Y_i \\ \frac{2}{n} (\sum_{i=1}^{n/2} Y_i - \sum_{i=n/2+1}^n Y_i) \end{pmatrix}$ .  
Par ailleurs,  ${}^tX\Sigma X = \frac{n}{2} \begin{pmatrix} \bar{\sigma}^2 + \sigma^2 & \bar{\sigma}^2 \\ \bar{\sigma}^2 & \bar{\sigma}^2 \end{pmatrix}$  d'où  $\text{cov}(\hat{\theta}) = \frac{2}{n} \begin{pmatrix} \sigma^2 & -\sigma^2 \\ -\sigma^2 & \sigma^2 + \bar{\sigma}^2 \end{pmatrix}$ .  
Enfin, on facilement  $\sigma^2 = \frac{1}{2} (\bar{\sigma}^2 + \sigma^2)$ . Il est clair que  $\hat{\theta}_1$  est asymptotiquement gaussien car  $H$  est telle que  $\max(|H_{ii}|) \xrightarrow{n \rightarrow \infty} 0$ .  
La variance de  $\hat{\theta}_1$  est  $\frac{2}{n} (\sigma^2 + \bar{\sigma}^2) = \frac{4}{n} \sigma^2$ . Or on sait que  $\hat{\sigma}^2 \xrightarrow{\mathcal{P}} \sigma^2$ , donc  $\hat{T} = \frac{\sqrt{n} \hat{\theta}_1}{2\hat{\sigma}}$ , statistique de Student, converge bien en loi vers une  $\mathcal{N}(0, 1)$ .

□

## 2. (Sur 10 points) Exercice de TP utilisant le logiciel R

- (a) On a tapé les commandes suivantes:

```
n=100; Y=0; i=1:100;
Z1=i; Z2=5*rnorm(n,0)
Z3=runif(n,0,20); Z4=4*cos(2*pi*i/12)
epsilon=2*rnorm(n,0)^2
Y=10-3*Z3+4*sqrt(i+3)+5*epsilon
reg1=lm(Y~Z1+Z2+Z3+Z4)
summary(reg1)
```

On obtient les résultats:

Coefficients:

	Estimate	Std. Error	t value	Pr(> t )
(Intercept)	30.52028	3.52702	8.653	1.24e-13 ***
Z1	0.30467	0.04661	6.537	3.12e-09 ***
Z2	0.13032	0.28060	0.464	0.643
Z3	-2.84563	0.22257	-12.785	< 2e-16 ***
Z4	-0.79840	0.48118	-1.659	0.100

Residual standard error: 13.44 on 95 degrees of freedom  
 Multiple R-squared: 0.6933, Adjusted R-squared: 0.6804  
 F-statistic: 53.68 on 4 and 95 DF, p-value: < 2.2e-16

*Questions 1: Quelle est la loi de epsilon? Ecrire  $Y$  sous la forme  $Y = X\theta + \varepsilon$  avec  $X$  dépendant des  $Z_i$  et  $\mathbb{E}(\varepsilon) = 0$ . Que pensez-vous des résultats de cette régression? Pouvait-on s'y attendre?*

*Proof.* La loi de epsilon est 2 fois un Chi-deux à 1 degré de liberté (**0.5pts**).

Le modèle s'écrit  $Y = \theta_0 + \theta_1 \sqrt{Z_1 + 3} + \theta_3 Z_3 + \varepsilon$ , avec  $\varepsilon_i = 5(\text{epsilon} - 2)$  car  $\mathbb{E}(\text{epsilon}) = 2$ , d'où  $\theta_0 = 20$ ,  $\theta_1 = 4$  et  $\theta_3 = -3$  (**1.5pts**).

Les résultats indiquent que Z2 et Z4 sont non significatives, ce qui n'est pas surprenant car elles ne sont pas dans le modèle (**0.5pts**). □

(b) On tape ensuite les commandes:

```
library(MASS)
ZZ=as.data.frame(cbind(Z1,Z2,Z3,Z4));
y.lm=lm(Y~.,data=ZZ);
y.bic=stepAIC(y.lm,k=log(n));
```

Voici les résultats:

Start: AIC=537.54

Y ~ Z1 + Z2 + Z3 + Z4

	Df	Sum of Sq	RSS	AIC
- Z2	1	39.0	17198	533.16
- Z4	1	497.3	17656	535.79
<none>			17159	537.54
- Z1	1	7718.8	24878	570.08
- Z3	1	29524.2	46683	633.02

Step: AIC=533.16

Y ~ Z1 + Z3 + Z4

	Df	Sum of Sq	RSS	AIC
- Z4	1	515.2	17713	531.50
<none>			17198	533.16
- Z1	1	7710.1	24908	565.59
- Z3	1	31283.9	48482	632.19

Step: AIC=531.5

Y ~ Z1 + Z3

	Df	Sum of Sq	RSS	AIC
<none>			17713	531.50
- Z1	1	7551.5	25264	562.41
- Z3	1	30880.0	48593	627.82

*Questions 2: Qu'a-t-on fait avec ces commandes et que peut-on en conclure? Pouvait-on s'y attendre?*

*Proof.* On a effectué une sélection de modèle à l'aide du critère BIC et on a obtenu un modèle ne contenant que Z1 et Z3. Ce n'est pas surprenant puisque ce sont les seules variables intervenant dans le modèle (**1pt**). □

(c) De nouvelles commandes sont tapées:

```
summary(y.bic)
plot(y.bic)
```

Voici les résultats et un des graphes obtenus:


Coefficients:

	Estimate	Std. Error	t value	Pr(> t )
(Intercept)	30.57434	3.52651	8.670	9.93e-14 ***
Z1	0.30105	0.04681	6.431	4.79e-09 ***
Z3	-2.84153	0.21851	-13.004	< 2e-16 ***

Residual standard error: 13.51 on 97 degrees of freedom

Multiple R-squared: 0.6834, Adjusted R-squared: 0.6768

F-statistic: 104.7 on 2 and 97 DF, p-value: < 2.2e-16



Questions 3: Qu'a-t-on fait avec ces commandes? Que signifie précisément la valeur numérique 30.57434 et pouvait-on s'y attendre? Dire également en termes mathématiques ce que sont 0.30105,  $-2.84153$ , 0.21851,  $-13.004$  et  $4.79e - 09$ . Au final que pensez-vous des résultats obtenus?

*Proof.* On a effectué une régression linéaire par moindres carrés de  $Y$  par rapport à  $Z1$  et  $Z3$ , variables issus de la sélection de modèle BIC (**0.5pts**).

30.57434 représente l'estimation de  $\alpha_0$  par moindres carrés dans le modèle  $Y_i = \alpha_0 + \alpha_1 Z1 + \alpha_3 Z3 + \varepsilon_i$ . Notons ici que la valeur théorique de  $\alpha_0$  est  $\theta_0 + 4 * \sqrt{3} \simeq 27$ , donc on n'est pas surpris d'avoir obtenu 30.57434 (**1pt**).

0.30105 et  $-2.84153$  sont les estimateurs respectifs  $\hat{\alpha}_1$  et  $\hat{\alpha}_3$ , où  $\hat{\alpha} = ({}^t Z Z)^{-1} Z Y$ ,  $Z$  étant la matrice de 3 colonnes contenant des 1,  $Z1$  et  $Z3$  (**0.5pts**).

0.21851 représente une estimation de l'écart-type de  $\hat{\alpha}_3$ , obtenue en prenant la racine carrée du terme (3,3) de la matrice  $\hat{\sigma}^2 ({}^t Z Z)^{-1}$  (**0.5pts**).

$-13.004$  représente la valeur du test de Student de significativité de  $Z3$ , test de nullité de  $\alpha_3$ , statistique qui vaut  $\frac{\hat{\alpha}_3}{\sigma \sqrt{{}^t C_3 ({}^t Z Z)^{-1} C_3}}$ ,

avec  ${}^t C_3 = (0, 0, 1)$  (**0.5pts**).

$4.79e - 09$  représente la p-value du test précédent, c'est-à-dire la probabilité que  $|T| > 13.004$  lorsque  $T$  suit une loi de Student à 97 degrés de liberté (**0.5pts**).

Si toutes les variables sont significatives, le graphe des  $\hat{\varepsilon}$  en fonction des  $\hat{Y}$  indique une forme particulière qui nous indique un problème de modèle. Cela n'est pas surprenant puisque ce n'est pas  $Z1$  qui intervient mais plutôt  $\sqrt{3 + Z1}$  (**0.5pts**).  $\square$

(d) On a enfin tapé les commandes:

```
Q=matrix(0,50,50)
for (a in c(1:50))
{ for (b in c(1:50))
{ Z1a=Z1^(a/10); Z3b=Z3^(b/10)
reg=lm(Y~Z1a+Z3b)
Q[a,b]=sum(reg$res^2) }}
which(Q==min(Q),arr.ind = TRUE)
```

Voici le résultat:

```
row col
[1,] 6 10
```

Questions 4: Qu'a-t-on fait avec ces commandes et qu'a-t-on obtenu? Pouvait-on s'attendre au résultat obtenu? Si vous deviez prédire  $Y_i$  pour  $i = 101$ , quelles commandes R utiliseriez vous?

*Proof.* Ici on a cherché les valeurs de  $\alpha$  et  $\beta$  qui optimise le modèle  $Y_i = \theta_0 + \theta_1 Z1_i^\alpha + \theta_3 Z3_i^\beta + \varepsilon_i$  au sens de la somme des résidus au carré (donc qui maximise le  $R^2$ ). On effectue des régressions pour  $\alpha$  et  $\beta$  variant dans  $\{0.1, 0.2, \dots, 4.9, 5\}$ . On obtient  $\hat{\alpha} = 0.6$  et  $\hat{\beta} = 1$  (**1pt**). On pouvait s'attendre à de tels résultats puisque le modèle simulé l'est avec  $\alpha \simeq 0.5$  (on considère  $\sqrt{Z1 + 3}$ ) et  $Z3$  (**0.5pts**).

Pour la prédiction, on pourrait utiliser les commandes (on remplace  $Z3$  par son espérance, donc 10): (**1pt**)

```
Z1a=Z1^0.6
y.reg=lm(Y~Z1a+Z3)
y.pred=y.reg$coeff[1]+ y.reg$coeff[2]*101^0.6+ y.reg$coeff[3]*10
```