

# TESTS de STUDENT ET FISHER

Rappelons les hypothèses des MCO:

$$H_0^1 : n \geq k$$

$H_0^2$  La matrice X des variables explicatives est de plein rang, alors  ${}^tXX$  est de rang k et donc inversible.

Hypothèses sur les erreurs

$H_1^1$  : les erreurs sont des variables aléatoires, les variables explicatives sont non aléatoires

$H_1^2$  : les erreurs ont une espérance nulle  $E(\epsilon_t) = 0$  pour tout t

$H_1^3$  : les erreurs ont une variance constante inconnue notée  $\sigma^2$ ,  $\forall t \rightarrow V(\epsilon_t) = \sigma^2$   
on parlera d'homoscédasticité

$H_1^4$  : les covariances des erreurs sont nulles  $Cov(\epsilon_t, \epsilon_{t+h}) = 0$  Non Autocorrélation

$H_1^5$ : si  $n \rightarrow \infty$  alors  $\lim_{n \rightarrow \infty} \frac{{}^tXX}{n} = V_X$  matrice finie définie positive.

$H_1^6$ : les erreurs sont indépendantes et suivent la même loi inconnue (i.i.d.)

$H_1^7$ : les erreurs suivent la même loi Normale  $N(0, \sigma^2)$

## 1 Les tests de student

Ils portent sur les coefficients  $a_i$  constants mais inconnus.

### 1.1 Le test de base

C'est le test d'un coefficient du modèle  $Y = a_0 + a_1X_1 + a_2X_2 + \dots + a_kX_{k-1} + \epsilon$  modèle à k variables explicatives dont l'unité (correspondant au terme constant)

On veut tester si un coefficient est égal ou non à une valeur donnée le test

$$H_0 : a_i = b, \quad b \text{ étant une constante donnée}$$

$$H_1 : a_i \neq b$$

**Le cas particulier important** en économétrie correspond à  $b=0$ . Si on trouve que dans un modèle le test de Student indique un coefficient significatif (décision  $H_1$ ) alors on peut admettre la variable correspondante comme intéressante dans le modèle, elle apporte de l'explication.

Si on trouve que dans un modèle le test de Student indique un coefficient non significatif (décision  $H_0$ ) alors on peut admettre ce coefficient comme nul et donc la variable comme non intéressante dans le modèle. Cette seconde conclusion n'est pas toujours vraie quand il existe une forte colinéarité entre les variables. Pour être sûr que la variable est négligeable dans le modèle, il faut construire un **nouveau modèle** sans cette variable et si le s du nouveau modèle est inférieur ou presque égal au modèle avec cette variable c'est qu'en effet elle n'avait pas de rôle explicatif. Si par contre le s a augmenté alors la variable était intéressante et la décision  $H_0$  était due seulement aux problèmes de colinéarité. ( Voir chapitre sur la colinéarité).

## 1.2 Construction du test

### 1.2.1 Choix de la variable aléatoire

$\vec{\hat{a}} = ({}^tXX)^{-1} {}^tX\vec{Y}$  est l'estimateur des MCO de  $\vec{a}$  c'est le meilleur si toutes les hypothèses de base sont vérifiées.

### 1.2.2 loi de la variable sous l'hypothèse $H_a$

Nous avons vu (dans le chapitre propriétés des MCO) qu'alors  $\vec{\hat{a}}$  suit une loi  $N_k(\vec{a}, \sigma^2({}^tXX)^{-1})$  non dégénérée. En conséquence, chaque  $\hat{a}_i$  suit une loi  $N(a_i, \sigma^2 h_{ii})$ . Si on nomme  $h_{ij}$  l'élément sur la ligne  $i$  et la colonne  $j$  de la matrice  $({}^tXX)^{-1}$ , la variance de  $\hat{a}_i$  est sur la ligne  $i$  et colonne  $i$  de cette matrice.

$$\frac{\hat{a}_i - a_i}{\sigma\sqrt{h_{ii}}} \text{ suit une loi } N(0,1)$$

$\sigma$  étant inconnu nous avons vu que le meilleur estimateur de  $\sigma^2$  était  $s^2 = SCR/(n-k) = \sum_1^n e_t^2 / (n-k)$ , nous savons aussi que

$$\frac{(n-k)s^2}{\sigma^2} = \frac{\sum_1^n e_t^2}{\sigma^2} \text{ suit la loi du } \chi_{n-k}^2$$

En utilisant la définition de la loi de student comme rapport d'une variable normale centrée réduite et de la racine d'un  $\chi^2$  divisé par son nombre de degrés de liberté et indépendant de la variable normale on trouve :

$$\frac{\frac{\hat{a}_i - a_i}{\sigma\sqrt{h_{ii}}}}{\sqrt{\frac{\sum_1^n e_t^2}{\sigma^2(n-k)}}} = \frac{\hat{a}_i - a_i}{\sqrt{s^2 h_{ii}}} = \frac{\hat{a}_i - a_i}{s\sqrt{h_{ii}}} \text{ suit la loi de Student à } (n-k) \text{ degrés de liberté}$$

Les variables  $\hat{a}_i$  et  $s^2$  sont indépendantes car elles sont issues dans le cadre de la loi Normale de deux sous-ensembles orthogonaux  $H_k$  et  $H_{n-k}$

$$\begin{aligned} \text{Si } H_0 \text{ vraie alors } \frac{\hat{a}_i - b}{s\sqrt{h_{ii}}} &= T_{n-k} \\ \text{Si } H_1 \text{ vraie alors } \frac{\hat{a}_i - a_i}{s\sqrt{h_{ii}}} &= T_{n-k} \end{aligned}$$

### 1.2.3 Région critique

L'estimation des MCO donne la valeur de  $\hat{a}_i$  estimation dans l'échantillon de taille  $n$  de  $a_i$ , on calcule  $\frac{\hat{a}_i - b}{s\sqrt{h_{ii}}} = \frac{\hat{a}_i - b}{\text{écart-type estimé de } \hat{a}_i} = T$

Si  $T$  est proche de 0, alors  $\hat{a}_i$  est proche de  $b$  et on décide  $H_0$ , sinon on décide  $H_1$ . la borne  $T_\alpha$  est fournie par la table de Student au risque  $\alpha$ .

$$\begin{array}{ccccccc} & -T\alpha & & 0 & & T\alpha & \\ \hline H_1 & & & H_0 & & & H_1 \end{array}$$

### 1.3 Cas le plus utilisé : $b=0$

tester la nullité des coefficients de ce modèle. Ce test particulier de nullité des coefficients est donné directement dans RATS

$$Y = a_0 + a_1X_1 + \epsilon$$

Linear Regression - Estimation by Least Squares

Dependent Variable Y

Usable Observations	140	Degrees of Freedom	138
Centered R**2	0.915883	R Bar **2	0.915274
Uncentered R**2	0.993195	T x R**2	139.047
Mean of Dependent Variable	692268.63700		
Std Error of Dependent Variable	206128.93876		
Standard Error of Estimate	59999.61073		
Sum of Squared Residuals	4.96794e+11		
Regression F(1,138)	1502.5742		
Significance Level of F	0.00000000		
Log Likelihood	-1737.93725		
Durbin-Watson Statistic	0.120471		


Variable	Coeff	Std Error	T-Stat	Signif
*****				
1. Constant	-68443.58769	20269.23173	-3.37672	0.00095323
2. X1	7.40009	0.19091	38.76305	0.00000000

#### 1.3.1 Test de $a_0$

Rats donne le coefficient estimé = -68443.587 , son écart-type estimé =  $s\sqrt{h_{ii}} = 20269.23173$  et le rapport des deux =  $\frac{\hat{a}_i - 0}{s\sqrt{h_{ii}}} = -3.37672$

si on fait les tests au risque  $\alpha = 5\%$

pour le coefficient  $a_0$  test  $H_0 : a_0 = 0$  contre  $H_1: a_0 \neq 0$  la valeur de la statistique T estimée est de -3.3767. ici n étant grand  $T\alpha = 1.96$



On en déduit  $H_1$  le coefficient de la constante n'est pas nul donc la variable a un intérêt dans le modèle

#### 1.3.2 Test de $a_1$

Rats donne le rapport  $\frac{\hat{a}_1 - 0}{s\sqrt{h_{11}}} = 38.76305$  très supérieur à 1.96 on décide donc très nettement  $H_1$ , la variable est très importante dans le modèle. Rappelons que ce n'est pas parce qu'un coefficient est grand qu'il est important dans le modèle, nous avons vu que sa grandeur dépend juste des unités et non de son intérêt (voir chapitre sur RATS).

## 2 Test de Fisher

Il est utile pour tester des contraintes sur non plus un mais plusieurs coefficients. On va présenter ce test à l'aide d'un exemple.

### 2.1 Exemples de tests de Fisher

Avec toujours le même exemple  $Y = b_0 + b_1X_1 + b_2X_2 + \epsilon$  on va effectuer le test

$$H_0 : b_1 = 1. \text{ et } b_2 = 0.5$$

$$H_1 : \text{l'une des deux hypothèses au moins est fautive}$$

MCO sur le modèle de base

```
Linear Regression - Estimation by Least Squares
Dependent Variable Y
Usable Observations    140      Degrees of Freedom    137
Centered R**2          0.999998    R Bar **2            0.999998
Uncentered R**2        1.000000    T x R**2             140.000
Mean of Dependent Variable 692268.63700
Std Error of Dependent Variable 206128.93876
Standard Error of Estimate 291.88445
Sum of Squared Residuals 11671924.919
Regression F(2,137)    34660910.1766
Significance Level of F 0.00000000
Log Likelihood         -991.82521
Durbin-Watson Statistic 1.753973
```

Variable	Coeff	Std Error	T-Stat	Signif
1. Constant	834.92234985	102.69414057	8.13018	0.00000000
2. X1	0.80325350	0.00288544	278.38191	0.00000000
3. X2	0.49984476	0.00020700	2414.74856	0.00000000

Si maintenant on utilise la contrainte  $Y = b_0 + 1. * X_1 + 0.5 * X_2 + \epsilon$

$$Y - X_1 - 0.5X_2 = b_0 + \epsilon$$

On estime le modèle  $Y - X_1 - 0.5X_2 = b_0 + \epsilon = Z = b_0 + \epsilon$  seule la constante est donc estimée dans cet exemple.

```
Linear Model - Estimation by Restricted Regression
Dependent Variable Y
Usable Observations    140      Degrees of Freedom    139
Mean of Dependent Variable 692268.63700
Std Error of Dependent Variable 206128.93876
Standard Error of Estimate 5307.36674
Sum of Squared Residuals 3915371695.7
Durbin-Watson Statistic 0.017286
```

Variable	Coeff	Std Error	T-Stat	Signif
1. Constant	-19579.262998	448.554358	-43.64970	0.00000000
2. X1	1.000000	0.000000	1.60667e+09	0.00000000
3. X2	0.500000	0.000000	3.07521e+09	0.00000000

### 2.1.1 Construction du test de Fisher


Sous l'hypothèse  $H_1$  on a la somme des carrés des résidus  $SCR_a$  (indice a car souvent on parle d'hypothèse alternative) et  $SCR_a/\sigma^2$  suit une loi du  $\chi^2_{n-k}$  ici  $\chi^2_{140-3}$

Sous l'hypothèse  $H_0$  la somme des carrés des est  $SCR_0$  et comme on a 1 seule variable explicative  $SCR_0/\sigma_1^2$  suit une loi du  $\chi^2_{n-1}$  ici  $\chi^2_{140-1}$ . Dans le cas général si on a k variables explicatives et r contraintes, le modèle sous  $H_0$  ne contient plus que k-r variables et donc le  $\chi^2$  aura  $n-(k-r) = n-k+r$  degrés de liberté.

La variable de Fisher est le rapport de deux  $\chi^2$  indépendants divisés par leur nombre de degrés de liberté. SI  $H_0$  est vraie, sous les deux hypothèses la variance des erreurs est la même  $\sigma^2$  et  $(SCR_0 - SCR_a)/\sigma^2$  suit un  $\chi^2$  a  $(n - k + r - (n - k)) = r$  degrés de liberté on a donc

$$\frac{SCR_0 - SCR_a}{\sigma^2 r} / \frac{SCR_a}{\sigma^2 (n - k)} = F(r, n - k) = \frac{SCR_0 - SCR_a}{SCR_a} \cdot \frac{n - k}{r}$$

Remarque : comme  $SCR_0 > SCR_a$  le fisher est toujours positif.



Dans notre exemple les résultats de Rats donnent les estimations  $SCR_a = 11671924.919$ ,  $n-k=137$ ,  $r=2$ ,  $SCR_0 = 3915371695.7$  et  $F_\alpha = 19,5$  dans la table de Fisher (2,137)

$\frac{SCR_0 - SCR_a}{SCR_a} \cdot \frac{n-k}{r} = 22909.97$  on decide donc très nettement  $H_1$  l'une au moins des deux hypothèses n'est pas vérifiée.

## 2.2 Cas particulier: test de Fisher global

Il existe un test de Fisher qui dans un modèle avec terme constant permet de tester si tous les coefficients sont nuls sauf le terme constant.

Modèle à k-1 variables explicatives  $X_1, \dots, X_{k-1}$  autres que la constante

$$Y_t = a_0 + a_1 X_{1t} + a_2 X_{2t} + \dots + a_{k-1} X_{k-1t} + \epsilon_t$$

$H_0$ : tous les coefficients nuls sauf la constante soit  $a_0 \neq 0$  et  $a_1 = a_2 = \dots = a_{k-1} = 0$

$H_1$ : au moins un des  $a_i \neq 0$  pour  $i=1$  à  $k-1$

- Sous l'hypothèse  $H_1$  on effectue les MCO sur l'échantillon global avec toutes les variables. La variable  $SCR_1/\sigma^2$  suit un  $\chi^2_{n-k}$

- Sous l'hypothèse H0 le modèle s'écrit  $Y_t = a_0 + \epsilon_t$ . On voit facilement que le résultat des MCO dans ce modèle est  $\hat{a}_0 = \bar{Y}$  la moyenne des  $Y_t$ . On a donc  $\hat{Y}_t = \hat{a}_0 = \bar{Y}$ . Les résidus de ce modèle sont  $e_t = Y_t - \bar{Y}$  et  $SCR0 = \sum(Y_t - \bar{Y})^2$ . La variable  $SCR0/\sigma^2$  suit un  $\chi^2_{n-1}$ . Le Fisher est le rapport de deux  $\chi^2$  indépendants divisés par leurs degrés de liberté, soit

$$\frac{SCR0 - SCR1}{SCR1} * \frac{n - k}{k - 1} = F_{(k-1), n-k} \text{ sous H0 vrai}$$

et le test se fait comme un test de Fisher classique.

### 2.2.1 Remarque

Ce test est en fait le test du  $R^2$  du modèle global sous H1  $Y_t = a_0 + a_1X_{1t} + a_2X_{2t} + \dots + a_{k-1}X_{k-1t} + \epsilon_t$

Démonstration: le  $R^2$  du modèle global est  $R^2 = 1 - SCR1 / \sum(Y_t - \bar{Y})^2 = 1 - SCR1 / SCR0$  soit  $SCR1 / SCR0 = 1 - R^2$

$$F_{(k-1), n-k} = \frac{1 - SCR1 / SCR0}{SCR1 / SCR0} * \frac{n - k}{k - 1} = \frac{1 - (1 - R^2)}{1 - R^2} * \frac{n - k}{k - 1}$$

soit

$$F_{(k-1), n-k} = \frac{R^2}{1 - R^2} * \frac{n - k}{k - 1}$$

On voit ainsi que le test peut s'écrire aussi

H0:  $R^2 = 0$

H1:  $R^2 \neq 0$

en effet sous l'hypothèse H0 le  $R^2$  est  $1 - SCR0 / \sum(Y_t - \bar{Y})^2 = 1 - 1 = 0$  donc un modèle constitué seulement d'un terme constant et une erreur a un  $R^2$  nul.

Voilà pourquoi ce test est peu regardé car si vous avez un  $R^2$  grand il est évident qu'il est inutile de tester  $R^2 = 0$ .

### 2.2.2 Exemple

Dans le modèle ci-dessous

```
Linear Regression - Estimation by Least Squares
Dependent Variable Y
Usable Observations    140      Degrees of Freedom    137
Centered R**2          0.999998      R Bar **2            0.999998
Uncentered R**2        1.000000      T x R**2             140.000
Mean of Dependent Variable    692268.63700
Std Error of Dependent Variable 206128.93876
Standard Error of Estimate      291.88445
Sum of Squared Residuals      11671924.919
Regression F(2,137)          34660910.1766
Significance Level of F              0.00000000
Log Likelihood                -991.82521
Durbin-Watson Statistic        1.753973
```

Variable	Coeff	Std Error	T-Stat	Signif
1. Constant	834.92234985	102.69414057	8.13018	0.00000000
2. X1	0.80325350	0.00288544	278.38191	0.00000000
3. X2	0.49984476	0.00020700	2414.74856	0.00000000

Rats donne le test de tous les coefficients nuls sauf la constante, c'est ici la ligne Regression F(2,137) , on retrouve bien avec k=3 et n=140 le résultat k-1=2 et n-k=137. Ici le résultat du test est F=34660910.1766 valeur très forte avec un niveau de significativité nul donc une décision H1 très nette, ce qui est normal car le  $R^2 = 0.999998$  donc très loin de 0. Nous voyons ici un niveau de significativité (significance level) = 0.000000 nul.

**RAPPEL : le niveau de significativité est la probabilité pour que le Fisher soit supérieur à la valeur trouvée dans le test. ici c'est la  $\text{PRO}\{F > 34660910.1766\} = 0,0000$**

D'autre part il est évident que chaque coefficient est très loin de 0 avec des 't de Student' de 278.38 et 2414.74 très nettement supérieurs à 1.96 , vous constatez que le niveau de significativité est aussi 0,00000

### 2.3 Si l'on n'est pas dans l'hypothèse de normalité

Si l'hypothèse  $H_1^7$  n'est plus vérifiée et si l'on souhaite tester r contraintes comme ci-dessus, on montre que la même variable F est telle que sous l'hypothèse  $H_0$  vraie alors

$$rF = \chi_r^2 \text{ si n est grand}$$