

Économétrie II

Ch. 4 Autocorrélation

L3 Économétrie – L3 MASS

Prof. Philippe Polomé, U. Lyon 2

Année 2015-2016

Rappel

1. $E(\varepsilon_i) = 0 \forall i$: **Espérance nulle**
2. $\checkmark \text{var}(\varepsilon_i) = \sigma^2 \forall i$: **Homoscédasticité**
3. $\text{cov}(\varepsilon_t, \varepsilon_s) = 0 \forall t \neq s$: **Pas d'autocorrélation**
4. $E(\varepsilon_i x_i) = 0 \forall i$: **Exogénéité**
5. \checkmark La matrice X est de plein rang : **Pas de multicollinéarité**
6. Le modèle est **correctement spécifié**
7. La variable dépendante Y est **continue**

Table des matières

Ch. 4. $\exists t, s : \text{cov}(\varepsilon_t, \varepsilon_s) \neq 0$: Autocorrélation

Définition & conséquences

Causes & exemples

Séries temporelles

Séries temporelles : Tendances

Séries temporelles : I(0)

Séries temporelles autorégressives d'ordre 1 AR(1)

Test d'autocorrélation AR(1)

Application : Capital Asset Pricing Model

Traitement de l'autocorrélation

Table des matières

Ch. 4. $\exists t, s : \text{cov}(\varepsilon_t, \varepsilon_s) \neq 0$: Autocorrélation

Définition & conséquences

Causes & exemples

Séries temporelles

Séries temporelles : Tendances

Séries temporelles : I(0)

Séries temporelles autorégressives d'ordre 1 AR(1)

Test d'autocorrélation AR(1)

Application : Capital Asset Pricing Model

Traitement de l'autocorrélation

Définition

- ▶ $\exists t, s : \text{cov}(\varepsilon_t, \varepsilon_s) \neq 0$

$$\Sigma_{\varepsilon} = \begin{pmatrix} \sigma^2 & \rho_{12} & \cdots & \rho_{1N} \\ & \sigma^2 & & \rho_{2N} \\ & & \ddots & \vdots \\ \text{sym} & & & \sigma^2 \end{pmatrix}$$

- ▶ Plusieurs formes sont possibles
 - ▶ Autorégressive d'ordre 1 AR(1) : $\varepsilon_t = \rho\varepsilon_{t-1} + \mu_t$
 - ▶ avec μ_t “bruit blanc”
 - ▶ À préciser (séries temporelles)
- ▶ $\Sigma_{\varepsilon} \neq \sigma^2 I_N$
 - ▶ La matrice de var-cov des erreurs n'est pas **diagonale**
 - ▶ Les observations ne sont **pas indépendantes** entre elles

Conséquences

- ▶ En principe, $\hat{\beta}_{MCO}$ est **non-biaisé** et **consistant**
 - ▶ Ces propriétés ne dépendent pas de Σ_ε
 - ▶ Sauf si autocorrélation causée par un problème plus grave
 - ▶ Endogénéité
 - ▶ Intégration I(1) d'une série temporelle
- ▶ Gauss-Markov ne s'applique plus \implies MCO n'est **plus efficace**
- ▶ Comme hétéroscédasticité : $\Sigma_{\hat{\beta}} = (X'X)^{-1} X' \Sigma_\varepsilon X (X'X)^{-1}$
 - ▶ Inférence basée sur $\Sigma_{\hat{\beta}} = \sigma^2 (X'X)^{-1}$ fautive : tests t, F...
 - ▶ Bootstrap faux car pas indépendance
 - ▶ \exists estimateur pour $\Sigma_{\hat{\beta}}$ semblable à l'estimateur de White en cas d'hétéroscédasticité
 - ▶ Peu utilisé car l'autocorrélation est souvent dans un contexte de séries temporelles et on veut les étudier plus en détails
 - ▶ Exception parfois avec données de panel

Table des matières

Ch. 4. $\exists t, s : \text{cov}(\varepsilon_t, \varepsilon_s) \neq 0$: Autocorrélation

Définition & conséquences

Causes & exemples

Séries temporelles

Séries temporelles : Tendances

Séries temporelles : I(0)

Séries temporelles autorégressives d'ordre 1 AR(1)

Test d'autocorrélation AR(1)

Application : Capital Asset Pricing Model


Traitement de l'autocorrélation

Autocorrélation en séries temporelles

- ▶ Forme “naturelle” : Le passé influence le présent / persistance
 - ▶ Ex. demande de monnaie
 - ▶ $\ln M1_t = \beta_0 + \beta_1 \ln PIB_t + \beta_2 \ln IPC_t + \varepsilon_t$
 - ▶ Cette influence peut être capturée par les régresseurs ou pas
- ▶ Terme d'erreur capture l'influence de variables ou de chocs **omis**
 - ▶ Variables omises : tendances et cycles (ci-dessous)
 - ▶ Chocs : Souvent l'effet dure plus d'une période
 - ▶ Cas le plus abondant et objet d'étude des séries temporelles
 - ▶ Cas AR(1) dans les sections suivantes
 - ▶ On dit souvent “autocorrélation sérielle”
 - ▶ Conséquences potentiellement graves (Endogénéité)


Exemple : Omission d'un terme cyclique

- ▶ Données Verbeek, moyennes / 4 semaines, Etats-Unis, 1951-53
- ▶ Expliquée : Consommation de crème glacée per capita
- ▶ Régresseurs inclus : prix et revenus moyens
- ▶ Régresseur omis : température moyenne




Omission d'un terme cyclique (2)

- ▶ La température suit des cycles annuels (été–hiver)
 - ▶ Les ventes de crème glacée aussi !
- ▶ Si la température n'est pas incluse comme régresseur, les résidus suivront les cycles été–hiver
 - ▶ Ces résidus auront tendance à apparaître groupés par signe = autocorrélation




Omission d'un terme cyclique : Correction de l'autocorrélation

- ▶ Si on a les données correspondantes au régresseur manquant, on ajoute ce régresseur manquant
 - ▶ Si on a pas les données ...



Régresseur quadratique manquant [Regr manquant.ods](#)

- ▶ Monte-Carlo : $Y = \beta_0 + \beta_1 x + \beta_2 x^2 + \varepsilon$ avec $\beta_1 > 0$ et $\beta_2 < 0$
 - ▶ Mais on régresse $Y = \beta_0 + \beta_1 x + \mu$
 - ▶ On “ajuste” une droite dans un nuage de points “courbe”
 - ▶ Résidus \ominus pour des valeurs petites et grandes de X et \oplus pour des valeurs moyennes de X
 - ▶ Il faut ordonner selon X pour le voir
 - ▶ Pas facilement détecté par logiciel, sauf si X croit avec le temps




- ▶ Conséquences potentiellement graves (Endogénéité)

Autocorrélation en coupe transversale

- ▶ Généralement : autocorrélation si données **structurées**
 - ▶ Coupe transversale, échantillonnage aléatoire \Rightarrow pas d'autocorrélation
 - ▶ Corrélation spatiale

Résidus régression % County votes pour Bush contre revenu par habitant



Residuals from OLS Model
■ [-50,-25] ■ [-25,-5] □ [-5,5] ■ [5,25] ■ [25,50]

Source Y.M. Zukhov, 2010

Table des matières

Ch. 4. $\exists t, s : \text{cov}(\varepsilon_t, \varepsilon_s) \neq 0$: Autocorrélation

Définition & conséquences

Causes & exemples

Séries temporelles

Séries temporelles : Tendances

Séries temporelles : I(0)

Séries temporelles autorégressives d'ordre 1 AR(1)

Test d'autocorrélation AR(1)

Application : Capital Asset Pricing Model

Traitement de l'autocorrélation

Séries temporelles

- ▶ En dehors du cas spatial, l'autocorrélation n'est considérée que pour les séries chronologiques
 - ▶ Variables macro-économiques : PIB, inflation, chômage...
 - ▶ Suivi mensuel d'un individu / population : emploi, salaire, consommation...
 - ▶ Cotation d'une action : annuelle, mensuelle, journalière, à la minute...
 - ▶ Taux de change
 - ▶ Flux de passagers dans une compagnie aérienne
 - ▶ Ventes / achats
 - ▶ Rendements : plante, entreprise, titre...
- ▶ La suite de ce chapitre leur est consacrée

Séries temporelles vs. coupes transversales

- ▶ Les observations des séries chronologiques sont ordonnées
 - ▶ l'ordre des observations d'une coupe transversale n'a pas d'importance
- ▶ Les observations de séries chronologiques sont issues d'un **processus stochastique** (aléatoire)
 - ▶ pas d'un échantillon aléatoire (coupes transversales)
- ▶ Les modèles chronologiques sont généralement indexés par t :

$$y_t = \beta_0 + \beta_1 x_{1t} + \dots + \beta_k x_{kt} + \varepsilon_t$$

Modèles à retards distribués

- ▶ Le modèle $y_t = \beta_0 + \delta_0 x_t + \varepsilon_t$ est dit **statique**
 - ▶ Courbe de Phillips classique $\text{inflation}_t = \beta_0 + \beta_1 \text{chomage}_t + \varepsilon_t$
- ▶ Modèles à **retards distribués** (du régresseur) finis
 - ▶ un ou plusieurs x affectent y avec un ou plusieurs retards (lags)
 - ▶ $gf_t = \beta_0 + \delta_0 te_t + \delta_1 te_{t-1} + \delta_2 te_{t-2} + \varepsilon_t$
 - ▶ gf “general (average) fertility”
 - ▶ te “tax exemption”
 - ▶ “à l’ordre 2”
 - ▶ δ_0 = impact immédiat (= de court terme) de x sur y
 - ▶ L’ensemble $\delta_0, \delta_1, \dots, \delta_q$ décrit la relation de long terme entre x et y

Modèles à retards distribués

- ▶ Modèle d'ordre 2 $y_t = \beta_0 + \delta_0 x_t + \delta_1 x_{t-1} + \delta_2 x_{t-2} + \varepsilon_t$
- ▶ Choc transitoire (1 t) Δ sur x constant intervenant en t
 - ▶ $y_t = \beta_0 + \delta_0 (x + \Delta) + \delta_1 x + \delta_2 x + \varepsilon_t$
 - ▶ $y_{t+1} = \beta_0 + \delta_0 x + \delta_1 (x + \Delta) + \delta_2 x + \varepsilon_{t+1}$
 - ▶ $y_{t+2} = \beta_0 + \delta_0 x + \delta_1 x + \delta_2 (x + \Delta) + \varepsilon_{t+2}$
- ▶ Choc permanent (à partir de t) Δ sur x constant
 - ▶ $y_t = \beta_0 + \delta_0 (x + \Delta) + \delta_1 x + \delta_2 x + \varepsilon_t$
 - ▶ $y_{t+1} = \beta_0 + \delta_0 (x + \Delta) + \delta_1 (x + \Delta) + \delta_2 x + \varepsilon_{t+1}$
 - ▶ $y_{t+2} = \beta_0 + \delta_0 (x + \Delta) + \delta_1 (x + \Delta) + \delta_2 (x + \Delta) + \varepsilon_{t+2}$

Table des matières

Ch. 4. $\exists t, s : \text{cov}(\varepsilon_t, \varepsilon_s) \neq 0$: Autocorrélation

Définition & conséquences

Causes & exemples

Séries temporelles

Séries temporelles : Tendances

Séries temporelles : I(0)

Séries temporelles autorégressives d'ordre 1 AR(1)

Test d'autocorrélation AR(1)

Application : Capital Asset Pricing Model

Traitement de l'autocorrélation

Modèles à tendance

- ▶ Le modèle $y_t = \beta_0 + \delta_0 t + \varepsilon_t$ est une **tendance**
 - ▶ y “suit” le temps avec un bruit stochastique ε
- ▶ Multiples spécifications de tendance
 - ▶ Linéaire $y_t = \beta_0 + \beta_1 z_t + \beta_2 \mathbf{t} + \varepsilon_t$, $t = 1, 2, \dots, T$
 - ▶ Exponentielle $\ln y_t = \beta_0 + \beta_1 z_t + \beta_2 \mathbf{t} + \varepsilon_t$
 - ▶ Arrive lorsque y a le même taux de croissance t après t (ci-dessous)
 - ▶ Quadratique $y_t = \beta_0 + \beta_1 z_t + \beta_2 \mathbf{t} + \beta_3 \mathbf{t}^2 + \varepsilon_t$

Note sur log

- ▶ $\Delta \log(y_t) = \log(y_t) - \log(y_{t-1}) \approx \frac{y_t - y_{t-1}}{y_{t-1}}$
 - ▶ Le **différentiel** de log (ln en fait) est approximativement égal au taux de croissance
 - ▶ Pour des taux plutôt faibles
- ▶ Une tendance exponentielle sans régresseur est alors $\ln y_t = \beta_0 + \beta_2 t + \varepsilon_t$
 - ▶ $\Delta \ln(y_t) = \beta_2 + \Delta \varepsilon_t$: tx de croissance constant + une erreur à espérance nulle

Régression spurieuse

- ▶ Différentes variables économiques chronologiques ont souvent une **tendance** temporelle
- ▶ *Régresser une tendance sur une tendance semble souvent bon*
 - ▶ R^2 , t élevés
 - ▶ Des facteurs **inobservés** par l'économètre peuvent causer les tendances
 - ▶ \equiv problème des cigognes
 - ▶ Ces facteurs inobservés peuvent être **contrôlés** en modélisant la tendance temporelle
 - ▶ p.e. introduire un régresseur $t = 1, \dots, T$ peut ramener la significativité des autres régresseurs à leur juste niveau
 - ▶ **Régression fallacieuse** (spurieuse/spurious)

Exemple tableur Trend Coint RndWalk.odt


- ▶ Générer $y=a+bt+\mu$
 - ▶ $=2+3*C3+10*SQRT(-2*LN(RAND()))*SIN(2*PI()*RAND())$
- ▶ Générer $x=ct+v$:
 - ▶ $=-10*C3+10*SQRT(-2*LN(RAND()))*SIN(2*PI()*RAND())$
 - ▶ indépendant de y car $RAND()$ génère indépendamment
- ▶ Régresser y sur t et une constante (plage L)
 - ▶ $=LINEST(A3 :A53 ;C3 :C53 ;1 ;1)$
- ▶ Régresser y sur x et une constante (plage M)
 - ▶ $=LINEST(A3 :A53 ;H3 :H53 ;1 ;1)$
 - ▶ Calculer t-stat : x semble significatif
- ▶ Insérer tendance dans régression y sur x
 - ▶ x n'est plus significatif
- ▶ Régresser detrended y sur detrended x

Exemple : investissement immobilier et prix

- ▶ Fichier Gretl hseinv.gdt dans données Wooldridge
- ▶ Série 1947-88 “housing investment and housing price index”

$$\ln(\widehat{invpc}) = -.55 + 1.24 \ln(price)$$

- ▶ L'élasticité de l'investissement individuel (pc) p/r prix est significativement différente de zéro, mais pas de un.
 - ▶ Un changement de prix est répercuté complètement sur l'investissement
 - ▶ Mais les deux séries suivent une tendance



Exemple : investissement immobilier et prix

- ▶ En rajoutant une tendance

$$\ln(\widehat{invpc}) = -.91 - .38 \ln(price) + .0098t$$

- ▶ Le prix cesse d'être significatif
 - ▶ Mais l'investissement (réel) croît d'environ 1% l'an
 - ▶ Possiblement, cela reflète l'effet de régresseurs omis
- ▶ Le résultat antérieur était spurieux
- ▶ Si y et x ont des trends opposés
 - ▶ Introduire une tendance peut **accroître** la significativité de x
 - ▶ La t-stat sur une tendance n'est pas nécessairement correcte (section sur I(1))

Purger une tendance (detrending)

- ▶ Au lieu d'introduire une tendance linéaire : purger les données de la tendance (**detrend**)

1. Régression de chaque variable du modèle sur une tendance
2. Utilisation des résidus de chaque équation comme nouvelles variables

- ▶ Par exemple $y_t = \beta_0 + \beta_1 z_t + \beta_2 t + \varepsilon_t$

1. Création de variables purgées de la tendance

$$y_t = \gamma_0 + \gamma_1 t + \zeta_t \rightarrow y_t^d = \hat{\zeta}_t$$

$$z_t = \theta_0 + \theta_1 t + \xi_t \rightarrow z_t^d = \hat{\xi}_t$$

2. Régression sur les variables purgées $y_t^d = \lambda z_t^d + v_t$

- ▶ Plus utile de mettre une constante car $E(y_t^d) = E(z_t^d) = 0$ par construction

Purger une tendance (2)

- ▶ Purger la tendance est une méthode en 2 étapes qui introduit un **erreur de mesure** sur la deuxième étape
 - ▶ Les variables purgées de la tendance sont construites à partir de **paramètres estimés**
 - ▶ $\hat{\xi}_t$ est une mesure avec erreur de z_t^d
- ▶ L'introduction d'une tendance et l'utilisation de variables purgées de la tendance sont deux approches **équivalentes**
- ▶ Remarque sur le R^2
 - ▶ Les régressions en séries temporelles ont souvent un R^2 élevé du seul fait de la tendance
 - ▶ Mais ne correspond pas au pouvoir explicatif réel du modèle estimé
 - ▶ Le R^2 de la régression avec variables purgées de la tendance reflète de manière plus juste le pouvoir explicatif du modèle économique

Table des matières

Ch. 4. $\exists t, s : \text{cov}(\varepsilon_t, \varepsilon_s) \neq 0$: Autocorrélation

Définition & conséquences

Causes & exemples

Séries temporelles

Séries temporelles : Tendances

Séries temporelles : I(0)

Séries temporelles autorégressives d'ordre 1 AR(1)

Test d'autocorrélation AR(1)

Application : Capital Asset Pricing Model

Traitement de l'autocorrélation

Stationnarité

- ▶ Un processus stochastique est **stationnaire**
 - ▶ Lorsque sa distribution ne change pas dans le temps
 - ▶ paramètres compris
 - ▶ La stationnarité est semblable à “**identiquement distribués**”
- ▶ Les tendances ne sont pas stationnaires
 - ▶ car leur espérance change avec le temps
- ▶ Un processus stochastique est **covariance-stationnaire**
 - ▶ Si son espérance et sa variance sont constantes dans le temps
 - ▶ Et si la covariance entre 2 périodes ne dépend que du nombre de périodes entre elles

Intégration

- ▶ Un processus stationnaire est
 - ▶ **Faiblement dépendant** ou
 - ▶ **Intégré d'ordre zéro I(0)** si
 - ▶ x_t et x_{t+h} sont “presque indépendant” quand $h \rightarrow \infty$
- ▶ Une définition semblable existe pour un proc. non stationnaire
- ▶ Une série covariance-stationnaire est I(0) si la corrélation entre x_t et $x_{t+h} \rightarrow 0$ quand $h \rightarrow \infty$
- ▶ I(0) implique que la loi des grands nombres et le théorème central limite s'appliquent
 - ▶ La dépendance faible est semblable à “**indépendamment distribués**”
 - ▶ Stationnaire + I(0) remplace l'hypothèse d'échantillon aléatoire simple (iid)
 - ▶ I(0) est une condition suffisante pour pouvoir utiliser une série en régression

MA(1) : Processus de moyenne mobile d'ordre 1

- ▶ MA(1) $x_t = e_t + \alpha e_{t-1}$, $t = 1, 2, \dots$
 - ▶ $\{e_t : t = 0, 1, \dots\}$ est une séquence i.i.d avec moyenne zéro et variance σ_e^2
 - ▶ **Bruit blanc**
- ▶ Un MA(1) est I(0)
 - ▶ Les termes adjacents dans une séquence sont corrélés
 - ▶ Dès qu'il y a 2 périodes ou plus entre 2 termes d'un MA(1), la corrélation est zéro car e_t est i.i.d.
 - ▶ Comme e_t est i.i.d., le MA(1) est stationnaire

Table des matières

Ch. 4. $\exists t, s : \text{cov}(\varepsilon_t, \varepsilon_s) \neq 0$: Autocorrélation

Définition & conséquences

Causes & exemples

Séries temporelles

Séries temporelles : Tendances

Séries temporelles : I(0)

Séries temporelles autorégressives d'ordre 1 AR(1)

Test d'autocorrélation AR(1)

Application : Capital Asset Pricing Model

Traitement de l'autocorrélation

AR(1) : $\varepsilon_t = \rho\varepsilon_{t-1} + \mu_t$ processus autorégressif d'ordre 1

- ▶ AR(1) est dit **stable** lorsque $|\rho| < 1$
- ▶ $\mu_t \sim iid(0, \sigma_\mu^2)$ **bruit blanc**
 - ▶ Espérance 0, variance constante et covariance 0
- ▶ On peut écrire $\varepsilon_t = \mu_t + \rho\mu_{t-1} + \rho^2\mu_{t-2} + \dots$

- ▶ D'où $var(\varepsilon_t) = \sigma_\varepsilon^2 = \sigma_\mu^2 + \rho^2\sigma_\mu^2 + \rho^4\sigma_\mu^2 + \dots = \frac{\sigma_\mu^2}{1-\rho^2}$

- ▶ Et $cov(\varepsilon_t, \varepsilon_{t-1}) = cov(\rho\varepsilon_{t-1} + \mu_t, \varepsilon_{t-1}) = \rho\sigma_\varepsilon^2 = \frac{\rho\sigma_\mu^2}{1-\rho^2}$

- ▶ Par substitutions répétées dans AR(1)

$$\varepsilon_t = \rho\varepsilon_{t-1} + \mu_t = \rho(\rho\varepsilon_{t-2} + \mu_{t-1}) + \mu_t = \rho^2\varepsilon_{t-2} + \rho\mu_{t-1} + \mu_t = \dots = \rho^s\varepsilon_{t-s} + \sum_{i=0}^{s-1} \rho^i\mu_{t-i}$$

$$\text{Donc } cov(\varepsilon_t, \varepsilon_{t-s}) = \frac{\rho^s\sigma_\mu^2}{1-\rho^2} = \rho^s\sigma_\varepsilon^2$$

Matrice var-cov des erreurs AR(1)

$$\begin{aligned} \Sigma_{\varepsilon} &= \sigma_{\varepsilon}^2 \begin{pmatrix} 1 & \rho & \rho^2 & \dots & \rho^{T-1} \\ & 1 & \rho & \dots & \rho^{T-2} \\ & & \ddots & & \vdots \\ & & & 1 & \rho \\ & \text{sym} & & & 1 \end{pmatrix} \text{AR(1) stable est I(0)} \\ &= \sigma_{\varepsilon}^2 I_T + \sigma_{\varepsilon}^2 \begin{pmatrix} 0 & \rho & \rho^2 & \dots & \rho^{T-1} \\ & 0 & \rho & \dots & \rho^{T-2} \\ & & \ddots & & \vdots \\ & & & 0 & \rho \\ & \text{sym} & & & 0 \end{pmatrix} \\ &= \sigma_{\varepsilon}^2 I_T + \sigma_{\varepsilon}^2 \Phi \end{aligned}$$

- ▶ Stationnaire car μ_t i.i.d.
- ▶ Cov $\rightarrow 0$ quand écart entre périodes $\rightarrow \infty$

Matrice var-cov des coefficients MCO avec erreurs AR(1)

- ▶ $y = X\beta + \varepsilon$ avec $\varepsilon_t = \rho\varepsilon_{t-1} + \mu_t$

$$\Sigma_{\hat{\beta}} = (X'X)^{-1} X' \Sigma_{\varepsilon} X (X'X)^{-1}$$

- ▶
$$= (X'X)^{-1} X' [\sigma_{\varepsilon}^2 I_T + \sigma_{\varepsilon}^2 \Phi] X (X'X)^{-1}$$

$$= \sigma_{\varepsilon}^2 (X'X)^{-1} + \sigma_{\varepsilon}^2 (X'X)^{-1} X' \Phi X (X'X)^{-1}$$

- ▶ On ne peut pas dire si elle est + grande que $\Sigma_{\hat{\beta}} = \sigma_{\varepsilon}^2 (X'X)^{-1}$
 - ▶ On ne peut pas dire si les t-stats seront sur- ou sous-évaluées

Table des matières

Ch. 4. $\exists t, s : \text{cov}(\varepsilon_t, \varepsilon_s) \neq 0$: Autocorrélation

Définition & conséquences

Causes & exemples

Séries temporelles

Séries temporelles : Tendances

Séries temporelles : I(0)

Séries temporelles autorégressives d'ordre 1 AR(1)

Test d'autocorrélation AR(1)

Application : Capital Asset Pricing Model

Traitement de l'autocorrélation

Examen visuel des résidus

- ▶ Voir exemples antérieurs
 - ▶ Autocorrélation \oplus
 - ▶ Les résidus tendent à être groupés par signe
 - ▶ Ils changent de signe trop peu souvent par rapport à des résidus non-autocorrélés
 - ▶ Autocorrélation \ominus c'est l'inverse
 - ▶ Les résidus alternent plus d'une fois sur deux
- ▶ Le plus souvent, l'analyse graphique est **délicate** à interpréter

Test de Durbin-Watson

- ▶ Test d'autocorrélation de type AR(1) : $\varepsilon_t = \rho\varepsilon_{t-1} + \mu_t$
 - ▶ $|\rho| < 1$
 - ▶ $\mu_t \sim iid(0, \sigma_\mu^2)$
- ▶ On veut tester $H_0 : \rho = 0$ versus $H_1 : \rho \neq 0$

▶ Stat du test : $DW = \frac{\sum_{t=2}^T (\hat{\varepsilon}_t - \hat{\varepsilon}_{t-1})^2}{\sum_{t=1}^T \hat{\varepsilon}_t^2}$ où $\hat{\varepsilon} = y - X\hat{\beta}$

Analyse de DW

- ▶ Si on estime $\hat{\varepsilon} = \alpha \hat{\varepsilon}_{-1} + \nu$ avec $\hat{\varepsilon}_{-1} =$ vecteur des $\hat{\varepsilon}_{t-1}$

$$\bullet \hat{\alpha} = \left(\hat{\varepsilon}'_{-1} \hat{\varepsilon}_{-1} \right)^{-1} \hat{\varepsilon}'_{-1} \hat{\varepsilon} = \frac{\sum_{t=2}^T \hat{\varepsilon}_{t-1} \hat{\varepsilon}_t}{\sum_{t=2}^T \hat{\varepsilon}_{t-1}^2} = \hat{\rho}$$


- ▶ $\hat{\rho}$ est un estimateur non-biaisé de ρ

$$\bullet DW = \frac{\sum_{t=2}^T (\hat{\varepsilon}_t - \hat{\varepsilon}_{t-1})^2}{\sum_{t=1}^T \hat{\varepsilon}_t^2} = \frac{\sum_{t=2}^T (\hat{\varepsilon}_t^2 + \hat{\varepsilon}_{t-1}^2) - 2 \sum_{t=2}^T \hat{\varepsilon}_t \hat{\varepsilon}_{t-1}}{\sum_{t=1}^T \hat{\varepsilon}_t^2} \approx 2 - 2\hat{\rho}$$

Règle de décision

- ▶ Comme $\rho \in [-1, 1]$, $DW \in [0, 4]$ avec
 - ▶ Autocorrélation \ominus : ρ proche de -1 $\Leftrightarrow DW$ proche de 4
 - ▶ Autocorrélation \oplus : ρ proche de 1 $\Leftrightarrow DW$ proche de 0
 - ▶ Pas d'autocorrélation : ρ proche de 0 $\Leftrightarrow DW$ proche de 2
 - ▶ C'est la 2^o "règle du 2" en économétrie (la 1^o était le t-stat)
- ▶ Durbin et Watson (1950) ont tabulé les valeurs critiques de DW au seuil de 5%
 - ▶ Taille de l'échantillon T
 - ▶ Nombre de variables explicatives k
 - ▶ La table donne 2 valeurs d_L et d_U (Low et Up)

FIGURE – Règle de Durbin-Watson



- ▶ Si $DW < d_L$: Autocorrélation \oplus
- ▶ Si $DW > 4 - d_L$: Autocorrélation \ominus
- ▶ Si $DW \in [d_U, 4 - d_U]$: pas d'autocorrélation
- ▶ Entre d_L et d_U et entre $4 - d_U$ et $4 - d_L$ on ne peut conclure

FIGURE – Table de Durbin-Watson à 5%

k = nbr de régresseurs (constante exclue)

n = nbr observations (au minimum 15)

n	$k = 1$		$k = 2$		$k = 3$		$k = 4$	
	dL	dU	dL	dU	dL	dU	dL	dU
15	1.08	1.36	.95	1.54	.82	1.75	.69	1.97
16	1.10	1.37	.98	1.54	.86	1.73	.74	1.93
17	1.13	1.38	1.02	1.54	.90	1.71	.78	1.90
18	1.16	1.39	1.05	1.53	.93	1.69	.82	1.87
19	1.18	1.40	1.08	1.53	.97	1.68	.86	1.85
20	1.20	1.41	1.10	1.54	1.00	1.68	.90	1.83

Conditions d'utilisation de Durbin Watson

- ▶ DW ne permet de tester que l'autocorrélation d'ordre 1
 - ▶ Mais souvent c'est la principale
- ▶ Intercept obligatoire
- ▶ Nombre d'observations ≥ 15
- ▶ Pas y_{t-1} dans les variables explicatives
 - ▶ AR(1) : $\varepsilon_t = \rho\varepsilon_{t-1} + \mu_t$
 - ▶ Si $y_t = \beta_0 + \beta_1 z_t + \beta_2 y_{t-1} + \varepsilon_t$
 - ▶ Alors
$$y_t = \beta_0 + \beta_1 z_t + \beta_2 [\beta_0 + \beta_1 z_{t-1} + \beta_2 y_{t-2} + \varepsilon_{t-1}] + [\rho\varepsilon_{t-1} + \mu_t]$$
 - ▶ Donc : corrélation erreur-régresseur : Ch. endogénéité
 - ▶ On cumule les problèmes (on ne traite pas)

Tests alternatifs

- ▶ DW est un vieux test
 - ▶ Un de ses intérêts principaux est de minimiser les calculs
 - ▶ On réutilise les résidus de MCO pour un calcul “simple”
- ▶ Test de résidus AR(1) : estimer $\hat{\varepsilon} = \alpha \hat{\varepsilon}_{-1} + \nu$
 - ▶ Si $\hat{\alpha}$ est significatif, (t-test) il y a AR(1), \oplus ou \ominus selon le signe
 - ▶ Mais si ρ proche de 1, ce test n'est plus valable
- ▶ Test de résidus AR(q) : estimer $\hat{\varepsilon} = \alpha \hat{\varepsilon}_{-q} + \nu$
 - ▶ t-test sur $\hat{\alpha}$
- ▶ Test d'autocorrélation plus générale : $\hat{\varepsilon} = \sum_{i=1}^q \alpha_i \hat{\varepsilon}_{-i} + \nu$
 - ▶ F-test $H_0 : \hat{\alpha}_1 = \hat{\alpha}_2 = \dots = \hat{\alpha}_q = 0$

Table des matières

Ch. 4. $\exists t, s : \text{cov}(\varepsilon_t, \varepsilon_s) \neq 0$: Autocorrélation

Définition & conséquences

Causes & exemples

Séries temporelles

Séries temporelles : Tendances

Séries temporelles : I(0)

Séries temporelles autorégressives d'ordre 1 AR(1)

Test d'autocorrélation AR(1)

Application : Capital Asset Pricing Model

Traitement de l'autocorrélation

Application : Capital Asset Pricing Model

- ▶ Modèle d'évaluation des actifs financiers (MEDAF)
- ▶ Suppose que tout investisseur compose son portefeuille d'actifs en équilibre entre sa rentabilité et son risque
 - ▶ Investisseur au sens large, p.e. entreprise multiproduit
 - ▶ Risque = variance de la rentabilité (return)
- ▶ D'où chaque investisseur détient un portefeuille dit **mean variance efficient**
 - ▶ qui donne le return maximum pour un niveau de risque donné : le risque maximum accepté par l'investisseur
- ▶ Si
 1. Tous les investisseurs ont les mêmes croyances sur les risques et les returns
 2. Il n'y a pas de coût de transaction

Alors, le portefeuille de marché (la somme de tous les portefeuilles individuels) doit **aussi** être mean variance efficient

Formalisation

- ▶ Si le marché est mean variance efficient,
 - ▶ alors le **return espéré d'un actif individuel est une proportion du return espéré du marché** :

$$E(r_{jt} - r_f) = \beta_j E(r_{mt} - r_f)$$

- ▶ où r_{jt} est le return (risqué) sur l'actif j dans la période t
- ▶ r_{mt} est le return du marché en t
- ▶ r_f est le return sans risque (p.e. bon d'état)
 - ▶ La différence espérée $r_{jt} - r_f$ est une rémunération du risque
- ▶ β_j = facteur de proportionnalité (inconnu)
 - ▶ indique comment des fluctuations du marché affectent le return de l'actif j
 - ▶ β_j = volatilité de l'actif / celle du marché : $\beta_j = \frac{\text{cov}(r_{jt}, r_{mt})}{\text{var}(r_{mt})}$

CAPM comme modèle économétrique

- ▶ On n'observe pas les espérances E mais seulement les cours réalisés
- ▶ Hypothèse d'espérances rationnelles
 - ▶ en moyenne les agents ne se trompent pas

Définitions

Return **inespéré de l'actif j** $\mu_{jt} = r_{jt} - E(r_{jt})$

Return inespéré du **marché** $\mu_{mt} = r_{mt} - E(r_{mt})$

- ▶ Alors modèle de régression sans intercept
 - ▶ $r_{jt} - r_f = \beta_j (r_{mt} - r_f) + \varepsilon_{jt}$
 - ▶ avec $\varepsilon_{jt} = \mu_{jt} - \beta_j \mu_{mt}$
 - ▶ Pourrait être hétéroscédastique et/ou autocorrélé
 - ▶ Sous espérances rationnelles $E(\varepsilon_{jt}) = 0$
 - ▶ On peut montrer que $(r_{mt} - r_f)$ n'est pas corrélé à ε_{jt}

Estimation

- ▶ Gretl file **capm.gdt**, données Verbeek non-préchargées, disponibles en ligne sur www.econ.kuleuven.ac.be/GME/
 - ▶ 1988 :1 à 1996 :2
- ▶ Returns de 3 grandes entreprises belges sur la bourse de Bruxelles
 - ▶ Pétrofina, Générale de banque, CBR
- ▶ Return du marché = Belgian All Share index
- ▶ Actif sans risque : bons du trésor à 3 mois

Résultats pour Générale de Banque

- ▶ On regarde Générale de Banque : définir les rendements nets
 - ▶ Volatilité Générale (coefficient estimé) : $\hat{\beta}_{gén} = .72$
- ▶ CAPM implique que d'autres régresseurs ne devraient pas être pertinents y-compris une constante
 - ▶ Constante pas significative : conforme à la théorie
 - ▶ Effet Janvier : il existe quelques indications que janvier serait un mois dans lequel les returns seraient plus élevés
 - ▶ pas dans ces données-ci

Résultats pour Générale de Banque

- ▶ Menu modèle → MCO
 - ▶ Remarque : bouton “retards” = retards distribués des régresseurs
 - ▶ DW est en sortie standard : 1.80
 - ▶ avec 98 données & 3 régresseurs, on voit tout de suite qu’on est dans la zone “pas d’autocorrélation”
 - ▶ Peut paraître bizarre, mais la régression porte sur des différences de séries
- ▶ post-estimation menu “tests”
 - ▶ p-critique DW = 15% environ
 - ▶ Autocorrélation AR(x)
 - ▶ Sélectionner x = ordre d’autocorrélation
 - ▶ Plusieurs tests
 - ▶ Sortie MCO modifiée
 - ▶ Tests (fin d’output) : rejette Hét
- ▶ R^2 “moyen” 47%, mais peu de variables explicatives
 - ▶ significativité globale très élevée

Résultats pour CBR

- ▶ $DW < \text{valeur critique}$ [via tools / statistical tables] : autocorrél \oplus
 - ▶ C'est une erreur ?
 - ▶ Voir aussi DW p-value dans postestimation
- ▶ On va voir à présent ce qu'on peut faire

Table des matières

Ch. 4. $\exists t, s : \text{cov}(\varepsilon_t, \varepsilon_s) \neq 0$: Autocorrélation

Définition & conséquences

Causes & exemples

Séries temporelles

Séries temporelles : Tendances

Séries temporelles : I(0)

Séries temporelles autorégressives d'ordre 1 AR(1)

Test d'autocorrélation AR(1)

Application : Capital Asset Pricing Model

Traitement de l'autocorrélation

Moindres Carrés Généralisés

- ▶ Pour autant que l'autocorrélation ne révèle pas un problème plus grave
 - ▶ Régresseur manquant / endogénéité
 - ▶ Série temporelle I(1)
- ▶ On a vu qu'en présence d'autocorrélation
 - ▶ MCO sans biais (si exogénéité stricte, cfr ch. suivant)
 - ▶ MCO ne sont plus de variance minimale
- ▶ On cherche un estimateur qui soit de variance minimale
- ▶ Proposition
 - ▶ Soit le modèle $Y = X\beta + \varepsilon$ avec $\Sigma_\varepsilon = \sigma^2\Psi \neq \sigma^2I$
 - ▶ Alors l'estimateur $\hat{\beta}_{MCG} = [X'\Psi^{-1}X]^{-1}X'\Psi^{-1}Y$ est efficient

Preuve

- ▶ Toute matrice de var-cov est définie positive, donc Ψ aussi
- ▶ Pour toute matrice définie positive, on peut définir une matrice carrée non-singulière non nécessairement unique P t.q.

$$P'P = \Psi^{-1}$$
- ▶ On transforme le modèle : $PY = PX\beta + P\varepsilon \rightarrow Y^* = X^*\beta + \varepsilon^*$
 - ▶ $\Sigma_{\varepsilon^*} = E(\varepsilon^* \varepsilon^{*\prime}) = E(P\varepsilon \varepsilon' P') = PE(\varepsilon \varepsilon')P' = \sigma^2 P\Psi P'$
 - ▶ $P\Psi P' = P(P'P)^{-1}P' = PP^{-1}(P')^{-1}P' = I$
 - ▶ Donc $\Sigma_{\varepsilon^*} = \sigma^2 I$
 - ▶ les données transformées ne sont plus autocorrélées
 - ▶ Et $E(\varepsilon^*) = 0$
 - ▶ Donc MCO appliqué à ces données est efficient

Propriétés des MCG

► L'estimateur des MCG

- $\hat{\beta}_{MCG} = (X^{*'} X^*)^{-1} X^{*'} Y^* = (X' \Psi^{-1} X)^{-1} X' \Psi^{-1} Y$
- est BLUE
- suit asymptotiquement une loi normale centrée en β et de variance

$$\Sigma_{\hat{\beta}_{MCG}} = \sigma^2 (X^{*'} X^*)^{-1} = \sigma^2 (X' \Psi^{-1} X)^{-1}$$

- Les MCO sont un cas particulier des MCG pour $\Psi = I$

Appliquer les MCG

- ▶ Dans la pratique on ne connaît pas Ψ
 - ▶ Il faut l'estimer dans une première étape.
- ▶ Les tests d'hypothèses des MCO peuvent être directement appliqués au modèle transformé.
- ▶ Le R^2 n'est plus comparable à celui des MCO
 - ▶ \exists plusieurs alternatives (non développées ici)

MCG faisables

- ▶ Pour appliquer les MCG, on suit 3 étapes
 - ▶ Estimation de Ψ : $\hat{\Psi}$
 - ▶ Transformer les données
 - ▶ Appliquer MCO aux données transformées
- ▶ L'ensemble s'appelle MCG faisables
 - ▶ Parfois MC “quasi-généralisés”
- ▶ Rem. La première étape introduit des paramètres estimés (avec erreur) dans la deuxième étape.

Application des MCGF aux erreurs AR(1)

▶ AR(1) : $\varepsilon_t = \rho\varepsilon_{t-1} + \mu_t$

▶ $|\rho| < 1$

▶ $\mu_t \sim iid(0, \sigma_\mu^2)$

▶ $\Sigma_\varepsilon = \sigma_\varepsilon^2 \begin{pmatrix} 1 & \rho & \rho^2 & \dots & \rho^{T-1} \\ & 1 & \rho & \dots & \rho^{T-2} \\ & & \ddots & & \vdots \\ & & & 1 & \rho \\ \text{sym} & & & & 1 \end{pmatrix} = \sigma_\varepsilon^2 \Psi$

Application des MCGF aux erreurs AR(1)

- ▶ Applique MCO $\rightarrow \hat{\varepsilon}$
- ▶ On estime $\hat{\varepsilon} = \rho \hat{\varepsilon}_{-1} + v$ avec $\hat{\varepsilon}_{-1} =$ vecteur des $\hat{\varepsilon}_{t-1}$ comme indiqué dans Durbin-Watson $\rightarrow \hat{\rho}$
- ▶ L'estimation de Ψ est alors

$$\hat{\Psi} = \begin{pmatrix} 1 & \hat{\rho} & \hat{\rho}^2 & \dots & \hat{\rho}^{T-1} \\ & 1 & \hat{\rho} & \dots & \hat{\rho}^{T-2} \\ & & \ddots & & \vdots \\ & & & 1 & \hat{\rho} \\ \text{sym} & & & & 1 \end{pmatrix}$$

- ▶ L'estimation MCGF est $\hat{\beta}_{MCGF} = (X' \hat{\Psi}^{-1} X)^{-1} X' \hat{\Psi}^{-1} Y$

Procédure itérative de Cochrane-Orcutt

- ▶ On itère MCGF :
 - ▶ Avec les résidus MCGF $\hat{\varepsilon}_{MCGF} = Y - X\hat{\beta}_{MCGF}$
 - ▶ on calcule une nouvelle estimation de ρ : $\hat{\rho}_1$
 - ▶ Avec $\hat{\rho}_1$ on calcule une nouvelle estimation MCGF des coefficients
 - ▶ On itère jusqu'à ce que les coefficients estimés ne changent plus
- ▶ En principe, pas d'avantage à itérer, l'estimateur a toujours les mêmes propriétés
 - ▶ Mais beaucoup de logiciels proposent la procédure Cochrane-Orcutt
- ▶ Prais-Winsten est une procédure équivalente à Cochrane-Orcutt

Procédure de balayage de Hildreth-Lu

- ▶ Première étape : Statistique de Durbin-Watson
 - ▶ Autocorrélation positive $\hat{\rho}_0 > 0$ ou négative $\hat{\rho}_0 < 0$
- ▶ Deuxième étape : Régression pour l'intervalle des valeurs possibles de ρ
 - ▶ Si $\hat{\rho}_0 > 0$ alors on “balaie” (on en essaie plusieurs) sur des valeurs de ρ sur $[0,1]$
 - ▶ Si $\hat{\rho}_0 < 0$ alors on balaie sur des valeurs de ρ sur $[-1,0]$
- ▶ On retient la valeur de ρ qui minimise la somme des carrés des résidus en balayant l'intervalle avec un pas correspondant au degré de précision désiré
- ▶ Gretl : Cochrane-Orcutt, Prais-Winsten, Hildreth-Lu accessibles via “modèle” “séries temporelles”

Propriétés de MCGF

- ▶ Si l'estimateur de ρ est consistant
 - ▶ l'estimation en 2 étapes MCGF est **asymptotiquement** équivalente à utiliser le vrai paramètre ρ
- ▶ Les propriétés à échantillon fini de l'estimateur MCGF sont inconnues dans le cas général.
 - ▶ N'est plus «sans biais»
 - ▶ Les statistiques de tests ne sont que des approximations du fait de l'approximation de ρ par $\hat{\rho}$
- ▶ Différentes études (Monte-Carlo) montrent que MCGF est **souvent plus efficace** que MCO
 - ▶ mais, si le problème d'autocorrélation n'est pas trop grave, MCO peut être plus efficace que MCGF sur **petits** échantillons
- ▶ Si erreur sérieuse sur la forme de l'autocorrélation
 - ▶ $\hat{\rho}$ n'est pas un estimateur consistant de ρ (mauvaise spécification)
 - ▶ Peut induire inconsistance de MCGF alors que MCO consistant

Application CAPM : Résultats pour CBR

- ▶ On a vu : $DW < \text{valeur critique}$ [via tools / statistical tables] : autocorrél \oplus
- ▶ MCGF dans Gretl : Cochrane-Orcutt, Prais-Winsten, Hildreth-Lu
 - ▶ accessibles via menu modèle \rightarrow séries temporelles \rightarrow AR(1)
 - ▶ menu modèle \rightarrow séries temporelles \rightarrow modèle autorégressif = Cochrane-Orcutt avec des AR(x)