

2. Relâchement des hypothèses du modèle classique

- Rappel: Hypothèses du MRLCN
 - 1. Le modèle est linéaire dans les paramètres.
 - 2. Les variables explicatives sont non stochastiques.
 - 3. Pour des valeurs fixes de X , la valeur moyenne des erreurs u_i est nulle.
 - 4. Homoscédasticité.
 - 5. Absence d'autocorrélation des erreurs u_i .
 - 6. Si les variables X sont stochastiques, le terme d'erreur u_i et les variables X sont indépendants ou du moins non corrélés.
 - 7. Le nombre d'observation > nombre de variables explicatives.
 - 8. Il suffisamment de variabilité des valeurs prises par les variables explicatives.
 - 9. Le modèle est correctement spécifié.
 - 10. Il n'y a pas de relation linéaire exacte telles les variables explicatives (pas de multicolinéarité).
 - 11. Le terme d'erreur u_i suit une loi normale.

- Quid si hyp. 8 pas satisfait?

Les estimateurs des MCO sont BLUE mais paramètres pop. ne sont pas estimés avec une grande précision.

- Quid si hyp. 7 ne pas satisfait?

Micronumérosité : estimateurs toujours BLUE mais s.e. gds par rapport aux coeff. estimés.

- Hypothèse 2 :

On suppose que pour problème particulier, les valeurs prises par les variables expl. sont fixes, même si les variables expl. elles-mêmes sont intrinsèquement stochastiques.

Si variable est stochastique : vérifier si var. expl. est indépendante du terme d'erreur ou du moins si les valeurs de la var. expl. sont non corrélées au terme d'erreur.

Si hypothèse 6 est satisfaite : estimateurs des RCO peuvent être biaisés mais ils sont consistants.

Si hypothèse 6 n'est pas satisfaite : estimateurs des RCO sont biaisés et inconsistants (variables instrumentales).

- Hypothèse 3 :

Spérance cond. des erreurs est nulle.

Si hyp. 3 non satisfaite ?

$$\left\{ \begin{array}{l} Y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \dots + \beta_k X_{ki} + u_i \\ E(u_i | X_{2i}, X_{3i}, \dots, X_{ki}) = \frac{\omega}{3} \end{array} \right.$$

où $\omega = \text{constante } (\neq 0)$

$$\begin{aligned} \Rightarrow E(Y_i | X_{2i}, X_{3i}, \dots, X_{ki}) &= \beta_1 + \beta_2 X_{2i} + \dots + \beta_k X_{ki} + \frac{\omega}{3} \\ &= (\beta_1 + \omega) + \beta_2 X_{2i} + \dots + \beta_k X_{ki} \\ &= \alpha + \beta_2 X_{2i} + \dots + \beta_k X_{ki} \end{aligned}$$

où $\alpha = (\beta_1 + \omega)$

Estimation biaisée de β_1 , autres coeff. sont BLUE

Rem: si $E(u_i) = w_i$, alors coeff. de pente peuvent être biaisés et inconsistants.

- Hypothèse II:

Normalité du terme d'erreur.

Estimateurs des MCO sont BLUE indépendant de l'hyp. II.

Sous hyp. de normalité:

- a) estimateurs des coeff. de régr. (MCO) suivent loi normale.
- b) $(n-k) \hat{F}^2 / \sigma^2 \sim \chi^2$
- c) test "t" et "F" peuvent être utilisés pour inférence statistique indépendant taille de l'échantillon.

Quid si hyp. II n'est pas satisfaite?

Théorème limite central : si termes d'erreur u_i sont indép. et suivent une m^e distribution de moyenne "0" et de variance σ^2 (constante) et que variables expl. non stochast.
⇒ coeff. de régression des MCO suivent asympt. une distrib. normale dont moyenne est égale à la vraie.
Valeurs des paramètres pop. ⇒ tests "t" et "F"
restent valables asympt.

Corollaire:

Si échant. est petit, tests "t" et "F" ne peuvent plus être utilisés pour faire de l'inférence stat.
(techniques d'estimation "non paramétriques").

2.1. La multicollinearité

Quelle est la nature de la multicollinearité ?

Est-ce vraiment un problème ?

Quelles sont les conséquences pratiques ?

Comment la détecter ?

Comment y remédier ?

(Hypothèse 10 - 7 - 8)

2.1.1. Nature de la multicollinearité

Multicollinearité = existence d'une relation "linéaire"
"exacte" parmi certaines ou toutes les variables explicatives.

$$\alpha_1 X_{1i} + \alpha_2 X_{2i} + \dots + \alpha_k X_{ki} = 0 \quad (1) \equiv \text{rel. lin. exacte}$$

où $\alpha_1, \dots, \alpha_k$ des constantes non toutes nulles

X_{1i} = intercepte; $X_{2i} \dots X_{ki}$ = variables explicatives.

Aujourd'hui, multicollinearité désigne l'existence d'une relation linéaire parfaite ou indique que les variables explicatives sont corrélées (en moyennant).

$$\alpha_1 X_{1i} + \alpha_2 X_{2i} + \dots + \alpha_k X_{ki} + v_i = 0 \quad (2) \equiv \text{rel. lin. impf.}$$

où $\alpha_1, \dots, \alpha_k$ des constantes non toutes nulles

et v_i un terme d'erreur stochastique.

Soit, $\alpha_2 \neq 0$:

$$(1) : X_{2i} = -\frac{\alpha_1}{\alpha_2} X_{1i} - \frac{\alpha_3}{\alpha_2} X_{3i} - \dots - \frac{\alpha_k}{\alpha_2} X_{ki}$$

$$(2) : X_{2i} = -\frac{\alpha_1}{\alpha_2} X_{1i} - \frac{\alpha_3}{\alpha_2} X_{3i} - \dots - \frac{\alpha_k}{\alpha_2} X_{ki} - \frac{1}{\alpha_2} v_i$$

• Exemple :

X_{2i}	X_{3i}	X_{3i}^*
10	50	52
15	75	75
18	90	97
24	120	129
30	150	152

$$X_{3i} = 5X_{2i} \quad (\tau_{23} = 1)$$

X_3^* ne peut pas être écrite comme une combili de X_2

• Hyp. 10 ne concerne pas les relations non linéaires :

$$Y_i = \beta_0 + \beta_1 X_i + \beta_2 X_i^2 + \beta_3 X_i^3 + u_i$$

où $\begin{cases} Y = \text{coût total de production} \\ X = \text{niveau de production} (= l'output) \\ X^2 = \text{output au carré} \\ X^3 = \text{output au cube} \end{cases}$

Relation non linéaire tel X, X^2 et $X^3 \rightarrow$ ne viole pas l'hyp. 1c
Multicollinearité imparfaite.

• Principales sources de multicollinearité ?

1. Méthode de collecte des données.
2. Contraintes sur la population dont on tire l'échantillon.
3. La spécification du modèle.
4. Sur-identification du modèle.
5. Les variables expl. ont une tendance commune.

2.1.2. Estimation en présence de multicollinearité pft

En présence de multicollinearité pft, coeff. de régr. des variables expl. sont indéterminés.

$$y_i = \hat{\beta}_2 x_{2i} + \hat{\beta}_3 x_{3i} + \hat{u}_i \quad (1)$$

$$\hat{\beta}_2 = \frac{(\sum y_i x_{2i}) (\sum x_{3i}^2) - (\sum y_i x_{3i}) (\sum x_{2i} x_{3i})}{(\sum x_{2i}^2) (\sum x_{3i}^2) - (\sum x_{2i} x_{3i})^2} \quad (2)$$

$$\hat{\beta}_3 = \frac{(\sum y_i x_{3i}) (\sum x_{2i}^2) - (\sum y_i x_{2i}) (\sum x_{2i} x_{3i})}{(\sum x_{2i}^2) (\sum x_{3i}^2) - (\sum x_{2i} x_{3i})^2} \quad (3)$$

$$\text{Soit } X_{3i} = \lambda X_{2i}$$

$$\Rightarrow \hat{\beta}_2 = \frac{(\sum y_i x_{2i}) (\lambda^2 \sum x_{2i}^2) - (\lambda \sum y_i x_{2i}) (\lambda \sum x_{2i}^2)}{(\sum x_{2i}^2) (\lambda^2 \sum x_{2i}^2) - \lambda^2 (\sum x_{2i}^2)^2}$$

$$= \frac{0}{0}$$

Impossible de distinguer l'influence qui est exercée sur y par X_2 et X_3 .

Alternative : substituer $X_{3i} = \lambda X_{2i}$ dans (1)

$$\begin{aligned} y_i &= \hat{\beta}_2 x_{2i} + \hat{\beta}_3 (\lambda x_{2i}) + \hat{u}_i \\ &= (\hat{\beta}_2 + \lambda \hat{\beta}_3) x_{2i} + \hat{u}_i \\ &= \hat{\alpha} x_{2i} + \hat{u}_i \end{aligned}$$

$$\text{où } \hat{\alpha} = (\hat{\beta}_2 + \lambda \hat{\beta}_3)$$

$$\hat{\alpha} = (\hat{\beta}_2 + \lambda \hat{\beta}_3) = \frac{\sum x_{2i} y_i}{\sum x_{2i}^2}$$

Paramètre α peut être estimé de façon unique, il n'en va pas de même pour les paramètres β_2 et β_3 .

2.1.3. Estimation en présence d'une forte multicollinearité (toujours faite)

$$x_{3i} = \lambda x_{2i} + v_i \quad (1)$$

où $\lambda \neq 0$ et v_i terme d'erreur stochastique t.q. $\sum x_{2i} v_i = 0$

Estimation unique des coeff. de régression β_1 et β_2 .
est possible.

En substituant (1) dans formule de $\hat{\beta}_2$:

$$\hat{\beta}_2 = \frac{(\sum y_i x_{2i}) (\lambda^2 \sum x_{2i}^2 + \sum v_i^2) - (\lambda \sum y_i x_{2i} + \sum y_i v_i)(\lambda \sum)}{\sum x_{2i}^2 (\lambda^2 \sum x_{2i}^2 + \sum v_i^2) - (\lambda \sum x_{2i}^2)^2}$$

Quand $v_i \rightarrow 0$, on tend vers multicollinearité pte et indétermination.

2.1.4. La multicollinearité : bcp de bruit pour rien

Multicollinearité a pour seule conséquence d'augmenter l'erreur standard des estimateurs (càd. de rendre peu précise l'estimation des paramètres population).

(sauf que lorsque problème de micronumerosité ou peu de variabilité dans les variables explicatives)

Ne détruit pas propriétés stat. des estimateurs nice (ils sont tjs BLUE)

→ pourquoi en paule-t-on autant?

- 1) Le fait qu'un estimateur soit non biaisé ne donne aucune garantie concernant valeur de l'estimation pour un échantillon particulier.

2) Estimateurs de variance minimale de l'ensemble de classe des estimateurs non biaisés (efficients) ... mais ne garantit pas que la variance des estimateurs sera faible au regard des coeff. de régression.

2. 2. 5. Consequences pratiques de la multicollinearité imparfaite

- 1) Estimateurs des MCO sont tjs BLUE mais larges variances et covariance \rightarrow estimation peu précise des paramètres pop.
- 2) Intervalles de confiance relativement larges \rightarrow on accepte trop sut. l'hypothèse nulle
- 3) t-stat. associées à un ou plusieurs coeff. de régression sont non significatives.
- 4) R^2 peut être très élevé
- 5) Estimateurs des MCO sensibles à de petits chang. dans les données.

Estimateurs des MCO ont de larges variances et covariances

$$\text{var}(\hat{\beta}_2) = \frac{\sigma^2}{\sum x_{2i}^2 (1 - r_{23}^2)}$$

$$\text{var}(\hat{\beta}_3) = \frac{\sigma^2}{\sum x_{3i}^2 (1 - r_{23}^2)}$$

$$\text{cov}(\hat{\beta}_2, \hat{\beta}_3) = \frac{-r_{23} \sigma^2}{(1 - r_{23}^2) \sqrt{\sum x_{2i}^2 \sum x_{3i}^2}}$$

où r_{23} = coeff. de corrél. tel X_2 et X_3

Lorsque $r_{23} \rightarrow 1$, $\left. \begin{array}{l} \text{var}(\hat{\beta}_2) \\ \text{var}(\hat{\beta}_3) \end{array} \right\} \rightarrow \infty$

$$VIF = \frac{1}{(1 - r_{23}^2)}$$

\equiv Variance inflating factor

$r_{23} \rightarrow 1, VIF \rightarrow \infty$

$r_{23} = 0, VIF = 1$

$$\text{var}(\hat{\beta}_2) = \frac{\sigma^2}{\sum x_{2i}^2} VIF$$

$$\text{var}(\hat{\beta}_3) = \frac{\sigma^2}{\sum x_{3i}^2} VIF$$

Table : The effect of increasing r_{23} on $\text{var}(\hat{\beta}_2)$ and $\text{cov}(\hat{\beta}_2, \hat{\beta}_3)$

Value of r_{23} (1)	VIF (2)	$\text{var}(\hat{\beta}_2)$ (3)	$\text{var}(\hat{\beta}_2) (r_{23} \neq 0)$		$\text{cov}(\hat{\beta}_2, \hat{\beta}_3)$ (5)
			$\text{var}(\hat{\beta}_2) (r_{23} = 0)$ (4)		
0, 00	1, 00	$\frac{\sigma^2}{\sum x_{2i}^2} = A$	—		0
0, 50	1, 33	$1,33 \times A$	1, 33		$0,67 \times B$
0, 70	1, 96	$1,96 \times A$	1, 96		$1,37 \times B$
0, 80	2, 78	$2,78 \times A$	2, 78		$2,18 \times B$
0, 90	5, 26	$5,26 \times A$	5, 26		$4,73 \times B$
0, 95	10, 26	$10,26 \times A$	10, 26		$9,74 \times B$
0, 97	16, 92	$16,92 \times A$	16, 92		$19,41 \times B$
0, 99	50, 25	$50,25 \times A$	50, 25		$49,75 \times B$
0, 995	100, 00	$100,00 \times A$	100, 00		$99,50 \times B$
0, 999	500, 00	$500,00 \times A$	500, 00		$499,50 \times B$

Note : $A = \frac{\sigma^2}{\sum x_{2i}^2}, B = \frac{-\sigma^2}{\sqrt{\sum x_{2i}^2 \sum x_{3i}^2}}$




FIGURE 10.2 The behavior of $\text{var}(\hat{\beta}_2)$ as a function of r_{23} .

- Extension pour modèle à k variables

$$\text{var}(\hat{\beta}_j) = \frac{\sigma^2}{\sum x_j^2} \left(\frac{1}{1 - R_j^2} \right)$$

où $\hat{\beta}_j$ = coeff. rég. partiel relatif à X_j

R_j^2 = R^2 de la régression de X_j sur ($k-2$) variables expl. restantes

$$\sum x_j^2 = \sum (X_j - \bar{X}_j)^2$$

$$\Rightarrow \text{var}(\hat{\beta}_j) = \frac{\sigma^2}{\sum x_j^2} VIF_j$$

$$\text{où } VIF_j = \frac{1}{1 - R_j^2}$$

De larges intervalles de confiance

Table : The effect of increasing collinearity on the 95% CI for β_2 ($\hat{\beta}_2 \pm 1,96 \text{ se}(\hat{\beta}_2)$)

Value of r_{23}	95% confidence interval for β_2
0,00	$\hat{\beta}_2 \pm 1,96 \sqrt{\frac{\sigma^2}{\sum x_{2i}^2}}$
0,50	$\hat{\beta}_2 \pm 1,96 \cdot \sqrt{1,33} \sqrt{\frac{\sigma^2}{\sum x_{2i}^2}}$
0,95	$\hat{\beta}_2 \pm 1,96 \cdot \sqrt{10,26} \sqrt{\frac{\sigma^2}{\sum x_{2i}^2}}$
0,995	$\hat{\beta}_2 \pm 1,96 \sqrt{100} \sqrt{\frac{\sigma^2}{\sum x_{2i}^2}}$
0,999	$\hat{\beta}_2 \pm 1,96 \sqrt{500} \sqrt{\frac{\sigma^2}{\sum x_{2i}^2}}$

Rem : $\begin{cases} \text{hyp. } \sigma^2 \text{ est connue} \rightarrow \text{on utilise distrib. normale} \\ \text{valeur critique à } 5\% = 1,96 \end{cases}$

Lorsque $r_{23} \uparrow \rightarrow$ risque de second espèce $\uparrow \rightarrow$ puissance du test.

Des t stat non significatives

Exemple : $H_0: \beta_2 = 0 \rightarrow t = \hat{\beta}_2 / \text{se}(\hat{\beta}_2)$

Un R² élevé mais peu de t stat significative

R² élevé, F stat significative

sensibilité des estimateurs des β 's et de leurs se à de petits changements de données

Table A : Hypothetical data
on Y , X_2 and X_3

Y	X_2	X_3
1	2	4
2	0	2
3	4	12
4	6	0
5	8	16

$$\hat{Y}_i = 1,1939 + 0,4463 X_{2i} + \frac{0,0030}{(0,0851)} X_{3i}$$

$$t = (1,5431) \quad (\underline{2,4151}) \quad (0,0358)$$

$$R^2 = 0,8101, \quad r_{23} = 0,5523$$

$$\text{cov}(\hat{\beta}_2, \hat{\beta}_3) = -0,00868 \quad df = 2$$

$$H_0: \beta_2 = 0$$

$$H_1: \beta_2 \neq 0 \Rightarrow |t| > t_{\alpha/2, df} \quad (\alpha = 0,10)$$

$$(t_{0,025; 2df} = 4,303 \text{ valeur critique à } 5\% \text{ lorsque } 2df \text{ (Student)})$$

$$t_{0,050; 2df} = 2,920 \quad ; \quad t_{0,10; 2df} = 1,886$$

$$H_0: \beta_2 \leq 0$$

$$H_1: \beta_2 > 0 \Rightarrow t > t_{\alpha; df} \quad (\alpha = 0,10)$$

$$(t_{0,010; 2df} = 1,886)$$

Table B : Hypothetical data
on Y , X_2 and X_3

Y	X_2	X_3
1	1	4
2	0	2
3	4	0
4	6	12
5	8	16

$$\hat{Y}_i = 1,2108 + 0,4014 X_{2i} + \frac{0,0270}{(0,1252)} X_{3i}$$

$$t = (1,6187) \quad (\underline{2,4751}) \quad (0,2158)$$

$$R^2 = 0,8143, \quad r_{23} = 0,8285$$

$$\text{cov}(\hat{\beta}_1, \hat{\beta}_2) = -0,0282 \quad df = 2$$

$$H_0: \beta_2 \leq 0$$

$$H_1: \beta_2 > 0 \Rightarrow t > t_{\alpha; df}$$

(un phénomène en présence de micronumérosité)

- 2.13 -

$$R^2 = 0,9567$$

$$Y_i = 24,411 + 0,0498 X_{3i}$$

$$\epsilon = (3,551) \quad (13,13)$$

$$(6,824) \quad (0,0032)$$

$$E = (3,551)$$

$$R^2 = 0,9621$$

$$Y_i = 24,4545 + 0,5091 X_{2i}$$

$$\epsilon = (3,8128) \quad (14,2432)$$

$$(6,4138) \quad (0,0357)$$

$$E = (3,8128)$$

$$R^2 = 0,9975$$

$$X_{3i} = 7,5454 + 10,1909 X_{2i}$$

$$(0,256) \quad (62,0405)$$

$$(0,1643) \quad (29,4758)$$

$$E = (0,256)$$

$$t_{\text{calulée}} > t_{\alpha} (2,7)$$

$$t_{\text{calculée}} < t_{\alpha} (2,7)$$

$$t_{\text{calculée}} = \frac{46,3494}{488,7770} = 98,4019$$

$$t_{\alpha} = 4,74 \quad ; \quad t_{\alpha/2} = 3,55$$

$$(p < 0,01)$$

source of variation	SS	df	MS	due to regression	due to residual
				324,4459	46,3494
				8,565,5541	4282,7770

ANOVA table for consumption - income - wealth example

$$n = 10 \quad , \quad df = f_p \quad (= 10 - 3)$$

$$R^2 = 0,9635 \quad , \quad \underline{df} = 0,9531$$

$$Y_i = 24,7747 + 0,9415 X_{2i} - 0,0421 X_{3i}$$

$$(6,4525) \quad (0,8229) \quad (0,0407)$$

$$(3,6690) \quad (1,1442) \quad (-0,5261)$$

$$\epsilon = (3,6690)$$

Exemple : Relation rel. dep. des cons. / revenus du travail / richesse

2.3.6. Détection de la multicolinéarité

- 1) L'obtention d'un R^2 élevé et de peu de t stat. signif.
Décelle uniq. multicol. aigüe
- 2) Des corrélations bi-variees élevées. ($r > 0,8$)
Mais cdt suff. mais non nécess.
- 3) Les régressions auxiliaires : calculer $R^2_{x_i}$
Exemple : $R^2_{x_1}$ obtenus à partir de $X_{2i} = a_1 + a_3 X_{3i} + \dots + a_k X_k$
 $\bar{F} = \frac{R^2 / (k-1)}{(1-R^2) / (n-k)}$

\Rightarrow stat. de test : $F_i = \frac{R^2_{x_i} / (k-1)}{(1-R^2_{x_i}) / (n-k+1)}$

où $\begin{cases} n = \text{taille de l'éch.} \\ k = \# \text{var. expl. + intercepte} \\ R^2_{x_i} = \text{coeff. détermin. de } X_i \text{ sur les autres var. expl. (intercept compris)} \end{cases}$

F_i suit distribution de Fisher à $(k-1)$ et $(n-k+1)$ df

Règle de décision : $F_i (\text{calculée}) > F_\alpha ((k-1), (n-k+1))$

$\Rightarrow H_0$ (on rejette absence de multicol. tel X_i est une var. expl.)

Règle de Klien (1962) : problème de multicol. est sérieux seulement si R^2 (régr. auxiliaire) $> R^2$ (modèle complet)

Inconvénient : détecte multicol. uniq. si elle implique un gd nbre de var. expl.

4) Le VIF

$$VIF_j = \frac{1}{1 - R_j^2}$$

où R_j^2 est obtenu à partir de X_j vs ($k-2$) var. expl. restantes (sans intercepte)

Généralement : multicollinearité lorsque $VIF_j > 10$ ($R_j^2 > 0,90$)

Inconvénient : $\text{var}(\hat{\beta}_j) = \frac{\sigma^2}{\sum x_j^2} VIF_j$

$\Rightarrow VIF_j$ élevé \neq cond° nécess. suff. pour obtention erreur standard élevée pour estimateur.

2.1.7. Remèdes à la multicollinearité

- 1) Utiliser l'information disponible a priori

$$Y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + u_i$$

où $\begin{cases} Y = \text{dép. cons.} \\ X_2 = \text{revenu du travail} \\ X_3 = \text{richesse} \end{cases}$

$$\beta_3 = 0,10 \beta_2 \Rightarrow Y_i = \beta_1 + \beta_2 X_{2i} + 0,10 \beta_2 X_{3i} + u_i \\ = \beta_1 + \beta_2 X_i + u_i$$

$$\text{où } X_i = X_{2i} + 0,10 X_{3i}$$

- 2) Combiner des données en couper et des données longitud.
 \Rightarrow "pooling" des données.

Exemple: demande de pain aux USA ("time series")

$$\ln Y_t = \beta_1 + \beta_2 \ln P_t + \beta_3 \ln I_t + u_t \quad (1)$$

où $\begin{cases} Y = \text{nbre de pains vendus} \\ P = \text{prix moyen du pain} \\ I = \text{revenu moyen des consommateurs} \\ t = \text{temps} \end{cases}$

Solution de Tobin (1950) : utiliser un "cross-section" pour estimer l'élasticité-revenu β_3

$$\Rightarrow \boxed{\ln Y_i = \beta_1 + \beta_2 \ln P_i + \beta_3 \ln I_i + u_i} \quad (2)$$

où $\begin{cases} Y_i = \text{nbre de pains achetés par l'individu } i \text{ au temps } t \\ P_i = \text{prix moyen des pains achetés par l'individu } i \text{ au temps } t \\ I_i = \text{revenu moyen de l'individu } i \text{ au temps } t \end{cases}$

Permet d'obtenir une estimation relativement précise de β_3
 $\Rightarrow \hat{\beta}_3$

En utilisant cette estimation, (1) peut être réécrite comme:

$$Y_t^* = \beta_1 + \beta_2 \ln P_t + u_t \quad (3)$$

où $Y_t^* = \ln Y_t - \hat{\beta}_3 \ln I_t$

En estimant (3) on obtient estimation de β_2 en évitant problème de colinéarité (et P_t et I_t).

! préférable de ne pas utiliser cette technique si estimations en cross-section varient fréquemment dans le temps

3) Exclure certaines variables en évitant un pbme de spécification.

4) Transformer les variables

$$Y_t = \beta_1 + \beta_2 X_{2t} + \beta_3 X_{3t} + u_t \quad (1)$$

si variable ent \rightarrow variable en $(t-1)$

$$Y_{t-1} = \beta_1 + \beta_2 X_{2,t-1} + \beta_3 X_{3,t-1} + u_{t-1} \quad (2)$$

$$(1) - (2) :$$

$$Y_t - Y_{t-1} = \beta_2 (X_{2,t} - X_{2,t-1}) + \beta_3 (X_{3,t} - X_{3,t-1}) + v_t \quad (3)$$

$$\text{où } v_t = u_t - u_{t-1}$$

Écriture du modèle en différences premières permet de réduire pbme de colinéarité, + (dans certains cas) permet de rendre une série stationnaire.

Autre transformation: "transf. en ratio"

$$Y_t = \beta_1 + \beta_2 X_{2t} + \beta_3 X_{3t} + u_t$$

où

$$\begin{cases} Y = \text{dép. de cons en \$ réel} \\ X_2 = PIB \\ X_3 = \text{pop. totale} \end{cases}$$

PIB et pop. ont une tendance commune \Rightarrow colinéarité

$$\Rightarrow \frac{Y_t}{X_{3t}} = \beta_1 \left(\frac{1}{X_{3t}} \right) + \beta_2 \left(\frac{X_{2t}}{X_{3t}} \right) + \beta_3 + \left(\frac{u_t}{X_{3t}} \right)$$

$$\text{où } \begin{cases} Y/X_3 = \text{dép. de cons par tête} \\ X_2/X_3 = PIB par tête \end{cases}$$

- ⚠ i) Transformation en \neq premières :
- * (de la plupart des cas) lorsque les erreurs originales u_t sont non corrélées, leurs \neq prem. v_t le seront.
 - * perte d'1 df.
 - * inadaptée pour données en coupe.

- ii) Transformation en ratio :

* lorsque terme d'erreur original u_t est homosced. niveau terme d'erreur (u_t / x_{3t}) sera hétéroscléast.

- 5) Utiliser un autre échantillon ou ajouter des observations

$$\text{Var}(\hat{\beta}_2) = \frac{\sigma^2}{\sum x_{2i}^2 (1 - r_{23}^2)}$$

$$\text{si } n \uparrow \rightarrow \sum x_{2i}^2 \uparrow$$

Exemple : relation entre dép. de cons. (Y), revenu (X_2) et X_3 (richesse)

$$n = 10 \Rightarrow \hat{Y}_i = 24,377 + 0,8716 X_{2i} - 0,0349 X_{3i}$$

$$t = (3,875) \quad (2,7726) \quad (-1,1595)$$

$$R^2 = 0,9682$$

$$n = 40 \Rightarrow \hat{Y}_i = 2,0907 + 0,7299 X_{2i} + 0,0605 X_{3i}$$

$$t = (0,8713) \quad (6,0014) \quad (2,0014)$$

$$R^2 = 0,9672$$

- 6) Autres méthodes tq. l'analyse factorielle, ACP.

2.2. L'hétérosédarsticité


Quelle est la nature de l'hétérosédarsticité ?

Quelles en sont les conséquences ?

Comment la détecter ?

Comment y remédier ?


2.2.1. Nature de l'hétérosédarsticité



$$E(u_i^2) = \sigma^2$$

$\forall i$

FIGURE 11.1 Homoscedastic disturbances.



$$E(u_i^2) = \sigma_i^2$$

FIGURE 11.2 Heteroscedastic disturbances.

$$Y_i = \beta_1 + \beta_2 X_i + u_i$$

où $\begin{cases} Y = \text{l'épargne} \\ X = \text{revenu} \end{cases}$

- Causes de l'hétéroscedasticité

- 1) Existence d'un processus d'apprentissage




FIGURE 11.3 Illustration of heteroscedasticity.

- 2) Pouvoir discrétionnaire des individus ↑ avec leurs revenus
- 3) Existence de valeurs aberrantes („outliers“)
- 4) Mauvaise spécification du modèle de régression
- 5) Distribution d'une ou de plusieurs variables explicatives est asymétrique
- 6) Autres sources :
 - transformation peu appropriée des données
 - utilisation d'une forme fonctionnelle inadéquate

Concernne surtout les séries en „cross-section“, qui portent généralement sur les membres d'une population à un moment donné (tg consommateurs, familles, firmes, secteurs).

TABLE 11.1
COMPENSATION PER EMPLOYEE (\$) IN NONDURABLE MANUFACTURING INDUSTRIES ACCORDING TO
EMPLOYMENT SIZE OF ESTABLISHMENT, 1958

Industry	Employment size (average number of employees)								
	1-4	5-9	10-19	20-49	50-99	100-249	250-499	500-999	1000-2499
Food and kindred products	2994	3295	3565	3907	4189	4486	4678	4968	5342
Tobacco products	1721	2057	3336	3320	2980	2848	3072	2969	3822
Textile mill products	3600	3657	3674	3437	3340	3334	3225	3163	3168
Apparel and related products	3494	3787	3533	3215	3030	2834	2750	2967	3453
Paper and allied products	3498	3847	3913	4135	4445	4885	5132	5342	5326
Printing and publishing	3611	4206	4695	5083	5301	5259	5182	5395	5552
Chemicals and allied products	3875	4660	4930	5005	5114	5248	5630	5870	5876
Petroleum and coal products	4616	5181	5317	5337	5421	5710	6318	6455	6347
Rubber and plastic products	3508	3984	4014	4287	4221	4539	4721	4905	5481
Leather and leather products	3016	3196	3149	3317	3414	3254	3177	3346	4067
Average compensation	3396	3787	4013	4104	4146	4241	4388	4538	4843
Standard deviation	742.2	851.4	727.8	805.06	929.9	1080.6	1241.2	1307.7	1110.5
Average productivity	9355	8584	7962	8275	8389	9418	9795	10,281	11,750

Source: *The Census of Manufacturers*, U.S. Department of Commerce, 1958 (computed by author).




FIGURE 11.6 Standard deviation of compensation and mean compensation.

2.2.2. Estimation par RCO en présence d'hétérosécédasticité

$$Y_i = \beta_1 + \beta_2 X_i + u_i$$

$$\hat{\beta}_2 = \frac{\sum x_i y_i}{\sum x_i^2}$$

$$\text{var}(\hat{\beta}_2) = \frac{\sum x_i^2 \sigma^2}{(\sum x_i^2)^2} \quad \left(\text{si homoscéd. : } \text{var}(\hat{\beta}_2) = \frac{\sigma^2}{\sum x_i^2} \right)$$

sous hyp. modèle rég. lin. classique, $\hat{\beta}_2$ est BLUE

En présence d'hétérosécédasticité, $\hat{\beta}_2$ est linéaire, non biaisé et consistant. (pas efficient).

Idem pour $\hat{\beta}_1$.

2.2.3. La méthode des moindres carrés généralisés (MCG)

Pq estimateur des RCO $\hat{\beta}_2$ n'est-il pas de variance minimale?

On voudrait une procédure d'estimation qui accorderait un poids plus important aux observations provenant des classes de taille où la variabilité des salaires est + faible.

→ permettrait une estimation + précise de la fonction de régression population.

RCO attribue un poids identique à toutes les observations.

MCG pondère les observations en fonction de la variance conditionnelle du terme d'erreur → fournit des estimateurs BLUE en présence d'hétérosécédasticité (variance minimale dans l'ensemble de la classe des estimateurs linéaires non biaisés).

$$\bullet \quad Y_i = \beta_0 + \beta_1 X_{0i} + \beta_2 X_i + u_i \quad (1)$$

$$\Rightarrow Y_i = \beta_1 X_{0i} + \beta_2 X_i + u_i \quad (2)$$

où $X_{0i} = 1, b_i$

Supposons que σ_i^2 soient connues.

$$\Rightarrow \left[\frac{Y_i}{\sigma_i} = \beta_1 \left(\frac{X_{0i}}{\sigma_i} \right) + \beta_2 \left(\frac{X_i}{\sigma_i} \right) + \left(\frac{u_i}{\sigma_i} \right) \right] \equiv \text{FRP}$$

$$\Rightarrow Y^* = \beta_1^* X_{0i}^* + \beta_2^* X_i^* + u_i^*$$

- Pq transformer le modèle de cette façon ?

$$\begin{aligned} \text{var}(u_i^*) &= E(u_i^* - E(u_i^*))^2 \\ &= E(u_i^*)^2 \quad \text{car } E(u_i^*) = 0 \\ &= E\left(\frac{u_i}{\sigma_i}\right)^2 \\ &= \frac{1}{\sigma_i^2} \cdot E(u_i^2) \quad \text{où } \sigma_i^2 \text{ est connue} \\ &= \frac{1}{\sigma_i^2} \cdot \sigma_i^2 \quad \text{car } E(u_i^2) = \sigma_i^2 \\ &= 1 \end{aligned}$$

(u_i^* est homoscélastique !)

- En résumé : méthode des RCG consiste à appliquer les RCG aux variables transformées, cæd. aux variables qui satisfont les hypothèses du modèle de régr. linéaire classique.

Estimateurs de RCG sont BLUE en présence d'hétéroscélast.

- Comment obtenir estimateurs des MCG $\hat{\beta}_1^*$ et $\hat{\beta}_2^*$?

$$TRE = \frac{Y_i}{\sigma_i} = \hat{\beta}_1^* \left(\frac{X_{0i}}{\sigma_i} \right) + \hat{\beta}_2^* \left(\frac{X_i}{\sigma_i} \right) + \left(\frac{\hat{u}_i}{\sigma_i} \right)$$

$$\Rightarrow Y_i^* = \hat{\beta}_1^* X_{0i}^* + \hat{\beta}_2^* X_i^* + \hat{u}_i^*$$

$$\min \sum \hat{u}_i^{*2} \equiv \min \sum (Y_i^* - \hat{\beta}_1^* X_{0i}^* - \hat{\beta}_2^* X_i^*)^2$$

$$\Rightarrow \min \sum \left(\frac{\hat{u}_i}{\sigma_i} \right)^2$$

$$\Rightarrow \min \sum \left[\left(\frac{Y_i}{\sigma_i} \right) - \hat{\beta}_1^* \left(\frac{X_{0i}}{\sigma_i} \right) - \hat{\beta}_2^* \left(\frac{X_i}{\sigma_i} \right) \right]^2$$

soit

$$w_i = \frac{1}{\sigma_i^2}$$

$$\Rightarrow \min \sum w_i \hat{u}_i^2$$

$$\Rightarrow \boxed{\min \sum w_i (Y_i - \hat{\beta}_1^* - \hat{\beta}_2^* X_i)^2}$$

MCG \equiv minimise somme des carrés des résidus pondérée où poids w_i sont inverses proportionnellement à la variance conditionnelle des résidus \hat{u}_i ($\text{var}(\hat{u}_i | X_i) = \text{var}(Y_i | X_i)$)

$$\frac{\partial \sum w_i \hat{u}_i^2}{\partial \hat{\beta}_1^*} = 2 \sum w_i (Y_i - \hat{\beta}_1^* - \hat{\beta}_2^* X_i) (-1)$$

$$\frac{\partial \sum w_i \hat{u}_i^2}{\partial \hat{\beta}_2^*} = 2 \sum w_i (Y_i - \hat{\beta}_1^* - \hat{\beta}_2^* X_i) (-X_i)$$

$$\sum w_i Y_i = \hat{\beta}_1^* \sum w_i + \hat{\beta}_2^* \sum w_i X_i$$

$$\sum w_i X_i Y_i = \hat{\beta}_1^* \sum w_i X_i + \hat{\beta}_2^* \sum w_i X_i^2$$

\Rightarrow

$$\hat{\beta}_2^* = \bar{Y}^* - \hat{\beta}_1^* \bar{X}^*$$

$$\hat{\beta}_2^* = \frac{(\sum w_i)(\sum w_i X_i Y_i) - (\sum w_i Y_i)}{(\sum w_i)(\sum w_i X_i^2) - (\sum w_i X_i)^2}$$


$$var(\hat{\beta}_2^*) = \frac{\sum w_i}{(\sum w_i)(\sum w_i X_i^2) - (\sum w_i X_i)^2}$$

- \neq le l MCO et MCG

$$MCO : \min \sum \hat{u}_i^2 = \min \sum (Y_i - \hat{\beta}_1 - \hat{\beta}_2 X_i)^2$$

$$MCG : \min \sum w_i \hat{u}_i^2 = \min \sum w_i (Y_i - \hat{\beta}_1^* X_{0i} - \hat{\beta}_2^* X_i)^2$$

$$\text{où } w_i = \frac{1}{\sigma_i^2}$$



Utilisation des MCG en présence d'hétérosécédasticité attribue un poids + élevé aux observations proches de leur moyenne ce qui permet estimation + précise de la FRP.

2.2.4. Répercussions de l'utilisation des RCO en présence d'hétérosécédasticité

Estimateurs $\hat{\beta}_2^*$ (HCG) et $\hat{\beta}_2$ (RCO) sont linéaires et non biaisés.

$\hat{\beta}_2^*$ est efficient (pas $\hat{\beta}_2$).

i) Estimation par RCO en tenant compte de l'hétérosc.

$$\hat{\beta}_2 = \frac{\sum x_i y_i}{\sum x_i^2}$$

$$\text{var}(\hat{\beta}_2) = \frac{\sum x_i^2 \tau_i^2}{(\sum x_i^2)^2} \quad (\text{prend en compte l'hétérosc.})$$

Généralement : $\text{var}(\hat{\beta}_2^*) < \text{var}(\hat{\beta}_2)$

(ou encore : $\text{var}(\hat{\beta}_2^*) \leq \text{var}(\hat{\beta}_2)$)

ii) Estimation par RCO en ignorant l'hétérosécédasticité

$$\hat{\beta}_2 = \frac{\sum x_i y_i}{\sum x_i^2}$$

$$\text{var}(\hat{\beta}_2) = \frac{\tau^2}{\sum x_i^2}$$

$\text{var}(\hat{\beta}_2) = \frac{\sigma^2}{\sum x_i^2}$ est un estimateur biaisé de la vraie

variance de l'estimateur $\hat{\beta}_2$ en présence d'hétérosc.

qui est donné par expression suivante : $\text{var}(\hat{\beta}_2) = \frac{\sum x_i^2 \tau_i^2}{(\sum x_i^2)^2}$

\Rightarrow En moyenne, on sur ou sous-estime la vraie valeur de la variance de $\hat{\beta}_2$. Généralement, on ne sait pas si sur ou sous-estimation au départ relatif (et τ_i^2 et X).

Biais découle du fait que estimateur de la variance conditionnelle des erreurs : $\hat{\sigma}^2 = \frac{\sum \hat{u}_i^2}{(n-2)}$ est un estimateur biaisé de σ_i^2 .

2.2.5. Comment détecter l'hétérosécédasticité ?

Repose en gde partie sur intuition et expérience.


Plupart des méthodes basées sur analyse de résidu des MCO \hat{u}_i (pas sur terme d'erreur u_i). On espère que les résidus \hat{u}_i fournissent bonne estimation des erreurs u_i (espérance généralement satisfaisante pour de gros échantillons).

i) Méthodes informelles


1) Méthode basée sur la nature du plotme.

Lorsqu'on travaille avec des données en "cross-section" faisant intervenir des unités hétérogènes, l'hétérosc. est davantage la règle que l'exception.

2) Méthode graphique



Exemple: Epargne \sim Revenu



Variance hétérosclélastique des résidus est propor. au revenu.

ii) Méthodes formelles

1) Test de Park

Hyp. : τ_i^2 est une fonction de X_i

suggestion : $\tau_i^2 = \sigma^2 X_i^\beta e^{v_i}$

$$\Rightarrow \ln \tau_i^2 = \ln \sigma^2 + \beta \ln X_i + v_i \quad (1)$$

où v_i = terme d'erreur stochastique

On utilise \hat{u}_i^2 comme proxy de τ_i^2 :

$$\begin{aligned} \ln \hat{u}_i^2 &= \ln \sigma^2 + \beta \ln X_i + v_i \\ &= \alpha + \beta \ln X_i + v_i \end{aligned} \quad (2)$$

Règle de décision : si β est significatif \rightarrow pr^es. d'hétérosc.

Inconvénient : v_i ne satisfait pas les hyp. modèle de régr. linéaire classique (peut m^e s'avérer hétérosc.)
cf. Goldfeld et Quandt (1971)

2) Test de Goldfeld - Quandt

Hyp. : τ_i^2 dépend "positivement" d'une seule variable explicative du mod. de régression.

$$Y_i = \beta_1 + \beta_2 X_i + u_i$$

$$\tau_i^2 = \tau^2 \cdot X_i^2$$

Procédure :

- Etape 1 : ordonner observations en fonction des valeurs de X_i (en commençant par la plus petite valeur de X)
- Etape 2 : omettre " c " observations centrales et diviser les $(n-c)$ observations restantes en 2 groupes de $\frac{(n-c)}{2}$ observations.
- Etape 3 : Régression par MCO pour 2 sous-échantillons pris séparément, obtenir SCR de chaque régression

SCR_1 = SCR pour groupe d'obs. dont variance est supposée faible.

SCR_2 = SCR pour groupe d'obs. dont variance est supposée imp.

Chaque SCR caractérisée par :

$$\frac{(n-c)}{2} - h \text{ ou } \frac{(n-c-2h)}{2} \text{ df}$$

- Etape 4 : Calculer valeur de

$$\lambda = \frac{SCR_2 / df}{SCR_1 / df}$$

Si u_i suit loi normale et homoscéd. :

λ suit dist. Fisher avec $\frac{(n-c-2h)}{2}$ df

Règle de décision :

si F calculée > $F_{\alpha}, \frac{(n-c-k)}{2}$ df \Rightarrow rejette hyp. nulle d'homoscédasticité

Remarques :

- on omet „c“ observations centrales pour accentuer \neq les SCR₁ & SCR₂
- puissance du test ($= 1 - \text{risque 2nd espèce}$) dépend du nombre d'obs. „c“ omises.

Rappel : $\begin{cases} \text{risque 2d espèce} = \text{prob. d'accepter une hyp. fausse} \\ \text{puissance test} = \text{prob. rejeter l'hyp. nulle lorsqu'elle est fausse.} \end{cases}$

- d'après Judge et al. (1982), si $k = 2$
 $\Rightarrow „c“ = 4$ lorsque $n = 30$
 $„c“ = 10$ lorsque $n = 60$

3) Test de Breusch - Pagan - Godfrey

$$Y_i = \beta_1 + \beta_2 X_{2i} + \dots + \beta_k X_{ki} + u_i$$

Soit : $\tau_i^2 = f(\alpha_1 + \alpha_2 Z_{2i} + \dots + \alpha_m Z_{mi})$

où $\begin{cases} Z = \text{variables non stochastiques} \\ \text{Certaines ou toutes les variables } X \text{ peuvent servir comme variable } Z \end{cases}$

Plus spécifiquement :

$$\tau_i^2 = \alpha_1 + \alpha_2 Z_{2i} + \dots + \alpha_m Z_{mi}$$

$$\text{Si } \alpha_2 = \alpha_3 = \dots = \alpha_m = 0 \Rightarrow \tau_i^2 = \alpha_1 \quad (= \text{constante})$$

Procédure :

- Etape 1 : Estimer le modèle de régression linéaire à k variables par RCO, obtenir n résidus : $\hat{u}_1, \hat{u}_2, \dots, \hat{u}_n$
 - Etape 2 : Calculer $\tilde{\sigma}^2 = \frac{\sum \hat{u}_i^2}{n}$ (estim. MV de σ^2)
 - + est. RCO
 - $\hat{\sigma}^2 = \frac{\sum \hat{u}_i^2}{(n-k)}$
 - Etape 3 : Construire variables p_i , où
$$p_i = \frac{\hat{u}_i^2}{\tilde{\sigma}^2}$$
 - Etape 4 : Régresser les p_i sur variables Z :
$$p_i = \alpha_1 + \alpha_2 Z_{2i} + \dots + \alpha_m Z_{mi} + v_i$$

où v_i = terme d'erreur

 - Etape 5 : SCE de régress. des p_i sur cst et Z et calculer :

Sous hyp. normalité du terme d'erreur ϵ_i ,
en présence d'hétéroscéasticité :

$$n \sim_{asy} \chi^2_{m-1}$$

Règle de décision :

si $\Omega_{\text{calculé}} > \chi^2_{\alpha, (m-1) \text{ df}}$ \Rightarrow rejette l'hyp. nulle
d'homoscédasticité.

• Exemple:

Echantillon de 30 obs. concernant dép. de cons. et revenu des ménages US en 1988.

Test d'homoscedasticité de Breusch - Pagan - Godfrey :

Etape 1: $\hat{Y}_i = 9,2903 + 0,6378 X_i$
 $s_e = (5,2314) \quad (0,0286)$

$$SCR = 2361,153 ; R^2 = 0,9466$$

Etape 2: $\hat{\sigma}^2 = \frac{\sum \hat{u}_i^2}{30} = \frac{2361,153}{30} = 78,7051$

Etape 3: On divise chaque carré de résidu \hat{u}_i^2 par
 $\hat{\sigma}^2 = 78,7051$, pour obtenir p_i

Etape 4: Hyp.: p_i dépend linéairement de X_i ($= Z_i$)

$$\hat{p}_i = -0,7426 + 0,0101 X_i$$

$$s_e = (0,7529) \quad (0,0041)$$

$$SCE = 10,4280 ; R^2 = 0,18$$

Etape 5: Calcul de la stat. de test :

$$n = \frac{1}{2} (SCE) = 5,2140$$

$$(n \sim \chi^2_{\text{asy}})$$

$$\chi^2_{0,05; 2 \text{ df}} = 3,841$$

\Rightarrow rejette hyp. nulle d'homoséd. à 5%.

⚠ Test de Breusch - Pagan - Godfrey est asympt.
+ vérifier hyp. de normalité de u_i .

4) Test de White

Ne nécessite pas hyp. de normalité de u_i (cf. B-P-G)

Ne requiert pas d'ordonner des. d'après X supposée à la base du pbme d'hétérosc. (cf. 6-Q)

$$Y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + u_i \quad (1)$$

Procédure :

- Etape 1 : Estimer modèle de rég. (1) et obtenir \hat{u}_i

- Etape 2 : Estimer régression auxiliaire :

$$\begin{aligned}\hat{u}_i^2 &= \alpha_1 + \alpha_2 X_{2i} + \alpha_3 X_{3i} + \alpha_4 X_{2i}^2 \\ &\quad + \alpha_5 X_{3i}^2 + \alpha_6 X_{2i} X_{3i} + v_i\end{aligned}\quad (2)$$

Obtenir R^2 de cette rég.

- Etape 3 : $m.R^2 \underset{\text{asy}}{\sim} \chi^2_{df}$

$df = \text{nbre de var. expl. dans rég. auxiliaire}$
(sans l'intercepte)

- Etape 4 : si $m.R^2 > \chi^2_{\alpha/2, df}$ \Rightarrow rejette hyp. nulle d'homoscédatilité
 \Rightarrow rejette hyp nulle que

$$\begin{aligned}\alpha_2 &= \alpha_3 = \alpha_4 = \alpha_5 \\ &= \alpha_6 = 0\end{aligned}$$

Remarques :

- consomme svt bcp de df
- si mR^2 significatif, il est possible qu'il y ait une erreur de spécification plutôt qu'un pbme d'hétéroscédatilité.

Si produits croisés des variables pas inclus dans régression auxiliaire : test d'hétérosécédasticité pur.

Sinon, test de White teste simultanément pour hétérosécad. et biais de spécification.

2.2.6. Rémedes à l'hétérosécédasticité

i) Lorsque σ_i^2 est connue : moindres carrés pondérés (MCP)

Moindres carrés pondérés (MCP) (Weighted least squares, WLS)

MCP = cas particulier de RCG, MCP fournit estim. BLUE

TABLE 11.1
COMPENSATION PER EMPLOYEE (\$) IN NONDURABLE MANUFACTURING INDUSTRIES ACCORDING TO
EMPLOYMENT SIZE OF ESTABLISHMENT, 1958

Industry	Employment size (average number of employees)								
	1-4	5-9	10-19	20-49	50-99	100-249	250-499	500-999	1000-2499
Food and kindred products	2994	3295	3565	3907	4189	4486	4676	4968	5342
Tobacco products	1721	2057	3306	3320	2980	2843	3072	2969	3822
Textile mill products	3600	3657	3674	3437	3340	3334	3225	3163	3168
Apparel and related products	3494	3787	3533	3215	3030	2834	2750	2967	3453
Paper and allied products	3498	3847	3913	4135	4445	4885	5132	5342	5326
Printing and publishing	3611	4206	4695	5083	5301	5269	5182	5395	5552
Chemicals and allied products	3875	4660	4930	5005	5114	5248	5630	5870	5876
Petroleum and coal products	4616	5181	5317	5337	5421	5710	6316	6455	6347
Rubber and plastic products	3538	3984	4014	4287	4221	4539	4721	4905	5481
Leather and leather products	3016	3198	3149	3317	3414	3254	3177	3346	4067
Average compensation	3396	3787	4013	4104	4146	4241	4388	4538	4843
Standard deviation	742.2	851.4	727.8	805.06	929.9	1080.6	1241.2	1307.7	1110.5
Average productivity	9355	8584	7962	8275	8389	9418	9795	10,281	11,750

Source: The Census of Manufacturers, U.S. Department of Commerce, 1958 (computed by author).

Soit $\begin{cases} Y & \text{le salaire moyen d'un travailleur en \$} \\ X & \text{la taille de l'entreprise} \end{cases}$

$$\frac{Y_i}{\sigma_i} = \hat{\beta}_1^* \left(\frac{1}{\sigma_i} \right) + \hat{\beta}_2^* \left(\frac{X_i}{\sigma_i} \right) + (\hat{u}_i / \sigma_i)$$

où σ_i = écart-type des erreurs pour chaque valeur de X

$$\widehat{(\bar{Y}_i/\tau_i)} = 3406,639 \left(1/\tau_i\right) + 154,153 \left(X_i/\tau_i\right)$$

$$(80,983) \qquad \qquad \qquad (16,959)$$

$$t = (42,066) \qquad \qquad \qquad (9,090)$$

$$\hat{Y}_i = 3417,833 + 148,767 X_i \qquad \Rightarrow \text{Var}(\hat{\beta}_2) = \frac{\sigma^2}{\sum x_i^2}$$

$$(81,136) \qquad (14,418)$$

$$t = (42,125) \qquad (10,319)$$

Remarque :

$$\hat{\beta}_2 = \frac{\sum x_i y_i}{\sum x_i^2} \quad \text{et} \quad \hat{\beta}_2^* = \frac{\sum x_i^* y_i^*}{\sum x_i^{*2}}$$

$$\text{où } x_i = X_i - \bar{X}, y_i = Y_i - \bar{Y}$$

$$x_i^* = \left(\frac{X_i}{\tau_i}\right) - \left(\frac{\bar{X}}{\bar{\tau}}\right), \quad y_i^* = \left(\frac{Y_i}{\tau_i}\right) - \left(\frac{\bar{Y}}{\bar{\tau}}\right)$$

(ii) Lorsque τ_i^2 est inconnue

Comment obtenir une estimation constante de la variance des estimateurs des RCO en présence d'hétéroscedasticité ?

- White heteroscedasticity-consistent variances and stand. errors

Utiliser des erreurs stand. "robustes".

$$Y_i = \beta_1 + \beta_2 X_i + u_i \quad (1)$$

$$\text{où } \text{var}(u_i) = \tau_i^2$$

$$\text{var}(\hat{\beta}_2) = \frac{\sum x_i^2 \tau_i^2}{(\sum x_i^2)^2} \quad (2) \Rightarrow \boxed{\text{var}(\hat{\beta}_2) = \frac{\sum x_i^2 \hat{u}_i^2}{(\sum x_i^2)^2}} \quad (3)$$

(3) est un estimateur constant de (1)

Généralisation pour k variables :

$$Y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \dots + \beta_k X_{ki} + u_i \quad (4)$$

$$\text{var}(\hat{\beta}_j) = \frac{\sum \hat{w}_{ji}^2 \hat{u}_i^2}{\left(\sum \hat{w}_{ji}^2\right)^2} \quad (5)$$

où :

\hat{u}_i = résidu de la régression (4)

\hat{w}_{ji} = résidu d'une régression auxiliaire où on régresse X_j sur les autres régressions (var. expl. & intercepte) contenues du modèle de régression (4).

Exemple : dépenses d'enseignement \sim $\frac{\text{revenu}}{\text{tête}}$, $\left(\frac{\text{revenu}}{\text{tête}}\right)^2$
dans 50 Etats américains en 1979.

$$\hat{y}_i = 832,91 - 1834,2 \left(\frac{\text{Revenu}}{\text{tête}}\right) + 1587,04 \left(\frac{\text{Revenu}}{\text{tête}}\right)^2$$

$$\text{se}(MCO) = (327,3) \quad (829,0) \quad (519,1)$$

$$t = (2,54) \quad (2,21) \quad (3,06)$$

$$\text{se}(\text{White}) = (460,9) \quad (1243,0) \quad (830,0)$$

$$t = (1,81) \quad (-1,48) \quad (-1,91)$$

Procédure uniq. valable pour de gdz échantillons


Estimateurs obtenus par procédure de White généralement moins efficaces que ceux que l'on obtient lorsqu'on utilise une méthode de transf. qui corrige pour hétéros.

Rappel : $\text{var}(\hat{\beta}_2^*) \leq \text{var}(\hat{\beta}_2)$ où $\hat{\beta}_2^*$ estimateur MCP et $\hat{\beta}_2$ estimateur des MCO en pré. d'hétros. ($\text{var}(\hat{\beta}_2) = \frac{\sum x_i^2 \tau_i^2}{(\sum x_i^2)^2}$)

• Hypothèses relatives à la forme structuelle de l'hétérosédaricité

$$Y_i = \beta_1 + \beta_2 X_i + u_i$$

Hypothèse 1 : La variance de l'erreur est proportionnelle à X_i^2
 $\Rightarrow E(u_i^2) = \sigma^2 X_i^2$



$$\begin{aligned} \frac{Y_i}{X_i} &= \frac{\beta_1}{X_i} + \beta_2 + \frac{u_i}{X_i} \\ &= \beta_2 \left(\frac{1}{X_i} \right) + \beta_2 + v_i \end{aligned}$$

$$\text{ou } v_i = \frac{u_i}{X_i}$$

$$E(v_i^2) = E\left(\frac{u_i}{X_i}\right)^2 = \frac{1}{X_i^2} E(u_i^2) = \sigma^2$$

$$\text{car } E(u_i^2) = \sigma^2 X_i^2$$

v_i est homosédastique, on peut appliquer RCO pour estimer modèle de rég. transformé.

modèle de log. fouriforme.
Si on soustrait la moyenne des observations pour chaque


$$\text{ou } E(u_i) = \delta_i X_i$$

$$\delta_i = (u_i - E(u_i)) \frac{X_i}{\sqrt{X_i}} = \left(\frac{X_i}{\sqrt{X_i}} \right) E = E(u_i) \frac{X_i}{\sqrt{X_i}}$$

$$\text{ou } u_i = \delta_i + \frac{\sqrt{X_i}}{X_i}$$


$$= \beta_0 + \sqrt{\beta_1} X_i + \sqrt{\beta_2} \sqrt{X_i} + \delta_i$$

$$Y_i = \sqrt{\beta_1} + \sqrt{\beta_2} \sqrt{X_i}$$



Hypothèse 2: La variance de l'erreur est proportionnelle à X_i

Hypothèse 3 : La variance de l'erreur est proportionnelle au carré de la valeur moyenne (conditionnelle) de Y

$$\Rightarrow E(u_i^2) = \sigma^2 (E(Y_i))^2$$


$$\frac{Y_i}{E(Y_i)} = \frac{\beta_1}{E(Y_i)} + \beta_2 \frac{X_i}{E(Y_i)} + \frac{u_i}{E(Y_i)}$$

$$= \beta_1 \left[\frac{1}{E(Y_i)} \right] + \beta_2 \frac{X_i}{E(Y_i)} + v_i$$

où $v_i = \frac{u_i}{E(Y_i)}$

$$E(v_i^2) = E\left(\frac{u_i}{[E(Y_i)]}\right)^2 = \frac{1}{[E(Y_i)]^2} \cdot E(u_i^2) = \sigma^2$$

car $E(u_i^2) = \sigma^2 [E(Y_i)]^2$

v_i est homoscedastique

Ne peut être appliquée car $E(Y_i) = \beta_1 + \beta_2 X_i$ et (β_1, β_2) sont inconnues.

$\hat{Y}_i = \hat{\beta}_1 + \hat{\beta}_2 X_i \equiv \text{estimateur de } E(Y_i)$

• Trois étapes :

i) Estimer modèle de régression initial $\Rightarrow \hat{Y}_i$

ii) Transformation :

$$\frac{Y_i}{\hat{Y}_i} = \beta_1 \left(\frac{1}{\hat{Y}_i} \right) + \beta_2 \left(\frac{X_i}{\hat{Y}_i} \right) + v_i \quad (1)$$

où $v_i = \left(\frac{u_i}{\hat{Y}_i} \right)$

iii) Estimation du modèle transformé (1)

Procédure asymptotique.

Hypothèse 4 : Lorsqu'on a un modèle de rég. lin. $Y_i = \beta_1 + \beta_2 X_i + u_i$ très souvent on réduit l'hétéroscedasticité en y appliquant une transf. log., c.à.d. en estimant $\ln Y_i = \beta_1 + \beta_2 \ln X_i + u_i$

Exemple : $80 = 10x + \text{gd que } 8$

$$\ln(80) = \pm 2x + \text{gd que } \ln(8)$$

Remarques :

Nature de la variance cond. des erreurs σ^2 est tout à fait incertaine
 → est difficile de déterminer quelle transf. est adéquate
 → si on dispose d'un gd échantillon, est + facile d'utiliser la procédure de White qui estime mieux par tjs efficients.

Transformations posent certains problèmes :

- 1) Quelle var. expl. utiliser pour transformer les données ?
- 2) Transf. log. ne peut pas être utilisée lorsque var. prennent valeurs nulles ou négatives.
- 3) Corrélation fallacieuse ("Spurious correlation")
Variables initiales non corrélées mais ratio de ces var. corrélées
Exemple : $y_i = \beta_1 + \beta_2 x_i + u_i \Rightarrow y_i$ et x_i non corrélés
 $y_i/x_i = \beta_1 (1/x_i) + \beta_2 + (u_i/x_i) \Rightarrow (y_i/x_i)$ et $(1/x_i)$ corrélés
- 4) Inférence uniq. permise asympt.

- Exemple :

TABLE 11.5
INNOVATION IN AMERICA: RESEARCH AND DEVELOPMENT (R&D) EXPENDITURE
IN THE UNITED STATES, 1988 (All Figures in Millions of Dollars)

Industry grouping	Sales	R&D expenses	Profits
1. Containers and packaging	6,375.3	62.5	185.1
2. Nonbank financial	11,626.4	92.9	1,569.5
3. Service industries	14,655.1	178.3	276.8
4. Metals and mining	21,869.2	258.4	2,828.1
5. Housing and construction	26,408.3	494.7	225.9
6. General manufacturing	32,405.6	1,083.0	3,751.9
7. Leisure time industries	35,107.7	1,620.6	2,684.1
8. Paper and forest products	40,295.4	421.7	4,645.7
9. Food	70,761.6	509.2	5,036.4
10. Health care	80,552.8	6,620.1	13,869.9
11. Aerospace	95,294.0	3,918.6	4,487.8
12. Consumer products	101,314.1	1,595.3	10,278.9
13. Electrical and electronics	116,141.3	6,107.5	8,787.3
14. Chemicals	122,315.7	4,454.1	16,438.8
15. Conglomerates	141,849.9	3,163.8	9,761.4
16. Office equipment and computers	175,025.8	13,210.7	19,774.5
17. Fuel	230,614.5	1,703.8	22,625.6
18. Automotive	293,543.0	9,628.2	18,415.4

Source: Business Week, Special 1989 Bonus Issue, R&D Scorecard, pp. 180-224.

Note: The industries are listed in increasing order of sales volume.

Estimation par MCO :

$$\widehat{R&D}_i = 192,9931 + 0,0319 \text{ Sales}_i \quad (1) \quad (\text{var}(\widehat{\beta}_2) = \frac{\sigma^2}{\sum x_i^2})$$

$$se = (533,9317) (0,0083)$$

$$t = (0,3614) \quad (3,8433)$$

$$R^2 = 0,4783$$




FIGURE 11.13

Test de Park

$$\hat{u}_i^2 = -974469,1 + 86,321 \text{ Sales}_i$$

$$se = (4802,343) \quad (40,3625)$$

$$t = (-0,2029) \quad (2,1364)$$

$$R^2 = 0,2219$$

Test de White

$$\hat{u}_i^2 = -6219665 + 229,3508 \text{ Sales}_i - 0,000537 \text{ Sales}_i^2$$

$$se = (6459809) \quad (126,2197) \quad (0,0004)$$

$$t = (0,9628) \quad (1,8170) \quad (-1,3425)$$

$$R^2 = 0,2895$$

$$n = 18 \implies n \cdot R^2 = 5,214 \sim \chi^2_{2df} \text{ (sous H_0)}$$

$$p\text{-value} = 0,074$$

⇒ Analyse graphique, test de Park et test de White suggèrent présence d'hétéroscédastité.

$$\epsilon = 0,4783 \quad (\text{h}51\text{s}) \quad (\text{a},362\text{h})$$

$$se = (533,9931) \quad (0,0104)$$

$$(A\Delta D_i) = 192,9931 + 0,0319 \sqrt{\text{Sales}_i}$$

Ulike referencemethode - kontraktuelle sfatvadade euvens:

$$\epsilon = (0,3614) \quad (3,8433)$$

$$se = (533,9317) \quad (0,0083)$$

$$(A\Delta D_i) = 192,9931 + 0,0319 \sqrt{\text{Sales}_i}$$

Koppel: si applicafion des MCO aux donnees mean frenuf:

$$\epsilon^2 = 0,3648$$

$$(\text{h}51,690) \quad (\text{a},6472) \quad \epsilon =$$

$$(0,0074) \quad (31,1285) \quad se =$$

$$(A\Delta D_i) = -246,6769 \frac{1}{\sqrt{\text{Sales}_i}} + 0,0367 \sqrt{\text{Sales}_i}$$

par MCO:

← divisible en ensemble des variables par $\sqrt{\text{Sales}_i}$ et estivalisier

Analyse graphique suggestive que: $E(u_i^2) = \Gamma_i \cdot \text{Sales}_i$

σ_i^2 n'est pas connue \rightarrow impossible d'utiliser les MCO

• En résumé :

- 1) En présence d'hétérosécédasticité, estimateurs des MCO sont non biaisés et consistants mais leur variance n'est plus minimale \rightarrow ils ne sont pas efficaces.
(ne sont pas BLUE).
- 2) Lorsque σ_i^2 est connue, MCP fournit des estimateurs BLUE.
- 3) En présence d'hétérosécédasticité, les variances des estimateurs des MCO pas fournies par formules habit.
 \rightarrow si on persiste à utiliser formules habit., tests en t, F, etc... peuvent conduire à cel. erronées.
- 4) Plus facile de décrire conséquences de l'hét. que de la détecter. $\exists \neq$ test mais aucun n'est infaillible.
- 5) Remèdes lorsque σ_i^2 inconnue :
 - si n est grand : cercles standard de White
 \rightarrow permet inference (mais estimateurs pas très efficaces).
 - si n petit : utiliser résidus des MCO, diag. forme fonctionnelle terme d'un tel hétérose.
 \rightarrow transformat° des données, estimat° par MCO.

2.3. L'autocorrélation

- Cross-section porte sur un échantillon aléatoire d'unités (par exemple ménages, firmes).

A priori, pas de raison que termes d'eux soient corrélés. Le cas échéant, on parle d'autocorrélation spatiale.

Généralement pas d'ordre logique dans les unités d'un cross-section → il suffit suffit de changer ordre des unités pour que problème d'autocorrelation soit résolu.

- Time series : observations ordonnées de façon logique dans le temps.

Forte probabilité que les observ. successives soient corrélées surtout lorsque l'intervalle de temps est court.

⇒ Quelle est la nature de l'autocorrélation ?

Quelles sont les conséquences théoriques et pratiques ?

Comment détecter l'autocorrélation ?

Comment remédier à l'autocorrélation ?

2.3.1. La nature du problème


Autocorrélation = corrélation tel une série d'observations qui sont ordonnées dans le temps (time series) ou dans l'espace (cross-section).

Absence d'autocorrélation des erreurs :

$$E(u_i u_j) = 0 \quad i \neq j$$


\Rightarrow terme d'erreur d'une obs. n'est pas influencé par terme d'erreur d'une autre observation.

Cause de l'autocorrélation ? PIB



1) L'inertie

2) Il y a un biais de spécification suite à l'exclusion de variables explicatives importantes.



Exemple :

$$Y_t = \beta_1 + \beta_2 X_{2t} + \beta_3 X_{3t} + \beta_4 X_{4t} + u_t \quad (1)$$

où

$$\left\{ \begin{array}{l} Y = \text{qté de viande de boeuf demandée} \\ X_2 = \text{prix du boeuf} \\ X_3 = \text{revenu des consommateurs} \\ X_4 = \text{prix du porc} \\ t = \text{temps} \\ u = \text{terme d'erreur} \end{array} \right.$$

$$Y_t = \beta_1 + \beta_2 X_{2t} + \beta_3 X_{3t} + v_t \quad (2)$$


Si modèle (1) est correct $\Rightarrow v_t = \beta_4 X_{4t} + u_t$
 v_t seront autocorrélés.

- 3) Existant d'un biais de spécification suite à l'utilisation d'une forme fonctionnelle inadéquate.

Exemple :

$$\text{Marginal cost}_i = \beta_1 + \beta_2 \text{Output}_i + \beta_3 \text{Output}_i^2 + u_i \quad (1)$$

$$\text{Marginal cost}_i = \alpha_1 + \alpha_2 \text{Output}_i + v_i \quad (2)$$



$$v_i = \text{Output}_i^2 + u_i \Rightarrow v_t \text{ est autocorrélé.}$$

4) Omission d'une variable dépendante retardée (laguée).

Exemple:

$$\text{Consommation}_t = \beta_1 + \beta_2 \text{ Income}_t + \beta_3 \text{ Cons}_{t-1} + u_t$$

⇒ modèle autoregressif.

5) „Manipulation“ des données.

(lissage, extra & extrapolations)

6) „Transformation“ des données

Exemple:

$$Y_t = \beta_1 + \beta_2 X_t + u_t \quad (1)$$

où $\begin{cases} Y = \text{dépenses de cons.} \\ X = \text{revenu} \end{cases}$

$$Y_{t-1} = \beta_1 + \beta_2 X_{t-1} + u_{t-1} \quad (2)$$

$$(1) - (2) : \Delta Y_t = \beta_2 \Delta X_t + v_t \quad \Rightarrow \text{mod. en } \neq \text{1ères.}$$

où $\begin{cases} \Delta = \text{opérateur différence première} \\ \Delta Y_t = Y_t - Y_{t-1} \\ \Delta X_t = X_t - X_{t-1} \\ v_t = \Delta u_t = u_t - u_{t-1} \end{cases}$

Même si u_t n'est pas autocorrélé, v_t le sera.

Démonstration :

a) $v_t = u_t - u_{t-1}$

$$\Rightarrow E(v_t) = E(u_t - u_{t-1}) = E(u_t) - E(u_{t-1}) = 0$$

car par hyp. $E(u_t) = 0, \forall t$. \Rightarrow esp. cond. v_t est nulle

b) $\text{var}(v_t) = \text{var}(u_t - u_{t-1}) = \text{var}(u_t) + \text{var}(u_{t-1}) = 2\sigma^2$

Pq ?

- par hyp. : $\begin{cases} \text{var}(u_t) = \sigma^2, \forall t \\ E(u_t u_s) = 0, t \neq s \Rightarrow \text{cov}(u_t, u_s) = 0 \end{cases}$

- par déf. : $\text{var}(a - b) = \text{var}(a) + \text{var}(b) - 2\text{cov}(a, b)$

$\Rightarrow v_t$ est homoscedastique

c) $\text{cov}(v_t, v_{t-1}) = E(v_t v_{t-1}) = E[(u_t - u_{t-1})(u_{t-1} - u_{t-2})]$

$$= E(u_t u_{t-1}) - E(u_t u_{t-2}) - E(u_{t-1}^2) + E(u_{t-1} u_t)$$

$$= 0 - 0 - \sigma^2 - 0$$


$$= -\sigma^2$$

Pq ? Par hyp. u_t ne sont pas autocorrélés $\rightarrow E(u_t u_s) = 0 \quad \forall t \neq s$

\Rightarrow si u_t ne sont pas autocorrélés, leurs 1ères dérivées v_t le seront.

7) La non stationnarité des variables

- Remarque : Autocorrélation peut être \oplus comme \ominus (mais + sur \oplus)



2.3.2 Estimation par MC en présence d'autocorrélation

$$Y_t = \beta_1 + \beta_2 X_t + u_t \quad (1)$$

$$u_t = \rho u_{t-1} + \varepsilon_t \quad (2)$$

où ρ = coefficient d'autocovariance
 ε_t = terme d'erreur stochastique tq :

$$\begin{cases} E(\varepsilon_t) = 0 \\ \text{var}(\varepsilon_t) = \sigma_\varepsilon^2 \\ \text{cov}(\varepsilon_t, \varepsilon_{t+s}) = 0, s \neq 0 \\ \Rightarrow \text{"bruit blanc"} \\ (\text{white noise error term}) \end{cases}$$

Forme structuelle du terme d'erreur u_t est un processus autoregressif d'ordre 1 = AR(1)

Rém. : AR(1) = $u_t = \rho_1 u_{t-1} + \rho_2 u_{t-2} + \varepsilon_t$

Propriétés : ρ s'interprète comme coeff. de corrélation d'ordre 1
 $\Rightarrow \rho = \frac{E[(u_t - E(u_t))(u_{t-1} - E(u_{t-1}))]}{\sqrt{\text{var}(u_t)} \sqrt{\text{var}(u_{t-1})}}$

$$= \frac{E(u_t u_{t-1})}{\text{var}(u_{t-1})} \quad \text{car} \begin{cases} E(u_t) = 0 \quad \forall t \\ \text{var}(u_t) = \text{var}(u_{t-1}) \quad \text{car} \\ \text{hyp. d'homosc. maintenu} \end{cases}$$

ρ = coeff. de pente de régression de u_t sur u_{t-1}

- Quid de la variance, de la covariance et de la corrélation de u_t ?

$$\text{var}(u_t) = E(u_t^2) = \frac{\sigma_e^2}{1-\rho^2} \quad (1)$$

$$\text{cov}(u_t, u_{t+s}) = E(u_t u_{t+s}) = \rho^s \frac{\sigma_e^2}{1-\rho^2} \quad (2)$$

$$\text{cor}(u_t, u_{t+s}) = \rho^s \quad (3)$$

- \Rightarrow
- i) $\rho \in [-1, 1]$, variance u_t tjs homoscedastique.
 - ii) u_t est corrélé avec sa valeur à $t+s$ lags d'écart.
 - iii) $|\rho| = 1 \rightarrow \text{var}(u_t)$ & $\text{cov}(u_t, u_{t+s})$ indéterminés
 $|\rho| < 1 \rightarrow$ processus AR(1) est stationnaire
(moyenne, var. et cov. sont définies et leurs valeurs ne dépendent pas du temps).

- soit : $Y_t = \beta_1 + \beta_2 X_t + u_t$

$$\hat{\beta}_2 = \frac{\sum x_t y_t}{\sum x_t^2}$$

$$\begin{aligned} \text{var}(\hat{\beta}_2) &= \frac{\sigma^2}{\sum x_t^2} \quad (4), \quad \text{var}(\hat{\beta}_2)_{\text{AR}(1)} = \frac{\sigma^2}{\sum x_t^2} \left[1 + 2\rho \frac{\sum x_t x_{t-1}}{\sum x_t^2} \right. \\ &\quad \left. + 2\rho^2 \frac{\sum x_t x_{t-2}}{\sum x_t^2} + \dots \right. \\ &\quad \left. + 2\rho^{n-1} \frac{x_n x_1}{\sum x_t^2} \right] \quad (2) \end{aligned}$$

Difficile de prédir si $\text{var}(\hat{\beta}_2)$ est $>$, $<$ ou $=$ $\text{var}(\hat{\beta}_2)_{\text{AR}(1)}$

Si $\rho = 0 \Rightarrow \text{var}(\hat{\beta}_2) = \text{var}(\hat{\beta}_2)_{\text{AR}(1)}$

Si corrélations telles que les valeurs de X faible \Rightarrow {variance estimatrice nco peu biaisée}

- Hypothèse : X suit un processus AR(1)

$$\Rightarrow \text{cor}(X_t, X_{t+s}) = \tau^s$$

$$\text{où } \tau = \frac{\sum x_t x_{t+1}}{\sum x_t^2}$$

On peut montrer que :

$$\text{var}(\hat{\beta}_2)_{\text{AR}(1)} = \frac{\tau^2}{\sum x_t^2} \left(\frac{1+\tau\rho}{1-\tau\rho} \right) = \text{var}(\hat{\beta}_2)_{\text{OLS}} \left(\frac{1+\tau\rho}{1-\tau\rho} \right)$$

Exemple : $\tau = 0,6$ et $\rho = 0,8$

$$\Rightarrow \text{var}(\hat{\beta}_2)_{\text{AR}(1)} = 2,8461 \text{ var}(\hat{\beta}_2)_{\text{OLS}}$$

$$\Rightarrow \text{var}(\hat{\beta}_2)_{\text{OLS}} = 0,3513 \text{ var}(\hat{\beta}_2)_{\text{OLS}}$$

Formule usuelle de la variance de $\hat{\beta}_2$ sous-estime de +/- 65% la variance de $\hat{\beta}_2$ lorsque terme d'erreur suit un processus AR(1).

- Quid si on utilise estimateur des MO $\hat{\beta}_2$ et qu'on ajuste formule usuelle de la variance pour tenir compte de la structure AR(1) du terme d'erreur ?

$$\hat{\beta}_2 = \frac{\sum x_t y_t}{\sum x_t^2}$$

$$\begin{aligned} \text{var}(\hat{\beta}_2)_{\text{AR}(1)} &= \frac{\sigma^2}{\sum x_t^2} \left[1 + 2\rho \frac{\sum x_t x_{t-1}}{\sum x_t^2} + \rho^2 \frac{\sum x_t x_{t-2}}{\sum x_t^2} + \dots \right. \\ &\quad \left. + 2\rho^{n-1} \frac{x_1 x_n}{\sum x_t^2} \right] \end{aligned}$$

$\hat{\beta}_2$ est linéaire et non biaisé mais variance n'est pas minimale \Rightarrow estimateur n'est pas efficient.

2.3.3. Estimateur BLUE en présence d'autocorrélation

Technique des MCG fournit des estimateurs BLUE.

Pour modèle de rég. à 2 variables, sous hyp. que terme d'erreur soit processus AR(1), estimateur BLUE de β_2 est donné par :

$$\hat{\beta}_2^{\text{GLS}} = \frac{\sum_{t=2}^m (x_t - \rho x_{t-1})(y_t - \rho y_{t-1})}{\sum_{t=2}^m (x_t - \rho x_{t-1})^2} + C$$

$$\text{var}(\hat{\beta}_2^{\text{GLS}}) = \frac{\sigma^2}{\sum_{t=2}^m (x_t - \rho x_{t-1})^2} + D$$

où C et D sont des termes correcteurs

Estimateur des MCG est BLUE parce qu'il utilise au mieux l'information disponible.

2.3.4. Conséquences de l'utilisation des MCO en présence d'autocorrélation

Estimateurs des MCO sont tjs linéaires, non biaisés, constants et asympt. normaux mais pas efficient.

Quid des procédures habituelles d'inférence statistique ?

- (i) Lorsqu'on tient compte de l'autocorrélation.
- (ii) Lorsqu'on ignore la présence d'autocorrélation.

(i) Estimation par RCO en tenant compte de l'autocorrélation

Estimateur des RCO $\hat{\beta}_2$ n'est pas BLUE. Même si on utilise $\text{var}(\hat{\beta}_2)_{\text{AR}(1)}$ intervalles de confiance + larges que si on utilise $\text{var}(\hat{\beta}_2)^{\text{OLS}}$

- $\Rightarrow \hat{\beta}_2$ n'est pas efficient même asymptotiquement.
- \Rightarrow pour faire inference utiliser RCG.

(ii) Estimation par RCO en ignorant autocorrelation

Quid si on utilise (en présence d'autocorrelation) :

$$\hat{\beta}_2 = \frac{\sum x_t y_t}{\sum x_t^2}, \quad \text{var}(\hat{\beta}_2) = \frac{\sigma^2}{\sum x_t^2} \quad ?$$

- variance résiduelle $\hat{\tau}^2 = \sum \hat{u}_t^2 / (n-2)$ sous-estime généralement la vraie valeur de $\tau^2 \Rightarrow$ on surestime généralement R^2

- même si valeur de τ^2 n'est pas sous-estimée, $\text{var}(\hat{\beta}_2)$ peut sous-estimer $\text{var}(\hat{\beta}_2)_{\text{AR}(1)}$ ($\neq \text{var}(\hat{\beta}_2)_{\text{AR}(1)}$ inefficiente // $\text{var}(\hat{\beta}_2)^{\text{OLS}}$)

- \Rightarrow tests usuels de significativité ne sont plus valables.

- sous hyp. modèle rég. lin. classique :

$$\hat{\tau}^2 = \frac{\sum \hat{u}_t^2}{(n-2)} \text{ est un estimateur non biaisé de } \tau^2$$

$$\Rightarrow E(\hat{\tau}^2) = \tau^2$$

Si terme d'erreur suit processus AR(1) :

$$E(\hat{\tau}^2) = \frac{\tau^2 \{ n - [2/(1-\rho)] - 2\rho\tau \}}{n-2}$$

où $n = \# \text{ d'observations}$

$\rho = \text{coeff. autocorr. terme d'erreur}$

$\tau = \text{coeff. de corrélation tel valeurs successives}$
de $X \rightarrow \tau = \frac{\sum_{t=1}^{n-1} x_t x_{t+1}}{\sum_{t=1}^n x_t^2}$

Si ρ et τ positifs (hyp. rais. pour plupart séries eco.)
 $\Rightarrow E(\hat{\tau}^2) < \tau^2$

Formule habituelle de la variance des résidus
tous-estimé en moyenne la vraie valeur de τ^2 .

Biais dans $\hat{\tau}^2$ se transmet dans var($\hat{\beta}_2$)
car $\text{var}(\hat{\beta}_2) = \hat{\tau}^2 / \sum x_t^2$

- Même si τ^2 n'est pas tous-estimé, on peut montrer que var($\hat{\beta}_2$) est un estimateur biaisé de var($\hat{\beta}_2$)_{AR(1)}.

Si ρ et τ positifs : var($\hat{\beta}_2$) < var($\hat{\beta}_2$)_{AR(1)}

\Rightarrow si on utilise var($\hat{\beta}_2$), on sur-estime précision de $\hat{\beta}_2$
(on sur-estime t), on rejette trop souvent.

2.3.5. Relation entre les salaires et la productivité dans le secteur privé aux Etats-Unis (de 1959 à 1988)

- Estimation par RCO :

$$\hat{Y}_t = 29,5192 + 0,7136 X_t$$

$$se = (1,9423) \quad (0,0241)$$

$$t = (15,1977) \quad (29,6066)$$

$$R^2 = 0,9584$$

$$d = 0,1229$$

$$\hat{\sigma} = 2,6755$$

où

$$\begin{cases} Y = \text{indice du salaire horaire} \\ X = \text{indice de l'output par heure} \end{cases}$$

Fidélité des résultats ?

En présence d'autocorrélation, les estimateurs sont biaisés (t stat pas fiables)

2.3.6. Détection de l'autocorrélation

(i) La méthode graphique

Résidus des RCO fournissent une approximation des erreurs

→ représentation graphique des résidus // temps.




Fig. Residuals from wage - productivity regression




Fig. Positive autocorrelation




Fig. Negative autocorrelation




Fig. Current residuals versus lagged residuals

Analyse graphique est subjective et qualitative.

(iii) Le test des séquences ("runs test")




Fig. Residuals from wage - productivity regression.

Test des séquences ou "Geary-test" est non paramétrique

- Série de signes :

(-----) (++++++ ++++++) (-----)

Séquence = série ininterrompue de signes positifs ou négatifs
 Longueur d'une séquence = nombre de symboles qu'elle contient

- Autocorrélation ? Obtenir 3 séquences pour 40 observations, est-ce trop élevé / faible au regard de ce qu'on aurait obtenu pour 40 observations aléatoires ?

Intuition :

- si # de rég. trop élevé \Rightarrow résidus sont trop fréq. de signe \Rightarrow autocorrélation négative.
- si # de rég. trop faible \Rightarrow résidus ne sont pas suffisamment de signe \Rightarrow autocorrélation positive.

- Soit : $N = \text{nombre total d'observations} = N_1 + N_2$

$$N_1 = \text{nombre de symboles "+"}$$

$$N_2 = \text{nombre de symboles "-"} \quad$$

$$R = \text{nombre de séquences}$$

\Rightarrow sous hyp. nulle que résidus sont indépendants et lorsque $N_1 > 10$ et $N_2 > 10$, nombre de séquences suit asympt. une distrib. normale

tq. Moyenne : $E(R) = \frac{2N_1N_2}{N} + 1$

Variance : $\sigma_R^2 = \frac{2N_1N_2(2N_1N_2 - N)}{(N)^2(N-1)}$

\Rightarrow sous hyp. nulle d'indépendance, d'après prop. dist. normale :

$$\text{Prob}\left[-1,96 \leq \frac{R - E(R)}{\sigma_R} \leq +1,96\right] = 0,9$$

$$\Rightarrow \text{Prob} [E(R) - 1,96 \cdot \sigma_R \leq R \leq E(R) + 1,96 \cdot \sigma_R] = 0,95$$

Règle de décision :

Rejette l'hyp. nulle d'absence d'autocorrélation au niveau de prob. 95% lorsque nbre de séquences R n'est pas contenue ds l'intervalle de confiance. Sinon on ne rejette pas H_0 .

Exemple :

$$\left. \begin{array}{l} N_1 = 19 \\ N_2 = 21 \\ R = 3 \end{array} \right\} \Rightarrow \begin{aligned} E(R) &= \frac{2N_1N_2}{N} + 1 = 10,975 \\ \sigma^2_R &= \frac{2N_1N_2(2N_1N_2 - N)}{N^2(N-1)} = 3,6836 \\ \Rightarrow \sigma_R &= 3,1134 \end{aligned}$$

$$\text{IC : } [10,975 \pm 1,96 (3,1134)] = [4,8728 ; 17,0722]$$

On rejette H_0 au niveau de prob. 95%.

Nbre de séq. trop faible \Rightarrow autocorrélation positive.

Quid si $N < 20$?

Tables de Swed & Eisenhart

(iii) Le test de Durbin-Watson (d test)

$$d = \frac{\sum_{t=2}^{T=n} (\hat{u}_t - \hat{u}_{t-1})^2}{\sum_{t=1}^{T=n} \hat{u}_t^2}$$

Hypothèses à vérifier pour utiliser la stat. "d"

1. Le modèle de régression contient un intercepte
Sinon, réestimer modèle avec constante ou
utiliser les tables stat. de Faubrother (1980).
2. Les variables explicatives X doivent être non
stochastiques.
3. Les erreurs u_t doivent être générées par processus
 $AR(1)$: $u_t = \rho u_{t-1} + \epsilon_t$
DW pas en mesure de détecter processus
autoregressif dont ordre > 1 .
4. Terme d'erreur suit une distribution normale.
5. Le Modèle de régression ne contient pas de
variable dépendante laguée (parmi var. expl.)
DW ne peut pas être utilisé si on estime
modèle autoregressif du type:
$$Y_t = \beta_1 + \beta_2 X_{2t} + \beta_3 X_{3t} + \dots + \beta_k X_{kt} + \lambda Y_{t-1} + u_t$$
6. Pas de valeurs manquantes parmi les observations.

Distribution d'échantillonnage exacte de la stat. "d" ?

Difficile à dériver car elle dépend de manière
complexe des valeurs prises par les variables expl. X
⇒ pas de valeur critique unique permettant
de rejeter ou de ne pas rejeter H_0 que perturbation
suivent processus AR(1)
⇒ limiter supérieure (d_u) et inférieure (d_l)
dont valeur dépend uniq. du nbre d'observations (n)
et du nbre de variables explicatives (et pas de la
valeur des variables explicatives).

- Valeur de la stat. "d" comprise tel 0 et 4

$$d = \frac{\sum_{t=2}^n (\hat{u}_t - \hat{u}_{t-1})^2}{\sum_{t=1}^n \hat{u}_t^2} \Rightarrow d = \frac{\sum \hat{u}_t^2 + \sum \hat{u}_{t-1}^2 - 2 \sum \hat{u}_t \hat{u}_{t-1}}{\sum_{t=1}^n \hat{u}_t^2}$$

$\sum \hat{u}_t^2$ & $\sum \hat{u}_{t-1}^2$ diffèrent d'une seule observation \Rightarrow
deux sommes sont approx. égales

\Rightarrow

$$d \approx 2 \left[1 - \frac{\sum \hat{u}_t \hat{u}_{t-1}}{\sum \hat{u}_t^2} \right]$$

Comme, on sait que :

$$\hat{\rho} = \frac{\sum \hat{u}_t \hat{u}_{t-1}}{\sum \hat{u}_t^2} \quad (\text{coeff. d'autocorr. d'ordre } 1 \text{ des résidus})$$

$$\Rightarrow d \approx 2(1 - \hat{\rho})$$

Comme, on sait que :

$$-1 \leq \rho \leq 1$$

\Rightarrow

$$0 \leq d \leq 4$$

Lorsque :

$$\hat{\rho} = 0 \Rightarrow d \approx 2 \quad (\text{absence d'autoc.})$$

$$\hat{\rho} = 1 \Rightarrow d \approx 0 \quad (\text{autoc. positive})$$

$$\hat{\rho} = -1 \Rightarrow d \approx 4 \quad (\text{autoc. négative})$$

positive led negatif

$d < d_L \Rightarrow$ négatif hypo. d'absence d'antécédent

$$d_L = 1,44 \text{ et } d_U = 1,54 \quad (\alpha = 0,05)$$

Exemple : $d = 0,1225$, too old, à tout. explicative

e) $d - d_L > d \leq d_U$, négatif Ho d'absence d'antécédent. Neg. d'ordre 1

d) $d - d_U \leq d \leq d_L$, zone d'indétermination (pas de cc.)

c) $d_U \leq d < d - d_L$, on ne négatif pas Ho d'absence d'ant. d'ordre 2


b) $d_L \leq d < d_U$, zone d'indétermination (pas de cc.)

a) $0 \leq d < d_L$, négatif Ho d'absence d'antécédent. positive d'ant. à

Fig. Dubin - Watson d statistic

H₀ : No negative autocorrelation

Legend : H₀ : No positive autocorrelation



4. On applique, règle de décision suivante :
- de calculer esp. incluse dans le modèle.
- On trouve les valeurs critiques d_L et d_U écartant la taille de l'échantillon et le niveau de signification alpha.
- On trouve les valeurs critiques d_L et d_U écartant le modèle pour H₀ et on décide les termes
- On calcule la statistique "d".
- On calcule la méthode pour H₀ et on décide les termes

En pratique :

- Principal "inconvénient du test de DW : Il y a une zone d'indétermination.

→ propositions pour contourner ce problème : idée générale = dans de nombreux cas, d_U = valeur critique.

→ lorsque d comprise de zone d'indétermination, suivre règle de décision suivante :

- 1) si $H_0 : \rho = 0$ vs. $H_1 : \rho > 0 \Rightarrow R_{H_0}(\alpha)$ si $d < d_U$
- 2) si $H_0 : \rho = 0$ vs. $H_1 : \rho < 0 \Rightarrow R_{H_0}(\alpha)$ si $(4-d) < d_L$
- 3) si $H_0 : \rho = 0$ vs. $H_1 : \rho \neq 0 \Rightarrow R_{H_0}(2\alpha)$ si $\begin{cases} d < d_U \\ \text{ou} \\ (4-d) < d_L \end{cases}$

- Quid si on utilise test de DW pour modèle autorégressif (variable dpte laguée parmi var. explic.) ?

d sera généralement proche de 2 pour présence d'autocorrélation d'ordre 1. Solution : „h test“ de DW mais moins puissant que test de Breusch - Godfrey → mieux vaut utiliser BG.

- Quid si terme d'erreur ne suit pas dist. normale ?

Si échantillon petit \Rightarrow stat d ne peut pas être utilisée.

Si échantillon gd \Rightarrow stat d peut être utilisée
Pq?

$$\sqrt{n} (1 - \frac{1}{2} d) \underset{\text{asy}}{\approx} N(0, 1)$$

Exemple : $d = 0,1229$, $n = 40$

$$\sqrt{n} (1 - \frac{1}{2} d) = \sqrt{40} \left(1 - \frac{0,1229}{2}\right) = 5,94$$

Val. crit. statistique : ζ at 1% = 1,96 et 2,58

R_{H_0}
d'absence
d'autocor

- Quid si variables explicatives stochastiques ?

Test de DW n'est pas valable \hat{m} lorsque l'échantillon est grand.

Avec séries chronologiques où l'une des variables explicatives est la variable dpdt laguée \rightarrow 1 régresseur stochastique, DW non utilisable !

(iv) Le test de Breusch - Godfrey

Aussi appelé LM-test (basé sur le principe du multiplicateur de Lagrange)

Test "général" d'autocorrélation car permet :

- * que les régresseurs soient stochastiques.
 - * de tester pour structures autoregressives d'ordre supérieur à 1.
 - * de vérifier si terme d'erreur peut être représenté comme une moyenne mobile d'un bruit blanc ϵ_t
- ↳ Exemple : $y_t = \beta_1 + \beta_2 x_t + u_t$

$$? \quad \text{où } u_t = \epsilon_t + \lambda_1 \epsilon_{t-1} + \lambda_2 \epsilon_{t-2}$$

(terme d'erreur u_t = moyenne mobile d'ordre 3 du bruit blanc ϵ_t)

Fonctionnement du test de Breusch-Godfrey ?

Exemple : $Y_t = \beta_1 + \beta_2 X_t + u_t$

où $u_t = \rho_1 u_{t-1} + \rho_2 u_{t-2} + \dots + \rho_p u_{t-p} + \varepsilon_t$

(processus AR(p))

$$H_0 : \rho_1 = \rho_2 = \dots = \rho_p = 0$$

1) On estime le modèle de régression : $Y_t = \beta_1 + \beta_2 X_t + u_t$
et on obtient les résidus \hat{u}_t .

2) On régresse \hat{u}_t sur la/les variables explicatives X_t
et sur les valeurs laguées des résidus obtenus
en 1ère étape (càd. $\hat{u}_{t-1}, \hat{u}_{t-2}, \dots, \hat{u}_{t-p}$).
Si $p = 4$ ($\rightarrow n-4$ observations) :

$$\begin{aligned}\hat{u}_t = \alpha_1 + \alpha_2 X_t + \rho_1 \hat{u}_{t-1} + \rho_2 \hat{u}_{t-2} + \rho_3 \hat{u}_{t-3} \\ + \rho_4 \hat{u}_{t-4} + \varepsilon_t\end{aligned}$$

On calcule le R^2 de cette régression auxiliaire.

(on inclut X_t du rég. aux. pour tenir compte du
fait qu'elle n'est p-è pas strictement non stochast.)

3) BG ont montré que lorsque la taille de
l'échantillon est grande :

$$(n-p) R^2 \underset{\text{asy}}{\sim} \chi_p^2 \quad (\text{asympt. } (n-p).R^2 \text{ suit loi de } \chi^2 \text{ à } p \text{ df})$$

Règle de décision :

si $(n-p) R^2$ excède valeur critique de la
chi-caré $\Rightarrow R_{H_0}$ (au moins un des
paramètres " ρ_{hi} " est signif. \neq de zéro).

Remarques :

- 1) Si on teste présence processus AR(1), test de BG est appelé le test "m" de Durbin.
- 2) Test de BG ne spécifie pas la valeur de ϕ .
Dans certains cas, on peut utiliser critères d'information d'Akaike et Schwartz.

2.3.7. Remèdes à l'autocorrélation

4 options :

- 1) Déterminer si le problème d'autocorrélation est "pure", càd. s'il ne découle pas d'un biais de spécification (modèle mal spécifié, variables imp. omises, forme fonctionnelle pas adaptée, ...)
- 2) Si autocorrélation pure, on peut essayer de transformer modèle initial pour faire disparaître le pbme \rightarrow MCG (méthode de Moindres Carrés Généralisés).
- 3) Si échantillon est grand, 6 option = utiliser méthode de Newey - West (fournit des se corrigés utiles pour autocorrélation).
- 4) Dans certains cas, on peut continuer à utiliser MCO.

2.3.3. Mauvaise spécification versus autocorrélation „pure“

Exemple : Relation tel salaires & productivité

$$d = 0,1229$$

→ suggère autocorrélation positive
→ modèle mal spécifié ?

2 séries chronologiques → possible qu'elles aient une tendance commune → inclure trend du modèle pour analyser relation tel salaires & productivité nette de la tendance commune.

$$\hat{Y}_t = 1,4752 + 1,3057 X_t - 0,9032 t$$

$\text{se} = (13,18)$	$(0,2765)$	$(0,4203)$
$t = (0,1119)$	$(4,7230)$	$(-2,1490)$

$$R^2 = 0,9631 \quad d = 0,2046$$

d reste faible, suggère autocorrélation „pure“.

Relation tel salaires & productivité quadratique ?

$$\hat{Y}_t = -16,2181 + 1,9488 X_t - 0,0079 X_t^2$$

$t = (-5,4891)$	$(24,9868)$	$(-15,9363)$
-----------------	-------------	--------------

$$R^2 = 0,9947 \quad d = 1,02$$

$$d_L = 1,3191, d_U = 1,60 \Rightarrow \text{cd : RHo d'absence d'autocorrelat° positif}$$

Rem.: pour tester normalité utiliser p.ex. test de JB.

2.3.3. Corriger pour l'autocorrélation (pure) : la méthode des momodes corrigés généralisés (MCG)

Mauvaise efficacité des estimateurs des RCO en présence d'autocorrélation \rightarrow remède dépend de notre connaissance qt à la nature de l'interdépendance tel les erreurs.

$$Y_t = \beta_1 + \beta_2 X_t + u_t \quad (1)$$

$$\text{où } u_t = \rho u_{t-1} + \epsilon_t \quad (2)$$

$$(-1 < \rho < 1)$$

Deux possibilités :

(i) Valeur de ρ est connue

(ii) Valeur de ρ est inconnue (mais elle peut être estimée)

(i) Lorsque valeur de ρ est connue

Si ρ est connue équation d'autocorrélation facilement résolue.

Si éq. (1) valable en t , elle l'est également

$$\text{en } (t-1) \Rightarrow Y_{t-1} = \beta_1 + \beta_2 X_{t-1} + u_{t-1} \quad (3)$$

$$\Rightarrow \rho Y_{t-1} = \rho \beta_1 + \rho \beta_2 X_{t-1} + \rho u_{t-1} \quad (4)$$

(1) - (4) :

$$(Y_t - \rho Y_{t-1}) = \beta_1 (1-\rho) + \beta_2 (X_t - \rho X_{t-1}) + \epsilon_t$$

$$\text{où } \epsilon_t = u_t - \rho u_{t-1}$$

$$\Rightarrow Y_t^* = \beta_1^* + \beta_2^* X_t^* + \varepsilon_t$$

où

$$\begin{cases} \beta_1^* = \beta_1 (1 - \rho) \\ Y_t^* = (Y_t - \rho Y_{t-1}) \\ X_t^* = (X_t - \rho X_{t-1}) \\ \beta_2^* = \beta_2 \\ \varepsilon_t = u_t - \rho u_{t-1} \end{cases}$$

Comme ε_t satisfait aux hyp. habituelles des MCO, on peut appliquer MCO aux données transformées Y^* et X^*
 \Rightarrow estimateurs BLUE.

Rappel : MC6 = appliquer MCO aux données modifiées qui satisfont hyp. classiques.

Lorsque ρ est connue \rightarrow appliquer MC6 : on soustrait de chaque variable une proportion ρ de sa valeur à la période précédente et on estime le $\hat{\pi}$ par MCO.

On appelle cette régression l'équation en différence généralisée („generalized difference equation").

Opération engendre perte de la première obs.

Pour éviter cela, on transforme première obs de Y et X comme suit :

$$Y_1^* = Y_1 \sqrt{1 - \rho^2}$$

$$X_1^* = X_1 \sqrt{1 - \rho^2}$$

\Rightarrow transformation de Prais-Winsten.

(ii) Lorsque valeur de ρ est inconnue

En pratique, ρ rarement connue \rightarrow MCG difficile à utiliser \rightarrow trouver méthode pour estimer valeur de ρ .

• Méthode en différence première

Soit $\rho = +1$: éq en \neq généralisée \equiv éq. en \neq réc

$$\Rightarrow Y_t - Y_{t-1} = \beta_1 (X_t - X_{t-1}) + (u_t - u_{t-1})$$

$$\Rightarrow \Delta Y_t = \beta_1 \Delta X_t + \varepsilon_t \quad (\text{où } \varepsilon_t \text{ white noise})$$

Qd utiliser cette méthode ?

Lorsque ρ est très élevé (p.ex. $> 0,8$) ou d" très faib

Lorsque $d < R^2$ (cf. Maddala)

Exemple: $d (= 0,1229) < R^2 (= 0,9584)$

$$\widehat{\Delta Y_t} = 0,7199 \Delta X_t$$

$$t = (9,2073)$$

$$R^2 = 0,3610$$

$$d = 1,5096 \quad \rightarrow \text{autocorrelat° ne pose plus problème}$$

$$\hat{Y}_t = 29,5191 + 0,7136 X_t$$

$$se = (1,9423) \quad (0,0241)$$

$$t = (15,1977) \quad (29,6066)$$

$$R^2 = 0,9584$$

$$d = 0,1229, \quad \hat{\sigma} = 2,6755$$

Autre avantage : (dans certains cas) transf. en \neq 1ère permet de rendre des séries chronologiques stationnaires.

Si terme d'erreur suit processus AR(1) : $u_t = \rho u_{t-1} + \epsilon_t$,
on a que :

$$\text{Var}(u_t) = E(u_t^2) = \frac{\sigma_\epsilon^2}{1-\rho^2}$$

$$\text{cov}(u_t, u_{t+s}) = E(u_t u_{t+s}) = \rho^s \cdot \frac{\sigma_\epsilon^2}{1-\rho^2}$$

Si $\rho = 1$, $\text{var}(u_t)$ et $\text{cov}(u_t, u_{t+s})$ sont infinies
 $\Rightarrow u_t$ est non stationnaire.

$$\begin{aligned} \text{Si } \rho = 1 &\Rightarrow u_t = u_{t-1} + \epsilon_t \\ &\Rightarrow u_t - u_{t-1} = \Delta u_t = \epsilon_t \end{aligned}$$

Δu_t est stationnaire

Test de Breuchblutt - Webb ($H_0: \rho = 1$)

$$g = \frac{\sum_{t=2}^m \hat{\epsilon}_t^2}{\sum_{t=1}^m \hat{u}_t^2}$$

où \hat{u}_t : résidus des RCO de la régression en niveau.

$\hat{\epsilon}_t$: résidus des RCO de la régression en 1ère.

$d \approx 2(1-\hat{\rho}) \rightarrow$ sous $H_0: \rho = 1$, on s'attend

à ce que d soit proche de zéro.

Exemple : $\sum_{t=1}^m \hat{u}_t^2 = 272,022$ et $\sum_{t=2}^m \hat{\epsilon}_t^2 = 0,33427$

$$\Rightarrow g = \frac{0,33427}{272,022} = 0,0012$$

Pour 39 obsv. et 1 var. expl. : $d_L = 1,435$ et $d_U = 1,540$ à 5%

$\hat{\rho}$ calculée < d_L \Rightarrow on ne rejette pas $H_0 : \rho = 1$.

\Rightarrow résultats régression en \neq 1ère paraisent acceptables.

- Valeur de ρ basée sur „d“ de Durbin-Watson

$$d \approx 2(1 - \hat{\rho}) \Rightarrow \hat{\rho} \approx 1 - \frac{d}{2} \quad (1)$$

Si gd échantillon, utiliser valeur de d pour estimer ρ , transformer nos données conformément à l'éq. en diff. généralisée (à p. de $\hat{\rho}$).

Si petit échantillon, utiliser relation (modifiée) de Theil & Nagar (cf. Gujarati)

Exemple: $d = 0,1229 \Rightarrow \hat{\rho} \approx 0,9386$

$$(Y_t - \hat{\rho} Y_{t-1}) = \beta_1 (1 - \hat{\rho}) + \beta_2 (X_t - \hat{\rho} X_{t-1}) + \epsilon_t$$

- Valeur de ρ estimée à partir des résidus

si terme d'erreur u_t suit processus AR(1): $u_t = \rho u_{t-1} + \epsilon_t$

\Rightarrow estimer ρ en régressant \hat{u}_t sur \hat{u}_{t-1}

car \hat{u}_t \equiv estimateur consistant du terme d'erreur u_t

\Rightarrow estimer: $\hat{u}_t = \hat{\rho} \hat{u}_{t-1} + v_t$

(où \hat{u}_t sont les résidus de la régression en niveau)

Rem.: pas d'intercepte

Exemple: $\hat{u}_t = 0,9142 \hat{u}_{t-1}$

$$t = (16,2281) \quad R^2 = 0,8736$$

$\Rightarrow \hat{\rho} = 0,9142 \dots$ à utiliser pour transformer les variables & estimer l'éq. en \neq généralisée.

- Méthodes itératives pour estimer ρ

Exemples : méthode itérative de Cochrane - Orcutt

méthode en 2 étapes de Durbin

méthode de scanning de Hilbreth - Lu

Remarques :

- 1) Estimateur RCO tout consistants (indpd de l'hyp d'autocorrelat°). Pour gts échantillons, qlq soit méthode d'estimation de ρ (d de DW, résidu n rendu $_{t-1}$, Cochrane - Orcutt), on obtiendra estimation consistante de la vraie valeur de ρ .
- 2) Méthodes d'estimation en 2 étapes. Comme on utilise $\hat{\rho}$ plutôt que $\rho \rightarrow$ moindres carrés généralisés "estimés" (estimated GLS ou EGLS ; feasible GLS ou FGLS)
- 3) Pour de petits échantillons EGLS fournit estimateurs qui ne sont pas nécess. BLUE.
- 4) Pour de petits échantillons, important d'inclure la 1ère observation à la Pras - Winsten.
→ MCG estimés avec inclusion de la première observation à la Pras - Winsten
≡ Full estimated generalized least squares, FEGLS ou full GLS.

2.3.10. Correction des erreurs standard des RCO
par la méthode de Newey - West

Procédure de Newey - West fournit des erreurs standard qui sont HAC ('heteroscedasticity and autocorrelation consistent').

= méthode asymptotique

(si gd échantillon pas lieu d'utiliser RCG estimés).

Exemple :

$$\hat{Y}_t = 29,5192 + 0,7136 X_t$$

$$se = (4,1180) \quad (0,0512)$$

$$R^2 = 0,9584 \quad d = 0,1229$$

Procédure de Newey - West

$$\hat{Y}_t = 29,5192 + 0,7136 X_t$$

$$se = (1,9423) \quad (0,0241)$$

$$t = (15,1977) \quad (29,6066)$$

$$R^2 = 0,9584$$

$$d = 0,1229 \quad \hat{\sigma} = 2,675$$

Sans correction pour
autocorr. / hétérosc.

⇒ Méthode des RCO habituelle (sans correction)
sous-estime la vraie valeur des erreurs standard.

! stat. „d“ est la \bar{m} de les 2 car mais la procédure de Newey - West les erreurs standard ont été corrigées pour autocorrelation & hétéroscedasticité.

- En présence d'autocorrélation, estimateurs des MCO sont non biaisés, constants et asympt. normaux. Mais, ils ne sont pas efficaces \rightarrow inférence basée sur t, F et χ^2 n'est pas appropriée.
- MC6 estimés et procédure de Newey - West fournissent estimateurs asympt. efficaces.
Mais propriétés stat. de ces estimateurs mal connues pour petits échantillons \rightarrow si échantillon petit, procédure de Newey - West ou MC6 estimés peuvent être moins appropriés que MCO.

Griliches et Rao (1969) ont montré (à l'aide de simulations Monte Carlo) que lorsque l'éch. est relativement petit et que $p < 0,3$, la méthode MCO aussi bonne voire meilleure que celle des MC6 estimés.

2.3.11. Modèles ARCH et GARCH

Si caré des erreurs au temps t est corrélé au caré des erreurs au temps $(t-1)$: „ autoregressive conditional heteroscedasticity " \equiv ARCH

Si caré des erreurs est corrélé au caré des erreurs à t écus périodes d'intervalle : „ generalized autoregressive conditional heteroscedasticity " \equiv GARCH
 \Rightarrow autocorrélat° pas confinée à la relati° (el erreurs présentes et passées, elle peut aussi concerner la variance présente et passée des erreurs).

2.4. Modélisation économétrique : spécification du modèle et tests de diagnostic

Questions :

- 1) Quels sont les critères pour choisir la spécification d'un modèle ?
- 2) Quels types d'erreurs de spécification rencontre-t-on en pratique ?
- 3) Quelles sont les conséquences des erreurs de spécificat° ?
- 4) Comment détecte-t-on les erreurs de spécificat° ?
- 5) Quels sont les remèdes et bénéfices ?
- 6) Comment évalue-t-on les performances relatives de modèles concurrents ?

2.4.1. Critères de sélection d'un modèle

Critères qu'un bon modèle devrait satisfaire (d'après Hendry et Richard) :

- * Il faut que les données soient admissibles
- * Il faut que le modèle soit compatible avec la théorie.
- * Il faut que les régresseurs soient (au moins) faiblement exogènes. Au mieux non stochastiques.
- * La valeur des paramètres doit être stable dans le temps.
- * Il faut que les données soient cohérentes.

2.4.2. Type d'erreurs de spécification

$$Y_i = \beta_1 + \beta_2 X_i + \beta_3 X_i^2 + \beta_4 X_i^3 + u_{xi} \quad (1)$$

où Y = coût total de production
 X = output

$$\bullet \quad Y_i = \alpha_1 + \alpha_2 X_i + \alpha_3 X_i^2 + u_{xi} \quad (2)$$

Si on estime (2) et que (1) est le bon modèle,
 erreur de spécification = omettre variable explicative
 d'intérêt (X_i^3).

$$\Rightarrow u_{xi} = u_{xi} + \beta_4 X_i^3$$

$$\bullet \quad Y_i = \lambda_1 + \lambda_2 X_i + \lambda_3 X_i^2 + \lambda_4 X_i^3 + \lambda_5 X_i^4 + u_{xi} \quad (3)$$

Si on estime (3) et que (1) est correct, erreur de spécification = inclure une variable explicative non nécessaire (superflue) car λ_5 ds (1) est nul.

$$\Rightarrow u_{xi} = u_{xi} - \lambda_5 X_i^4 \\ = u_{xi} \quad (\text{car } \lambda_5 = 0)$$

$$\bullet \quad \ln Y_i = \gamma_1 + \gamma_2 X_i + \gamma_3 X_i^2 + \gamma_4 X_i^3 + u_{xi} \quad (4)$$

Erreur de spécification = utilisation d'une forme fonctionnelle inadéquate.

$$\bullet \quad Y_i^* = \beta_1^* + \beta_2^* X_i^* + \beta_3^* X_i^{*2} + \beta_4^* X_i^{*3} + u_i^* \quad (5)$$

où $Y_i^* = Y_i + \varepsilon_i$

$X_i^* = X_i + \omega_i$

et ε_i, ω_i sont des erreurs de mesure.

Erreurs de mesure : plutôt que d'utiliser les vraies variables, on utilise les proxy Y_i^* et X_i^* (mesurées avec erreurs).

- Finalité, erreur de spécification concernant modélisation du terme d'erreur.

Exemple:
$$Y_i = \beta X_i u_i \quad (7)$$

où (u_i) satisfait hyp. classiques.

Plutôt que d'estimer (7), on estime (8) :

$$Y_i = \alpha X_i + u_i \quad (8)$$

Si (7) est bon modèle, $\hat{\alpha}$ est estimateur biaisé de $\beta \Rightarrow E(\hat{\alpha}) \neq \beta$

En résumé:

- Omettre variable importante.
- Inclure variable superflue.
- Choisir forme fonctionnelle maladaptée.
- Utiliser des variables mesurées avec erreur.
- Ne pas spécifier correctement le terme d'erreur stochastique.

2.4.3. Consequences des erreurs de spécification

(i) Omission d'une variable d'intérêt

$$Y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + u_i \quad (\text{vrai modèle})$$

$$Y_i = \alpha_1 + \alpha_2 X_{2i} + v_i \quad (\text{modèle estimé})$$

Consequences de l'omission de X_3 :

1. Si les variables X_2 et X_3 sont corrélées, $\hat{\alpha}_1$ et $\hat{\alpha}_2$ sont des estimateurs biaisés et inconsistants $\rightarrow E(\hat{\alpha}_1) \neq \beta_1, E(\hat{\alpha}_2) \neq \beta_2$

$$\underset{n \rightarrow \infty}{\text{plim}} \hat{\alpha}_2 \neq \beta_2, \underset{n \rightarrow \infty}{\text{plim}} \hat{\alpha}_2 \neq \beta_2$$

Biais persiste asymptotiquement.

2. Si les variables X_2 et X_3 sont non corrélées, $\hat{\alpha}_2$ est non biaisé mais $\hat{\alpha}_1$ est biaisé.
3. La variance homoscedastique du terme d'erreur n'est pas estimée correctement.
4. La mesure habituelle de la variance de l'estimateur $\hat{\alpha}_2$ ($= \sigma^2 / \sum x_{2i}^2$) est un estimateur biaisé de la variance du vrai estimateur β_2 .
5. Dès lors, intervalles de confiance et tests d'hyp. habituels sont susceptibles de conduire à des ccl. erronées.
6. Prévisions à partir du modèle et intervalles de confiance des prévisions ne sont pas corrects.

Intuition :

* On peut montrer que : $E(\hat{\alpha}_2) = \beta_2 + \beta_3 b_{23}$ (1)

où b_{23} = coefficient de pente dans la régression de la variable X_3 sur la variable $X_2 \rightarrow$

$$b_{23} = \frac{\sum x_{3i}x_{2i}}{\sum x_{2i}^2}$$

$E(\hat{\alpha}_2) \neq \beta_2$ sauf si β_3 et/ou $b_{23} = 0$

Par hyp., on sait que $\beta_3 \neq 0$ (sinon pas de biais de spé.)
 $b_{23} = 0$, si X_2 et X_3 non corrélées (hyp. rarement satisfaites avec séries éco.)

\Rightarrow ampleur du biais dépend du produit de β_3 et b_{23}

si β_3 et $b_{23} > 0 \Rightarrow$ en moyenne $\hat{\alpha}_2$ supérieure à β_2

* Nous savons que :

$$\text{var}(\hat{\alpha}_2) = \sigma^2 / \sum x_{2i}^2$$

$$\text{var}(\hat{\beta}_2) = \frac{\sigma^2}{\sum x_{2i}^2 (1 - r_{23}^2)} = \frac{\sigma^2}{\sum x_{2i}^2} \text{ VIF}$$

Comme $\text{var}(\hat{\beta}_2)$ est non biaisée, $\text{var}(\hat{\alpha}_2)$ est généralement biaisée: $0 < r_{23}^2 < 1 \Rightarrow \text{var}(\hat{\alpha}_2) < \text{var}(\hat{\beta}_2)$

Rem: $r_{23} \neq 0$ car variables éco. très corrélées.
 $r_{23} \neq 1$ car par hyp. pas de colinéarité pft.

\Rightarrow dilemme: $\hat{\alpha}_2$ est biaisé mais variance + faible que l'estimateur non biaisé $\hat{\beta}_2$.

Estimation de τ^2 sera \neq relou qu'on estime 1er ou 2nd modèle.

$$\hat{\tau}^2 = SCR / df$$

où SCR = somme des carrés résiduelle

df = degrees of freedom

Si nbre de variables explicatives $P \Rightarrow \begin{cases} SCR \downarrow \text{généralement} \\ df \downarrow \end{cases}$

Si on ajoute variable supplément. au pouvoir explicatif imp. \Rightarrow baisse de SCR sera + imp. que baisse du nbre de degrés de liberté \Rightarrow inclusion variable expl. supplément. \downarrow le biais et variance de l'estimateur.

Si variable incluse a un impact limité sur variable étudiée et que var. expl. sont fortement corrélées (VIF est gd), ajout de cette var. réduira biais de l'estimateur mais variance $\uparrow \Rightarrow$ trade off tel précision & précision de l'estimateur. Solution ?

Par exemple, choisir estimateur dont erreur moyenne au carré (mean squared error = MSE) est la + faible.

Rappel :

$$\begin{aligned} MSE(\hat{\theta}) &= E(\hat{\theta} - \theta)^2 \\ &= E[\hat{\theta} - E(\hat{\theta}) + E(\hat{\theta}) - \theta]^2 \\ &= E[\hat{\theta} - E(\hat{\theta})]^2 + E[E(\hat{\theta}) - \theta]^2 \\ &\quad + \cancel{2E[(\hat{\theta} - E(\hat{\theta}))[E(\hat{\theta}) - \theta]]} = 0 \\ &= E[\hat{\theta} - E(\hat{\theta})]^2 + E[E(\hat{\theta}) - \theta]^2 \\ &= \text{var}(\hat{\theta}) + \text{bias}(\hat{\theta})^2 = \text{variance de } \hat{\theta} \text{ plus} \end{aligned}$$


Remarque :

$$Pq \quad 2E[(\hat{\theta} - E(\hat{\theta})) [E(\hat{\theta}) - \theta]] = 0 ?$$

$$\Rightarrow 2 \left[[E(\hat{\theta})]^2 - [E(\hat{\theta})]^2 - \theta E(\hat{\theta}) + \theta E(\hat{\theta}) \right] = 0$$

$$E[E(\hat{\theta}) - \theta]^2 = [E(\hat{\theta}) - \theta]^2 \quad (\text{car espérance d'une constante} = \text{constante})$$

Graphiquement :



* Supposons que X_2 et X_3 non corrélées $\Rightarrow r_{23} = 0 \Rightarrow b_{23} = 1$

$$E(\hat{x}_2) = \beta_2 + \beta_3 b_{23} \quad \Rightarrow \quad E(\hat{\alpha}_2) = \beta_2$$

Estimateur $\hat{\alpha}_2$ est non biaisé.

On sait que :

$$\text{var}(\hat{\alpha}_2) = \sigma^2 / \sum x_{2i}^2$$

$$\text{var}(\hat{\beta}_2) = \frac{\sigma^2}{\sum x_{2i}^2 (1 - r_{23}^2)} = \frac{\sigma^2}{\sum x_{2i}^2} \text{ VIF}$$

\Rightarrow variance de $\hat{\alpha}_2$ et $\hat{\beta}_2$ semble raisonnable.

En réalité, $\text{var}(\hat{\alpha}_2)$ biaisée car estimation de σ^2 n'est pas la $\hat{\sigma}^2$ lorsqu'on oublie une val.

* Quid de $\hat{\alpha}_1$ lorsque $r_{23} = 0$?

$\hat{\alpha}_1$ est biaisé.

Pq?

$$\hat{\beta}_1 = \bar{Y} - \hat{\beta}_2 \bar{X}_2 - \hat{\beta}_3 \bar{X}_3$$

$$\hat{\alpha}_1 = \bar{Y} - \hat{\beta}_2 \bar{X}_2$$

(ii) Inclusion d'une variable superflue

$$Y_i = \beta_1 + \beta_2 X_{2i} + u_i \quad (\text{= bon modèle})$$

$$Y_i = \alpha_1 + \alpha_2 X_{2i} + \alpha_3 X_{3i} + v_i \quad (\text{= modèle estimé})$$

Consequences de l'inclusion d'une variable superflue:

1. Estimateurs des MCO des paramètres du "mauvais" modèle sont non biaisés et consistants \rightarrow

$$E(\hat{\alpha}_1) = \beta_1, \quad E(\hat{\alpha}_2) = \beta_2, \quad E(\hat{\alpha}_3) = \beta_3 = 0$$

$$\operatorname{plim}_{n \rightarrow \infty} \hat{\alpha}_1 = \beta_1, \quad \operatorname{plim}_{n \rightarrow \infty} \hat{\alpha}_2 = \beta_2$$

2. Variance du terme d'erreur σ^2 correctement estimée.

3. Intervalles de confiance et tests d'hypothèse habituels restent valables.

4. Cependant, estimateurs $\hat{\alpha}$ généralement inefficients
(variance des $\hat{\alpha}$ généralement + gd que celle des $\hat{\beta}$)

$$\text{Pq? } \left. \begin{aligned} \operatorname{Var}(\hat{\beta}_2) &= \frac{\sigma^2}{\sum x_{2i}^2} \\ \operatorname{Var}(\hat{\alpha}_2) &= \frac{\sigma^2}{\sum x_{2i}^2 (1 - r_{23}^2)} \end{aligned} \right\} \Rightarrow \frac{\operatorname{Var}(\hat{\alpha}_2)}{\operatorname{Var}(\hat{\beta}_2)} = \frac{1}{1 - r_{23}^2}$$

$$\text{Comme } 0 \leq r_{23}^2 \leq 1 \Rightarrow \operatorname{Var}(\hat{\alpha}_2) \geq \operatorname{Var}(\hat{\beta}_2)$$

2.4.4. Les tests d'erreur de spécification

(i) Détection la présence de variables superflues

$$Y_i = \beta_1 + \beta_2 X_{2i} + \dots + \beta_k X_{ki} + u_i$$

Faut-il inclure X_k ? Test en "t" habituel \rightarrow si
 $t = \hat{\beta}_k / se(\hat{\beta}_k)$ significative, on garde X_k

Faut-il inclure X_2, X_3 et X_4 ? F test habituel \rightarrow
 $H_0: \beta_2 = \beta_3 = \beta_4 = 0$

Il est déconseillé de construire un modèle de façon "itérative" \rightarrow "data mining", "regression fishing", "data cruching", ...

(ii) Test pour des variables omises ou une forme fonctionnelle inadaptee

Examiner les résidus

$$Y_i = \beta_1 + \beta_2 X_i + \beta_3 X_i^2 + \beta_4 X_i^3 + u_i \quad (\text{vrai modèle})$$

où $\begin{cases} Y = \text{coût total de production} \\ X = \text{niveau de production} \end{cases}$

$$Y_i = \alpha_1 + \alpha_2 X_i + \alpha_3 X_i^2 + u_{2i} \quad (\text{modèle alternatif (a)})$$

$$Y_i = \lambda_1 + \lambda_2 X_i + u_{3i} \quad (\text{modèle alternatif (b)})$$




FIGURE 13.1 Residuals \hat{u}_t from (a) linear, (b) quadratic, and (c) cubic total cost functions.

La statistique d de Durbin-Watson

TABLE 13.1 ESTIMATED RESIDUALS FROM THE LINEAR, QUADRATIC, AND CUBIC TOTAL COST FUNCTIONS

Observation number	\hat{u}_t linear model*	\hat{u}_t quadratic model†	\hat{u}_t cubic model‡
1	6.600	-23.900	-0.222
2	9.667	9.500	1.607
3	13.733	18.817	-0.915
4	-2.200	13.050	-4.426
5	-9.133	11.200	4.435
6	-26.067	-5.733	1.032
7	-32.000	-16.750	0.726
8	-26.933	-23.850	-4.119
9	4.133	-6.033	1.859
10	54.200	23.700	0.022

$$\cdot \hat{Y}_t = 166.457 + 19.933X_t \quad R^2 = 0.8409 \\ (19.021) \quad (3.068) \quad \hat{R}^2 = 0.8210 \\ (8.752) \quad (6.502) \quad d = 0.715$$

$$† \hat{Y}_t = 222.383 - 8.0250X_t + 2.542X_t^2 \quad R^2 = 0.9234 \\ (23.488) \quad (9.809) \quad (0.869) \quad \hat{R}^2 = 0.9079 \\ (9.468) \quad (-0.818) \quad (2.925) \quad d = 1.038$$

$$‡ \hat{Y}_t = 141.767 + 63.479X_t - 12.952X_t^2 + 0.938X_t^3 \quad R^2 = 0.9983 \\ (6.375) \quad (4.778) \quad (0.9958) \quad (0.0592) \quad \hat{R}^2 = 0.9975 \\ (22.238) \quad (13.285) \quad (-13.151) \quad (15.881) \quad d = 2.70$$

pour $n=10$, $k=1$, $\alpha=0.05$
 $d_L = 0,879$; $d_U = 1,320$
 $d_L = 0,697$; $d_U = 1,641$
 $d_L = 0,525$; $d_U = 1,016$

Corrélation positive dans les résidus des 2 premières spécifications ne découle pas d'un phénomène d'autocorrélation „pure“ mais bien d'une biais de spécification.

Si on exclut X_i^3 de la fonction de coût $\Rightarrow u_{2i} = (u_{1i} + \beta_3 X_i^3)$

Test de Durbin-Watson en pratique :

1. On estime le modèle de régression et on obtient les résidus des RCO.
2. Imaginons qu'on veuille test si modèle mal spécifié en raison de l'exclusion de la variable Z .
Dans ce cas, on ordonne résidus (obtenus en 1ère étape) de manière croissante // à Z .
3. Calcule statistique d à partir des résidus ordonnés
$$d = \frac{\sum_{t=2}^n (\hat{u}_t - \hat{u}_{t-1})^2}{\sum_{t=1}^n \hat{u}_t^2}$$
- (peut être utilisé pour time series & cross-section).
4. Règle de décision: si statistique d est significative, on rejette hypothèse nulle que modèle est correctement spécifié. Remède (si d signif.): inclure variable Z !

Exemple: la variable $Z (=X)$, le coût de production, était ordonnée de façon croissante \rightarrow il en va de même pour X^2 et $X^3 \rightarrow$ stat. d suggèrent la présence d'une erreur de spécif. du modèle linéaire & quadratique \rightarrow estimer modèle cubique.

Le test de Ramsey (RESET)

RESET = regression specification error

Intuition :

$$Y_i = \lambda_1 + \lambda_2 X_i + u_{3i}$$

où $\begin{cases} Y = \text{coût total} \\ X = \text{niveau de production} \end{cases}$




Fig. Residuals \hat{u}_i and estimated \hat{Y} from the linear cost function : $Y_i = \lambda_1 + \lambda_2 X_i + u_i$

Résidus présentent une structure systématique et leur moyenne dépend de la valeur de $\hat{Y}_i \Rightarrow$ introduction de \hat{Y}_i (sous une forme particulière) devrait pouvoir $\uparrow R^2$.

Règle de décision : si \uparrow du R^2 est statist. significative au base d'un F-test, on rejette l'hyp. que l'fct^o de coût linéaire est une bonne spécification.

En pratique :

1. On estime modèle, p.ex. $Y_i = \alpha_1 + \alpha_2 X_i + u_{3i}$ (1)
et on obtient estimations des observations Y_i (\hat{Y}_i)
2. On réestime modèle en incluant \hat{Y}_i sous forme additive.
3. Comme on observe relation curviligne entre u_i et \hat{Y}_i (cf. Fig. slide 2.88.) , on pourrait décider d'inclure \hat{Y}_i au carré et au cube:

$$Y_i = \beta_1 + \beta_2 X_i + \beta_3 \hat{Y}_i^2 + \beta_4 \hat{Y}_i^3 + u_i \quad (2)$$

4. R^2_{new} = coeff. dét. modèle (2)
 R^2_{old} = coeff. dét. modèle (1)

$$F = \frac{(R^2_{\text{new}} - R^2_{\text{old}}) / \text{nb of new regressors}}{(1 - R^2_{\text{new}}) / (\text{n} - \text{nb of parameters in old model})}$$

5. Si statistique F est significative, on rejette hypothèse que modèle (1) est correctement spécifié.

Exemple :

$$\hat{Y}_i = 166,467 + 19,933 X_i$$

$$se = (19,021) \quad (3,066)$$

$$R^2 = 0,8409$$

$$\hat{Y}_i = 2140,7223 + 476,6557 X_i - 0,09187 \hat{Y}_i^2 + 0,000119 \hat{Y}_i^3$$

$$se = (132,0044) \quad (33,3951) \quad (0,0062) \quad (0,000074)$$

$$R^2 = 0,9983$$

$$F = \frac{(0,9983 - 0,8409) / 2}{(1 - 0,9983) / (10 - 4)} = 284,4035 \quad (\text{fort sign.})$$

\Rightarrow modèle (1) mal spécifié.

Avantage et inconvénient du test RESET :

ne requiert pas de spécification alternative ...
si modèle s'avère mal spécifié ou ne sait pas quelle alternative choisir.

Le test du multiplicateur de Lagrange (LM test)

Fonction de coût linéaire = version restreinte de la fonction de coût cubique. (suppose que coeff. relatif à X_i^2 et X_i^3 sont égaux à zéro).

⇒ LM test :

1. Estimation du modèle restreint : $\hat{Y}_i = \lambda_1 + \lambda_2 X_i + u_i$

→ on obtient résidus des RCO (\hat{u}_i)

2. Si modèle non restreint : $\hat{Y}_i = \beta_1 + \beta_2 X_i + \beta_3 X_i^2 + \beta_4 X_i^3 + u_i$
est correct, résidus du modèle restreint devraient dépendre de X_i^2 et X_i^3 .

3. $\hat{u}_i = \alpha_1 + \alpha_2 X_i + \alpha_3 X_i^2 + \alpha_4 X_i^3 + v_i$ (*)

où v_i terme d'erreur qui satisfait aux hyp. class.

4. Asympt. n (taille de l'éch.) fois R^2 (coeff. de déterminat° de reg. auxiliaire (*)) suit une loi de chi - caré où $df = \text{nbre de restrictions imposées dans modèle restreint}$.

$$\Rightarrow n \cdot R^2 \underset{\text{asy}}{\sim} \chi^2_{df = \text{nbre de restrictions}}$$

5. Règle de décision: si χ^2 calculée excède valeur critique au niveau prob. α , on rejette reg. restreint

Exemple :

$$\hat{Y}_i = 166,467 + 19,333 X_i$$

où $\begin{cases} Y = \text{coût total} \\ X = \text{niveau d'output} \end{cases}$

Régression auxiliaire :

$$\hat{u}_i = -24,7 + 43,5443 X_i + 12,9615 X_i^2 + 0,9396 X_i^3$$

se	(6,375)	(4,779)	(0,986)	(0,059)
----	---------	---------	---------	---------

$$R^2 = 0,9896$$

$$1 * R^2 = 10 * 0,9896 = 9,896$$

Valeur critique χ^2 à 2df = 9,21 ($\alpha = 0,01$)
 χ^2 calculée est significative à 1% \Rightarrow on rejette modèle restreint.

2.4.5. Modèles imbriqués et non imbriqués

Modèle A : $Y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \beta_4 X_{4i} + \beta_5 X_{5i} + u_i$

Modèle B : $Y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + u_i$

\rightarrow Modèle B est imbriqué dans modèle A car si sur base d'un F-test, on ne rejette pas $H_0: \beta_4 = \beta_5 = 0$, modèle A se résume au modèle B.

Modèle C : $Y_i = \alpha_1 + \alpha_2 X_{2i} + \alpha_3 X_{3i} + u_i$

Modèle D : $Y_i = \beta_1 + \beta_2 Z_{2i} + \beta_3 Z_{3i} + v_i$

où $X \neq Z$

\rightarrow Modèles C et D ne sont pas imbriqués car aucun n'est un cas particulier de l'autre.

Modèles peuvent être non imbriqués nute à l'utilisation d'une forme fonctionnelle ≠, par exemple :

$$\text{Modèle D : } Y_i = \beta_1 + \beta_2 Z_{2i} + \beta_3 Z_{3i} + \nu_i$$

$$\text{Modèle E : } Y_i = \beta_1 + \beta_2 \ln Z_{2i} + \beta_3 \ln Z_{3i} + \omega_i$$

Tests relatifs aux modèles non imbriqués

Approche „discriminante“ : sélectionner un modèle sur base d'un critère relatif à la qualité de l'ajustement des modèles.

Approche „de discernement“ : choisir modèle qui est le plus adéquat en utilisant information contenue dans l'ð modèle

(i) Approche discriminante

$$\text{Modèle C : } Y_i = \alpha_1 + \alpha_2 X_{2i} + \alpha_3 X_{3i} + u_i$$

$$\text{Modèle D : } Y_i = \beta_1 + \beta_2 Z_{2i} + \beta_3 Z_{3i} + \nu_i$$

Le coefficient de détermination

$$R^2 = \frac{SCE}{SCT} = 1 - \frac{SCR}{SCT}$$

Pblmes ?

R^2 mesure qualité de l'ajustement au sein de l'échantillon.

Il faut que variable d'apt soit identique.

R^2 ne diminue jamais lorsque # var. expl. ↑

Le coefficient de détermination ajusté

$$\bar{R}^2 = 1 - \frac{SCR / (n-k)}{SCT / (n-1)} = 1 - (1-R^2) \frac{n-1}{n-k}$$

$$\Rightarrow \bar{R}^2 \leq R^2$$

(! pour que comparaison ait un sens, il faut que variables dépendantes soient identiques).

Le critère d'information de Akaike (AIC)

$$AIC = e^{2k/m} \frac{\sum \hat{u}_i^2}{m} = e^{2k/m} \frac{SCR}{n}$$

où $\begin{cases} k = \text{nbre de régresseurs (intercepte compris)} \\ n = \text{nbre d'observations} \end{cases}$

$$\Rightarrow \ln AIC = \left(\frac{2k}{m} \right) + \ln \left(\frac{SCR}{n} \right)$$

où $\frac{2k}{m}$ = facteur de pénalité

Choisir modèle dont valeur critère AIC est la plus faible.

Permet d'évaluer qualité de la prévision au sein de l'échantillon et en dehors.

Souvent utilisé pour déterminer le nbre de lags dans un modèle AR(p).

Le critère d'information de Schwartz (SIC)

$$SIC = n^{\frac{k}{2}} \frac{\sum \hat{u}^2}{n} = n^{\frac{k}{2}} \frac{SCR}{n}$$

$$\Rightarrow \boxed{\ln SIC = \frac{k}{n} \ln(n) + \ln\left(\frac{SCR}{n}\right)}$$

où $\left[\frac{k}{n} \ln(n)\right]$ = facteur de pénalité

Mêmes avantages que critère AIC mais impose pénalité + imp. pour inclusion de var. expl. suppl.

On choisit modèle pour lequel critère SIC prend valeur la + faible.

(ii) Approche de discernement

Le F test non imbriqué (Encompassing F test)

Modèle C : $Y_i = \alpha_1 + \alpha_2 X_{2i} + \alpha_3 X_{3i} + u_i$

Modèle D : $Y_i = \beta_1 + \beta_2 Z_{2i} + \beta_3 Z_{3i} + v_i$

Faire un choix tel C & D ?

Modèle F : $Y_i = \lambda_1 + \lambda_2 X_{2i} + \lambda_3 X_{3i} + \lambda_4 Z_{2i} + \lambda_5 Z_{3i} + u_i$

\Rightarrow Modèle F imbrique ou englobe modèles C et D.

Modèles C & D non autorisés.

Si modèle C correct : $\lambda_4 = \lambda_5 = 0$
 Si modèle D correct : $\lambda_2 = \lambda_3 = 0$ } \rightarrow F test tradit.

Inconvénients :

1. Le choix du modèle de référence peut avoir une influence déterminante sur le modèle sélectionné (surtout lorsque il y a une forte multicollinearité (les régresseurs des modèles) ≠ modèles)
2. Modèle F ne donne pas toujours lieu à une interprétation économique cohérente.

Le J test de Davidson - MacKinnon

Supposons qu'on compare les modèles suivants :

$$\text{Modèle C : } Y_i = \alpha_1 + \alpha_2 X_{2i} + \alpha_3 X_{3i} + u_i$$

$$\text{Modèle D : } Y_i = \beta_1 + \beta_2 Z_{2i} + \beta_3 Z_{3i} + v_i$$

Differentes étapes :

1. On estime modèle D $\rightarrow \hat{Y}_i^D$
2. On ajoute \hat{Y}_i^D comme régresseur du modèle C.
$$Y_i = \alpha_1 + \alpha_2 X_{2i} + \alpha_3 X_{3i} + \alpha_4 \hat{Y}_i^D + u_i$$
3. $H_0: \alpha_4 = 0$ (utiliser t test)
4. Si $\not\sim H_0 \rightarrow$ on ne rejette pas l'hyp. que modèle C est le bon.

Intuition : si $\not\sim H_0$ que $\alpha_4 = 0$, variables incluses dans D et pas dans C ne permettent pas d'améliorer perp. du modèle C \Rightarrow modèle C englobe (encompasses) modèle D.

5. On renverse rôle des hyp : on estime C, on obtient \hat{Y}_i^C , on estime D en excluant \hat{Y}_i^C
$$(Y_i = \beta_1 + \beta_2 Z_{2i} + \beta_3 Z_{3i} + \beta_4 \hat{Y}_i^C + v_i)$$
, on teste $H_0: \beta_4 = 0$. Si $\not\sim H_0$, on choisit D, sinon C.

Inconvénients:

1. 4 types de résultats:

Hyp. $\alpha_4 = 0$ ($H_0: C$ vs. $H_1: D$)

Hyp. $\beta_4 = 0$ ($H_0: D$ vs. $H_1: C$)	Ne pas rejeter	Ne pas rejeter	Rejeter
	Accepter C et D	Accepter D Rejeter C	Rejeter C et D
Rejeter	Accepter C Rejeter D		

→ si 2 modèles rejétés : aucun modèle ne reflète correctement le comportement de la variable Y.

si 2 modèles acceptés : (apparemment) les données ne contiennent pas assez d'info pour les départager

2. t stat suit une distib. normale centrée réduite asymptotique (problème parfois pour tester signif. de β_i pour)
- pas très puissant si petit échantillon.
(reflette trop sur H_0 lorsque petit éch.)