

## Première Année Master M.A.E.F. 2013 – 2014

**Econométrie II**

Examen final, mai 2014

*Examen de 3h00. Tout document ou calculatrice est interdit.*

1. **(18 points)** Soit une expérience médicale consistant à mesurer le taux d'insuline (variable  $T$ ) en fonction du sexe du patient (variable  $S$ ) et de la prise ou non d'un médicament (variable  $M$ ). On suppose que l'on a ainsi  $2n$  individus (où  $n \in \mathbf{N}$ ) et avec  $(\varepsilon_i)_{i \in \mathbf{N}}$  une suite de variables aléatoires centrées indépendantes de même loi possédant un moment d'ordre 4, on a :

$$T_i = \theta_0 + \theta_1 S_i + \theta_2 M_i + \varepsilon_i \quad \text{pour } i = 1, \dots, 2n, \text{ avec} \quad (1)$$

- $S_i = 1$  (femme) pour  $i$  pair et  $S_i = 0$  (homme) pour  $i$  impair;
- $M_i = 1$  (prise du médicament) pour  $i = 1, \dots, n$ ,  $M_i = 0$  (prise d'un placebo) pour  $i = n + 1, \dots, 2n$ ;
- $\theta = {}^t(\theta_0, \theta_1, \theta_2) \in \mathbf{R}^3$  est le vecteur des paramètres inconnus.

- (a) Déterminer explicitement l'estimateur  $\hat{\theta}$  par moindres carrés ordinaires de  $\theta$  pour  $n \geq 2$  (on obtient notamment  $\hat{\theta}_1 = \frac{1}{n} \sum_{i=1}^n (Y_{2i-1} - Y_{2i})$  et  $\hat{\theta}_2 = \frac{1}{n} \sum_{i=1}^n (Y_i - Y_{n+i})$ ) **(3pts)**.
- (b) Montrer que cet estimateur est convergent quand  $n \rightarrow \infty$  **(2pts)** et donner le théorème de la limite centrale qu'il vérifie **(1pt)**.
- (c) Déterminer un estimateur de  $\sigma^2 = \text{var}(\varepsilon_0)$  **(1pt)**. Déterminer un théorème de la limite centrale vérifié par cet estimateur lorsque  $n \rightarrow \infty$  **(1pt)**.
- (d) Proposer un test (expliciter la statistique de test)  $\hat{T}$  pour décider si  $\theta_1 = \theta_2$  **(2pts)**. Quel est le comportement asymptotique de  $\hat{T}$  lorsque  $n \rightarrow \infty$  **(1pt)**?
- (e) On suppose que le vrai modèle est bien (1) mais qu'on ne le sait pas. On effectue d'abord une régression du modèle comportant  $S$  mais pas  $M$  et on obtient ainsi  $\tilde{\theta}$ . Démontrer qu'asymptotiquement  $\tilde{\theta}$  ne tend pas vers  $\theta$  **(3pts)**. Démontrer qu'asymptotiquement le critère BIC de ce sous-modèle a une probabilité tendant vers 0 d'être inférieur au critère BIC du vrai modèle **(2pts)**.
- (f) On suppose maintenant que la variance de  $(\varepsilon_{n+1}, \dots, \varepsilon_{2n})$  n'est plus  $\sigma^2$  mais  $2\sigma^2$ . Déterminer l'expression de l'estimateur par moindres carrés généralisés de  $\theta$  ainsi que sa matrice de covariance asymptotique **(2pts)**.

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

- (a) On a tapé les commandes suivantes:

```
k=c(1:100); v=runif(100); X=4+3*rnorm(100); Y=log(v*k)*sqrt(k)+2*X
```

*Questions 1: Quelle est la loi de X? On supposera que les valeurs de X sont connues, mais pas celles de u. Quel modèle suit formellement Y? Est-ce un modèle linéaire? Si c'est le cas, l'écrire exactement sous la forme habituelle (2pts).*

- (b) On a ensuite tapé les commandes:


```
reg1=lm(Y~X+k); summary(reg1); plot(reg1)
```

Voici les résultats et une partie des graphes obtenus:

Coefficients:

	Estimate	Std. Error	t value	Pr(> t )
(Intercept)	0.70971	1.72023	0.413	0.681
X	2.06024	0.24904	8.273	7.05e-13 ***
k	0.36965	0.02652	13.940	< 2e-16 ***

Residual standard error: 7.574 on 97 degrees of freedom  
 Multiple R-squared: 0.7573, Adjusted R-squared: 0.7523  
 F-statistic: 151.3 on 2 and 97 DF, p-value: < 2.2e-16



Questions 2: Qu'a-t-on fait ici? Dites exactement ce que représentent les résultats numériques suivants: 0.70971, 0.02652, 8.273, 7.574, 0.7523 et 151.3. S'attendait-on aux résultats 2.06024 et 0.36965? Décrire les 2 graphes en expliquant ce qu'ils représentent et les conclusions à en tirer. Au final, que pensez-vous de cette régression? Que voudrait-on faire pour améliorer cette régression? (4pts)

(c) On tape ensuite les commandes:

```
Z=cbind(1+0*k,X,sqrt(k)*log(k)); Sig=diag(1/sqrt(k))
Theta2=solve(t(Z)%*%Sig%*%Z)%*%t(Z)%*%Sig%*%Y; Theta2
```

Voici les résultats:

```
-2.5266115
X  2.1811195
    0.8097249
```

Questions 3: Qu'a-t-on fait ici et pourquoi? Est-on satisfait des résultats obtenus? (2pts)

(d) Enfin on a tapé les commandes:

```
YY=(Y>20)*1; YY; kk=sqrt(k)*log(k)
logitY=glm(YY~X+kk,family=binomial(link="probit"),na.action=na.pass)
summary(logitY)
library(lmtest); lrtest(logitY,1:2)
```

Voici ce que l'on obtient:

```
YY
 [1] 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 1 1 0 1 0 1 0 0 1 1 0 0 1 1 1 1 0 1 1
 [38] 1 1 0 0 1 1 1 1 0 1 1 1 1 0 1 1 0 1 1 0 1 1 1 1 1 1 1 1 1 1 1 0 1 1 1 1 1
 [75] 0 1 0 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1
```

Coefficients:

```
              Estimate Std. Error z value Pr(>|z|)
(Intercept) -4.58638     1.03427  -4.434 9.23e-06 ***
X              0.48411     0.13154   3.680 0.000233 ***
kk              0.14704     0.03018   4.873 1.10e-06 ***
```

Likelihood ratio test

Model 1: YY ~ X + kk

Model 2: YY ~ 1

```
  #Df  LogLik Df  Chisq Pr(>Chisq)
1    3 -26.911
2    1 -64.104 -2  74.385 < 2.2e-16 ***
```

Questions 4: Expliquez ce qui a été fait. Pouvait-on s'y attendre? Que conclure du test? Pouvait-on s'y attendre? (2pts)