

Séance 9 – Travailler sur des comparaisons longitudinales : questions d'estimation

Pierre Pora

Rappel des séances précédentes

- ▶ Ce que l'on a vu jusque là
 - ▶ Pour les premières séances :
 - ▶ Un outil de comparaison **entre des unités d'une même population**
 - ▶ Ces comparaisons sont essentiellement des **comparaisons de moyennes entre des groupes** définis par les variables indépendantes
 - ▶ Quand on observe seulement un **échantillon** et pas la population toute entière, les calculs que l'on fait sur l'échantillon sont **informatifs** quant à ce qui se passe dans la population

Rappel des séances précédentes

- ▶ Ce que l'on a vu jusque là
 - ▶ Pour la **dernière séance** :
 - ▶ En adaptant un tout petit peu l'outil
 - ▶ Et lorsque l'on a des **données où l'on peut suivre les mêmes individus en plusieurs points du temps**
 - ▶ On peut faire de petites adaptations du cadre pour passer de **comparaisons entre individus** (*inter / between / en coupe*) à des **comparaisons longitudinales** (*intra / within*)

Ce que l'on va voir aujourd'hui

- ▶ On sait **interpréter les coefficients** que donnent les régressions linéaires pour ces comparaisons longitudinales
- ▶ On va exprimer un tout petit peu plus abstraitement ces coefficients
- ▶ On va se pencher un peu plus précisément sur l'**estimation** et l'**inférence**
- ▶ En rentrant moins dans les détails que ce que l'on avait fait pour les comparaisons entre individus
 - ▶ Mais quand même...

Partir d'un exemple (toujours le même !)

```
library(AER)
library(bife)

data("psid")

psid[,
  children :=
    as.numeric(
      KID1 > 0
      | KID2 > 0
      | KID3 > 0
    )]
```

Partir d'un exemple (toujours le même !)

- ▶ On veut estimer la régression

$$LFP_{it} = \beta \text{children}_{it} + \lambda_i + u_{it} \text{ avec}$$

- ▶ $\mathbb{E}[\text{children}_{it} u_{is}] = 0$ pour toutes les périodes t et s
 - ▶ Important ! Les résidus doivent ne pas être corrélés avec les covariables des autres périodes

- ▶ $\mathbb{E}[C_i u_{it}] = 0$ pour tous les individus i

- ▶ On n'a **aucune restriction sur les λ_i** , et on sait que le coefficient β s'interprète comme une **moyenne sur la population des femmes mariées de comparaisons longitudinales** (au long de la vie de chaque femme) entre leur activité quand elles ont et n'ont pas d'enfants qui vivent avec elles

Peut-on avoir une écriture formalisée de β ?

- ▶ Pour chaque individu on peut construire
 - ▶ $\bar{Y}_i = \frac{1}{T} \sum_{t=1}^T Y_{it}$
 - ▶ C'est juste le **taux d'activité moyen** de chaque femme sur la **période observée**
 - ▶ $\ddot{Y}_{it} = Y_{it} - \bar{Y}_i$
 - ▶ Et exactement la même chose sur les variables indépendantes X_{it}
 - ▶ Et aussi sur les résidus u_{it}
 - ▶ Evidemment **inobservés** mais on peut toujours raisonner dessus !

Peut-on avoir une écriture formalisée de β ?

- ▶ Si on empile tous les Y_{it} dans un vecteur colonne Y_i de taille T
- ▶ Et qu'on définit la matrice Q comme $Q = I_T - \frac{1}{T}e_T e_T'$
 - ▶ où $e_T = (1 \dots 1)'$
 - ▶ donc $e_T e_T'$ est la matrice carrée de taille T remplie de 1

$$Q := \begin{pmatrix} 1 - \frac{1}{T} & -\frac{1}{T} & \dots & -\frac{1}{T} & -\frac{1}{T} \\ -\frac{1}{T} & 1 - \frac{1}{T} & -\frac{1}{T} & -\frac{1}{T} & -\frac{1}{T} \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ -\frac{1}{T} & -\frac{1}{T} & \dots & 1 - \frac{1}{T} & -\frac{1}{T} \\ -\frac{1}{T} & -\frac{1}{T} & \dots & -\frac{1}{T} & 1 - \frac{1}{T} \end{pmatrix} \begin{matrix} T \text{ lignes} \\ T \text{ colonnes} \end{matrix}$$

Peut-on avoir une écriture formalisée de β ?

- ▶ Avec ces notations $QY_i = \ddot{Y}_i$
- ▶ Et de la même façon $QX_i = \ddot{X}_i$ et $Qu_i = \ddot{u}_i$
- ▶ On en tire $QY_i = QX_i\beta + Qu_i$ avec $\mathbb{E}[(QX_i)'Qu_i] = 0$
 - ▶ Car $\ddot{Y}_{it} = Y_{it} - \frac{1}{T} \sum_{s=1}^T Y_{is}$
 - ▶ Mais $Y_{it} = \lambda_i + X'_{it}\beta + u_{it}$
 - ▶ En substituant $\ddot{Y}_{it} = \ddot{X}'_{it}\beta + \ddot{u}_{it}$
 - ▶ Avec $\mathbb{E}[\ddot{X}_{it}\ddot{u}_{it}] = 0$
 - ▶ Et c'est vrai pour t variant de 1 à T

Peut-on avoir une écriture formalisée de β ?

- ▶ On retombe bien sur nos pieds :
 - ▶ QY_i est un vecteur colonne de taille T
 - ▶ QX_i est une matrice de taille $T \times d$
 - ▶ β un vecteur de colonne de taille d
 - ▶ Qu_i est un vecteur de taille T

Peut-on avoir une écriture formalisée de β ?

- ▶ On retrouve le **même principe que ce qu'on faisait pour les MCO**
 - ▶ On part de $\mathbb{E}[(QX_i)'Qu_i] = 0$
 - ▶ On substitue $\mathbb{E}[(QX_i)'(QY_i - QX_i\beta)] = 0$
 - ▶ Par linéarité $\beta = \mathbb{E}[X_i'Q'QX_i]^{-1}\mathbb{E}[X_i'Q'QY_i]$
 - ▶ A condition que $\mathbb{E}[X_i'Q'QX_i]$ soit bien inversible !
 - ▶ En définitive $\beta = \mathbb{E}[X_i'QX_i]^{-1}\mathbb{E}[X_i'QY_i]$
 - ▶ Car $Q' = Q$ et $Q^2 = Q$

Que dit la condition de rang ?

- ▶ $\mathbb{E}[X_i' Q X_i]$ doit être inversible
 - ▶ Cela revient exactement à dire que $\mathbb{E}[\ddot{X}_i' \ddot{X}_i]$ est inversible
 - ▶ Il doit donc y avoir **indépendance linéaire** des différentes composantes de \ddot{X}_i
 - ▶ Au sens de l'algèbre linéaire une fois encore !
 - ▶ Quand on n'a qu'une dimension, cela revient simplement à dire qu'**il y a des individus qui changent de valeur de X_{it} au cours du temps**
 - ▶ Si ce n'est pas le cas alors $\ddot{X}_i = 0$
 - ▶ Distinction *stayers* / *movers* classique dans la littérature
 - ▶ Les coefficients ne portent (évidemment !) que sur les *movers*

Que dit la condition de rang ?

- ▶ Si on est à plusieurs dimensions alors il faut (en gros) que **les changements individuels n'interviennent pas au même moment pour toutes les dimensions**
 - ▶ C'est tout bête !
 - ▶ Si on suit une population de femmes à qui peuvent arriver deux choses
 - ▶ Se marier
 - ▶ Devenir mères
 - ▶ Si toutes ont leur premier enfant l'année où elles se marient
 - ▶ Alors on ne sait pas quand on fait des comparaisons longitudinales ce qu'il faut mettre sur les différences entre non-mariées et mariées et ce qu'il faut mettre sur les différences entre sans enfants et mères

Et maintenant : l'estimation !

- ▶ On a un échantillon de 1461 femmes observées 9 années consécutives
- ▶ Intuitivement, et du point de vue de l'estimation, qu'est-ce qui va marcher différemment des cas que l'on a étudié auparavant ?

Quel est le régime asymptotique pertinent ?

- ▶ On raisonne toujours dans la **limite d'un grand nombre d'observations**
- ▶ Schématiquement on a **trois raisons d'avoir beaucoup d'observations**
 - ▶ On observe **beaucoup d'individus**
 - ▶ Ici de femmes mariées
 - ▶ On les suit pendant **très longtemps**
 - ▶ Ici beaucoup d'années
 - ▶ **Les deux**
- ▶ Ici c'est clairement la première raison qui compte (*large N*) et pas la seconde (*large T*)

Quelles implications ?

- ▶ Chaque femme supplémentaire de l'échantillon nous donne
 - ▶ **Une comparaison longitudinale de plus à rajouter dans l'estimation de β** (pourvu que son statut change au cours de la période d'observation !)
 - ▶ Un λ_i de plus dans l'équation
 - ▶ Mais aucune information sur les valeurs de λ_i pour les autres femmes

Quelles implications ?

- ▶ On a dit la semaine dernière que la régression revenait à **régresser LFP_{it} sur $children_{it}$ et les indicatrices spécifique à chaque femme**
- ▶ En augmentant la taille de l'échantillon, on rajoute des comparaisons *intra* dont β n'est que la moyenne (avec de bons poids)
 - ▶ Donc on a une **information de plus en plus pertinente sur β**
- ▶ En revanche les λ_i qui seraient juste les coefficients sur les indicatrices **ne bénéficient pas de ce gain en précision !**

Quelles implications ?

- ▶ Pour le dire de façon plus savante
 - ▶ Dans le régime *large N* qui est le plus pertinent ici (et dans la grande majorité des applications en micro-économétrie appliquée)
 - ▶ On va facilement réussir à construire un **estimateur** $\hat{\beta}$ qui **convergera en probabilité vers** β
 - ▶ Et on aura encore des résultats de **normalité asymptotique** (et des tests etc.)
 - ▶ Mais on ne saura jamais rien dire d'intelligent sur les λ_i
 - ▶ **Même quand ce serait intéressant**
 - ▶ Même quand les logiciels de calcul statistique nous fournissent sournoisement des estimations...
 - ▶ Pour ça il faut être en *large T* (c'est logique !)

Comment construire l'estimateur *within* ?

- ▶ Il n'y a rien de difficile
- ▶ Mais la formalisation est quand même un peu pénible !
- ▶ On part d'un **échantillon** de N individus indexés par i , tirés de façon **équiprobable** dans une **grande population (infinie)**
 - ▶ Pour chacun d'entre eux on observe $((Y_{i1}, X_{i1}), \dots, (Y_{iT}, X_{iT}))$
 - ▶ Comme on tire de façon équiprobable dans la même population infinie, les grosses v.a. qui empilent toutes les trajectoires des individus i entre les instants 1 et T sont **indépendantes** et **identiquement distribuées**

Comment construire l'estimateur ? Un petit formalisme matriciel (encore !)

- ▶ Si on repart des grosses écritures matricielles où on empile toutes les observations : \mathbf{X} et \mathbf{Y} qui représentent les observations empilées
 - ▶ D'abord l'observation de l'individu tiré en 1 à la période 1, puis période 2, etc. puis T , puis l'individu tiré en 2 à la période 1 etc.
- ▶ L'équivalent de la matrice Q c'est de récupérer les résidus de la régression sur les indicatrices d'être une observations relative à chaque femme
- ▶ On peut noter \mathbf{C} la matrice dans laquelle on empile les observations de ces indicatrices, avec les observations mises dans le bon ordre

Comment construire l'estimateur ? Un petit formalisme matriciel (encore !)

$$\mathbf{C} := \begin{pmatrix} 1 & 0 & \cdots & 0 & 0 \\ \vdots & \vdots & \cdots & \vdots & \vdots \\ 1 & 0 & \cdots & 0 & 0 \\ 0 & 1 & \cdots & 0 & 0 \\ \vdots & \vdots & \cdots & \vdots & \vdots \\ 0 & 1 & \cdots & 0 & 1 \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & \cdots & 1 & 0 \\ \vdots & \vdots & \cdots & \vdots & \vdots \\ 0 & 0 & \cdots & 1 & 0 \\ 0 & 0 & \cdots & 0 & 1 \\ \vdots & \vdots & \cdots & \vdots & \vdots \\ 0 & 0 & \cdots & 0 & 1 \end{pmatrix} \quad \begin{array}{l} NT \text{ lignes} \\ \\ \\ N \text{ colonnes} \end{array}$$

Comment construire l'estimateur ? Un petit formalisme matriciel (encore !)

- ▶ La matrice \mathbf{C} est la matrice des régresseurs dans les régression sur toutes les indicatrices
 - ▶ Les estimateurs associés à ces régressions sont $(\mathbf{C}'\mathbf{C})^{-1}\mathbf{C}'\mathbf{Y}$ et $(\mathbf{C}'\mathbf{C})^{-1}\mathbf{C}'\mathbf{X}$
 - ▶ Donc les matrices qui empilent les résidus de ces régressions s'écrivent $\ddot{\mathbf{Y}} = (I_{NT} - (\mathbf{C}'\mathbf{C})^{-1}\mathbf{C}') \mathbf{Y}$ et $\ddot{\mathbf{X}} = (I_{NT} - (\mathbf{C}'\mathbf{C})^{-1}\mathbf{C}') \mathbf{X}$

Comment construire l'estimateur ? Un petit formalisme matriciel (encore !)

- ▶ On sait que l'on a $\ddot{Y}_i = \ddot{X}_i\beta + \ddot{u}_i$ avec $\mathbb{E}[\ddot{X}_i'\ddot{u}_i] = 0$
 - ▶ Et donc $\beta = \mathbb{E}[\ddot{X}_i'\ddot{X}_i]^{-1}\mathbb{E}[\ddot{X}_i'\ddot{Y}_i]$
- ▶ On n'a plus qu'à remplacer les espérances par les moyennes empiriques
 - ▶ $\hat{\beta} = (\ddot{\mathbf{X}}'\ddot{\mathbf{X}})^{-1}\ddot{\mathbf{X}}'\ddot{\mathbf{Y}}$
- ▶ Est-ce bien ce qu'on veut ?
 - ▶ $\ddot{\mathbf{X}}'\ddot{\mathbf{X}}$ est une matrice carrée de taille d
 - ▶ $\ddot{\mathbf{X}}'\ddot{\mathbf{X}}_{lm} = \sum_{i=1}^N \sum_{t=1}^T \ddot{X}_{it}^l \ddot{X}_{it}^m$
 - ▶ Donc $\frac{1}{N}\ddot{\mathbf{X}}'\ddot{\mathbf{X}}$ est l'équivalent en moyenne empirique de $\mathbb{E}[\ddot{X}_i'\ddot{X}_i]$
 - ▶ Même raisonnement pour l'autre terme

Est-ce que ça converge vers ce qu'on veut ?

► **Loi faible des grands nombres :**

► $\frac{1}{N} \ddot{\mathbf{X}}' \ddot{\mathbf{X}}$ converge en probabilité vers $\mathbb{E}[\ddot{X}_i' \ddot{X}_i]$

► $\frac{1}{N} \ddot{\mathbf{X}}' \ddot{\mathbf{Y}}$ converge en probabilité vers $\mathbb{E}[\ddot{X}_i' \ddot{Y}_i]$

► donc $\hat{\beta}$ converge en probabilité vers $\beta = \mathbb{E}[\ddot{X}_i' \ddot{X}_i]^{-1} \mathbb{E}[\ddot{X}_i' \ddot{Y}_i]$

Comportement asymptotique

- ▶ On ne va pas refaire tout le détail mais (en gros) on retombe sur le calcul du **comportement asymptotique pour les données groupées !**
 - ▶ Avec des *clusters* définis au niveau de chaque femme
 - ▶ Et c'est juste complètement logique !
 - ▶ **On est bien sur des données groupées** puisqu'on commence par tirer des femmes et ensuite on observe toutes les périodes sur lesquelles on les voit...
- ▶ Remarque : beaucoup d'ouvrages traitent aussi du cas où on ne prend pas en compte le caractère groupé des données mais c'est très peu crédible...

Un résumé rapide

- ▶ Avec un petite réarrangement : $\hat{\beta} - \beta = (\ddot{\mathbf{X}}' \ddot{\mathbf{X}})^{-1} \ddot{\mathbf{X}}' \ddot{\mathbf{u}}$
- ▶ Donc $\sqrt{N} \{ \hat{\beta} - \beta \} = (\frac{1}{N} \ddot{\mathbf{X}}' \ddot{\mathbf{X}})^{-1} \sqrt{N} (\frac{1}{N} \ddot{\mathbf{X}}' \ddot{\mathbf{u}})$
 - ▶ **Loi faible des grands nombres** : le premier terme converge en probabilité vers $\mathbb{E}[\ddot{X}_i' \ddot{X}_i]^{-1} = \mathbb{E}[X_i' Q X_i]^{-1}$
 - ▶ **TCL** : le second terme converge en loi vers $\mathcal{N}(0, \mathbb{E}[X_i' Q u_i u_i' Q X_i])$
 - ▶ **Théorème de Slutsky** : le produit converge en loi vers $\mathcal{N}(0, \mathbb{E}[X_i' Q X_i]^{-1} \mathbb{E}[X_i' Q u_i u_i' Q X_i] \mathbb{E}[X_i' Q X_i]^{-1})$
 - ▶ L'expression est très laide mais on peut **estimer simplement la matrice de variance-covariance asymptotique** par $(\ddot{\mathbf{X}}' \ddot{\mathbf{X}})^{-1} (\ddot{\mathbf{X}}' \ddot{\mathbf{u}} \ddot{\mathbf{u}}' \ddot{\mathbf{X}}) (\ddot{\mathbf{X}}' \ddot{\mathbf{X}})^{-1}$

Une toute petite extension

- ▶ Jusque là on a traité le cas où on suit **tous les individus sur la même période** et où on observe chaque individu autant de fois que les autres
 - ▶ Panel cylindré / *balanced panel*
- ▶ Ca marche exactement pareil pour le cas où le panel n'est pas cylindré
 - ▶ Quand on veut interpréter économiquement / causalement les comparaisons longitudinales, il faut juste parfois prendre garde aux raisons pour lesquelles certains individus sont observés moins longtemps que les autres...

Et en pratique avec R ?

- ▶ C'est la seule question réellement pertinente !
- ▶ Dans la plupart des cas, les *packages* qui font ces estimations proposent par défaut des matrices de variance-covariance
 - ▶ **Au pire** sous hypothèse d'homoscédasticité et sans prise en compte du caractère groupé des données
 - ▶ **Souvent** sans prise en compte du caractère groupé des données
 - ▶ **Ces matrices ne sont pas adaptées à la situation**
 - ▶ On regarde peu d'observations répétées de beaucoup d'individus
 - ▶ La population dans laquelle on tire est définie au niveau des individus pas au niveau des individus \times périodes

Le cas catastrophique

```
reg_longitudinale <-  
  lm(LFP ~ children + factor(ID),  
      data = psid)
```

```
reg_longitudinale$coefficients["children"]
```

```
children  
-0.0522696
```

```
sqrt(vcov(reg_longitudinale)["children","children"])
```

```
[1] 0.01183346
```

Une petite amélioration, et pour finir le bon écart-type

```
sqrt(vcovHC(reg_longitudinale,  
            type = "HC0")["children","children"])
```

```
[1] 0.01123627
```

```
sqrt(vcovCL(reg_longitudinale,  
            cluster = psid$ID,  
            type = "HC0"))["children","children"]
```

```
[1] 0.0156519
```

En pratique avec R

- ▶ Utiliser `lm` en introduisant explicitement les effets fixes dans la régression n'est pas une bonne solution
 - ▶ Pousse à calculer des λ_i qui sont inutilisables et prennent de la capacité de calcul
 - ▶ Les calculs sont vite assez longs
- ▶ **Ma recommandation : utiliser le package `lfe`**
 - ▶ Explicitement fait pour estimer ça !
 - ▶ Peut gérer des effets fixes sur plusieurs dimensions → utile pour vous à terme (cf conclusion de la séance)
 - ▶ On peut préciser qu'on veut la **matrice de variance-covariance groupée** dès le début

Avec le package lfe

```
library(lfe)

reg_longitudinale_lfe <-
  felm(LFP ~ children | ID | 0 | ID,
        data = psid)

coeftest(reg_longitudinale_lfe)
```

t test of coefficients:

	Estimate	Std. Error	t value	Pr(> t)
children	-0.052270	0.015652	-3.3394	0.0008608 ***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Une petite vérification

```
all.equal(  
  as.numeric(reg_longitudinale$coefficients["children"]),  
  as.numeric(reg_longitudinale_lfe$coefficients[1]))
```

```
[1] TRUE
```

```
all.equal(  
  sqrt(vcovCL(reg_longitudinale,  
              cluster = psid$ID, type = "HC0"))["children"],  
  as.numeric(sqrt(vcov(reg_longitudinale_lfe))),  
  scale = 1)
```

```
[1] "Mean absolute difference: 5.952536e-07"
```

Avec le package lfe

```
reg_longitudinale_lfe_mauvaise_vcov <-  
  felm(LFP ~ children | ID | 0 | 0,  
        data = psid)  
  
coeftest(reg_longitudinale_lfe_mauvaise_vcov)
```

t test of coefficients:

	Estimate	Std. Error	t value	Pr(> t)	
children	-0.052270	0.011833	-4.4171	1.009e-05	***

Signif. codes:	0	'***'	0.001	'**'	0.01
				'*'	0.05
				'.'	0.1
				'	

Une autre solution

```
psid[,  
  mean_indiv_children := mean(children),  
  by = c("ID")]  
  
reg_mundlak <-  
  lm(LFP ~ children + mean_indiv_children,  
    data = psid)
```

Une autre solution

```
coeftest(reg_mundlak,  
          vcov = vcovCL(reg_mundlak,  
                        cluster = psid$ID))
```

t test of coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	0.737654	0.022529	32.7425	< 2.2e-16
children	-0.052270	0.015653	-3.3393	0.0008424
mean_indiv_children	0.033888	0.030033	1.1284	0.2591834

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' '

Une dernière vérification

```
all.equal(  
  sqrt(vcovCL(reg_longitudinale,  
              cluster = psid$ID,  
              type = "HCO"))["children","children"],  
  sqrt(vcovCL(reg_mundlak,  
              cluster = psid$ID,  
              type = "HCO"))["children","children"])
```

```
[1] TRUE
```

En guise de conclusion

- ▶ Avec des **adaptations minimales**, on peut utiliser des régressions linéaires pour faire des **comparaisons longitudinales** et les considérer **en moyenne dans une certaine population**
- ▶ Ce n'est pas très compliqué d'utiliser R pour ça !
 - ▶ Mais il faut bien se demander si on estime la **bonne matrice de variance-covariance** !
 - ▶ Au total ce n'est pas trop compliqué
 - ▶ Si on a réussi à avoir une population où on observe le même individu plusieurs fois
 - ▶ C'est bien que l'on a commencé par tirer des individus puis par les suivre
 - ▶ Par parce que l'on tire des individus \times périodes au hasard...
 - ▶ **Les écarts-types pour les données groupées sont donc assez naturels à utiliser**

En guise de conclusion

- ▶ On peut bien entendu combiner et raffiner tout cela :
 - ▶ **Comparer entre des groupes de la population des évolutions individuelles** → modèles à doubles effets fixes, différences-de-différences etc.
 - ▶ Vous verrez tout ça dans la suite de votre parcours
 - ▶ Il y a évidemment à chaque fois des subtilités !
- ▶ On n'a pratiquement pas parlé de l'**interprétation causale des coefficients**
 - ▶ Vous avez vu que **tous les coefficients s'interprètent simplement comme des comparaisons de moyenne**
 - ▶ La question n'est donc jamais de savoir si vous avez utilisé une régression ou une autre façon de faire une comparaison
 - ▶ Mais seulement de savoir **à quelle condition ces comparaisons ont une interprétation causale !**

Ce qu'il reste pour ce semestre

- ▶ Une petite séance de TD sur les données de panel
- ▶ Une séance d'examen
 - ▶ Ce sera facile !
 - ▶ Sur ordinateur
 - ▶ Quelques manipulations de données et estimer quelques régressions avec R
 - ▶ Lire une table de régression issue d'un article
 - ▶ Quelques questions théoriques (faciles !!)