

# Première Année Master M.A.E.F. 2014 – 2015

## Econométrie II

Contrôle continu n°2, avril 2015

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

1. (**Sur 22 points**) Pour  $n$  et  $p$  deux entiers tels que  $n \geq p + 1$ , soit  $Y = {}^t(Y_i)_{1 \leq i \leq n}$  le vecteur colonne de variables aléatoires représentant une variable quantitative (le nombre de personne infectées par épidémie) en différents lieux d'un pays et défini par:

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

avec:

- $(X_i^{(j)})_{1 \leq i \leq n, 1 \leq j \leq p}$  étant connues et telles que  $X = \begin{pmatrix} 1 & X_1^{(1)} & \cdots & X_1^{(p)} \\ \vdots & \vdots & & \vdots \\ 1 & X_n^{(1)} & \cdots & X_n^{(p)} \end{pmatrix}$  soit une matrice de rang  $p + 1$ ;
- $\theta = (\theta_j)_{0 \leq j \leq p}$  un vecteur de nombres réels inconnus;
- $\varepsilon = {}^t(\varepsilon_i)_{1 \leq i \leq n}$  un vecteur d'erreur. On suppose qu'il y a une interférence spatiale entre les erreurs, qu'il existe une matrice connue  $W = (W_{ij})_{1 \leq i,j \leq n}$  vérifiant  $W_{ii} = 0$  et  $\sum_{j=1}^n |W_{ij}| \leq 1$  pour tout  $i = 1, \dots, n$ , pas forcément symétrique, donnant l'influence entre ces erreurs et ainsi:

$$\varepsilon = \lambda W \varepsilon + \xi,$$

avec  $\xi$  un vecteur gaussien de loi  $\mathcal{N}_n(0, \sigma^2 I_n)$ ,  $I_n$  la matrice identité,  $\sigma^2 > 0$  et  $\lambda \in \mathbf{R}$ , deux réels inconnus.

- (a) (**Facultatif, sur 6 points**) Pour  $A$  une matrice carrée d'ordre  $n$ , on note la norme matricielle  $\|A\| = \sup_{Z \in \mathbf{R}^n} \frac{\|AZ\|}{\|Z\|}$ , où  $\|Z\|^2 = \sum_{i=1}^n Z_i^2$ , avec  $Z = (Z_i)_{1 \leq i \leq n}$ . Montrer que  $\|W\| \leq \sqrt{n}$  (**2pts**), puis que pour tout  $\lambda \in [-1/\sqrt{n}, 1/\sqrt{n}]$ ,  $\|\lambda^N W^N\| \xrightarrow[N \rightarrow \infty]{} 0$  (**1.5pt**). Calculer  $(I_n - \lambda W)(I_n + \sum_{k=1}^N \lambda^k W^k)$  pour  $N \in \mathbf{N}^*$  (**1pt**), et en déduire que  $I_n - \lambda W$  est une matrice inversible pour tout  $\lambda \in [-1/\sqrt{n}, 1/\sqrt{n}]$  (**1.5pts**).
- (b) Montrer que pour tout  $\lambda \in [-1/\sqrt{n}, 1/\sqrt{n}]$   $\varepsilon$  peut s'écrire en fonction de  $\lambda W$ ,  $I_n$  et  $\xi$  (**1pt**). En déduire la loi de  $Y$  (**1pt**), puis que la log-vraisemblance de  $Y$  s'écrit (**1pt**):

$$\log(L_{\theta, \lambda, \sigma^2}(Y)) = \log(|\det(I_n - \lambda W)|) - \frac{n}{2} \log(2\pi\sigma^2) - \frac{1}{2\sigma^2} {}^t(Y - X\theta)(I_n - \lambda^t W)(I_n - \lambda W)(Y - X\theta).$$

- (c) Si on suppose que  $\lambda$  est connu, déterminer les expressions des estimateurs par maximum de vraisemblance  $(\hat{\theta}_\lambda, \hat{\sigma}_\lambda^2)$  de  $(\theta, \sigma^2)$  (**1.5pt**). Quelle est la loi de  $\hat{\theta}$  (**1pt**)?
- (d) On suppose maintenant que  $\lambda$  est inconnu. Exprimez  $\log(|\det(I_n - \lambda W)|)$  en fonction de  $P_W$  le polynôme caractéristique de la matrice  $W$  (**1pt**). Soit les estimateurs par maximum de vraisemblance  $(\hat{\theta}, \hat{\lambda}, \hat{\sigma}^2)$  de  $(\theta, \lambda, \sigma^2)$ . Exprimer  $\hat{\theta}$  en fonction de  $\hat{\lambda}$ ,  $\hat{\sigma}^2$  en fonction de  $\hat{\theta}$  et  $\hat{\lambda}$ , et une relation liant  $\hat{\theta}$ ,  $\hat{\lambda}$  et  $\hat{\sigma}^2$  en fonction de  $P'_W$  (**2pts**).
- (e) On veut tester s'il y a réellement une interaction spatiale entre les données. Proposer une statistique de test, dépendant de  $\hat{\theta}_0, \hat{\sigma}_0^2, \hat{\theta}, \hat{\lambda}$  et  $\hat{\sigma}^2$ , permettant de tester  $H_0: \lambda = 0$  contre  $H_1: \lambda \neq 0$  (**2pts**).
- (f) On se place dans le cadre où une observation (par exemple  $Y_1$ ) a une influence très forte sur toutes les autres et ainsi on pose  $W = \begin{pmatrix} 0 & 0 & \cdots & 0 \\ 1 & 0 & \cdots & 0 \\ \vdots & \vdots & & \vdots \\ 1 & 0 & \cdots & 0 \end{pmatrix}$ . Montrer que  $I_n - \lambda W$  est inversible pour tout  $\lambda \in \mathbf{R}$ . Déterminer alors les équations explicites permettant de calculer  $(\hat{\theta}, \hat{\lambda}, \hat{\sigma}^2)$  (**2pts**). Dans le cas où  $\theta$  est connu, montrer que  $\hat{\lambda}$  converge vers  $\lambda$  (**3.5pts**).

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

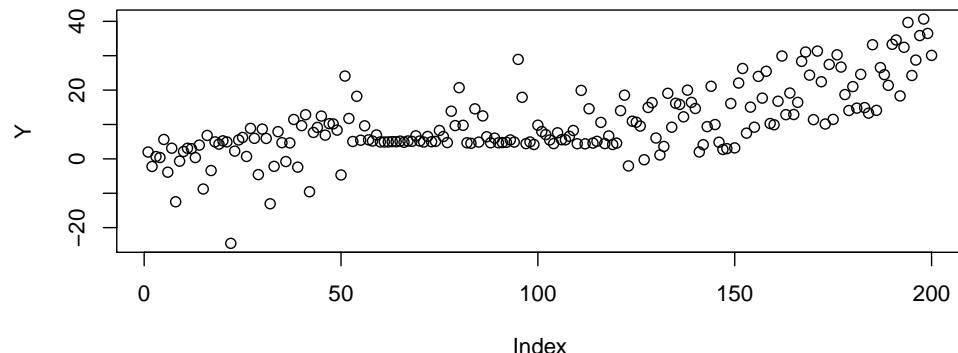
(a) On a tapé les commandes suivantes:

```

Y=0; i=1:200;
Z1=i; Z2=rnorm(200,0)^2
epsilon=runif(200,-3,3)
Y[1:50]=(3+0.2*Z1[1:50]-5*Z2[1:50]+epsilon[1:50])
Y[51:120]=(50-3*sqrt(Z1[51:120]))+10*Z2[51:120]^2+epsilon[51:120])^0.5
Y[121:200]=(-30+0.3*Z1[121:200]+4*epsilon[121:200])
plot(Y)

```

On obtient la figure:



Questions 1: Quelle est la loi de Z2? Quelle est la loi de epsilon et sa variance? Formaliser le modèle générée. A-t-on simulé un modèle linéaire?

(b) On tape ensuite les commandes:

```

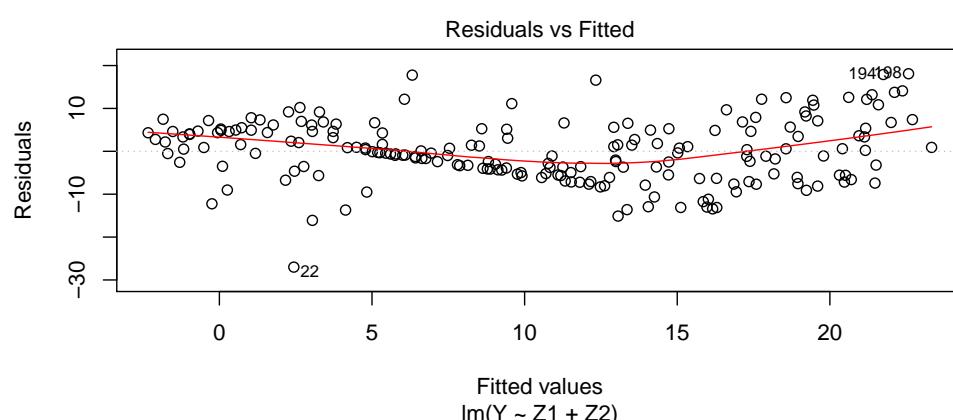
reg=lm(Y~Z1+Z2)
summary(reg)
plot(reg)

```

Voici les résultats et un des graphes obtenus:

Coefficients:					
	Estimate	Std. Error	t value	Pr(> t )	
(Intercept)	-2.15502	0.99535	-2.165	0.0316 *	
Z1	0.12480	0.00808	15.445	<2e-16 ***	
Z2	-0.81316	0.32420	-2.508	0.0129 *	

Residual standard error: 6.596 on 197 degrees of freedom  
Multiple R-squared: 0.5559, Adjusted R-squared: 0.5514  
F-statistic: 123.3 on 2 and 197 DF, p-value: < 2.2e-16



Questions 2: Qu'a-t-on fait avec ces commandes? Que représentent explicitement (en fonction des variables ( $Y_i$ ), ( $Z1_i$ ) et ( $Z2_i$ )) les valeurs numériques  $-0.81316$ ,  $0.00808$ ,  $-2.165$ ,  $0.5559$  et  $2.2e-16$ ? Que peut-on en conclure?

(c) On a ensuite tapé les commandes:

```

Q=c(); M=c()
for (j in c(3:195))
{for (k in c(j+3:200))
{reg1=lm(Y[1:j]~Z1[1:j]+Z2[1:j])
reg2=lm(Y[(j+1):k]~Z1[(j+1):k]+Z2[(j+1):k])
reg3=lm(Y[(k+1):200]~Z1[(k+1):200]+Z2[(k+1):200])
M=cbind(M,c(j,k))
Q=c(Q,sum(reg1$res^2)+sum(reg2$res^2)+sum(reg3$res^2))}}
i0=(Q==min(Q)); Indice=c(M[1,i0],M[2,i0]); Indice

```

Voici le résultat:

```
[1] 50 121
```

*Questions 3: Qu'a-t-on fait avec ces commandes et pourquoi l'a-t-on fait? Que conclure de ce résultat?*

(d) On a enfin tapé les commandes:

```

library(MASS)
Y3=Y[122:200]; Z13=Z1[122:200]; Z23=Z2[122:200]
ZZ=as.data.frame(cbind(Z13,Z23));
y.lm=lm(Y3~.,data=ZZ);
y.bic=stepAIC(y.lm,k=log(79)); plot(lm(Y3~Z13))

```

Voici les résultats:

```

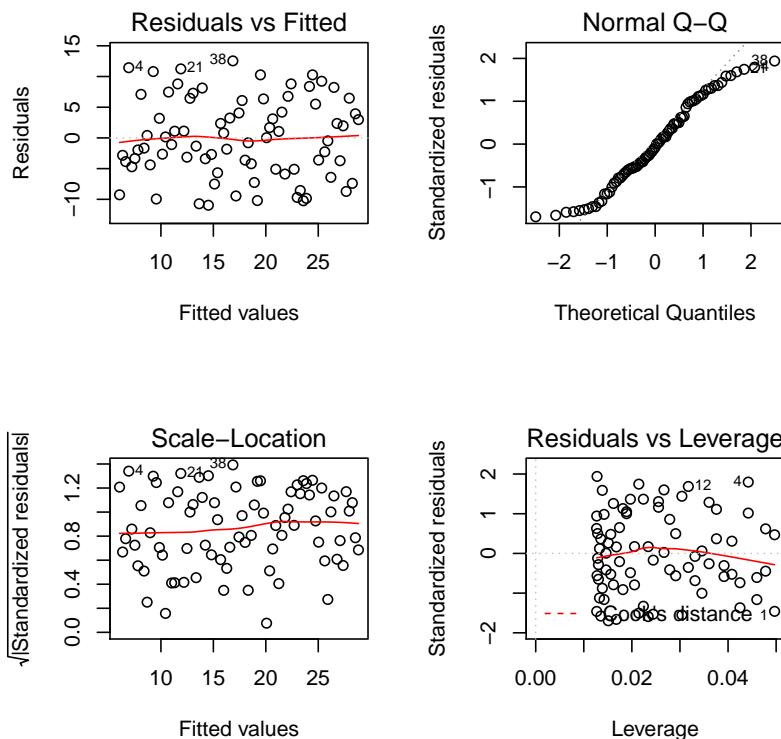
Start: AIC=306.66
Y3 ~ Z13 + Z23
Df Sum of Sq    RSS    AIC
- Z23   1      16.4 3262.7 302.69
<none>           3246.3 306.66
- Z13   1     3518.9 6765.1 360.30

```

```

Step: AIC=302.69
Y3 ~ Z13
Df Sum of Sq    RSS    AIC
<none>           3262.7 302.69
- Z13   1     3503 6765.7 355.93

```



*Questions 4: Qu'a-t-on fait avec ces commandes et qu'a-t-on obtenu? Qu'est-ce que le 79 apparaissant dans une commande? Est-on satisfait du résultat obtenu et expliquer pourquoi on pouvait s'y attendre?*