

## 3.2. L'économétrie des séries chronologiques : Quelques concepts des bases

### 3.2.1. Les concepts clés

Processus stochastiques, processus de stationnarité, processus purement aléatoires, processus non stationnaires, variables intégrées, modèles à marche aléatoire, cointégration, tests de racine unitaire.

### 3.2.2. Les processus stochastiques

Processus stochastique ou aléatoire = ensemble de variables aléatoires ordonnées dans le temps.

Exemple : données trimestrielles relatives au PIB américain sur la période 1970 - 1991.

Si  $Y$  représente le PIB  $\rightarrow Y_1, Y_2, Y_3, \dots, Y_{80}, Y_{81}, Y_{82}$   
où indice 1 correspond à la 1ère observation (PIB du 1er trimestre de 1970) et indice 89 à la dernière observation (PIB du 4ème trimestre de 1991).

PIB : un processus stochastique ?

Soit  $PIB = 2872$  milliards \$ au 1er trimestre de 1971

Théoriquement, il aurait pu prendre n'importe quelle valeur dépendant du climat pol. et éco. du moment.

Chiffre 2872 = réalisation particulière de toutes les possibilités.

$\rightarrow$  PIB = processus stochastique et valeurs observées (et 1970 & 1991 sont une réalisat° particulière de ce processus).

Distinction tel processus stochastique et sa réalisation est voisine de celle tel population et échantillon de données en cross-section.

De m<sup>me</sup> qu'on utilise les données d'un échantillon pour tirer des col concernant une pop., ou utilise des séries chronol. pour tirer des col. concernant un processus stochastique sous-jacent.

### 3.2.3. Les processus stochastiques stationnaires

Un processus stoch. est dit faiblement stationnaire (ou stat. de la covariance, ou stat. du 2nd ordre, ou stat. au sens large) si sa moyenne et sa variance sont constants dans le temps et si la valeur de la covariance tel 2 périodes de temps ne dépend que de la distance ou de l'écart tel ces deux périodes et non pas du moment auquel la covariance est calculée.

Un processus est rigoureusement stationnaire si tous les moments de sa distribution de probabilité (et pas seulement les 2 premiers moments) sont invariants dans le temps.

Ds suite du cours, par séries stat., on sous-entend séries faiblement stationnaires (car dans majorité des situations pratiques, ce type de stat. est suffisant pour faire des régress. avec des données temporelles).

## Faible stationnarité ?

Soit  $Y_t$  une série temporelle avec les propriétés suivantes :

$$\text{Moyenne : } E(Y_t) = \mu$$

$$\text{Variance : } \text{var}(Y_t) = E(Y_t - \mu)^2 = \sigma^2$$

$$\text{Covariance : } Y_k = E[(Y_t - \mu)(Y_{t+k} - \mu)]$$

où  $Y_k$  = (auto)covariance au décalage  $k$

si  $k = 0 \rightarrow Y_0$  = variance de  $Y$  ( $= \sigma^2$ )

si  $k = 1 \rightarrow Y_1$  = covariance des 2 valeurs contiguës de  $Y$

Imaginons qu'on déplace l'origine de  $Y_t$  à  $Y_{t+m}$   
(p. ex. du 1er trimestre de 1970 au 1er trimestre  
de 1975 pour données // PIB américain).

Si  $Y_t$  (faiblement) stationnaire : moyenne, variance et autocovariances de  $Y_{t+m}$  doivent être identiques à celles de  $Y_t$ .  $\rightarrow$  elles sont identiques quel que soit le point où elles sont mesurées (elles ne varient pas de le temps).

Caractéristiques d'une série (faiblement) stat. : elle tend à retourner à sa moyenne (qu'on appelle la moyenne de retour) et les fluctuations autour de cette moyenne (mesurées par la variance) présentent une amplitude généralement constante.

Série non stat. : moyenne et/ou variance variable(s) dans le temps.

Pq une série chronol. doit - elle être stationnaire ?

Si pas stat., on ne pourra étudier son comportement que pour une période spécifique. Impossible de généraliser les résultats à d'autres périodes. Dans tout prévisionnel, de telles séries ont une valeur très limitée.

Comment savoir si une série est stationnaire ?

Tests de stationnarité (cf. infra)

Analyse visuelle fournit une information pertinente.




Figure 21.1 PIB, RDM et CM, Etats-Unis, 1970-1991 (séries trimestrielles)




Figure 21.2 Profits et dividendes, Etats-Unis, 1970-1991 (trimestriellement)

## Processus purement aléatoire ou de bruit blanc ?

Processus stochastique est purement aléatoire si (s'il) :

- sa moyenne est nulle
- sa variance est constante
- n'est pas corrélé sériellement  
(càd. autocorrélation est nulle pour  $\neq$  retard)

Exemple de bruit blanc :

Terme d'erreur ut ds modèle de rég. linéaire classique normale car  $u_t \sim NID(0, \sigma^2)$

### 3.2.4. Les processus stochastiques non stationnaires

Exemple classique : modèle à marche aléatoire (MMA)

Terme marche aléatoire fait référence à la marche d'un ivrogne sortant d'un bar. Idée : lorsque ivrogne quitte un bar, il marche une distance  $u + t$ , où  $u$  est un terme aléatoire et  $t$  désigne le temps. S'il continue sa marche indéfiniment, il pourrait s'éloigner de + en + du bar.

cf.  $T_k$  de change, cours des actions.

Deux types de MMA :

- i) La marche aléatoire sans tendance  
(càd sans intercepte / terme constant)
- ii) La marche aléatoire avec tendance  
(càd avec intercepte / terme constant)

## A. La marche aléatoire sans tendance

Soit  $u_t$  un terme d'erreur bruit blanc (avec moyenne = 0 et variance constante  $\sigma^2$ ), alors  $y_t$  est une marche aléatoire si :

$$y_t = y_{t-1} + u_t$$

(17.4.1)

Modèle AR(1) : régression de  $Y$  au temps  $t$  sur sa valeur retardée d'une période.

cf. hyp. d'efficience des marchés : prix des actions sont avant tout aléatoires (pas de place pour la spéculat°).

Intuition : si ns pouvions prévoir le prix des actions de demain sur base de celui d'aujourd'hui, ns serions tous millionnaires.

A partir du modèle à marche aléatoire, on a que :

$$y_1 = y_0 + u_1$$

$$y_2 = y_1 + u_2 = y_0 + u_1 + u_2$$

$$y_3 = y_2 + u_3 = y_0 + u_1 + u_2 + u_3$$

Si processus débute à la période 0 avec  $y_0$  connue :

$$y_t = y_0 + \sum_{i=1}^t u_i \quad (17.4.2)$$

On peut montrer que :

$$E(y_t) = E\left(y_0 + \sum_{i=1}^t u_i\right) = y_0$$

(17.4.3)

(pq?)

$$\text{var}(Y_t) = t \cdot \sigma^2$$

(17.4.4)

(Pq?)

$\Rightarrow$  Moyenne de  $Y$  = valeur initiale (cste).

Variance croît indéfiniment  $\rightarrow$  pas conforme à une des hyp. de stat.

$\Rightarrow$  MITA sans tendance = processus stochastique non stationnaire.

Caract. imp. des MITA: "persistance des chocs aléatoires"  
(càd. des erreurs aléatoires)

$$Pq? \quad Y_t = Y_0 + \sum_{i=1}^t u_i$$

L'effet d'un choc particulier ne s'éteint pas.

Exemple : si  $u_2 = 2$  alors tous les  $Y_t$  à partir de  $Y_2$  seront supérieurs de 2 unités et l'effet de ce choc ne s'effacera pas.

Une marche aléatoire a une mémoire infinie.

Réécriture :

$$Y_t - Y_{t-1} = \Delta Y_t = u_t$$

(17.4.5)

où  $\Delta$  = opérateur différence première.

Déférence première de  $Y_t$  est stationnaire alors que  $Y_t$  ne l'est pas

$\Rightarrow$   $\Delta$  d'une série chronol. à marche aléatoire sont stationnaires.

### 3. La marche aléatoire avec tendance

Soit  $u_t$  un terme d'erreur bruit blanc (avec moyenne = 0 et variance constante  $\sigma^2$ ) , alors  $Y_t$  est une marche aléatoire avec tendance si :

$$Y_t = \delta + Y_{t-1} + u_t \quad (17.4.6)$$

où  $\delta$  est le paramètre de tendance .

On parle de tendance car en réécrivant le modèle ,  
on voit que :

$$Y_t - Y_{t-1} = \Delta Y_t = \delta + u_t \quad (17.4.7)$$

$\Rightarrow$  variable  $Y_t$  se déporte systématiquement vers  
le haut ou vers le bas selon que la valeur de  
 $\delta$  est positive ou négative (lorsque  $t \uparrow$  d'une unité).

En procédant comme pour MTA sans tendance ,  
on peut montrer que :

$$E(Y_t) = Y_0 + t \cdot \delta \quad (17.4.8)$$

$$\text{Var}(Y_t) = t \cdot \sigma^2 \quad (17.4.9)$$

(Pq ?)

$\Rightarrow$  Moyenne et variance  $\uparrow$  avec le temps

$\Rightarrow$  MTA avec tendance = processus stochastique  
non stationnaire .

### 3.2.5. Les processus stochastiques à racine unitaire

Réécrivons MTA comme suit:

$$Y_t = \rho Y_{t-1} + u_t \quad (17.5.1)$$

où  $-1 \leq \rho \leq 1$

Si  $\rho = 1$   $\rightarrow$  pbme de racine unitaire, c'ds. situation de non stationnarité. Pg? Si  $\rho = 1$ , modèle équivalent à une marche aléatoire (sans tendance)  $\rightarrow \text{var}(Y_t) = t \cdot \sigma^2 \neq \text{cst}$   $\rightarrow$  série chrono. non stat.

Rem: termes „non stat.”, „marche aléat.” et „racine unitaire” sont des synonymes.

Si  $|\rho| < 1$   $\rightarrow$  série chrono.  $Y_t$  est (faiblement) stationnaire.

Pg? Si dans (17.5.1) on suppose que: valeur initiale de  $Y$  ( $Y_0$ ) = 0,  $|\rho| < 1$ ,  $u_t$  un bruit blanc distribué de façon normale avec moyenne nulle et variance unitaire, on peut montrer que :

$$E(Y_t) = 0 \quad \text{et} \quad \text{var}(Y_t) = \frac{1}{(1-\rho^2)} \quad (\text{comme})$$

Ces 2 termes sont des cstes,  $Y_t$  est une série chrono. stationnaire.

(Démonstrat°?)

### 3.2.6. La stationnarité du trend (ST) et la stationnarité différentielle (SD) du processus stochastique

Le processus stochastique (la série) présente-t-il un trend (valeur moyenne de la série change-t-elle à long terme ?) et ce trend est-il déterministe ou stochastique ?

Trend déterministe  $\rightarrow$  entièrement prévisible et non variable

Trend stochastique  $\rightarrow$  imprévisible.

Soit le modèle suivant :

$$Y_t = \beta_1 + \beta_2 t + \beta_3 Y_{t-1} + u_t \quad (17.6.1)$$

où  $u_t$  est terme d'erreur bruit blanc

$t$  est le temps

- Plusieurs situations possibles :

$$1. \underline{\beta_1 = 0, \beta_2 = 0, \beta_3 = 1} : Y_t = Y_{t-1} + u_t \quad (17.6.2)$$

Modèle à marche aléatoire sans tendance

non stationnaire (car  $\text{var}(Y_t) = t \cdot \sigma^2$ )

mais stationnaire en 1<sup>er</sup> différences car

$$\Delta Y_t = u_t \text{ et } E(u_t) = 0, \text{ var}(u_t) = \sigma^2 \text{ (par hyp.)}$$

$\Rightarrow$  MTA sans tendance =

"processus stationnaire différentiel" (SD)

$$2. \quad \underline{\beta_1 \neq 0, \beta_2 = 0, \beta_3 = 1} : \quad Y_t = \beta_1 + Y_{t-1} + u_t$$

Modèle à marche aléatoire (17.6.3)

avec tendance

non stationnaire (car  $E(Y_t) = Y_0 + t \cdot \beta_1$   
et  $\text{var}(Y_t) = t \cdot \sigma^2$ )

$$\text{En premières : } \Delta Y_t = \beta_1 + u_t \quad (17.6.4)$$

$\Rightarrow$  variable  $Y_t$  présente trend positif

si  $\beta_1 > 0$  et négatif si  $\beta_1 < 0$ .

$\Rightarrow$  trend stochastique.

MTA avec tendance = „processus stationnaire différencié“ (SD)

Pq ?

Moyenne et variance de  $\Delta Y_t$  sont constantes

$$(\text{car } E(\Delta Y_t) = \beta_1)$$

$$\begin{aligned} \text{var}(\Delta Y_t) &= E[(\Delta Y_t - E(\Delta Y_t))^2] \\ &= E[\beta_1 + u_t - \beta_1]^2 \\ &= \sigma^2 \end{aligned} \quad )$$

3.  $\beta_1 \neq 0, \beta_2 \neq 0, \beta_3 = 0$  :  $Y_t = \beta_1 + \beta_2 t + u_t$

Modèle avec un trend déterministe (17.6.5)  
non stationnaire

Pq ?

$$\begin{aligned}\text{Variance cste : } \text{var}(Y_t) &= E[Y_t - E(Y_t)]^2 \\ &= E[\beta_1 + \beta_2 t + u_t - (\beta_1 + \beta_2 t)]^2 \\ &= E(u_t)^2 = \sigma^2\end{aligned}$$

$$\text{Moyenne } \neq \text{cste} : E(Y_t) = \beta_1 + \beta_2 t$$

Mais „processus de trend stationnaire“ (ST)

Intuition: Une fois  $\beta_1$  et  $\beta_2$  connus (ou estimés),  
on peut calculer espérance mathématique (ou valeur  
moyenne) de  $Y_t$ . Si on soustrait de  $Y_t$  sa valeur  
moyenne pour chaque valeur de  $t$ , on obtient  
une série chronologique stationnaire.

Pq ?

$$E(Y_t) = \beta_1 + \beta_2 t \Rightarrow Y_t - E(Y_t) = u_t$$

et par hyp.  $E(u_t) = 0$  et  $\text{var}(u_t) = \sigma^2$ .

$$4. \underline{\beta_1 \neq 0, \beta_2 \neq 0, \beta_3 = 0} : Y_t = \beta_1 + \beta_2 t + Y_{t-1} + u_t$$

Modèle à marche aléatoire avec (17.6.6)  
 tendance (càd. trend stochastique)  
 et trend déterministe.  $\rightarrow$  non stat.

$$\text{En } \neq \text{ premières : } \Delta Y_t = (Y_t - Y_{t-1}) = \beta_1 + \beta_2 t + u_t \\ \rightarrow \text{processus non stationnaire} \quad (17.6.7)$$

(pdft, processus en  $\neq$  premières ( $\Delta Y_t$ ) est  
 "trend stationnaire" (càd. stat. autour d'un trend  
 déterministe )

$P_q$  ?

$$E(\Delta Y_t) = \beta_1 + \beta_2 t$$

$$\begin{aligned} \text{var}(\Delta Y_t) &= E[(\Delta Y_t - E(\Delta Y_t))^2] \\ &= E[\beta_1 + \beta_2 t + u_t - \beta_1 - \beta_2 t]^2 \\ &= E[u_t]^2 \\ &= \sigma^2 \end{aligned}$$

$\Rightarrow$  si on soustrait de  $\Delta Y_t$  sa valeur moyenne pour chaque valeur de  $t$ , on obtient une série stationnaire.

$$5. \underline{\beta_1 \neq 0, \beta_2 \neq 0, \beta_3 < 0} : Y_t = \beta_1 + \beta_2 t + \beta_3 Y_{t-1} + u_t$$

Modèle avec un trend déterministe et une (17.6.8)  
 composante stationnaire AR(1)

On peut montrer que  $Y_t$  est un processus de "trend stat."  
 Si on soustrait de  $Y_t$  sa valeur moyenne pour chaque valeur de  $t$ , on obtient une série stat.




Figure 21.5 Trend déterministe et stochastique

- Série stochastique : générée par MTA avec tendance

$$Y_t = 0,5 + Y_{t-1} + u_t$$

où 500 valeurs de  $u_t$  ont été tirées de façon aléatoire à partir d'une distribution normale standard et où valeur initiale de  $Y$  vaut 1.

- Série déterministe : obtenue par modèle avec trend déterministe

$$Y_t = 0,5 \cdot t + u_t$$

où  $u_t$  crée de la même manière que pour série stoch. et  $t$  = le temps (mesuré chronologique).

### Observations:

- Trend déterministe : écarts // à la droite de trend (càd la moyenne non stat.) sont purement aléat. et disparaissent rapidement, ils ne participent pas à l'évolution à LT de la série (qui est entièrement déterminée par composante du trend  $0,5 \cdot t$ )

> Trend stochastique : composante aléatoire qui influence cours de la série  $Y_t$  à moyen voire long terme.

### 3. 2.7. Les processus stochastiques intégrés

Modèle à marche aléatoire = cas particulier d'une catégorie plus générale de processus stochastiques appelés processus intégrés.

Rappel : MMA (avec ou sans tendance) ne sont pas stationnaires mais leurs  $\neq$  premières le sont.

Dès lors, MMA sont des modèles intégrés d'ordre 1, I(1).

Si une série doit être différenciée 2 fois pour qu'elle devienne stationnaire, cette série temp. est intégrée d'ordre 2, I(2).

De manière générale, si une série chronologique (non stationnaire) doit être différenciée "d" fois pour être rendue stationnaire, elle est intégrée d'ordre d, c'ds  $Y_t \sim I(d)$ .

Si une série chronol.  $Y_t$  est stationnaire (au départ, sans être différenciée), elle est intégrée d'ordre 0, c'ds  $Y_t \sim I(0)$ .

Rem:

- Série stationnaire  $\equiv$  série I(0)
- Plupart des séries temporelles sont I(1). Ex: PIB, emploi, coût du travail, stock de K

## Propriétés des séries intégrées ?

Soit trois séries chronologiques  $X_t$ ,  $Y_t$  et  $Z_t$

- a) Si  $X_t \sim I(0)$  et  $Y_t \sim I(1)$ , alors

$$Z_t = (X_t + Y_t) \sim I(1)$$

Une combinaison linéaire où la somme de séries temporelles stat. et non stat. est non stationnaire.

- b) Si  $X_t \sim I(d)$ , alors  $Z_t = (a + b \cdot X_t) \sim I(d)$ , où  $a$  et  $b$  sont des constantes.

Une combinaison linéaire d'une série  $I(d)$  est aussi  $I(d) \implies$  si  $X_t \sim I(0)$ , alors  $Z_t = (a + b \cdot X_t) \sim I(0)$ .

- c) Si  $X_t \sim I(d_1)$  et  $Y_t \sim I(d_2)$ , alors

$$Z_t = (a X_t + b Y_t) \sim I(d_2), \text{ où } d_1 < d_2.$$

- d) Si  $X_t \sim I(d)$  et  $Y_t \sim I(d)$ , alors

$Z_t = (a X_t + b Y_t) \sim I(d^*)$ , où  $d^*$  est généralement égal à  $d$ , mais dans certains cas  $d^* < d$  (cf. "cointégration").

$\implies$  Prudence lorsque'on combine 2 ou plusieurs séries temporelles qui sont intégrées avec des ordres  $\neq$ .

### 3.3.9. Le phénomène de la fausse régression

Soit 2 modèles à marche aléatoire :

$$Y_t = \beta_1 + Y_{t-1} + u_t \quad (17.8.1)$$

$$X_t = \alpha_1 + X_{t-1} + v_t \quad (17.8.2)$$

où on a créé 500 observations de  $u_t$  à partir d'une distribution  $N(0,1)$  et 500 autres à partir d'une distribution  $N(0,1)$ .

$\beta_1$  et  $\alpha_1$  sont des constantes et valeurs initiales de  $X$  et  $Y$  sont nulles.

$u_t$  et  $v_t$  ne sont pas sériellement ni mutuellement corrélés.

Comme il s'agit de marches aléat. avec tendance, nous savons qu'elles :

- ne sont pas stationnaires
- sont intégrées d'ordre 1,  $I(1)$
- présentent des trends stochastiques.

Supposons qu'on régresse  $Y_t$  sur  $X_t$ .

Comme par hypothèse  $Y_t$  et  $X_t$  ne sont pas des processus corrélés, le  $R^2$  de la régression de  $Y$  sur  $X$  devrait être proche de zéro (il ne devrait y avoir aucune relation entre les variables).

## Résultats de la régression :

Variable	Coefficient	Erreur standard	Statistique t
c	-13,2556	0,6203	-21,36856
x	0,3376	0,0443	7,61223

$$R^2 = 0,1044$$

$$d = 0,0121$$

Coeff. de rég. associé à x très sign. malgré que  $R^2$  faible  
 → suggère ∃ relation sign. tel Y et X, alors que par hyp. il n'y en a pas.

Ce phénomène est qualifié de "fausse régression", de "régression absurde" ou de "régression fallacieuse" ("spurious regression"). Décrit pour la 1ère fois par Yule (1962).

Caractère absurde des résultats aurait pu être suspecté à partir de la très faible valeur de la stat. d de Durbin-Watson (qui suggère l'existence d'une forte auto-corrélation du premier ordre).

Selon Granger et Newbold (1974), lorsque  $R^2 > d$ , on peut suspecter que la régression est fausse.

Pour se convaincre du caractère absurde des résultats, régresser  $\Delta Y_t$  sur  $\Delta X_t$ . On trouvera que  $R^2$  pratiquement nul et d de Durbin-Watson proche de 2.

### 3.2.3. Les tests de stationnarité

Deux questions :

- 1) Comment peut-on déterminer si une série chronol. est stationnaire ?
- 2) Si l'on découvre qu'une série est non stationnaire, comment peut-on la rendre stationnaire ?

#### A). L'analyse graphique

Il est tjs utile de représenter une série chronol. graph. et de l'analyser.

Permet d'avoir 1ère idée qt au caractère stationnaire d'une série.

#### B) La fonction d'autocorrélation (FAC) ou le corrélogramme

La FAC au décalage  $k$  ( $\rho_k$ ) :

$$\boxed{\rho_k = \frac{\gamma_k}{\gamma_0}} \quad (17.9.1)$$

= covariance pour le retard  $k$   
variance

$$\text{où } \gamma_k = E[Y_t - E(Y_t)][Y_{t+k} - E(Y_{t+k})]$$

$$\gamma_0 = E[Y_t - E(Y_t)]^2$$

$$\rho_k \in [0, 1]$$

Si on représente  $\rho_k$  pour  $k$  valeurs de  $k$ , on obtient le „corrélogramme de la population”.

En pratique, on ne dispose que d'une réalisation (ou d'un échantillon) d'un processus stochastique  
 $\Rightarrow$  on ne peut calculer que la fct<sup>e</sup> d'auto-corrélation de l'échantillon (FACE)  $\hat{\rho}_k$ .

Nécessite de calculer :

$$\hat{\sigma}_k = \frac{\sum (Y_t - \bar{Y})(Y_{t+k} - \bar{Y})}{n} \quad \begin{matrix} \text{= covariance de l'échantillon} \\ \text{pour décalage } k \end{matrix}$$

$$\hat{\sigma}_0 = \frac{\sum (Y_t - \bar{Y})^2}{n} \quad \begin{matrix} \text{= variance de l'échantillon} \end{matrix}$$

où  $\begin{cases} n = \text{taille de l'échantillon} \\ \bar{Y} = \text{moyenne de l'échantillon} \end{cases}$

$$\text{FACE : } \hat{\rho}_k = \frac{\hat{\sigma}_k}{\hat{\sigma}_0}$$

Représentation graphique des valeurs de  $\hat{\rho}_k$  pour  $k$  valeurs de  $k$  : „corrélogramme d'échantillon“.

- Comment „corrélogramme d'échantillon“ permet-il de déterminer si série temporelle est stationnaire ?

Comparons celui d'un :

- processus purement aléatoire (bruit blanc) :

$$Y_t = u_t \quad \text{où } u_t = \text{bruit blanc.}$$

- processus de marche aléatoire

$$Y_t = Y_{t-1} + u_t$$

i) Corrélogramme d'un processus purement aléatoire  
(bruit blanc)

Autocorrélation	Corrélation partielle	AC	ACP	Stat Q	Prob
1	1	-0,022	-0,022	0,2335	0,629
2	1	-0,019	-0,020	0,4247	0,809
3	1	-0,009	-0,010	0,4640	0,927
4	1	-0,031	-0,031	0,9372	0,919
5	1	-0,070	-0,072	3,4186	0,636
6	1	-0,008	-0,013	3,4493	0,751
7	1	0,048	0,045	4,6411	0,704
8	1	-0,069	-0,070	7,0385	0,532
9	1	0,022	0,017	7,2956	0,606
10	1	-0,004	-0,011	7,3059	0,696
11	1	0,024	0,025	7,6102	0,748
12	1	0,024	0,027	7,8993	0,793
13	1	0,026	0,021	8,2502	0,827
14	1	-0,047	-0,046	9,3726	0,806
15	1	-0,037	-0,030	10,074	0,815
16	1	-0,026	-0,031	10,429	0,843
17	1	-0,029	-0,024	10,865	0,863
18	1	-0,043	-0,050	11,807	0,857
19	1	0,038	0,028	12,575	0,860
20	1	0,099	0,093	17,739	0,605
21	1	0,001	0,007	17,739	0,665
22	1	0,065	0,060	19,923	0,588
23	1	0,053	0,055	21,404	0,556
24	1	-0,017	-0,004	21,553	0,606
25	1	-0,024	-0,005	21,850	0,644
26	1	-0,008	-0,008	21,885	0,695
27	1	-0,036	-0,027	22,587	0,707
28	1	0,053	0,072	24,068	0,678
29	1	-0,004	-0,011	24,077	0,725
30	1	-0,026	-0,025	24,445	0,752

Figure 21.6

Corrélogramme d'un terme d'erreur de type bruit blanc  $\epsilon$ , AC = autocorrelation, ACP = autocorrelation partielle (chapitre 22), Stat. Q = statistique Q, Prob = probabilité.

Création d'un échantillon de 500 termes d'erreur ( $\epsilon$ )  
à partir d'une distribution normale standard.

Corrélogramme établit jusqu'à 30 retards.

Autocorrelations pour  $\neq$  décalages oscillent autour de zéro.

Diagramme illustre le corrélogramme d'une série chronologique stationnaire.

ii) Corrélogramme d'une série à marche aléatoire

$$\text{où } Y_t = Y_{t-1} + u_t$$

Autocorrélation	Corrélation partielle	AC	ACP	Stat Q	Prob
		1 0,992	0,992	493,86	0,000
		2 0,984	0,000	980,68	0,000
		3 0,976	0,030	1461,1	0,000
		4 0,969	0,005	1935,1	0,000
		5 0,961	-0,059	2402,0	0,000
		6 0,953	0,050	2862,7	0,000
		7 0,946	0,004	3317,3	0,000
		8 0,939	0,040	3766,4	0,000
		9 0,932	-0,009	4210,1	0,000
		10 0,927	0,055	4649,1	0,000
		11 0,921	0,018	5083,9	0,000
		12 0,916	0,039	5514,9	0,000
		13 0,912	0,002	5942,4	0,000
		14 0,908	0,056	6367,0	0,000
		15 0,905	0,061	6789,8	0,000
		16 0,902	0,000	7210,6	0,000
		17 0,899	0,006	7629,4	0,000
		18 0,896	0,030	8046,7	0,000
		19 0,894	0,053	8463,1	0,000
		20 0,892	0,013	8878,7	0,000
		21 0,890	-0,041	9292,6	0,000
		22 0,886	-0,040	9704,1	0,000
		23 0,882	-0,044	10113,	0,000
		24 0,878	-0,012	10518,	0,000
		25 0,873	-0,023	10920,	0,000
		26 0,867	-0,041	11317,	0,000
		27 0,860	-0,055	11709,	0,000
		28 0,853	-0,045	12095,	0,000
		29 0,846	-0,010	12476,	0,000
		30 0,839	0,008	12851,	0,000
		31 0,832	-0,006	13221,	0,000
		32 0,825	0,003	13586,	0,000
		33 0,819	-0,006	13946,	0,000

Figure 21.7 à marche


Corrélogramme d'une série temporelle aléatoire. Pour les définitions, voir la figure 21.6

- Autocorrélation pour divers décalages sont très élevées et ce même pour les décalages supérieurs à 33 trimestres.

Corrélogramme typique d'une série non stationnaire : coeff. d'autocorrélat° part d'une valeur très élevée et diminue très progressivement vers zéro lorsque l'écart  $\tau$ .

- iii) Corrélogramme du PIB américain pour lequel on dispose de données trimestrielles (et 1970 & 1991 (jusqu'à 25 retards)

Corrélogramme similaire à celui d'un processus à marche aléatoire (autocorr. part de valeur imp et d'about)



Comment choisir longueur du décalage pour calculer FAC ?

Pas de réponse univoque.

En pratique, on calcule généralement FAC jusqu'au tiers ou au quart de la longueur de la série chronologique. Exemple : PIB américain  $\rightarrow$  88 observations  $\rightarrow$  1er 22 & 23 trimestres de décalage.

c) La signification statistique des coeff. d'autocorrélation

Signification statistique d'un coeff. d'autocorrélat°  $\hat{p}_k$  peut être déterminée à partir de son écart standard.

Bartlett (1946): si une série temp. est pur aléatoire (càd. si elle présente un bruit blanc  $\rightarrow$  moyenne = 0, variance = cst, autocorrélat° = 0) alors :

$$\hat{p}_k \sim N(0, \frac{1}{n}) \quad (\text{asympt.})$$

$$\Rightarrow \text{variable centrée réduite } z = \frac{\hat{p}_k - 0}{\sqrt{\frac{1}{n}}} = \frac{\hat{p}_k}{\sqrt{\frac{1}{n}}} \sim N(0, 1)$$

Cette statistique de test peut être calculée pour une série chronol. donnée.

Règle de décision: si stat. de test calculée est supérieure en valeur absolue à la valeur critique de la distrib. normale standard (pour valeur déterminée de  $\alpha$ ), on rejette l'hyp. nulle (selon laquelle coeff. d'autocorr. = 0) sinon on ne la rejette pas.

Application au PIB américain: tester significativité du coeff. d'autocorrél. pour décalage égal à 10.

$$n = 88, \hat{p}_{10} = 0,638 \Rightarrow z = \frac{\hat{p}_{10}}{\sqrt{\frac{1}{n}}} = \frac{0,638}{\sqrt{\frac{1}{88}}} = 5,98$$

Valeur critique de la distribut normale standard à 5% = 1,96  
 $\Rightarrow$  valeur stat test calculée > valeur critique  $\Rightarrow RH_0$

- Tester l'hyp. jointe que tous les coeff. d'autocorr. jusqu'à  $k$  retards ( $\rho_k$ ) sont simultanément égaux à zéro  
→ utiliser la statistique Q de Box et Pierce (1970).

$$Q = m \cdot \sum_{k=1}^m \hat{\rho}_k^2$$

où  $m$  = taille de l'échantillon

$m$  = longueur du retard

Sert à utiliser pour tester si une série chrono. est un bruit blanc.

Dans gds échant., stat. Q suit approxim. dist. de  $\chi^2$  avec  $m$  degrés de liberté.

Règle de décision: si  $Q$  calculée > valeur critique  $\chi^2$  pour  $\alpha$  choisi  $\Rightarrow$   $H_0$  selon laquelle tous les (vrais) coeff. d'autocorrel. ( $\rho_k$ ) sont simultanément nuls.

- Alternative : statistique LB de Ljung - Box (1978)

$$LB = m(m+2) \sum_{k=1}^m \left( \frac{\hat{\rho}_k}{m-k} \right)^2 \sim \chi^2(m)$$

- Dans petits échantillons, statistique LB présente des propriétés supérieures (càd. une puissance accrue au sens statistique) à la statistique Q.

### 3.2.10. Le test de racine unitaire

Soit l'expression :

$$\boxed{Y_t = \rho Y_{t-1} + u_t} \quad -1 \leq \rho \leq 1 \quad (17.10.1)$$

où  $u_t$  est un terme d'erreur de type bruit blanc.

Si  $\rho = 1$  (càd s'il y a une racine unitaire), expression devient un modèle à marche aléatoire sans tendance qui est un processus stochastique non stationnaire.

$\Rightarrow$  pour tester si une série chrono. est stat., il suffit de régresser  $Y_t$  sur  $Y_{t-1}$  et de tester si valeur estimée de  $\rho$  est stat. égal à 1.

Si on rejette hyp. que  $\rho = 1$ , la série  $Y_t$  est déclarée stationnaire (et inversement).  $\equiv$  idée générale des tests de racine unitaire.

En pratique, soustraire  $Y_{t-1}$  des 2 termes de (17.10.1) :

$$\begin{aligned} Y_t - Y_{t-1} &= \rho Y_{t-1} - Y_{t-1} + u_t \\ &= (\rho - 1) Y_{t-1} + u_t \end{aligned} \quad (17.10.2)$$

$$\Rightarrow \boxed{\Delta Y_t = \delta Y_{t-1} + u_t} \quad (17.10.3)$$

$$\text{où } \delta = (\rho - 1)$$

$\Delta$  = opérateur différence première.

On teste si  $\delta = 0$  (plutôt que si  $\rho = 1$ )

Si on ne peut rejeter que  $\delta = 0 \rightarrow$  on ne peut rejeter que  $\rho = 1 \rightarrow$  il y a une racine unitaire, la série temp. est non stationnaire.

Remarque: si  $\delta = 0$ , on trouve que :

$$\Delta Y_t = \alpha \cdot Y_{t-1} + u_t$$

$$\Rightarrow \boxed{\Delta Y_t = Y_t - Y_{t-1} = u_t} \quad (17.10.4)$$

Differences premières d'une série chron. à marche aléatoire sont stationnaire (car par hyp.  $u_t$  est bruit blanc).

En pratique: on régresse  $\Delta Y_t$  sur  $Y_{t-1}$  et on vérifie si coeff. de pente estimé  $\hat{\delta}$  est sign.  $\neq$  de zéro.

Si  $\hat{\delta}$  pas significativement  $\neq$  de zéro  $\rightarrow Y_t$  est non stat.

Si  $\hat{\delta} < 0 \rightarrow Y_t$  est stationnaire.

(Pq  $\delta < 0$  : pour qu'il y ait stat, il faut que  $\rho < 1$  (car si  $\rho > 1$ , la série temp. est explosive); comme  $\rho = (\delta + 1)$ , pour qu'il y ait stat, il faut que  $\delta < 0$ )

Quel test utiliser pour vérifier si  $\delta$  est signif.  $\neq 0$  (et négatif) ?

A priori, la statistique t habituelle :

$$t = \frac{\hat{\delta} - \delta_0}{\text{es}(\hat{\delta})} \quad \text{où } \delta_0 = \text{valeur de } \delta \text{ sous } H_0$$
$$\Rightarrow t = \hat{\delta} / \text{es}(\hat{\delta})$$

(pdt, Dickey et Fuller (1979) ont montré que sous  $H_0$  selon laquelle  $\delta=0$ , la statistique de test t ne suit plus une distribut° de Student (m̄ ds gds échant., elle n'a donc pas une distrib. asympt. normale) mais elle suit une distribut° de "tau" (dont les valeurs critiques sont supérieures à celles de la distribut° de Student).

Statistique de test tau connue sous le nom de test de Dickey - Fuller (DF).

Valeurs critiques de cette statistique tau, calculées par Dickey - Fuller et MacKinnon, incorporées de plupart des logiciels écon.

Exécution du test du DF implique trois décisions :  
marche aléatoire peut prendre trois formes  
(avec ou sans tendance, avec ou sans trend déterministe)

- Test de DF peut être estimé sous les trois formes suivantes:

1)  $Y_t$  est une marche aléatoire :

$$\Delta Y_t = \delta Y_{t-1} + u_t \quad (17.10.1)$$

2)  $Y_t$  est une marche aléatoire avec tendance :

$$\Delta Y_t = \beta_1 + \delta Y_{t-1} + u_t \quad (17.10.2)$$

3)  $Y_t$  est une marche aléatoire avec tendance et trend déterministe :

$$\Delta Y_t = \beta_1 + \beta_2 t + \delta Y_{t-1} + u_t \quad (17.10.3)$$

où  $t = \text{le temps} / \text{le trend déterministe}$ .

On teste tjs  $H_0 : \delta = 0$  (càd. s'il existe une racine unitaire).

Hypothèse alternative :  $\delta < 0$  (car on écoute possibilité que  $\delta > 0$  car ds ce cas  $\rho > 1 \rightarrow$  série temp. explosive).

Si  $RH_0$   $\rightarrow \delta < 0$ , ce qui signifie que  $Y_t$  est série chrono :

- (i) Stationnaire avec une moyenne nulle si marche aléatoire.
- (ii) Stationnaire avec une moyenne non nulle ( $= \beta_0 / (1 - \rho)$ ) si marche aléatoire avec tendance.
- (iii) Stationnaire autour d'un trend déterministe si marche aléatoire avec tendance et trend déterministe.

Attention:

- a) Valeurs critiques de la stat. "tau" but  $\neq$  pour les 3 spécifications du test de DF.
- b) Ne pas se tromper de spécification du test de DF  
 A priori, difficile de savoir quelle spécification est adéquate  $\rightarrow$  tester les  $\neq$  spécifications du test de DF et analyser les résultats dans leur ensemble.

Exemple: PIB américain tel 1970 & 1991

Résultats des 3 spécifications du test de DF:

$$\begin{cases} \widehat{\Delta PIB}_t = 0,00576 \\ t = (5,7980) \\ R^2 = -0,0152 \\ d = 1,34 \end{cases} \quad PIB_{t-1} \equiv \text{marche aléatoire} \quad (1)$$

$$\begin{cases} \widehat{\Delta PIB}_t = 28,2054 \\ t = (1,1576) \\ R^2 = 0,00056 \\ d = 1,35 \end{cases} \quad PIB_{t-1} \equiv \text{marche aléat. avec tendance} \quad (2)$$

$$\begin{cases} \widehat{\Delta PIB}_t = 190,3857 \\ t = (1,8389) \\ R^2 = 0,0305 \\ d = 1,31 \end{cases} \quad + 1,4776 t \quad - 0,0603 PIB_{t-1} \quad \begin{matrix} / \\ (-1,6209) \end{matrix} \quad \begin{matrix} / \\ (-1,6252) \end{matrix} \quad \begin{matrix} \backslash \\ \text{marche} \\ \text{aléat.} \\ \text{avec} \\ \text{tendance} \\ \text{et trend} \\ \text{détourn.} \end{matrix} \quad (3)$$

(1) :  $\delta_{>0} \rightarrow \hat{P}_{>1}$  (car  $\delta = p-1$ ) : série explosive

(2) et (3) :  $\hat{\delta} < 0 \rightarrow \hat{\rho} < 1$  (car  $\delta = (\rho - 1)$ )

$$\begin{cases} \hat{\rho} = 0,9986 & \text{du modèle (2)} \\ \hat{\rho} = 0,9397 & \text{du modèle (3)} \end{cases} \quad (\rho = \delta + 1)$$

- On ne peut pas rejeter  $H_0$  que  $\delta = 0$  (ou  $\rho = 1$ ) :
  - du modèle (2),  $t = -0,2191$  < valeur critique à 10% qui vaut  $-2,5842$
  - du modèle (3),  $t = -1,6252$  < valeur critique à 10% qui vaut  $-3,1567$

- Conclusion :

On peut conclure sur base de l'analyse graphique, du corrélogramme et du test de Dickey - Fuller, que le PIB américain n'était pas stationnaire sur la période 1970 - 1991.

### A) Le test de Dickey - Fuller augmenté (DFA)

Si terme d'erreur autocorrélé  $\rightarrow$  DFA.

Consiste simplement à "augmenter" les 3 équations de DF en y ajoutant des valeurs décalées de la variable dépendante  $\Delta Y_t$ .

Exemple : modèle à marche aléatoire avec tendance et trend déterministe

$$\text{DFA} = \boxed{\Delta Y_t = \beta_1 + \beta_2 t + \delta Y_{t-1} + \alpha_i \sum_{i=1}^m \Delta Y_{t-i} + \varepsilon_t}$$

où  $\varepsilon_t$  terme d'erreur bruit blanc et  $\Delta Y_{t-1} = (Y_{t-1} - Y_{t-2})$ ,  $\Delta Y_{t-2} = Y_{t-2} - Y_{t-3}$ , etc...

- Nbre de lags à inclure ? Question empirique.  
Rajouter termes décalés jusqu'au moment où il n'y a plus d'autocorrélation.
- Objectif de DFA ? Tester si  $\delta = 0$ .  
Comme stat de test de DFA  $\left[ \tau = \frac{\hat{\delta} - \delta_0}{\text{es}(\hat{\delta})} \right]$  suit une distribut° asympt. que stat de DF, les valeurs critiques sont identiques.
- Application de DFA au PIB américain :

$$\begin{bmatrix} \widehat{\Delta \text{PIB}_t} = 234,97 + 1,89 t - 0,08 \text{ PIB}_{t-1} + 0,36 \Delta \text{PIB}_{t-1} \\ t = (2,38) \quad (2,15) \quad (-2,22) \quad (3,46) \\ R^2 = 0,15 \\ d = 2,09 \end{bmatrix}$$

$$\hat{\delta} = -0,08 (< 0)$$

Rejette pas  $H_0$  selon laquelle  $\delta = 0$   
car  $t = -2,22 <$  valeur critique à 10% (-3,16)

Même après prise en compte de l'autocorrélation,  $\text{ccf} = \text{PIB}$  américain est non stationnaire.

- 3 autres tests de racine unitaire

Exemple : test de Phillips - Perron (1988)  $\rightarrow$  méthodes non paramétriques pour prendre en compte autocorrelat° du terme d'erreur sans ajouter des termes de différence décalés de la variable étalée.

Pq existe-t-il tant de tests de racine unitaire ?

La plupart des tests de racine unitaire ont une faible puissance.

Puissance d'un test = prob. rejeter  $H_0$  lorsqu'elle est fausse

→ puissance d'un test =  $1 - \text{risque seconde espèce } \beta$

$\beta$  = prob. accepter  $H_0$  alors qu'elle est fausse

$\alpha$  = prob rejeter  $H_0$  alors qu'elle est vraie.

Tests de racine unitaire ne rejettent pas assez sur  $H_0$  selon laquelle une série est non stationnaire.

Raisons :

- 1) Puissance d'un test dépend davantage de l'étendue de la période que de la taille de l'échantillon.
- 2) si  $\rho$  légèrement inférieur à 1, test de racine unitaire pourrait conduire à ne pas RH<sub>0</sub>.
- 3) Tests de racine unitaires présentés supposent l'existence d'une seule racine unitaire (càd que la série est I(1)) Il faut utiliser des tests de stat. alternatifs (p.ex. test de Dickey - Pantula (1987)) si plusieurs racines unitaires (p.ex. pour séries I(2)).
- 4) Tests de racine unitaire ne prennent pas en compte les changements structurels (cf. chap. relatif aux variables dummy) dont pouvait faire l'objet une série temp.

### 3.2.11. La transformation des séries temporelles non stationnaires

Pour éviter le pbme de la fausse régression ("spurious regression") qui peut se produire lorsqu'on régresse une série temp. non stat sur une ou plusieurs autres séries temp. non stat, il faut transformer les séries non stat afin de les rendre stat.

Méthode de transformation dépend de si séries temp sont:

i) stationnaires en différences premières  
(SDP ou "difference stationary")

ou

ii) stationnaires par rapport au trend  
(SD ou "trend stationary")

A) Les processus stationnaires en différences premières

Si une série temp. est  $I(1)$ , il suffit de prendre les  $\neq$  premières pour la rendre stationnaire.

De manière générale, si une série temp est  $I(d)$ , où d est un nbre entier, elle doit être différenciée d fois pour être rendue stationnaire.

Exemple: PIB américain qui est  $I(1)$

$$\Delta PIB_t = PIB_t - PIB_{t-1}$$

Soit  $D_t = \Delta PIB_t$ , considérons régr. suivante :

$$\begin{cases} \widehat{\Delta D}_t = 16,0049 + 0,06827 D_{t-1} \\ t = (3,6402) (-6,6303) \\ R^2 = 0,3435 \\ d = 2,0344 \end{cases}$$

Valeur critique de stat tau à 1% = -3,5073.

Valeur statistique  $t (=t)$  calculée ( $= -6,6303$ ) + négative que valeur critique  $\rightarrow H_0$  que  $\beta = 0$  (on rejette  $H_0$  selon laquelle PIB en  $\neq$  premières est non stat.  
 $\rightarrow \Delta PIB \sim I(0)$ .

### B) Les processus stationnaires par rapport au trend

Pour rendre une série stat. autour d'un trend réellement stat., il faut la régresser sur le temps. Résidus de cette régression seront stationnaires.

Explication:

$$Y_t = \beta_1 + \beta_2 t + u_t$$

où  $Y_t$  = série stat. autour d'un trend  $t$  (le temps)

$$\Rightarrow \hat{u}_t = (Y_t - \hat{\beta}_1 - \hat{\beta}_2 t)$$

(ces résidus sont stationnaires : „série temp. dépourvue de trend linéaire“)




Figure 21.1 PIB, RDM et CM, États-Unis [1970-1991] (séries trimestrielles)




Figure 21.9  
Différences premières du PIB américain, 1970-1991 (par trimestre)

- Trend peut ne pas être linéaire :

$$Y_t = \beta_1 + \beta_2 t + \beta_3 t^2 + u_t \quad (\text{trend quadratique})$$

$$\Rightarrow \hat{u}_t = (Y_t - \hat{\beta}_1 - \hat{\beta}_2 t - \hat{\beta}_3 t^2) : \text{,, série temp. dépourvues de trend quadratique"}$$

- Remarques:


Si une série chronol. est stat. en  $\neq$  premières (SDP) et qu'on la traite comme une série stat. autour d'un trend (ST)  $\rightarrow$  série est „sous-différenciée“.

Si une série chronol. est stat. autour d'un trend et qu'on la traite comme une série stat. en  $\neq$  premières  $\rightarrow$  série est „sur-différenciée“.

Les séries temp. macro-éco. sont ultmt + sur stationnaires en  $\neq$  premières (SDP) que stat. autour d'un trend (ST).

3.2.12. La cointégration: la régression d'une série temporelle à racine unitaire sur une autre série temp. à racine unitaire

Si l'on régresse série temp. non stat sur série temp. non stat, cela peut aboutir à une rég. fausse ou absurde.



Relation entre consommation des ménages (CM) et leur revenu disponible (RDM)?

$$CM_t \sim I(1)$$

$$CM_t = \hat{\beta}_1 + \hat{\beta}_2 RDM_t + \hat{u}_t$$

$$\hat{u}_t = CM_t - \hat{\beta}_1 - \hat{\beta}_2 RDM_t$$

Supposons qu'en soumettant résidus  $\hat{u}_t$  à un test de racine unitaire, on conclut qu'il faut RHO que terme d'erreur est non stat.  $\rightarrow$  terme d'erreur stat.,  $I(0)$ .

$\Rightarrow$  Combinaison linéaire de 2 séries temp non stat  $I(1)$  est stationnaire, cæd.  $I(0)$ .

Situation où combinaison linéaire annule les tendances stochastiques des 2 séries.

CM et RDM sont I(1) mais leur épargne (c'est leur revenu moins leur consommation) est I(0).

→ il est pertinent de régresser CM sur RDM car terme d'erreur (l'épargne) est stationnaire

→ régression ni fausse, ni abusée (no "spurious reg").

Lorsque la combinaison linéaire de 2 variables I(1) est stationnaire, on dit que ces 2 variables sont "cointégrées".

D'un point de vue économique, 2 variables seront cointégrées si elles se caractérisent par une relation de long terme (ou d'équilibre).

### Exemple

Théorie quantitative de la monnaie de Fisher met en évidence qu'à long terme :  $M \times V = P \times Q$ .  
(produit de la masse monétaire et de la vitesse de circulation de la monnaie = valeur de l'ensemble des transactions)

### En résumé

Si résidus d'une rég. impliquant des séries I(1) sont stat., on peut faire de l'inférence stat. de manière conventionnelle en utilisant les tests habituels (test en t, F test, etc.)

- Dans langage de la théorie relative à la cointégration :

$$CM_t = \hat{\beta}_1 + \hat{\beta}_2 ROM_t + \hat{u}_t$$

= „régression de cointégration“ et paramètre de pente  $\beta_2$  = „paramètre de cointégration“.

### A) Tester la cointégration

Test d'Engle - Granger (EG) et d'Engle - Granger augmenté (EGA).

Consiste à estimer la relation tel les variables susceptibles d'être cointégrées (p-ex.  $CM_t = \hat{\beta}_1 + \hat{\beta}_2 ROM_t + \hat{u}_t$ ), de sauver les résidus et de vérifier s'ils sont stationnaires à l'aide du test de Dickey - Fuller (DF) ou Dickey - Fuller augmenté (DFA).

Attention: les tests de DF et DFA sont appliqués à des valeurs estimées (les résidus) → les valeurs critiques de Dickey - Fuller et Mackinnon ne sont plus appropriées → il faut se référer aux valeurs critiques d'Engle - Granger (rempres dr + part des logiciels écon.)

Illustration:

$$\left[ \begin{array}{l} \widehat{CM}_t = -171,4412 + 0,9672 RDM_t \\ t = (-7,4808) \quad (119,8712) \\ R^2 = 0,9940 \\ d = 0,5316 \end{array} \right]$$

CM et RDM sont  $I(1)$   $\rightarrow$  régr. fallacieuse !

Test de racine unitaire sur les résidus :

$$\left[ \begin{array}{l} \Delta \widehat{u}_t = -0,2753 u_{t-1} \\ t = (-3,7791) \\ R^2 = 0,1422 \\ d = 2,2775 \end{array} \right]$$

Valeur critique (selon tables d'Eugle-Grainger) de la statistique  $T$  ( $=t$ ) à 1% = -2,5899.

Comme stat de test calculée est bien + négative (-3,7791),  $H_0$  selon laquelle les résidus sont non stat.  $\rightarrow$  résidus de la régr. de CM sur RDM sont  $I(0)$ .

On appelle la relation tel CM et RDM la "fonction de consommation statique" ou "de long terme".

Interprétation des paramètres de la régr. de cointégr. ds une optique de long terme  $\rightarrow$  coeff régr. // RDM ( $= 0,9672$ )  $\equiv$  propension Marg à cons (PmC) de LT ou

## B) La cointégration et le mécanisme de correction d'erreurs (MCE)

Les variables CM et RDM sont cointégrées  $\rightarrow$  Il existe une relation de „long terme“ ou d’„équilibre“ tel ces 2 variables.

A court terme, il peut y avoir un déséquilibre.

Il est mesuré par le terme d'erreur  $u_t$  de la régression de cointégration où  $u_t = CM_t - \beta_1 - \beta_2 RDM_t$ .

Terme d'erreur  $u_t$   $\equiv$  „erreur d'équilibre“  $\rightarrow$  mesure l'écart tel la valeur de CM à court terme et à long terme  $\rightarrow u_t$  permet de relier le comportement de court terme de CM à sa valeur de long terme.

A long terme (à l'équilibre),  $u_t = 0$

$\Rightarrow$

Si  $u_t > 0$  : valeur de CM  $>$  à sa valeur d'éq. (de LT).

Si  $u_t < 0$  : valeur de CM  $<$  à sa valeur d'éq. (de LT).

Mécanisme à correction d'erreurs (MCE), développé par Sargan (1984) et diffusé par Engle et Granger, permet de corriger ce déséquilibre.

D'après „théorème de représentation de Granger“, si deux variables X et Y sont cointégrées, la relation tel ces 2 variables X et Y peut être représentée par un modèle à correction d'erreurs (MCE).

## Illustration:

Exemple II à la CM et au RDM.

$$\Delta CM_t = \alpha_0 + \alpha_1 \Delta RDM_t + \alpha_2 u_{t-1} + \varepsilon_t$$

où  $\Delta$ : l'opérateur  $\neq$  première

$\varepsilon_t$ : terme d'erreur aléatoire

$u_{t-1} = (CM_{t-1} - \beta_1 - \beta_2 RDM_{t-1})$  c'est valeur retardée d'une période du terme d'erreur de la régr. de cointegration.

⇒ Équation "type" d'un MCE

$\Delta CM$  dépend de  $\Delta RDM$  et du terme d'erreur d'éq. ( $u_{t-1}$ )

Si terme d'erreur  $u_{t-1} \neq 0 \rightarrow$  modèle n'est pas à l'éq.

Si  $\Delta RDM = 0$  et  $u_{t-1} > 0 \rightarrow$  valeur de  $CM_{t-1} >$  à sa valeur d'éq. (qui est égale à  $\beta_1 + \beta_2 RDM_{t-1}$ ).

On s'attend à ce que  $\alpha_2 < 0$

Pq ?

Lorsque  $u_{t-1} > 0$  et  $\alpha_2 < 0 \rightarrow \alpha_2 \cdot u_{t-1} < 0$   
 $\rightarrow \Delta CM_t < 0$ .

Lorsque  $\alpha_2 < 0$ , le déséquilibre se résorbe progressivement. Autrement dit, valeur de CM qui (initial) est supérieure à sa valeur d'équilibre (car  $u_{t-1} > 0$ ) diminue et converge progressivement vers sa valeur de long terme.

De même, si  $\alpha_2 < 0$  et  $u_{t-1} < 0 \rightarrow \alpha_2 \cdot u_{t-1} > 0$   
 $\rightarrow \Delta CT_t > 0$

Lorsque  $\alpha_2 < 0$ , déséquilibre se resorbe progressivement.  
 Autrement dit, valeur de CM qui (initial) est inférieure à sa valeur d'équilibre (car  $u_{t-1} < 0$ ) augmente et converge vers sa valeur de long terme.

Résultats :

$$\widehat{\Delta CT_t} = 11,6918 + 0,2906 \Delta RDM_t - 0,0867 \hat{u}_{t-1}$$

$$t = (5,3249) \quad (4,1717) \quad (-1,6003)$$

$$R^2 = 0,1717$$

$$d = 1,9233$$

Terme d'erreur d'équilibre pas égal à zéro  $\rightarrow$  suggère que CM s'ajuste uniq. aux variations du RDM à la m<sup>e</sup> période.

Variations à court terme du RDM ont un effet positif et significatif sur les variations à court terme de CM.

$\hat{\alpha}_1 = 0,2906$  peut être interprété comme la propension marginale à consommer (Pmc) de court terme.

La Pmc de long terme est fournie par la régression de co intégration (càd la relation d'éq.) :  $\hat{\beta}_2 = 0,9672$ .