

*CORRIGE DE L'EXERCICE CHAPITRE 5 - EXERCICE 4

. *Dalila Chenaf-Nicet Université de Bordeaux.

. * Tout d'abord s'assurer d'avoir ouvert le fichier de données stata C5EX4 avant d'ouvrir le do.fileC5EX4 qui est fichier programme.

. * Une fois le fichier de données ouvert ainsi que le do-file appuyer sur Run (Execute en haut à droite de la barre de menu du dofile)

. * pour démarrer

. * Toutefois il est possible en sélectionnant les parties du programme de l'exécuter pas à pas afin de voir apparaître pas à pas les

. * différents résultats.

. * CHAPITRE 5 EXERCICE 4

. *Test de détection de l'hétéroscedasticité

. * Il faut tout d'abord définir les 6 groupes

. egen m=group(x)

. * Comme les données sont constituées pour m=6 groupes d'observations il faut calculer la variance empirique pour chacun groupe (i=1,..6)

. gsort -m

. bysort m: egen sdi=sd(y)

. bysort m : gen vari=sd^2

. * On peut faire un tableau noté V avec les 6 variances de chaque groupe

. mkmat vari, mat(variancei)

. matlist variancei

	vari
r1	127.3
r2	127.3
r3	127.3
r4	127.3
r5	127.3
r6	78.69999
r7	78.69999
r8	78.69999
r9	78.69999
r10	78.69999
r11	63.7
r12	63.7
r13	63.7
r14	63.7
r15	63.7
r16	18.8
r17	18.8
r18	18.8
r19	18.8
r20	18.8
r21	17.8
r22	17.8
r23	17.8
r24	17.8
r25	17.8
r26	3.2
r27	3.2
r28	3.2
r29	3.2
r30	3.2

```

. matrix var1=variancei[1,1]

. matrix var6=variancei[6,1]

. matrix var11=variancei[11,1]

. matrix var16=variancei[16,1]

. matrix var21=variancei[21,1]

. matrix var26=variancei[26,1]

.

. matrix V=[var1\var6\var11\var16\var21\var26]

. matlist V

-----+-----
      |          c1
      +-----+-----
      r1 |          127.3
      r1 |          78.69999
      r1 |          63.7
      r1 |          18.8
      r1 |          17.8
      r1 |           3.2

.

. * Calculer la variance totale à partir de la matrice V qui comporte les 6 variances des
groupes à partir de la
. *formule de l'ouvrage (en décomposant le numérateur "num" du dénominateur "den")
.
. svmat V, names(V)

. gen num=(4*V1)
(24 missing values generated)

. egen variancet=sum(num)

. gen den=(24)

. gen variancetotale =variancet/den

. display variancetotale
51.583328

.

. ** Les étapes du calcul du khi2
.
. *vi= ni-1 = 4 et la somme des vi= m*(ni-1) = 24 =den
.
. * la quantité à calculer selon la formule de l'ouvrage nécessite de calculer logvariance
totale et des 6 variances par groupe
. gen vlnvarT=den*log(variancetotale)

. gen vlnvari=4*log(V1)
(24 missing values generated)

. egen sommevlnvari=sum(vlnvari)

.

. * Le calcul de Qprime
. gen Qprime=vlnvarT-sommevlnvari

. display Qprime
13.266449

.

. * Pour affiner le calcul on peut calculer la grandeur C pour Q avec Q=Qprime/C
. gen C=1 +[1/(3*(6-1))]*[6*(1/4)-(1/4)]

. display C

```

```
1.0833334
```

```
.
. gen Q=Qprime/C
```

```
. display Q
12.245953
```

```
.
. * Q est supérieur à 11,07 lu sur la table pour un risque de 1ere espèce de 5% et 6ddl. Le
modèle est donc hétéroscédastique
```

```
.
. ***** On peut aussi faire le test de Golgfeld-Quandt
```

```
.
. * Etape 1 : il faut ordonner les observations en fonction des variables croissantes ou
décroissante de la variable à expliquer y.
```

```
. * Or elles sont déjà classées par ordre croissant
```

```
. * On choisit D observations situées au centre de l'échantillon en règle générale D= _N/4.
En prenant la partie entière de la division.
```

```
.
. gen D=_N/4
```

```
. display D
7.5
```

```
.
. * On choisit donc D=8. On exclut donc les 8 valeurs centrales de la série des observations
. * On conserve donc deux échantillons le premier de la 1er à la 11ème observations et le
deuxième de la 20ème à la 30ème
```

```
.
. * Faire les régressions pour les deux échantillons et récupérer les résidus
. regress y x in 1/11
```

Source	SS	df	MS	Number of obs	=	11
				F(1, 9)	=	0.02
Model	1.98	1	1.98	Prob > F	=	0.8895
Residual	872.02	9	96.8911111	R-squared	=	0.0023
				Adj R-squared	=	-0.1086
Total	874	10	87.4	Root MSE	=	9.8433

y	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
x	-1.32	9.23386	-0.14	0.889	-22.20844	19.56844
_cons	23.08	8.117016	2.84	0.019	4.718033	41.44197

```
. gen rss1=e(rss)
```

```
. display rss1
872.02002
```

```
.
. regress y x in 20/30
```

Source	SS	df	MS	Number of obs	=	11
				F(1, 9)	=	0.85
Model	15.5151515	1	15.5151515	Prob > F	=	0.3811
Residual	164.666667	9	18.2962963	R-squared	=	0.0861
				Adj R-squared	=	-0.0154
Total	180.181818	10	18.0181818	Root MSE	=	4.2774

y	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
x	-2.133333	2.31666	-0.92	0.381	-7.373982	3.107316
_cons	16.93333	8.418293	2.01	0.075	-2.110168	35.97683

```
. gen rss2=e(rss)
```

```
. display rss2
164.66667
```

```
. * Calculer le F avec ddl =n-2=11_2=9
. gen F=(rss1/9)/(rss2/9)
```

```
. display F
5.2956681
```

```
. * F est supérieur à 3.18 lu sur la table pour un risque de 1ere espèce de 5% et (9,9)ddl.
Le modèle est donc hétéroscédastique
```

```
. * *****On peut faire le Test de Gleisjer
```

```
. * Etape 1: on régresse le modèle complet et on récupère le vecteur des résidus
. regress y x
```

Source	SS	df	MS	Number of obs	=	30
Model	826.095708	1	826.095708	F(1, 28)	=	17.64
Residual	1311.40429	28	46.8358676	Prob > F	=	0.0002
				R-squared	=	0.3865
				Adj R-squared	=	0.3646
Total	2137.5	29	73.7068966	Root MSE	=	6.8437

y	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
x	-4.125322	.9822724	-4.20	0.000	-6.137416 -2.113228
_cons	24.09442	2.397697	10.05	0.000	19.18296 29.00588

```
. predict ei, re
```

```
. * On régresse ensuite la valeur absolue des résidus par rapport à X
```

```
. gen absei=abs(ei)
```

```
. regress absei x
```

Source	SS	df	MS	Number of obs	=	30
Model	104.501976	1	104.501976	F(1, 28)	=	6.55
Residual	446.860339	28	15.9592978	Prob > F	=	0.0162
				R-squared	=	0.1895
				Adj R-squared	=	0.1606
Total	551.362315	29	19.0124936	Root MSE	=	3.9949

absei	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
x	-1.467253	.5733893	-2.56	0.016	-2.641787 -.292718
_cons	8.090138	1.399626	5.78	0.000	5.223135 10.95714

```
. * On régresse ensuite la valeur absolue des résidus par rapport à X2
```

```
. gen x2=sqrt(x)
```

```
. regress absei x2
```

Source	SS	df	MS	Number of obs	=	30
Model	107.281344	1	107.281344	F(1, 28)	=	6.76
Residual	444.08097	28	15.8600347	Prob > F	=	0.0147
				R-squared	=	0.1946
				Adj R-squared	=	0.1658
Total	551.362315	29	19.0124936	Root MSE	=	3.9825

absei	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
x2	-4.147867	1.594832	-2.60	0.015	-7.414732	-.881003
_cons	10.71379	2.301941	4.65	0.000	5.99848	15.42911

```
.
. * Les t-students empiriques des deux relations indiquent que les coefficients sont
significativement différentes de zéro.
. * L'hétéroscedasticité est détectée.
.
. ***** On peut faire le Test de White
.
. * Il est fondé sur une relation significative entre le carré des résidus de la régression
y/ x et les x au carré
. * Ici nous n'avons qu'une seule variable explicative. on pourra recourir à la statistique
LM distribuée comme un Khi2 ou F.
```

```
. regress y x
```

Source	SS	df	MS	Number of obs	=	30
Model	826.095708	1	826.095708	F(1, 28)	=	17.64
Residual	1311.40429	28	46.8358676	Prob > F	=	0.0002
Total	2137.5	29	73.7068966	R-squared	=	0.3865
				Adj R-squared	=	0.3646
				Root MSE	=	6.8437

y	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
x	-4.125322	.9822724	-4.20	0.000	-6.137416	-2.113228
_cons	24.09442	2.397697	10.05	0.000	19.18296	29.00588

```
. predict re, re
```

```
. gen re2=re^2
```

```
.
. * Soit ici le modèle testé
. regress re2 x x2
```

Source	SS	df	MS	Number of obs	=	30
Model	31983.0303	2	15991.5151	F(2, 27)	=	4.04
Residual	106848.104	27	3957.3372	Prob > F	=	0.0292
Total	138831.135	29	4787.2805	R-squared	=	0.2304
				Adj R-squared	=	0.1734
				Root MSE	=	62.907

re2	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
x	59.06827	67.6917	0.87	0.391	-79.82363	197.9602
x2	-231.4947	188.8668	-1.23	0.231	-619.0173	156.0279
_cons	237.6825	120.9112	1.97	0.060	-10.40673	485.7717

```
. gen R2=e(r2)
```

```
. display R2
.23037362
```

```
. gen LM=_N*R2
```

```
. display LM
6.9112086
```

```
.
. *La valeur de LM calculée est supérieur au khi2 de la table (5.99) pour un risque de 1ere
espece de 6 % et p=2*k ddl
```

```

. *L'hétéroscédasticité est détectée
.
. ***** Correction de l'hétéroscédasticité
. * On crée un variable Z=(Y/sqrt(X)) , X1=1/(sqrt(X)) et X2=X/(sqrt(X))
.
. gen Z=y/sqrt(x)
.
. gen X1=1/sqrt(x)
.
. gen X2=x/sqrt(x)
.
. * On réalise la régression de ces variables
. regress Z X1 X2, noconstant

```

Source	SS	df	MS	Number of obs	=	30
Model	9127.90514	2	4563.95257	F(2, 28)	=	79.92
Residual	1599.01168	28	57.1075601	Prob > F	=	0.0000
				R-squared	=	0.8509
				Adj R-squared	=	0.8403
Total	10726.9168	30	357.563894	Root MSE	=	7.557

Z	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
X1	24.94147	2.503469	9.96	0.000	19.81335 30.06959
X2	-4.531905	1.535487	-2.95	0.006	-7.677207 -1.386603

```

.
. * Le modèle estimé est donc Y= 24,96 - 4.53 *X +e
.
. * Il existe bien une influence significative du temps de vérification sur le nombre de
défauts constatés.
. * Chaque heure de vérification permet de supprimer en moyenne 4,5 défauts
.
end of do-file

. exit, clear

```