

# Première Année Master M.A.E.F. 2024 – 2025

## Econométrie II

Examen terminal, mai 2025

*Examen de 2h00. Tout document ou calculatrice est interdit.*

### Exercice théorique (Sur 14 points)

Soit  $Y = {}^t(Y_1, \dots, Y_{2n})$  une variable réelle observée pour  $n$  individus et  $p$  variables exogènes  $X^{(j)} = {}^t(X_1^{(j)}, \dots, X_{2n}^{(j)})$  observées pour ces  $2n$  individus (avec  $n > p \geq 1$ ). En notant  $X^{(0)} = {}^t(1, \dots, 1)$  ( $2n$  fois), on supposera que les matrices  $Z_1 = (X_i^{(j)})_{1 \leq i \leq n, 0 \leq j \leq p}$  et  $Z_2 = (X_i^{(j)})_{n+1 \leq i \leq 2n, 0 \leq j \leq p}$  sont de rang  $p+1$ . On supposera également qu'il existe un vecteur  $\theta = (\theta_j)_{0 \leq j \leq p} \in \mathbf{R}^{p+1}$ , vecteur inconnu, tel que:

$$Y_i = \theta_0 + \sum_{j=1}^p \theta_j X_i^{(j)} + \varepsilon_i \quad \text{pour tout } 1 \leq i \leq 2n,$$

avec  $(\varepsilon_i)_{i \in \mathbf{N}}$  une suite de variables gaussiennes centrées indépendantes telles que  $\text{var}(\varepsilon_i) = \sigma_i^2 < \infty$  pour tout  $i$ . Dans la suite, on veut tester l'homoscédasticité du modèle, donc trouver une statistique de test pour décider entre:

$$H_0 : \exists \sigma^2 > 0 \text{ tel que pour tout } i \in \mathbf{N}, \sigma_i^2 = \sigma^2 \quad \text{contre} \quad H_1 : \text{les } \sigma_i^2 \text{ ne sont pas toutes égales}$$

1. Un premier test va être mis en place de la manière suivante: on effectue deux régressions par moindres carrés des  $Y_i$  par les  $X_i^{(j)}$ , la première pour  $Y^{(1)} = {}^t(Y_1, \dots, Y_n)$  et cela fournit l'estimateur  $\widehat{\theta}^{(1)}$ , la seconde pour  $Y^{(2)} = {}^t(Y_{n+1}, \dots, Y_{2n})$  et cela fournit l'estimateur  $\widehat{\theta}^{(2)}$ .

(a) Sous l'hypothèse  $H_0$ , en justifiant, donner la loi de  $Y^{(1)} - Z_1 \widehat{\theta}^{(1)}$ , puis celle de  $\|Y^{(1)} - Z_1 \widehat{\theta}^{(1)}\|^2$  (1pt).

(b) On considère la statistique de test

$$\widehat{S}_n = \frac{\|Y^{(1)} - Z_1 \widehat{\theta}^{(1)}\|^2}{\|Y^{(2)} - Z_2 \widehat{\theta}^{(2)}\|^2}.$$

Sous l'hypothèse  $H_0$ , en justifiant, donner la loi de  $\widehat{S}_n$  (2pts).

(c) Lorsque  $n \rightarrow \infty$ , déterminer la limite en loi de  $\widehat{S}_n$  sous  $H_0$  (1pt).

(d) Si on suppose que  $\sigma_i^2 = \sigma^2$  pour  $i = 1, \dots, n$  et  $\sigma_i^2 = \gamma^2$  pour  $i = n+1, \dots, 2n$ , quelle serait la limite en probabilité de  $\widehat{S}_n$  (1pt)?

(e) Expliquer concrètement quand accepter  $H_0$  avec un risque de 5% en utilisant  $\widehat{S}_n$  (1pt).

2. On propose une autre démarche. On note  $Y = {}^t(Y_1, \dots, Y_{2n})$  et  $Z = (X_i^{(j)})_{1 \leq i \leq 2n, 0 \leq j \leq p}$ ,  $\widehat{\theta}$  l'estimateur par moindres carrés de  $\theta$  par régression de  $Y$  par rapport aux  $X^{(j)}$ ,  $\widehat{Y} = (\widehat{Y}_i)_{1 \leq i \leq 2n} = Z \widehat{\theta}$  et  $\widehat{\varepsilon} = (\widehat{\varepsilon}_i)_{1 \leq i \leq 2n} = Y - \widehat{Y}$ . L'idée est de tester  $H_0$  contre  $H'_1$ : Il existe un vecteur  $\beta = {}^t(\beta_1, \dots, \beta_p) \in \mathbf{R}^p$ ,  $\beta \neq 0$ , tel que

$$\mathbb{E}[\varepsilon_i^2] = \sigma^2 + \sum_{j=1}^p \beta_j X_i^{(j)} \quad \text{pour tout } i = 1, \dots, 2n.$$

(a) Expliquer en quoi l'hypothèse  $H'_1$  est une hypothèse d'hétérosécédasticité. Sous  $H'_1$ , que vaut  $\mathbb{E}[\widehat{\theta}]$  (1pt)?

(b) Soit la matrice  $Z ({}^t Z Z)^t Z = (p_{ij})_{1 \leq i, j \leq p+1}$ . Soit  $C1$  la condition:  $\max_{1 \leq i \leq 2n} (|p_{ii}|) \xrightarrow[n \rightarrow \infty]{} 0$ . Montrer que l'hypothèse  $H_0$  et  $C1$  induisent que  $\text{var}(\widehat{\varepsilon}_i) \xrightarrow[n \rightarrow \infty]{} \sigma^2$  pour tout  $i = 1, \dots, n$  (1pt).

(c) Sous  $C1$  et quand  $n$  est grand, si une linéarité apparaît sur le nuage de points des  $\widehat{\varepsilon}_i^2$  en fonction des  $\widehat{Y}_i$ , cela caractérise plutôt  $H_0$  ou  $H'_1$  (1.5pts)?

(d) Montrer que sous l'hypothèse  $H_0$ ,  $\mathbb{E}[(\varepsilon_i^2 - \sigma^2)^2] = 2\sigma^4$  (1pt). En déduire que pour tout  $j \in \{0, \dots, p\}$ ,

$$\frac{1}{\sqrt{\sum_{i=1}^{2n} (X_i^{(j)})^2}} \sum_{i=1}^{2n} (\varepsilon_i^2 - \sigma^2) X_i^{(j)} \xrightarrow[n \rightarrow \infty]{\mathcal{L}} \mathcal{N}(0, 2\sigma^4) \quad (2\text{pts}).$$

Plus généralement on acceptera (ne pas le démontrer) sous  $H_0$  le TLC multidimensionnel

$$({}^t Z Z)^{-1/2} \sum_{i=1}^{2n} (\varepsilon_i^2 - \sigma^2) (X_i^{(j)})_{1 \leq j \leq p} \xrightarrow[n \rightarrow \infty]{\mathcal{L}} \mathcal{N}(0, 2\sigma^4 I_p). \quad (1)$$

- (e) Soit la condition  $C2$ :  $\frac{1}{\sqrt{2n}} \frac{\sum_{i=1}^{2n} X_i^{(j)}}{\sqrt{\sum_{i=1}^{2n} (X_i^{(j)})^2}} \xrightarrow{n \rightarrow \infty} 0$  pour  $j \in \{1, \dots, p\}$ . Montrer que si  $(U_i)_{i \in \mathbf{N}}$  est une suite de v.a.i.i.d. centrées de variance finie alors la convergence  $C2$  a lieu en probabilité pour  $(X_i^{(j)}) = (U_i)$  (**3pts**). Montrer que sous  $H_0$  et  $C2$ , avec  $Z^- = (X_i^{(j)})_{1 \leq i \leq 2n, 1 \leq j \leq p}$  et  $\hat{\sigma}^2 = \frac{1}{2n-p-1} \sum_{i=1}^{2n} \hat{\varepsilon}_i^2$ ,

$$({}^t Z^- Z^-)^{-1/2} \sum_{i=1}^{2n} (\varepsilon_i^2 - \hat{\sigma}^2) (X_i^{(j)})_{1 \leq j \leq p} \xrightarrow[n \rightarrow \infty]{\mathcal{L}} \mathcal{N}(0, 2\sigma^4 I_p) \quad (\text{2.5pts}).$$

- (f) Sous  $H_0$ ,  $C1$  et  $C2$ , on peut aussi montrer (ne pas le faire) que:

$$({}^t Z^- Z^-)^{-1/2} \sum_{i=1}^{2n} (\hat{\varepsilon}_i^2 - \hat{\sigma}^2) (X_i^{(j)})_{1 \leq j \leq p} \xrightarrow[n \rightarrow \infty]{\mathcal{L}} \mathcal{N}(0, 2\sigma^4 I_p).$$

On considère la statistique de test :  $\widehat{T}_n = {}^t E_n ({}^t Z^- Z^-)^{-1} E_n$  où  $E_n = \sum_{i=1}^{2n} (\hat{\varepsilon}_i^2 - \hat{\sigma}^2) (X_i^{(j)})_{1 \leq j \leq p}$ . Déterminer la loi limite de  $\widehat{T}_n$  sous  $H_0$  (**1.5pts**). Comment l'utiliser pour tester  $H_0$  (**1pt**)? Intuitivement, que se passe-t-il pour  $\widehat{T}_n$  sous  $H'_1$  (**0.5pts**)?

*Proof.* 1. (a)  $Y^{(1)} - Z_1 \hat{\theta}^{(1)} = P_{[Z_1]^\perp} (\varepsilon_i)_{1 \leq i \leq n} \stackrel{\mathcal{L}}{\sim} \mathcal{N}(0, \sigma^2 P_{[Z_1]^\perp})$ .

D'après le Théorème de Cochran,  $\|Y^{(1)} - Z_1 \hat{\theta}^{(1)}\|^2 \stackrel{\mathcal{L}}{\sim} \sigma^2 \chi^2(\dim([Z_1]^\perp)) = \sigma^2 \chi^2(n-p-1)$ .

- (b) On peut écrire que  $\widehat{S}_n = \frac{\frac{1}{(n-p-1)\sigma^2} \|Y^{(1)} - Z_1 \hat{\theta}^{(1)}\|^2}{\frac{1}{(n-p-1)\sigma^2} \|Y^{(2)} - Z_2 \hat{\theta}^{(2)}\|^2}$ . Comme on a également  $\|Y^{(2)} - Z_2 \hat{\theta}^{(2)}\|^2 \stackrel{\mathcal{L}}{\sim} \sigma^2 \chi^2(n-p-1)$ , et  $Y^{(1)} - Z_1 \hat{\theta}^{(1)} = P_{[Z_1]^\perp} (\varepsilon_i)_{1 \leq i \leq n}$  alors que  $Y^{(2)} - Z_2 \hat{\theta}^{(2)} = P_{[Z_2]^\perp} (\varepsilon_i)_{n+1 \leq i \leq 2n}$ , donc  $Y^{(1)} - Z_1 \hat{\theta}^{(1)}$  et  $Y^{(2)} - Z_2 \hat{\theta}^{(2)}$  indépendants, alors le numérateur et le dénominateur de  $\widehat{S}_n$  sont indépendants: par définition  $\widehat{S}_n$  suit une loi de Fisher  $F(n-p-1, n-p-1)$ .

- (c) Il est clair, par la loi des grands nombres que  $\frac{1}{n-p-1} \|Y^{(1)} - Z_1 \hat{\theta}^{(1)}\|^2 \xrightarrow[n \rightarrow +\infty]{\mathcal{P}} \sigma^2$ , de même  $\frac{1}{n-p-1} \|Y^{(2)} - Z_2 \hat{\theta}^{(2)}\|^2 \xrightarrow[n \rightarrow +\infty]{\mathcal{P}} \sigma^2$ , et comme la fonction  $g(x, y)$  est continue sur  $]0, \infty[^2$ , alors  $\widehat{S}_n \xrightarrow[n \rightarrow +\infty]{\mathcal{P}} 1$ .

- (d) De la même manière, on montre facilement que sous cette hypothèse  $\widehat{S}_n \xrightarrow[n \rightarrow +\infty]{\mathcal{P}} \frac{\sigma^2}{\gamma^2}$ .

- (e) Soit  $q_{0.025}$  et  $q_{0.975}$  les quantiles d'ordre 0.025 et 0.975 de la loi  $F(n-p-1, n-p-1)$ . On acceptera  $H_0$  si  $\widehat{S}_n \in [q_{0.025}, q_{0.975}]$ .

2. (a) Il est clair que  $H'_1$  est un cas particulier de  $H_1$ .

On a  $\mathbb{E}[\widehat{\theta}] = ({}^t Z Z)^{-1} t Z \mathbb{E}[Y] = \theta + ({}^t Z Z)^{-1} t Z \mathbb{E}[\varepsilon] = \theta$ .

- (b) Sous  $H_0$ , on sait que  $\hat{\varepsilon} = P_{[Z]^\perp} \varepsilon$ , et ainsi  $\text{var}(\hat{\varepsilon}_i) = \sigma^2(1-p_{ii})$  pour tout  $i \in \{1, \dots, 2n\}$ . D'où le résultat.

- (c) On sait que  $\widehat{Y}_i = \widehat{\theta}_0 + \widehat{\theta}_1 X_i^{(1)} + \dots + \widehat{\theta}_p X_i^{(p)}$ . S'il y a une linéarité dans le nuage de points, cela signifie que  $\hat{\varepsilon}_i^2 = \mu + \nu \widehat{Y}_i + \xi_i$  pour  $i = 1, \dots, 2n$ , avec des  $(\xi_i)$  suite de v.a. centrées. De ceci, 2 possibilités: si le slope de cette droite est nul, soit  $\nu = 0$ , car cela signifie que  $\mathbb{E}[\hat{\varepsilon}_i^2] \simeq \mu$ : ce sera plutôt l'hypothèse  $H_0$ , sinon ce sera  $H'_1$  car on a alors  $\text{var}(\hat{\varepsilon}_i) \simeq \text{var}(\varepsilon_i) \simeq \mu + \nu \widehat{Y}_i \simeq \mu + \nu (\widehat{\theta}_0 + \widehat{\theta}_1 X_i^{(1)} + \dots + \widehat{\theta}_p X_i^{(p)})$  ce qui est bien une combinaison linéaire comme dans  $H'_1$ .

- (d) Sous  $H_0$ ,  $\mathbb{E}[(\varepsilon_i^2 - \sigma^2)^2] = \sigma^4 \text{var}(U)$  où  $U$  suit une loi  $\chi^2(1)$  et on sait que pour une v.a. suivant un  $\chi^2(m)$  sa variance est  $2m$ . Donc ici  $\text{var}(U) = 2$  et  $\mathbb{E}[(\varepsilon_i^2 - \sigma^2)^2] = 2\sigma^4$ .

On va appliquer le Théorème de Lindeberg avec  $a_i^{(n)} = X_i^{(j)} / \sqrt{\sum_{i=1}^{2n} (X_i^{(j)})^2}$  ce qui fait que l'on a bien  $\sum_{i=1}^{2n} (a_i^{(n)})^2 = 1$ ,  $\xi_i = (\varepsilon_i^2 - \sigma^2) / \sqrt{2\sigma^4}$ , ce qui fait que les  $\xi_i$  sont indépendants (car les  $\varepsilon_i$  le sont), et  $\mathbb{E}[\xi_i] = 0$  puisque sous  $H_0$ ,  $\mathbb{E}[\varepsilon_i^2] = \sigma^2$ , et  $\text{var}(\xi_i) = 1$ . Toutes les conditions sont réunies et ainsi  $\sum_{i=1}^{2n} a_i^{(n)} \xi_i \xrightarrow[n \rightarrow \infty]{\mathcal{L}} \mathcal{N}(0, 1)$ , d'où le résultat.

- (e) Soit  $(U_i)_{i \in \mathbf{N}}$  est une suite de v.a.i.i.d. centrées de variance finie  $\rho^2$ . Alors en notant  $\overline{U}_{2n} = \frac{1}{2n} \sum_{i=1}^{2n} U_i$ , on a  $\overline{U}_{2n} \xrightarrow[n \rightarrow +\infty]{\mathcal{P}} 0$  par la loi forte des grands nombres, donc également  $\overline{U}_{2n}/\rho \xrightarrow[n \rightarrow +\infty]{\mathcal{P}} 0$ . De plus  $\frac{1}{2n} \sum_{i=1}^{2n} U_i^2 \xrightarrow[n \rightarrow +\infty]{\mathcal{P}} \rho^2$ , également par la LGN. Donc par le Lemme de Slutsky,

$$\frac{\overline{U}_{2n}}{\sqrt{\frac{1}{2n} \sum_{i=1}^{2n} U_i^2}} = \frac{1}{\sqrt{2n}} \frac{\sum_{i=1}^{2n} U_i}{\sqrt{\sum_{i=1}^{2n} U_i^2}} \xrightarrow[n \rightarrow +\infty]{\mathcal{P}} 0.$$

On peut écrire que l'on obtiendra le résultats demandé si

$$({}^t Z^- Z^-)^{-1/2} \sum_{i=1}^{2n} (\sigma^2 - \hat{\sigma}^2) (X_i^{(j)})_{1 \leq j \leq p} \xrightarrow[n \rightarrow +\infty]{\mathcal{P}} 0 \implies (\sigma^2 - \hat{\sigma}^2) ({}^t Z^- Z^-)^{-1/2} \sum_{i=1}^{2n} (X_i^{(j)})_{1 \leq j \leq p} \xrightarrow[n \rightarrow +\infty]{\mathcal{P}} 0$$

## Exercice de TP utilisant le logiciel R (Sur 9 points)

On s'intéresse à une base de données `Guns` relative à la criminalité annuelle dans les 50 états des USA entre 1977 et 1999. Nous allons étudier la variable `murder`, taux d'homicides pour 100000 habitants, en fonction d'autres variables:

- `year`: l'année, soit 1977, 1978, ..., 1998, 1999.
- `state`: le nom d'un des 50 états des USA.
- `density`: la densité de population de l'état.
- `population`: la population totale de l'état.
- `income`: le PNB par habitant de l'état.
- `male`: le pourcentage de jeunes hommes de 10 à 29 ans dans la population de l'état.
- `prisoners`: le taux de prisonniers par état pour 100000 habitants.
- `law`: existence d'une loi sur le port d'armes (yes or no).

1. Une première étape réside dans la préparation des données:

```
Guns$law=as.factor(Guns$law)
Guns$state=as.factor(Guns$state)
str(Guns);
```

Ce qui amène les résultats numériques:

```
'data.frame': 1150 obs. of 9 variables:
 $ year      : int 1977 1978 1979 1980 1981 1982 1983 1984 1985 1986 ...
 $ murder    : num 14.2 13.3 13.2 13.2 11.9 10.6 9.2 9.4 9.8 10.1 ...
 $ prisoners : int 83 94 144 141 149 183 215 243 256 267 ...
 $ male       : num 18.2 18 17.8 17.7 17.7 ...
 $ population: num 3.78 3.83 3.87 3.9 3.92 ...
 $ income     : num 9563 9932 9877 9541 9548 ...
 $ density    : num 0.0746 0.0756 0.0762 0.0768 0.0772 ...
 $ state      : Factor w/ 50 levels "Alabama","Alaska",...: 1 1 1 1 1 1 1 1 1 ...
 $ law        : Factor w/ 2 levels "no","yes": 1 1 1 1 1 1 1 1 1 ...
```

*Questions 1: Qu'a-t-on fait ici et pourquoi (0.5pts)?*

2. On commence ensuite par étudier l'effet global du temps sur la variable `murder`:

```
lin0=lm(murder ~ year, data = Guns)
summary(lin0)
```

Voici les résultats:

```
Coefficients:
            Estimate Std. Error t value Pr(>|t|)    
(Intercept) 169.13391   32.84502   5.149 3.07e-07 ***
year        -0.08164    0.01652  -4.941 8.91e-07 ***
```

```
Residual standard error: 3.716 on 1148 degrees of freedom
Multiple R-squared:  0.02083, Adjusted R-squared:  0.01997 
F-statistic: 24.42 on 1 and 1148 DF,  p-value: 8.906e-07
```

*Questions 2: Ecrire formellement le modèle considéré. Quelle sera la différence entre le taux d'homicides en 1999 et celui prévu par ce modèle en 2025 (en arrondissant)? Que conclure de cette première étude (1.5pts)?*

3. On tape ensuite les commandes:

```
lin1=lm(murder ~ year+state, data = Guns)
summary(lin1); anova(lin1)
```

On obtient les résultats numériques:

```
> summary(lin1)

Coefficients:
Estimate Std. Error t value Pr(>|t|)
(Intercept) 173.127036 12.403257 13.958 < 2e-16 ***
year -0.081640 0.006237 -13.089 < 2e-16 ***
stateAlaska -1.043478 0.413737 -2.522 0.011807 *
stateArizona -2.330435 0.413737 -5.633 2.25e-08 ***
: : : : :
: : : : :
stateWyoming -6.273913 0.413737 -15.164 < 2e-16 ***
```

Residual standard error: 1.403 on 1099 degrees of freedom

Multiple R-squared: 0.8664, Adjusted R-squared: 0.8603

F-statistic: 142.5 on 50 and 1099 DF, p-value: < 2.2e-16

```
> anova(lin1)
Analysis of Variance Table
```

```
Response: murder
Df Sum Sq Mean Sq F value Pr(>F)
year 1 337.3 337.26 171.32 < 2.2e-16 ***
state 49 13692.6 279.44 141.95 < 2.2e-16 ***
Residuals 1099 2163.4 1.97
```

*Questions 3: Préciser le modèle formel qui a été mis en place. Que conclure des résultats numériques? Quel test précisément a été effectué pour obtenir la valeur 141.95 (1.5pts)?*

4. On tape ensuite les commandes (on rappelle que la commande V1\*V2 permet d'obtenir un modèle avec interactions):

```
lin2=lm(murder ~ year*state, data = Guns)
summary(lin2); anova(lin2)
BIC(lin0,lin1,lin2); anova(lin0,lin1); anova(lin1,lin2)
```

On obtient les résultats numériques:

```
> summary(lin2)
```

```
Coefficients:
Estimate Std. Error t value Pr(>|t|)
(Intercept) 2.982e+02 7.725e+01 3.861 0.000120 ***
year -1.446e-01 3.886e-02 -3.721 0.000209 ***
stateAlaska 3.036e+02 1.092e+02 2.779 0.005542 **
stateArizona -2.557e+02 1.092e+02 -2.341 0.019417 *
: : : : :
: : : : :
stateWyoming 1.022e+02 1.092e+02 0.935 0.349910
year:stateAlaska -1.533e-01 5.495e-02 -2.789 0.005382 **
year:stateArizona 1.275e-01 5.495e-02 2.320 0.020548 *
: : : : :
: : : : :
year:stateWyoming -5.455e-02 5.495e-02 -0.993 0.321125
```

Residual standard error: 1.236 on 1050 degrees of freedom

Multiple R-squared: 0.9009, Adjusted R-squared: 0.8916

F-statistic: 96.45 on 99 and 1050 DF, p-value: < 2.2e-16

```
> anova(lin2)
Analysis of Variance Table
```

```
Response: murder
Df Sum Sq Mean Sq F value Pr(>F)
```

```

year      1   337.3  337.26 220.7273 < 2.2e-16 ***
state     49  13692.6 279.44 182.8878 < 2.2e-16 ***
year:state 49    559.1   11.41   7.4679 < 2.2e-16 ***

> BIC(lin0,lin1,lin2)
  df      BIC
lin0    3 6302.055
lin1   52 4356.759
lin2  101 4358.242

> anova(lin0,lin1)
Analysis of Variance Table

Model 1: murder ~ year
Model 2: murder ~ year + state
  Res.Df   RSS Df Sum of Sq    F    Pr(>F)
1   1148 15856.0
2   1099 2163.4 49      13693 141.95 < 2.2e-16 ***

> anova(lin1,lin2)
Analysis of Variance Table

Model 1: murder ~ year + state
Model 2: murder ~ year * state
  Res.Df   RSS Df Sum of Sq    F    Pr(>F)
1   1099 2163.4
2   1050 1604.3 49      559.11 7.4679 < 2.2e-16 ***

```

*Questions 4: Ecrire formellement le modèle considéré. Interpréter les résultats obtenus, notamment ceux des commandes `anova`. Quel test a été précisément effectué pour obtenir la valeur numérique 7.4679? Des trois modèles proposés, lequel choisir (1.5pts)?*

5. On tape ensuite les commandes:

```

lin3=lm(murder~.,data=Guns)
library(MASS)
lin4=stepAIC(lin3,k=log(1150))
summary(lin4); BIC(lin0,lin1,lin2,lin3,lin4); plot(lin4)

```

Avec pour résultats numériques et graphe:

```

> summary(lin4)

Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept) 1.275e+01 4.736e-01 26.928 < 2e-16 ***
prisoners   -7.602e-03 6.916e-04 -10.992 < 2e-16 ***
population  -3.547e-01 6.865e-02 -5.168 2.81e-07 ***
income       1.610e-04 4.008e-05  4.016 6.33e-05 ***
stateAlaska -3.530e+00 5.330e-01 -6.623 5.51e-11 ***
stateArizona -2.725e+00 3.980e-01 -6.846 1.26e-11 ***
:
:
stateWyoming -8.801e+00 4.776e-01 -18.427 < 2e-16 ***

```

```

Residual standard error: 1.33 on 1097 degrees of freedom
Multiple R-squared:  0.8801, Adjusted R-squared:  0.8744
F-statistic: 154.8 on 52 and 1097 DF,  p-value: < 2.2e-16

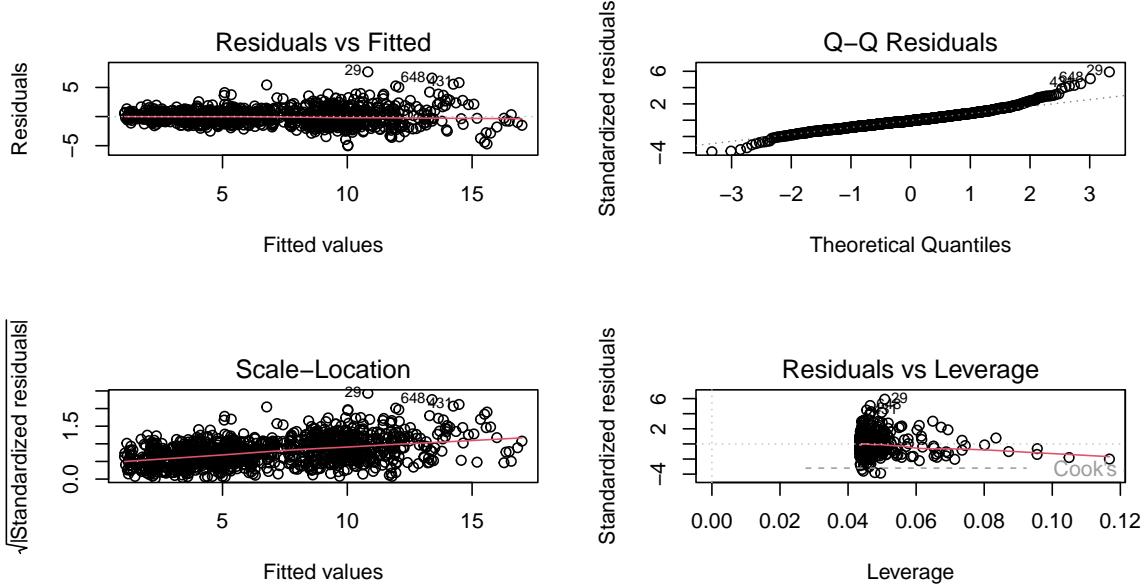
```

```

> BIC(lin0,lin1,lin2,lin3,lin4)
  df      BIC
lin0    3 6302.055
lin1   52 4356.759
lin2  101 4358.242

```

```
lin3 58 4272.193
lin4 54 4246.466
```



Questions 5: Qu'est-ce qui a été fait ici? Formaliser le modèle obtenu, préciser ses avantages et défauts (1.5pts)?

6. On tape ensuite les commandes:

```
BX=boxcox(lin4,plotit = TRUE,lambda = seq(-5,5,0.01),data=Guns)
ind=which(BX$y==max(BX$y)); lambda=BX$x[ind]; lambda
regBC=lm(I(log(murder))~ prisoners + population + income + state, data = Guns)
summary(regBC); plot(regBC)
```

Avec pour résultats numériques et graphe:

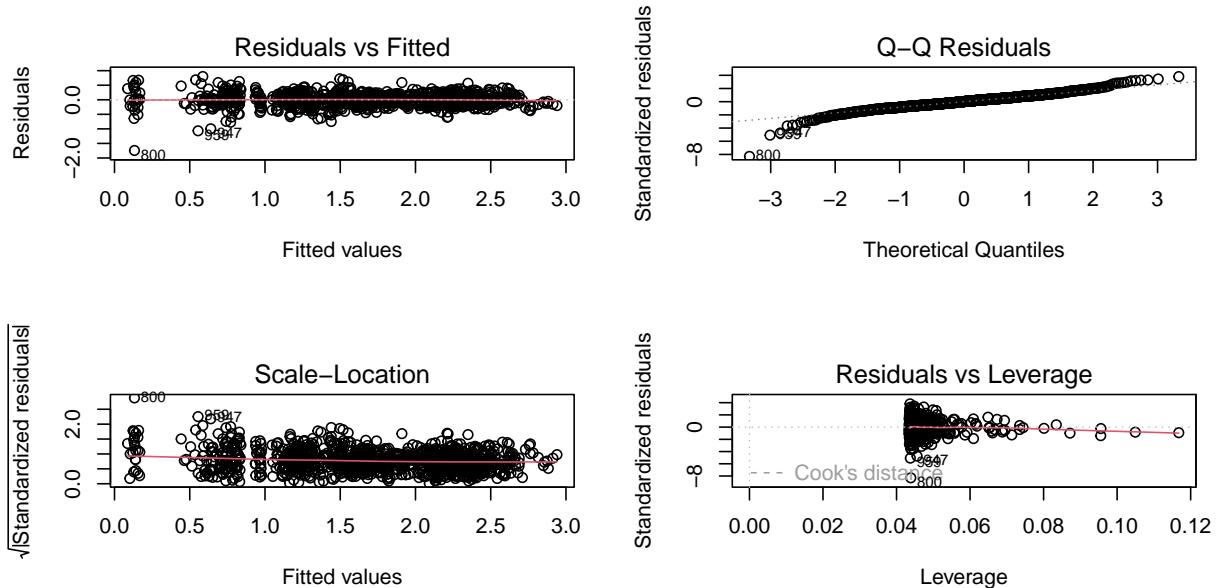
```
> ind=which(BX$y==max(BX$y)); lambda=BX$x[ind]; lambda
[1] 0.37

> summary(regBC)
```

Coefficients:

	Estimate	Std. Error	t value	Pr(> t )
(Intercept)	2.645e+00	7.645e-02	34.603	< 2e-16 ***
prisoners	-9.371e-04	1.116e-04	-8.394	< 2e-16 ***
population	-1.908e-02	1.108e-02	-1.722	0.085322 .
income	7.826e-06	6.470e-06	1.210	0.226687
stateAlaska	-2.767e-01	8.605e-02	-3.216	0.001339 **
stateArizona	-2.564e-01	6.425e-02	-3.991	7.02e-05 ***
:	:	:	:	:
:	:	:	:	:
stateWyoming	-1.136e+00	7.710e-02	-14.733	< 2e-16 ***

```
Residual standard error: 0.2148 on 1097 degrees of freedom
Multiple R-squared:  0.8945, Adjusted R-squared:  0.8895
F-statistic: 178.8 on 52 and 1097 DF,  p-value: < 2.2e-16
```



Questions 6: Qu'est-ce qui a été effectué ici? Formaliser le modèle obtenu et que conclure des graphes (1pt)?

7. On tape enfin les commandes:

```
reglaw1=glm(murder~law,data=Guns)
summary(reglaw1); Anova(reglaw1)
reglaw2=glm(law~murder,family=binomial(link="logit"),na.action=na.pass,data=Guns)
summary(reglaw2)
```

Voici les résultats:

```
> summary(reglaw1)

Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept)  7.3434    0.1241  59.191 < 2e-16 ***
lawyes      -2.0595    0.2492  -8.264 3.85e-16 ***

> Anova(reglaw1)
Analysis of Deviance Table (Type II tests)

Response: murder
          LR Chisq Df Pr(>Chisq)
law     68.295  1  < 2.2e-16 ***

> summary(reglaw2)

Coefficients:
            Estimate Std. Error z value Pr(>|z|)
(Intercept) -0.05314   0.14215 -0.374    0.709
murder       -0.16919   0.02165 -7.813 5.58e-15 ***
```

Questions 7: Préciser les 2 modèles formels considérés. Comment interpréter les résultats obtenus quant à l'influence d'une loi sur le port d'arme et le taux d'homicides (1.5pts)?