

Économétrie des Données de Panel

Ch 2. Modèles Linéaires Dynamiques

Pr. Philippe Polomé, Université Lumière Lyon 2

M1 APE Analyse des Politiques Économiques
M1 RISE Gouvernance des Risques Environnementaux

2018 – 2019



Introduction

- ▶ Le Ch. précédent a présenté des variantes du MRL avec
 - ▶ des EF ou des EA et
 - ▶ des régresseurs **strictement exogènes**

$$E[\varepsilon_{it} | \alpha_i, x_{i1}, \dots, x_{iT}] = 0, \quad t = 1, \dots, T$$

- ▶ Ce Ch. : Modèles linéaires en relaxant cette hyp.
 - ▶ Régresseurs **endogènes** $E[\varepsilon_{it} | x_{ijt}] \neq 0$ pour au moins un j

Plan

- ▶ Tous les estimateurs de ce Ch. sont des applications de la Méthode Généralisée des Moments (GMM)
- ▶ Cas général linéaire
 - ▶ Rappel en coupe transversale
 - ▶ Disponibilité des instruments en panel
- ▶ 2 applications
 - ▶ Hausman-Taylor
 - ▶ Essayer de récupérer des régresseurs invariants dans le temps
 - ▶ Arellano-Bond
 - ▶ p.e. **variable dépendante retardée**
 - ▶ endogène en panel puisque autocorrélation

Sommaire

Théorie GMM en coupes transversales

GMM linéaire en panel

Estimateur Variable Instrumentale

Modèle Hausman–Taylor

Modèle dynamique

Le principe d'analogie

- ▶ Les estimateurs GMM sont basés sur le principe d'analogie
 - ▶ On suppose une ou pls conditions sur des moments de la population
 - ▶ On trouve des valeurs des paramètres t.q. ces conditions se réalisent dans l'échantillon

Sommaire

Théorie GMM en coupes transversales

Exemples classiques de MM

GMM

GMM linéaire en panel

Estimateur Variable Instrumentale

Modèle Hausman–Taylor

Modèle dynamique

Estimateurs inconsistants ou inefficients

Arellano–Bond

Estimation de la moyenne de la population (espérance)

- ▶ Soit y est d'espérance μ
- ▶ Dans la population $E[y - \mu] = 0$ par définition
 - ▶ Soit un échantillon iid $\{y_i\}$
 - ▶ Remplacer $E[\cdot]$ pour la population par $N^{-1} \sum_{i=1}^N (\cdot)$ pour l'échantillon définit le moment empirique correspondant :

$$\frac{1}{N} \sum_{i=1}^N (y_i - \mu) = 0$$

- ▶ Résoudre pour μ définit l'estimateur MM
$$\hat{\mu}_{MM} = N^{-1} \sum_{i=1}^N y_i = \bar{y}$$
 - ▶ L'estimateur MM de l'espérance est la moyenne de l'échantillon

Régression linéaire en coupe transversale

- ▶ MRL $y = x' \beta + u$
 - ▶ x & β sont des vecteurs $K \times 1$
- ▶ Supposons $E[u|x] = 0$
 - ▶ Par la loi des espérances itérées (law of iterated expectations)
 - ▶ K conditions de moment inconditionnel $E[xu] = 0$
 - ▶ Donc, quand l'erreur a zéro moyenne conditionnelle / est "exogène" / orthogonale

$$E[x(y - x'\beta)] = 0$$

- ▶ Estimateur MM de β = solution de ces mêmes conditions dans l'échantillon

$$\frac{1}{N} \sum_{i=1}^N x_i (y_i - x_i' \beta) = 0$$

- ▶ Ça donne $\hat{\beta}_{MM} = \left(\sum_i x_i' x_i \right)^{-1} \sum_i x_i' y_i$

Estimateur Variable Instrumentale (VI) linéaire

- ▶ Imaginons qu'il y ait endogénéité : $E[u|x] \neq 0$
- ▶ Si on a des instruments z t.q. $E[u|z] = 0$ et
 - ▶ Que ces instruments sont **bons**
 - ▶ fortement corrélés avec les régresseurs
 - ▶ Que $\dim(z) = \dim(x)$: exactement un instrument par régresseur
 - ▶ modèle dit "exactement identifié"
- ▶ Alors $\hat{\beta}_{MM} = \left(\sum_i z_i' x_i \right)^{-1} \sum_i z_i' y_i$ est consistant
 - ▶ alors que $\hat{\beta}_{OLS} = \left(\sum_i x_i' x_i \right)^{-1} \sum_i x_i' y_i$ est inconsistant
 - ▶ $\hat{\beta}_{MM}$ est l'**estimateur Variable Instrumentale VI**
 - ▶ une application du principe MM

Sommaire

Théorie GMM en coupes transversales

Exemples classiques de MM

GMM

GMM linéaire en panel

Estimateur Variable Instrumentale

Modèle Hausman–Taylor

Modèle dynamique

Estimateurs inconsistants ou inefficients

Arellano–Bond

Conditions de Moments supplémentaires

- ▶ Des moments/instruments **additionnels** peuvent améliorer **l'efficience**
 - ▶ mais demande une adaptation de MM
- ▶ Considérons que $\dim(z) > \dim(x)$
 - ▶ plus d'instruments que de régresseurs
- ▶ Quels instruments prend-t-on ? Toute sélection est **arbitraire**
 - ▶ soit z_1 et z_2 deux sous-ensembles de z t.q.
 $\dim(z_1) = \dim(z_2) = \dim(x)$
 - ▶ Alors, $\hat{\beta}_{MM1} = (Z_1'X)^{-1} Z_1'Y \neq (Z_2'X)^{-1} Z_2'Y = \hat{\beta}_{MM2}$

Définition GMM

- ▶ Si on écrit les conditions de moment

$$E \left[Z \left(y - X' \beta \right) \right]$$

- ▶ Donc : plus de conditions que de paramètres à estimer
- ▶ L'estimateur GMM **choisit** $\hat{\beta}$ de sorte à ce que le vecteur de conditions de moments dans l'échantillon

$$\frac{1}{N} \sum_i z_i \left(y_i - x_i' \beta \right)$$

soit aussi petit que possible en termes quadratiques

- ▶ C'est-à-dire $\hat{\beta}_{GMM}$ **minimise** :

$$Q_N(\beta) = \left[\frac{1}{N} \sum_i z_i \left(y_i - x_i' \beta \right) \right]' \mathbf{W}_N \left[\frac{1}{N} \sum_i z_i \left(y_i - x_i' \beta \right) \right]$$

où \mathbf{W}_N est une matrice de poids dépendant de l'application

Comment choisir \mathbf{W}_N ?

- ▶ Soit $\dim(z) = r$; \mathbf{W}_N est $r \times r$, sdp et ne dépend pas de β
- ▶ Essentiellement, \mathbf{W}_N est un choix de pondération des instruments
 - ▶ Pour retrouver k instruments pondérés
- ▶ Tout choix de \mathbf{W}_N définit un estimateur consistant
 - ▶ mais avec différentes variances (quand $r > k$)
- ▶ GMM spécifie le choix **optimal** de la matrice de poids \mathbf{W}_N
 - ▶ selon chaque cas particulier (autocorrélation, hétéroscédasticité)
 - ▶ t.q. $\hat{\beta}_{GMM}$ a la plus **petite variance asymptotique**
 - ▶ 3 cas en panel

Sommaire

Théorie GMM en coupes transversales

GMM linéaire en panel

Estimateur Variable Instrumentale

Modèle Hausman–Taylor

Modèle dynamique

Hypothèses Panel

- ▶ Soit le modèle linéaire en panel

$$y_{it} = x_{it}\beta + u_{it} \quad (1)$$

x_{it} peut contenir des régresseurs invariants dans le temps et un intercept

- ▶ Pour le modèle de cette section, simplification :
 - ▶ **pas d'effet individuel** α_j
 - ▶ x_{it} comprend **seulement** des variables de la période courante
 - ▶ Pas de retard
 - ▶ On peut voir cette simplification comme si les données étaient transformées
 - ▶ comme dans le Ch. 1 avec les estimateurs $\tilde{\cdot}$
- ▶ En **gras** on empile les T observations pour le $i^{\text{ème}}$ agent

$$\mathbf{y}_i = \mathbf{X}_i\beta + \mathbf{u}_i \quad (2)$$

EF et EA avec endogénéité

- ▶ Temporairement on remet les α_i
 - ▶ le modèle (1) $y_{it} = x_{it}\beta + u_{it}$ devient

$$y_{it} = \alpha_i + \mathbf{x}'_{it}\beta + \epsilon_{it} \quad (3)$$
- ▶ Certains régresseurs dans x_{it} sont supposés **endogènes**, donc $E[\mathbf{x}_{it}(\alpha_i + \epsilon_{it})] \neq 0$
 - ▶ On appelle **EA** si \exists instruments Z_i t.q. $E[\mathbf{Z}'_i(\alpha_i + \epsilon_{it})] = 0$
 - ▶ Alors on applique GMM selon les formules présentées + loin
 - ▶ On appelle **EF** s'il est **seulement** possible de trouver des instruments t.q. $E[\mathbf{Z}'_i\epsilon_{it}] = 0$, mais $E[\mathbf{Z}'_i\alpha_i] \neq 0$
 - ▶ Dans ce cas, il faut éliminer les EF α_i par différentiation comme dans le Ch. 1
 - ▶ et seuls les coefficients des régresseurs variables dans le temps sont identifiés
 - ▶ C'est la même discussion qu'au Ch. 1

Conditions de moment GMM en panel

- ▶ On revient au modèle sans les α_i
 - ▶ Donc on est soit en EA, soit en EF après élimination des α_i
- ▶ On suppose une matrice $T \times r$ d'instruments Z_i
 - ▶ $r \geq K$ est le nbr d'instruments / conditions de moment t.q.

$$E \left[\mathbf{Z}_i' \mathbf{u}_i \right] = 0 \quad (4)$$

- ▶ L'estimateur GMM basé sur ces conditions **minimise** une forme quadratique : $\hat{\beta}_{PGMM} =$

$$\left[\left(\sum_i \mathbf{x}_i' \mathbf{z}_i \right) \mathbf{W}_N \left(\sum_i \mathbf{z}_i' \mathbf{x}_i \right) \right]^{-1} \left(\sum_i \mathbf{x}_i' \mathbf{z}_i \right) \mathbf{W}_N \left(\sum_i \mathbf{z}_i' \mathbf{y}_i \right)$$

- ▶ Cet estimateur est consistant pour autant que les conditions de moment (4) tiennent
 - ▶ 3 cas

Cas 1. Panel GMM juste identifié

- ▶ Dans ce cas $r = K$, donc $\dim(z) = \dim(x)$
 - ▶ alors $\hat{\beta}_{PGMM}$ **se simplifie** en l'estimateur **VI** quel que soit \mathbf{W}_N

$$\hat{\beta}_{VI} = \left[\left(\sum_i \mathbf{x}'_i \mathbf{z}_i \right) \right]^{-1} \left(\sum_i \mathbf{z}'_i \mathbf{y}_i \right)$$

- ▶ On voit bien que c'est la version panel de $\hat{\beta}_{VI} = (\mathbf{X}'\mathbf{Z})^{-1} \mathbf{Z}'\mathbf{Y}$
- ▶ S'il y a des régresseurs exogènes
 - ▶ Ils sont leurs propres instruments
- ▶ Si $r > K$: plus d'instruments que de régresseurs
 - ▶ Il faut utiliser la formule avec la matrice de poids \mathbf{W}_N
 - ▶ Il y a 2 cas (diapos suivantes)

Cas 2. estimateur 2SLS – MC2E

- ▶ Hyp. pas d'hétéroscédasticité & pas d'autocorrélation

- ▶ $\hat{\beta}_{2SLS} = \left[\mathbf{X}'\mathbf{Z} (\mathbf{Z}'\mathbf{Z})^{-1} \mathbf{Z}'\mathbf{X} \right]^{-1} \mathbf{X}'\mathbf{Z} (\mathbf{Z}'\mathbf{Z})^{-1} \mathbf{Z}'\mathbf{y}$

- ▶ Un estimateur PGMM suridentifié optimal

- ▶ Pourquoi MC en 2 étapes ?

- ▶ Étape 1. Éq. d'instrumentation

- ▶ Chaque régresser **endogène** x_j est régressé sur **tous** les instruments Z et tous les régresseurs exogènes X_{-j} :

$$x_j = Z\gamma_j + X_{-j}\delta_j + \mu_j$$

- ▶ Les valeurs prédites $\hat{x}_j = Z\hat{\gamma}_j + X_{-j}\hat{\delta}_j$ sont des instruments valides pour les x_j endogènes
 - ▶ Étape 2. y est régressé sur les valeurs prédites \hat{x}_j

Cas 3. estimateur "2-Step GMM"

- ▶ Possible hétéroscédasticité et/ou autocorrélation
 - ▶ Estimateur **robuste**
- ▶ $\hat{\beta}_{2SGMM} = \left[\mathbf{X}' \mathbf{Z} \hat{\mathbf{S}}^{-1} \mathbf{Z}' \mathbf{X} \right]^{-1} \mathbf{X}' \mathbf{Z} \hat{\mathbf{S}}^{-1} \mathbf{Z}' \mathbf{y}$
 - ▶ $\hat{\mathbf{S}} = \frac{1}{N} \sum_i \mathbf{Z}'_i \hat{\mathbf{u}}_i \hat{\mathbf{u}}'_i \mathbf{Z}_i$ est un estimateur robuste de type White
 - ▶ $\hat{\mathbf{S}}$ est consistant pour la matrice $r \times r$ $\mathbf{S} = \text{plim} \frac{1}{N} \sum_i \mathbf{Z}'_i \mathbf{u}_i \mathbf{u}'_i \mathbf{Z}_i$
 - ▶ C'est l'estimateur GMM en 2 étapes (2-Step GMM)
 - ▶ Premier pas est un estimateur consistant de β comme $\hat{\beta}_{2SLS}$
 - ▶ Ensuite on utilise les résidus $\hat{\mathbf{u}}_i = \mathbf{y}_i - \mathbf{X}_i \hat{\beta}_{2SLS}$ pour calculer $\hat{\mathbf{S}}$
 - ▶ Un estimateur PGMM suridentifié optimal

Panel GMM suridentifié

- ▶ Dans beaucoup d'applications \mathbf{Z}_i est composé de valeurs **retardées** des régresseurs
 - ▶ endogènes &/ou exogènes
- ▶ Imaginons qu'on dispose de r instruments
 - ▶ On peut souvent supposer que le premier retard de chaque régresseur est non-corrélé avec l'erreur courante
 - ▶ donc x_{it-1} est disponible comme instrument **additionnel** pour x_{it}
 - ▶ appelé **exogénéité faible / instruments prédéterminés**
 - ▶ On peut souvent poursuivre ainsi avec 2 retards, 3 retards...
 - ▶ On perd chaque fois une période d'observation, l'efficacité baisse...
 - ▶ mais on augmente le nombre d'instruments, l'efficacité augmente
 - ▶ Le modèle est alors très facilement **suridentifié**
 - ▶ Cela fait que même si on n'a pas d'endogénéité, panel GMM peut être plus efficace que MC

Inférence Panel-robuste

- ▶ $\hat{\beta}_{PGMM}$ est asymptotiquement normal
 - ▶ avec une matrice de var-cov asymptotique compliquée
- ▶ Un estimateur consistant de cette matrice existe
 - ▶ conditionnellement à un choix de \mathbf{W}_N
 - ▶ et on peut supposer l'indépendance entre i
- ▶ Un estimateur robuste de type White existe
 - ▶ Il permet de calculer des et robustes à l'Het. et l'Autoc.
 - ▶ Mais ça n'est pas généralement implémenté dans les logiciels
 - ▶ Sauf pour des cas particuliers (+ loin)
- ▶ Alternativement, Bootstrap est faisable
- ▶ C'est comme dans le Ch. 1

Sommaire

Théorie GMM en coupes transversales

GMM linéaire en panel

Estimateur Variable Instrumentale

Modèle Hausman–Taylor

Modèle dynamique

Estimateur Variable Instrumentale

- ▶ Tous les modèles du Ch. 1 peuvent être estimés en ajoutant des VI
 - ▶ Les instruments sont spécifiés à la fin de la formule
 - ▶ Après un signe |
 - ▶ Séparés par des +
 - ▶ Dans la commande `plm`
- ▶ On écrit, si p.e., le modèle est $y \sim x_1 + x_2 + x_3$
 - ▶ avec x_1 & x_2 endogène et z_1 & z_2 des instruments externes
 - ▶ `formula=y~x1+x2+x3 | x3+z1+z2`
 - ▶ OU bien
 - ▶ `formula=y~x1+x2+x3 | .-x1-x2+z1+z2` (attention au point .)

Estimateur Variable Instrumentale

- ▶ Chaque instrument est conceptuellement associé à son régresseur spécifique
 - ▶ Mais en pratique, tous les instruments sont utilisés pour tous les régresseurs
 - ▶ Les variables exogènes du modèle sont leurs propres instruments
 - ▶ La commande accepte plus d'instrument que de régresseurs, mais n'indique pas comment elle procède
 - ▶ Cfr MC2E
- ▶ Deux estimateurs sont disponibles avec l'arg. [inst.method](#)
 - ▶ [bvk](#), Balestra & Varadharajan-Krishnakumar (1987), le défaut
 - ▶ [baltagi](#), Baltagi (1981)

Application : déforestation amazonienne

Rappel

- ▶ Le fichier de données est en ligne sur le site du cours
- ▶ Données de 1988 à 2015 - on laisse tomber 1988 ama3
 - ▶ États de l'Amazonie légale (un état n'a pas 1988)
 - ▶ 9 états du bassin brésilien de l'Amazonie
- ▶ Modèle CKE

$$y_{it} = \alpha_i + \beta_1 \text{PIB}_{it} + \beta_2 \text{PIB}_{it}^2 + \gamma x_{it} + \epsilon_{it}$$

- ▶ On regarde dans x le PPCDAm
 - ▶ Plano para Prevenção e Controle do Desmatamento na Amazônia legal

PPCDAm

- ▶ Le Plan est actif à partir de 2004
 - ▶ On pourrait imaginer le représenter par une dichotomique
- ▶ On a le budget 2004-2015 complet pour 3 états
 - ▶ Amapá, Mato Grosso, Pará
 - ▶ Parmi lesquels Mato Grosso et Pará sont les 2 gros déforesteurs
 - ▶ On a donc le principal
 - ▶ `PP <- c("Amapá","Mato Grosso","Pará")`
 - ▶ `ama4 <- ama3[ama3$Etat %in% PP,]`
- ▶ Ce plan est en réaction à la déforestation
 - ▶ Donc, c'est un régresseur endogène
 - ▶ On peut imaginer l'instrumenter par sa valeur passée
 - ▶ Mais il faut tenir compte de la structure panel
 - ▶ On passe `ama4` en `pama4`
 - ▶ `Defor_km2~PIBh2010R+PIBSQR+PPCDAm2010R
|PIBh2010R+PIBSQR+lag(PPCDAm2010R)`

Sommaire

Théorie GMM en coupes transversales

GMM linéaire en panel

Estimateur Variable Instrumentale

Modèle Hausman–Taylor

Modèle dynamique

Motivation

- ▶ Habituellement, en panel, l'endogénéité
 - ▶ vient de régresseurs corrélés avec les effets individuels α_i
 - ▶ amène à l'inconsistance des estimateurs EA
- ▶ L'estimateur within est consistant
 - ▶ mais alors les coefficients des régresseurs invariants dans le temps ne peuvent être estimés
 - ▶ alors qu'il y a beaucoup d'études dont ce serait précisément le but

Spécification

- ▶ Modèle Hausman & Taylor

$$y_{it} = \mathbf{x}'_{1it}\beta_1 + \mathbf{x}'_{2it}\beta_2 + \mathbf{w}'_{1i}\gamma_1 + \mathbf{w}'_{2i}\gamma_2 + \alpha_i + \epsilon_{it} \quad (5)$$

où \mathbf{x}_{1it} & \mathbf{w}_{1i} ne sont pas corrélés avec α_i mais \mathbf{x}_{2it} & \mathbf{w}_{2i} le sont
 w indique les régresseurs invariants dans le temps

- ▶ C'est le modèle panel classique
 - ▶ sauf qu'on précise quels régresseurs sont corrélés avec α_i et lesquels sont invariants
 - ▶ Tous les régresseurs sont **non-corrélés** avec ϵ_{it}
- ▶ La transformation **Within** $\ddot{z}_{it} = z_{it} - \bar{z}_i$ élimine la corrélation avec α_i

$$\ddot{y}_{it} = \ddot{\mathbf{x}}'_{1it}\beta_1 + \ddot{\mathbf{x}}'_{2it}\beta_2 + \ddot{\epsilon}_{it}$$

- ▶ Mais aussi les régresseurs invariants dans le temps

Estimateur Hausman–Taylor consistant

- ▶ x_{2i} corrélé avec α_i
 - ▶ mais pas avec la transformation within $\ddot{x}_{2it} = x_{2it} - \bar{x}_{2i}$
 - ▶ Puisque la corrélation avec α_i ne peut être qu'avec la partie de $x_{2it} \forall t$ invariante au temps
 - ▶ Donc \ddot{x}_{2it} peut être utilisé comme **instrument** pour x_{2it} endogène
- ▶ On prend pareillement \ddot{x}_{1it} comme instrument pour x_{1it}
 - ▶ plutôt que x_{1it} lui-même comme on ferait d'habitude
 - ▶ Donc, même x_{1it} exogène est instrumenté
 - ▶ car cela sépare x_{1it} de sa partie invariante au temps \bar{x}_{1i}
 - ▶ Celle-ci (\bar{x}_{1i}) est utilisée comme instrument pour w_{2i} endogène
 - ▶ pourrait être un instrument faible
- ▶ w_{1i} exogène est utilisé comme instrument pour lui-même

Estimateur Hausman–Taylor

$$y_{it} = \underset{\downarrow}{\mathbf{x}'_{1it}}\beta_1 + \underset{\downarrow}{\mathbf{x}'_{2it}}\beta_2 + \underset{\downarrow}{\mathbf{w}'_{1i}}\gamma_1 + \underset{\downarrow}{\mathbf{w}'_{2i}}\gamma_2 + \alpha_i + \epsilon_{it}$$

$$\qquad \qquad \qquad \underset{\downarrow}{\ddot{\mathbf{x}}_{1it}} \qquad \qquad \qquad \underset{\downarrow}{\ddot{\mathbf{x}}_{2it}} \qquad \qquad \qquad \underset{\downarrow}{\mathbf{w}'_{1i}} \qquad \qquad \qquad \underset{\downarrow}{\bar{\mathbf{x}}_{1i}}$$

- ▶ **Identification** des coef. des régresseurs invariants dans le temps γ
 - ▶ si $\#$ régresseurs **exogènes variant dans le temps** $\geq \#$ régresseurs **endogènes invariants dans le temps**
 - ▶ c'est-à-dire si $\#$ de $x_1 \geq \#$ de w_2
 - ▶ C'est-à-dire si $\#$ instruments est au moins égal au $\#$ de régresseurs w_2
- ▶ **Inefficient** puisque cet estimateur ignore la structure de corrélation panel de $(\alpha_i + \epsilon_{it})$

Exemple : Baltagi and Khanti-Akom (1990)

- ▶ 595 obs. d'individus sur 1976–1982
 - ▶ Du Panel Study of Income Dynamics (PSID)

<i>lwage</i>		log-salaire, supposé fonction de :	y	Inst
<i>ed</i>	IT	années d'éducation	w_2	\bar{x}_1
<i>wks</i>	VT	le temps que la personne a travaillé pour la firme	x_2	\ddot{x}_2
<i>exp</i>	VT	expérience de travail		
		si la personne (0/1)		
<i>smsa</i>	VT	... vit dans une grande agglomération	x_1	\ddot{x}_1
<i>bluecol</i>	VT	... est ouvrier		
<i>south</i>	VT	... vit dans le sud		
<i>ind</i>	VT	... est dans l'industrie		
<i>ms</i>	VT	... est mariée	x_2	\ddot{x}_2
<i>union</i>	VT	... est syndiquée		
<i>sex</i>	IT	... est un homme	w_1	w_1
<i>black</i>	IT	... est African-American		

Endogénéité

- ▶ Les IT *sex*, *black* sont exogènes : w_1
- ▶ Les VT *exp*, exp^2 , *wks*, *ms*, *union*
 - ▶ Peuvent tous être corrélés avec les effets individuels inobservés
 - ▶ = sont endogènes
 - ▶ Ces variables présentent-elles suffisamment de variation within-panel pour être leurs propres instruments ?

$$\ddot{x}_{2it} = x_{2it} - \bar{x}_{2i}$$
 - ▶ Il faudrait regarder les variations within / between, mais on manque d'une commande dans R
- ▶ On suppose que les VT *bluecol*, *south*, *smsa*, *ind* sont toutes exogènes : x_1
 - ▶ \bar{x}_1 est utilisé comme instrument pour l'endogène IT *ed* : w_2
 - ▶ L'instrument pour x_1 is \ddot{x}_1
 - ▶ Corrélation suffisante pour identifier le coefficient de *ed* ?

Régression

- ▶ `pht(lwage~wks+south+smsa+married+exp+l(exp^2)
+bluecol+ind+union+sex+black+ed
| sex+black+bluecol+south+smsa+ind
, data=Wages,index=595)`
 - ▶ Donc endog : `exp exp2 wks ms union ed`
- ▶ Décomposition de la variance en σ_μ et σ_ϵ : 0.975 et 0.025, respectivement
 - ▶ indiquant qu'une large fraction de la variance totale de l'erreur est attribuée à μ_i
- ▶ Les variables IT `sex` et `black` ne sont pas signif

Sommaire

Théorie GMM en coupes transversales

GMM linéaire en panel

Estimateur Variable Instrumentale

Modèle Hausman–Taylor

Modèle dynamique

Dynamique

- ▶ Les régresseurs comprennent **un retard** de la variable dépendante

$$y_{it} = \gamma y_{i,t-1} + \mathbf{x}'_{it} \beta + \alpha_i + \epsilon_{it}, \quad i = 1, \dots, N, \quad t = 1, \dots, T \quad (6)$$

- ▶ On suppose $|\gamma| < 1$
 - ▶ Dans les applications, cela peut être testé en utilisant des tests de racines unitaires panel
 - ▶ $\neg R$ racine unitaire, alors y_{it} est une marche aléatoire (random walk)
 - ▶ L'inférence n'est pas valide
 - ▶ Pas dans ce cours

Corrélation entre y_{it} & $y_{i,t-1}$

- ▶ On a à présent une corrélation sérielle dans y_{it}
 - ▶ directement via $y_{i,t-1}$
 - ▶ en plus d'indirectement via la persistance donnée par α_i
 - ▶ Ces 2 causes amènent à **différentes interprétations** de la corrélation dans le temps
- ▶ Du modèle précédent (6) avec $\beta = 0$
 - ▶ $y_{it} = \gamma y_{i,t-1} + \alpha_i + \epsilon_{it}$, on a

$$\begin{aligned} \text{Cor}[y_{it}, y_{i,t-1}] &= \text{Cor}[\gamma y_{i,t-1} + \alpha_i + \epsilon_{it}, y_{i,t-1}] \\ &= \gamma \text{Cor}[y_{i,t-1}, y_{i,t-1}] + \text{Cor}[\alpha_i, y_{i,t-1}] \\ &= \gamma + \frac{1 - \gamma}{1 + (1 - \gamma) \sigma_\epsilon^2 / (1 + \gamma) \sigma_\alpha^2} \end{aligned}$$

- ▶ La 2^o égalité suppose $\text{Cor}[\epsilon_{it}, y_{i,t-1}] = 0$
- ▶ La 3^o égalité s'obtient dans le cas particulier des EA
 - ▶ avec $\epsilon_{it} \sim iid [0, \sigma_\epsilon^2]$ & $\alpha_{it} \sim iid [0, \sigma_\alpha^2]$

2 raisons possible de corrélation entre y_{it} & $y_{i,t-1}$

1. Véritable dépendance à l'état (True state dependence)

- ▶ Quand la corrélation dans le temps est due au mécanisme causal que $y_{i,t-1}$ détermine y_{it}
- ▶ Cette dépendance est relativement grande si
 - ▶ l'effet individuel est relativement petit $\alpha_i \simeq 0$
 - ▶ ou lorsque σ_α^2 est petit par rapport à σ_ϵ^2 car alors

$$\text{Cor}[y_{it}, y_{i,t-1}] \simeq \gamma$$

2. Corrélation **spurieuse** entre y_{it} & $y_{i,t-1}$, sans mécanisme causal,

- ▶ due à de **l'hétérogénéité inobservée** α_i
 - ▶ donc $\gamma = 0$
 - ▶ mais $\hat{\gamma}_{OLS} \neq 0$ car $\text{Cor}[y_{it}, y_{i,t-1}] = \sigma_\alpha^2 / (\sigma_\alpha^2 + \sigma_\epsilon^2)$ comme dans le Ch. 1
- ▶ due à des questions de **séries temporelles** : y_{it} is $I(1)$
 - ▶ Pas dans ce cours

Véritable dépendance à l'état vs. hétérogénéité inobservée

- ▶ Les 2 cas permettent une corrélation arbitrairement proche de 1 (100%)
 - ▶ parce que soit $\gamma \rightarrow 1$ ou $\sigma_{\alpha}^2/\sigma_{\epsilon}^2 \rightarrow 0$
 - ▶ Mais ces 2 explications ont des implications politiques radicalement différentes
 - ▶ On prend l'exemple des revenus y_{it}
- ▶ Explication "Véritable dépendance à l'état"
 - ▶ Les revenus y_{it} sont toujours au-dessus de la moyenne (ou en-dessous)
 - ▶ même après avoir contrôlé pour les régresseurs x_{it}
 - ▶ car les revenus futurs sont déterminés par les revenus passés
- ▶ Explication hétérogénéité inobservée
 - ▶ γ est en réalité petit mais des régresseurs importants ont été **omis** de x_{it} ,
 - ▶ ce qui amène à un α_j élevé
 - ▶ qui fait que $\hat{\gamma}_{LS}$ semble élevé (facteurs confondants)

Véritable dépendance à l'état vs. hétérogénéité inobservée

- ▶ C'est-à-dire, les gens sont-ils pauvres (ou riches) parce que
 - ▶ Ils ont été pauvres (ou riches) ?
 - ▶ Dans ce cas, il faut traiter la pauvreté en transférant de l'argent
 - ▶ Ou bien ont-ils des caractéristiques individuelles qui font qu'ils sont pauvres ?
 - ▶ Dans ce cas, la pauvreté pourrait être traitée par exemple en améliorant l'éducation ou la discrimination, selon les régresseurs significatifs

Sommaire

Théorie GMM en coupes transversales

Exemples classiques de MM

GMM

GMM linéaire en panel

Estimateur Variable Instrumentale

Modèle Hausman–Taylor

Modèle dynamique

Estimateurs inconsistants ou inefficients

Arellano–Bond

Inconsistance des estimateurs du Ch. 1

- ▶ **Tous** les estimateurs du Ch.1 sont **inconsistants** lorsqu'on inclut un retard de la variable dépendante
- ▶ p.e. **MCO** de y_{it} sur $y_{i,t-1}$ et \mathbf{x}_{it}
 - ▶ Erreur $(\alpha_i + \epsilon_{it})$, corrélée avec $y_{i,t-1}$ par α_i
- ▶ Estimateur **Within** : $y_{it} - \bar{y}_i$ sur $(y_{i,t-1} - \bar{y}_i)$ et $(\mathbf{x}_{it} - \bar{\mathbf{x}}_i)$ avec erreur $(\epsilon_{it} - \bar{\epsilon}_i)$
 - ▶ $y_{i,t-1}$ corrélée avec $\epsilon_{i,t-1}$ et donc avec $\bar{\epsilon}_i$
- ▶ Inconsistance aussi pour l'estimateur **EA** du Ch 1
 - ▶ puisqu'il s'agit d'une combinaison linéaire de within et between

Modèle différences premières

- ▶ Le modèle dyn. (6) en diff. premières, $t = 2, \dots, T$:

$$y_{it} - y_{i,t-1} = \gamma (y_{i,t-1} - y_{i,t-2}) + (\mathbf{x}_{it} - \mathbf{x}_{i,t-1})' \beta + (\epsilon_{it} - \epsilon_{i,t-1})$$

- ▶ MCO sur ce modèle est inconsistant parce que $y_{i,t-1}$ corrélé avec $\epsilon_{i,t-1}$
 - ▶ donc le régresseur $(y_{i,t-1} - y_{i,t-2})$ corrélé avec l'erreur $(\epsilon_{it} - \epsilon_{i,t-1})$
- ▶ Donc l'estimateur D1 du modèle dyn, est aussi inconsistant
- ▶ Par contre, on peut utiliser VI
 - ▶ avec $y_{i,t-2}$ comme instrument pour $(y_{i,t-1} - y_{i,t-2})$
 - ▶ $y_{i,t-2}$ instrument valide puisque non-corrélé avec $(\epsilon_{it} - \epsilon_{i,t-1})$
 - ▶ Ça pourrait encore dépendre de la corrélation sérielle des erreurs ϵ_{it}
 - ▶ $y_{i,t-2}$ est un "bon" instrument puisque corrélé à $(y_{i,t-1} - y_{i,t-2})$

Estimation plus efficace du modèle en différences premières

- ▶ L'estimateur VI précédent est **juste identifié**
 - ▶ il demande qu'au moins **3** périodes de données soient disponibles pour chaque individu
- ▶ Une estimation **plus efficace** est possible
 - ▶ En utilisant des retards **supplémentaires** de la variable dépendante comme instruments
 - ▶ L'estimateur devient alors **sur-identifié**
 - ▶ estimation par 2SLS ou 2SGMM

Sommaire

Théorie GMM en coupes transversales

Exemples classiques de MM

GMM

GMM linéaire en panel

Estimateur Variable Instrumentale

Modèle Hausman–Taylor

Modèle dynamique

Estimateurs inconsistants ou inefficients

Arellano–Bond

Estimateur Arellano–Bond

- ▶ L'estimateur panel GMM qui fait ça est appelé

Arellano–Bond $\hat{\beta}_{AB} =$

$$\left[\left(\sum_{i=1}^N \tilde{\mathbf{X}}_i' \mathbf{z}_i \right) \mathbf{W}_N \left(\sum_{i=1}^N \mathbf{z}_i' \tilde{\mathbf{X}}_i \right) \right]^{-1} \left(\sum_{i=1}^N \tilde{\mathbf{X}}_i' \mathbf{z}_i \right) \mathbf{W}_N \left(\sum_{i=1}^N \mathbf{z}_i' \tilde{\mathbf{y}}_i \right)$$

- ▶ avec
 - ▶ $\tilde{\mathbf{X}}_i$ est une matrice $(T-2) \times (K+1)$ avec $t^{\text{ème}}$ ligne $(\Delta y_{i,t-1}, \Delta \mathbf{x}'_{it})$, $T = 3, \dots, T$
 - ▶ $\tilde{\mathbf{y}}_i$ est un vecteur $(T-2) \times 1$ avec $t^{\text{ème}}$ ligne Δy_{it}
 - ▶ On est bien dans le modèle différences premières
 - ▶ \mathbf{Z} est défini à la prochaine diapo

Estimateur Arellano–Bond

- ▶ \mathbf{Z}_i est une matrice $(T - 2) \times r$ d'instruments :

$$\mathbf{Z}_i = \begin{bmatrix} \mathbf{z}'_{i3} & 0 & \cdots & 0 \\ 0 & \mathbf{z}'_{i4} & & \vdots \\ \vdots & & \ddots & 0 \\ 0 & \cdots & 0 & \mathbf{z}'_{iT} \end{bmatrix}$$

avec souvent $\mathbf{z}'_{it} = [y_{i,t-2}, y_{i,t-3}, \dots, y_{i1}, \Delta \mathbf{x}'_{it}]$

- ▶ Donc on rajoute un instrument à chaque période

Estimateur Arellano–Bond

- ▶ Des retards de x_{it} ou de Δx_{it} peuvent de plus être utilisés comme instruments
 - ▶ et pour T suffisamment grand, on peut limiter le nombre de retards de y_{it} qui sont utilisés comme instruments
 - ▶ p.e. pas plus que $y_{i,t-5}$
- ▶ 2SLS (“une” étape) et 2SGMM (“deux” étapes) correspondent à différentes matrices de poids W_N
 - ▶ selon le traitement de l’hétéroscédasticité et de l’autocorrélation
 - ▶ Voir section précédente

Exemple : données Arellano-Bond

- ▶ firm = firm index (index, devrait être un facteur)
- ▶ year = t
- ▶ emp = employment
- ▶ wage = real wage
- ▶ capital = gross capital
- ▶ output = industry output
- ▶ sector de 1 à 9 (devrait être un facteur)

Exemple : Estimateur Arellano-Bond

▶ commande pgmm

- ▶ `pgmm(log(emp)~lag(log(emp), 1 :2)+lag(log(wage), 0 :1)+log(capital)+lag(log(output), 0 :1) | lag(log(emp), 2 :99),...)`
- ▶ `lag`
 - ▶ Dans une commande plm, lag a une signification panel
 - ▶ `lag(log(emp), 1 :2)` = les deux 1^{er} lags de `log(emp)` : $emp_{i,t-1}$ et $emp_{i,t-2}$
- ▶ Instruments
 - ▶ Dans gmm estimation, il y a des instruments "normaux" et des instruments "gmm"
 - ▶ Les instruments gmm sont indiqués en 2^o partie de formule
 - ▶ `lag(log(emp), 2 :99)` veut dire que l'estimateur peut utiliser tous retards de l'endogène – mais 3 :99 ?
 - ▶ Par défaut, toutes les variables du modèles qui ne sont pas des intruments gmm sont des instruments normaux, avec la même structure de retard
 - ▶ Des instruments normaux peuvent être rajoutés dans une 3^o partie de la formule (après un nouveau `|)`

Exemple : Estimateur Arellano-Bond

- ▶ commande pgmm
 - ▶ effect
 - ▶ Par défaut "twoways", mais peut être aussi "individual" et "null"
 - ▶ Si "null", le modèle est estimé en niveaux (permet d'estimer un modèle avec des données en différences 1^o, sinon on imposerait des trends)
 - ▶ Si "individual", le modèle est estimé en différences 1^o pour éliminer les α_i
 - ▶ Si "twoways", le modèle est estimé en différences 1^o et on rajoute des trends
 - ▶ model peut être "onestep" (défaut 2SLS) ou "twosteps" (2SGMM)
 - ▶ "2SLS" assume pas autocorrélation & homoscé.
- ▶ La sortie est assez claire, vous devez pouvoir l'interpréter