

Semestre 6
LICENCE 3 mention ÉCONOMIE
LICENCE 3 mention ÉCONOMIE et MATHÉMATIQUES

ECONOMETRIE
(durée 1h30)

F. GASMI
T. MAGNAC

Mardi 7 mai 2013 ~ 12h30 – 14h00

-=====

PARTIE EMPIRIQUE (12 points)

Problème : On considère un échantillon de 1000 personnes, extrait de l'Enquête Emploi effectuée en France en 1999. On classe ces personnes en fonction de leur éducation dans trois sous-échantillons: le premier sous-échantillon comprend 166 personnes qui sont allées à l'école au plus jusqu'au collège (moins de 8 ans d'éducation depuis l'âge de 6 ans); le deuxième sous-échantillon comprend 528 personnes qui sont allées à l'école après le collège mais au plus jusqu'à la fin du secondaire (entre 9 et 11 ans d'éducation depuis l'âge de 6 ans); enfin, le troisième sous-échantillon comprend 306 personnes qui sont allées à l'université. Les variables indicatrices de ces trois groupes sont respectivement *educ_col*, *educ_sec* et *educ_sup* (par exemple. *educ_col* = 1 si la personne appartient au premier groupe et *educ_col* = 0 sinon).

(Rappel : le quantile d'ordre 0.995 d'une loi normale centrée et réduite est approximativement égal à 2.58).

Voici maintenant les résultats de la régression du logarithme du taux de salaire (*ltsal*) sur les variables indicatrices *educ_sec* et *educ_sup*, l'âge (*agd*), l'âge au carré (*agd2*) et le sexe (*s* ∈ {Homme = 0, Femme = 1}).

Source	SS	df	MS			
Model	46.9788694	5	9.39577389	Number of obs = 1000		
Residual	103.461621	994	.104086138	F(5, 994) = 90.27		
Total	150.44049	999	.150591082	Prob > F = 0.0000		
				R-squared = 0.3123		
				Adj R-squared = 0.3088		
				Root MSE = .32262		

ltsal	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
educ_sec	.2098154	.0300892	6.97	0.000	.1507698	.268861
educ_sup	.5725776	.0329807	17.36	0.000	.5078578	.6372975
agd	.0255319	.0125094	2.04	0.042	.000984	.0500798
agd2	-.0001281	.0001585	-0.81	0.419	-.0004392	.0001829
s	-.1469443	.0206648	-7.11	0.000	-.1874959	-.1063926
_cons	2.987725	.2422177	12.33	0.000	2.512409	3.463042

1. Pourquoi n'a-t-on pas introduit la variable indicatrice *educ_col* dans cette régression?
2. Quelle est l'interprétation du coefficient de *educ_sup* dans cette régression? Ecrivez de façon brève une phrase en français qui résume ce résultat.
3. Est-ce que ce dernier coefficient est significatif à un niveau de 1%? Pourquoi?
4. Quelle est la probabilité que le coefficient estimé de *s* soit supérieur à -.1063?
5. Comment écrivez-vous l'hypothèse nulle que l'éducation n'a pas d'influence sur le taux de salaire?

On régresse maintenant le logarithme du taux de salaire (*ltsal*) sur les variables indicatrices *educ_col* et *educ_sup*, l'âge (*agd*), l'âge au carré (*agd2*) et le sexe ($s \in \{\text{Homme} = 1, \text{Femme} = 2\}$). Vous vous servirez de la Table ci-dessus pour répondre aux questions suivantes:

6. Quelle est la valeur du coefficient estimé de *educ_col* dans cette nouvelle régression?
7. Quelle est la valeur de la statistique de Student qui est associée à ce dernier coefficient?
8. Quelle est la nouvelle valeur du coefficient estimé de *educ_sup*?

On crée maintenant une nouvelle variable qui est l'interaction entre le fait d'avoir été à l'université avec la variable indicatrice homme/femme (*s*). Cette nouvelle variable est notée $s_sup = s * educ_sup$.

9. Pour quel groupe de personnes dans la population cette variable est-elle égale à 1? Quelles sont les autres valeurs possibles?

On ajoute maintenant dans la première régression cette variable et on obtient les résultats suivants:

Source	SS	df	MS			
Model	47.023717	6	7.83728616	Number of obs =	1000	
Residual	103.416774	993	.104145794	F(6, 993) =	75.25	
Total	150.44049	999	.150591082	Prob > F =	0.0000	
				R-squared =	0.3126	
				Adj R-squared =	0.3084	
				Root MSE =	.32272	

ltsal	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
educ_sec	.2086618	.0301491	6.92	0.000	.1494986	.2678251
educ_sup	.5278817	.0756803	6.98	0.000	.3793699	.6763935
agd	.0258963	.0125253	2.07	0.039	.0013171	.0504754
agd2	-.0001325	.0001587	-0.83	0.404	-.0004439	.000179
s	-.1560756	.024918	-6.26	0.000	-.2049737	-.1071775
s_sup	.0292775	.0446154	0.66	0.512	-.0582739	.1168288
_cons	2.994337	.2424965	12.35	0.000	2.518473	3.470202

10. Calculer la statistique de Fisher correspondant au test de $H_0 : \beta_{s_sup} = 0$ contre $H_a : \beta_{s_sup} \neq 0$ (en utilisant les R^2 ou les sommes des carrés des résidus que vous tirerez des 2 tableaux de résultats). Quelle conclusion en tirez-vous ?

On considère un homme d'éducation secondaire et d'âge égal à 30 ans dont le logarithme du taux de salaire est égal à 4.04.

11. Quelle serait la meilleure prédiction de la valeur du logarithme du taux de salaire pour une femme de même âge et de même éducation?

12. Calculer l'intervalle de confiance à 95% pour cette valeur.

PARTIE THEORIQUE (8 points)

1. Considérez le modèle de régression simple

$$y = \beta_0 + \beta_1 x + u$$

Sous les 4 hypothèses standards (Linéarité, échantillonnage aléatoire, espérance conditionnelle du terme d'erreur nulle et absence de colinéarité parfaite), l'estimateur des MCO de β_1 , $\hat{\beta}_1$, est non-biaisé et convergent. Montrez que l'estimateur des MCO de β_0 , $\hat{\beta}_0$, satisfait également ces deux propriétés (*Suggestion : Vous pourriez vous servir de l'expression de $\hat{\beta}_0$ en fonction de $\hat{\beta}_1$*).

2. Le "R-carré" d'une régression représente la part de la somme des carrés totaux expliquée par le modèle, i.e., $R^2 \equiv \frac{ESS}{TSS}$ où $ESS \equiv \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$ est la somme des carrés expliqués et $TSS \equiv \sum_{i=1}^n (y_i - \bar{y})^2$ est la somme des carrés totaux. Le "Rbar-carré" est donné par $\bar{R}^2 \equiv 1 - \left(\frac{n-1}{n-k-1} \right) \left(\frac{SSR}{TSS} \right)$ où $SSR \equiv \sum_{i=1}^n \hat{u}_i^2$ est la somme des carrés des résidus, n le nombre d'observations et k le nombre de variables indépendantes. Montrez que :

- $0 \leq R^2 \leq 1$
- $\bar{R}^2 < R^2$
- Quand k augmente R^2 ne peut qu'augmenter ou rester le même alors que \bar{R}^2 peut diminuer.
- Alors que R^2 ne peut jamais être négatif, montrez que \bar{R}^2 peut l'être.

3. Répondez par "Oui" ou "Non" (sans donner d'explications): Lorsque les hypothèses standards du modèle de régression multiple sont satisfaites mais les erreurs sont hétéroscédastiques.

- L'estimateur des MCO est biaisé
- L'estimateur des MCO est convergent
- Le "ratio t" usuel ne suit plus une loi de student
- L'estimateur des MCO est BLUE