

# Méthodes d'analyse empirique

## *Partie Quantitative*

Michel Beine (suppl. S. Laurent)

`michel.beine@uni.lu`

Université du Luxembourg

`http://www.michelbeine.be`

# Manuel

- Ce cours est basé sur le livre [Introductory Econometrics, a Modern Approach](#) (second or third editions) de *Jeffrey M. Wooldridge*, édition Thomson South-Western.

# Manuel

- Ce cours est basé sur le livre [Introductory Econometrics, a Modern Approach](#) (second or third editions) de *Jeffrey M. Wooldridge*, édition Thomson South-Western.
- Logiciel économétrique : Ox et PcGive.

# Manuel

- Ce cours est basé sur le livre [Introductory Econometrics, a Modern Approach](#) (second or third editions) de *Jeffrey M. Wooldridge*, édition Thomson South-Western.
- Logiciel économétrique : Ox et PcGive.
- Evaluation: examen à livre fermé.

# Plan du cours

- Chapitre 17. Modèles de choix discret et maximum de vraisemblance.

# Plan du cours

- Chapitre 17. Modèles de choix discret et maximum de vraisemblance.
- Chapitre 15. Variables instrumentales et MCO en 2 étapes.

# Plan du cours

- Chapitre 17. Modèles de choix discret et maximum de vraisemblance.
- Chapitre 15. Variables instrumentales et MCO en 2 étapes.
- Chapitre 16. Modèles à équations simultanées.

# Plan du cours

- Chapitre 17. Modèles de choix discret et maximum de vraisemblance.
- Chapitre 15. Variables instrumentales et MCO en 2 étapes.
- Chapitre 16. Modèles à équations simultanées.
- Les processus modérateurs et médiateurs, ANOVA, ...



# Maximum de vraisemblance et modèles à choix discrets

# Motivation

- Le maximum de vraisemblance (MV) est une méthode d'estimation utile quand les paramètres d'un modèle ne peuvent pas être estimés par MCO. Des tests de restrictions sont également disponibles (principe du test de rapport des vraisemblances).

# Motivation

- Le maximum de vraisemblance (MV) est une méthode d'estimation utile quand les paramètres d'un modèle ne peuvent pas être estimés par MCO. Des tests de restrictions sont également disponibles (principe du test de rapport des vraisemblances).
- La méthode nécessite la spécification entière de la distribution de probabilité de l'échantillon observé, pas uniquement la moyenne conditionnelle de l'échantillon (tel le modèle de régression linéaire estimé par MCO).

# Motivation

- Le maximum de vraisemblance (MV) est une méthode d'estimation utile quand les paramètres d'un modèle ne peuvent pas être estimés par MCO. Des tests de restrictions sont également disponibles (principe du test de rapport des vraisemblances).
- La méthode nécessite la spécification entière de la distribution de probabilité de l'échantillon observé, pas uniquement la moyenne conditionnelle de l'échantillon (tel le modèle de régression linéaire estimé par MCO).
- L'estimation par MV du modèle de régression linéaire demande de spécifier aussi la structure de la dépendance de l'échantillon via les erreurs (i.i.d. par exemple) et la distribution du terme d'erreurs (comme  $\epsilon_t \sim N(0, \sigma^2)$ , mais une autre distribution est possible).

# Variable aléatoire

- Supposons que nous lançons une pièce 10 fois et comptons le nombre de fois que nous obtenons pile.

# Variable aléatoire

- Supposons que nous lançons une pièce 10 fois et comptons le nombre de fois que nous obtenons pile.
- Ceci est un exemple d'expérience.

# Variable aléatoire

- Supposons que nous lançons une pièce 10 fois et comptons le nombre de fois que nous obtenons pile.
- Ceci est un exemple d'expérience.
- Avant de lancer la pièce, nous savons que le nombre de piles sera un nombre de 0 à 10.

# Variable aléatoire

- Supposons que nous lançons une pièce 10 fois et comptons le nombre de fois que nous obtenons pile.
- Ceci est un exemple d'expérience.
- Avant de lancer la pièce, nous savons que le nombre de piles sera un nombre de 0 à 10.
- Une variable aléatoire est une variable qui prend des valeurs numériques et a un résultat qui est déterminé par une expérience.



# Variable aléatoire

- Supposons que nous lançons une pièce 10 fois et comptons le nombre de fois que nous obtenons pile.
- Ceci est un exemple d'expérience.
- Avant de lancer la pièce, nous savons que le nombre de piles sera un nombre de 0 à 10.
- Une variable aléatoire est une variable qui prend des valeurs numériques et a un résultat qui est déterminé par une expérience.
- → le nombre de fois que l'on obtient pile est un exemple de variable aléatoire.

# Variable aléatoire

- Supposons que nous lançons une pièce 10 fois et comptons le nombre de fois que nous obtenons pile.
- Ceci est un exemple d'expérience.
- Avant de lancer la pièce, nous savons que le nombre de piles sera un nombre de 0 à 10.
- Une variable aléatoire est une variable qui prend des valeurs numériques et a un résultat qui est déterminé par une expérience.
- → le nombre de fois que l'on obtient pile est un exemple de variable aléatoire.
- → 7 piles sur 10 est un exemple de réalisation de cette variable aléatoire pour une expérience donnée.

# Variable aléatoire

- Nous notons une variable aléatoire par une lettre majuscule:  $X$ .

# Variable aléatoire

- Nous notons une variable aléatoire par une lettre majuscule:  $X$ .
- Nous notons une valeur particulière que peut prendre cette variable aléatoire par une minuscule:  $x$ . Exemple:  $x = 6$ .

# Variable aléatoire

- Nous notons une variable aléatoire par une lettre majuscule:  $X$ .
- Nous notons une valeur particulière que peut prendre cette variable aléatoire par une minuscule:  $x$ . Exemple:  $x = 6$ .
- Notons que le lancer d'une pièce de monnaie peut être considéré comme une variable aléatoire suivant une distribution de Bernoulli où  $X = 1$  est appelé succès et  $X = 0$  échec.

# Variable aléatoire

- Nous notons une variable aléatoire par une lettre majuscule:  $X$ .
- Nous notons une valeur particulière que peut prendre cette variable aléatoire par une minuscule:  $x$ . Exemple:  $x = 6$ .
- Notons que le lancer d'une pièce de monnaie peut être considéré comme une variable aléatoire suivant une distribution de Bernoulli où  $X = 1$  est appelé succès et  $X = 0$  échec.
- Une variable aléatoire de Bernoulli est le plus simple exemple de variable aléatoire discrète.

# Variable aléatoire

- Nous notons une variable aléatoire par une lettre majuscule:  $X$ .
- Nous notons une valeur particulière que peut prendre cette variable aléatoire par une minuscule:  $x$ . Exemple:  $x = 6$ .
- Notons que le lancer d'une pièce de monnaie peut être considéré comme une variable aléatoire suivant une distribution de Bernoulli où  $X = 1$  est appelé succès et  $X = 0$  échec.
- Une variable aléatoire de Bernoulli est le plus simple exemple de variable aléatoire discrète.
- La seule chose que nous devons décrire pour une telle variable est la probabilité de succès:  $P(X = 1)$ .

# Variable aléatoire

- Nous notons une variable aléatoire par une lettre majuscule:  $X$ .
- Nous notons une valeur particulière que peut prendre cette variable aléatoire par une minuscule:  $x$ . Exemple:  $x = 6$ .
- Notons que le lancer d'une pièce de monnaie peut être considéré comme une variable aléatoire suivant une distribution de Bernoulli où  $X = 1$  est appelé succès et  $X = 0$  échec.
- Une variable aléatoire de Bernoulli est le plus simple exemple de variable aléatoire discrète.
- La seule chose que nous devons décrire pour une telle variable est la probabilité de succès:  $P(X = 1)$ .
- Dans le cas d'une pièce équilibrée,  $P(X = 1) = 0.5$  et comme  $P(X = 1) + P(X = 0) = 1$ ,  $P(X = 0) = 0.5$ .



# Variable aléatoire discrète

- Il n'y a pas de raison de penser que la probabilité de succès de toute variable binaire (0-1) est 0.5.

# Variable aléatoire discrète

- Il n'y a pas de raison de penser que la probabilité de succès de toute variable binaire (0-1) est 0.5.
- De manière générale disons que  $P(X = 1) = \theta$  et comme  $P(X = 1) + P(X = 0) = 1$ ,  $P(X = 0) = 1 - \theta$ .

# Variable aléatoire discrète

- Il n'y a pas de raison de penser que la probabilité de succès de toute variable binaire (0-1) est 0.5.
- De manière générale disons que  $P(X = 1) = \theta$  et comme  $P(X = 1) + P(X = 0) = 1$ ,  $P(X = 0) = 1 - \theta$ .
- Comment estimer  $\theta$  sur base d'un échantillon, c-à-d une expérience ?

# Variable aléatoire discrète

- Il n'y a pas de raison de penser que la probabilité de succès de toute variable binaire (0-1) est 0.5.
- De manière générale disons que  $P(X = 1) = \theta$  et comme  $P(X = 1) + P(X = 0) = 1$ ,  $P(X = 0) = 1 - \theta$ .
- Comment estimer  $\theta$  sur base d'un échantillon, c-à-d une expérience ?
- Plus généralement encore si  $X$  peut prendre des valeurs  $\{x_1, x_2, \dots, x_k\}$ , alors les probabilités  $p_1, p_2, \dots, p_k$  sont définies par

$$p_j = P(X = x_j), j = 1, 2, \dots, k$$

avec  $p_1 + p_2 + \dots + p_k = 1$ .

# Fonction de densité de probabilité

- La fonction de densité de probabilité (pdf) de  $X$  résume l'information concernant les différents résultats possibles de  $X$  et ses probabilités correspondantes:

$$f(x_j) = p_j, j = 1, 2, \dots, k$$

avec  $f(x) = 0$  pour toutes les valeurs de  $x$  hors de  $\{x_1, x_2, \dots, x_k\}$ .

# Fonction de densité de probabilité

- La fonction de densité de probabilité (pdf) de  $X$  résume l'information concernant les différents résultats possibles de  $X$  et ses probabilités correspondantes:

$$f(x_j) = p_j, j = 1, 2, \dots, k$$

avec  $f(x) = 0$  pour toutes les valeurs de  $x$  hors de  $\{x_1, x_2, \dots, x_k\}$ .

- La fonction de distribution jointe de  $n$  variables aléatoires discrètes  $X_j, j = 1, 2, \dots, n$  est notée  $f(x_1, x_2, \dots, x_n) = P(X_1 = x_1, X_2 = x_2, \dots, X_n = x_n)$ .

# Fonction de densité de probabilité

- La fonction de densité de probabilité (pdf) de  $X$  résume l'information concernant les différents résultats possibles de  $X$  et ses probabilités correspondantes:

$$f(x_j) = p_j, j = 1, 2, \dots, k$$

avec  $f(x) = 0$  pour toutes les valeurs de  $x$  hors de  $\{x_1, x_2, \dots, x_k\}$ .

- La fonction de distribution jointe de  $n$  variables aléatoires discrètes  $X_j, j = 1, 2, \dots, n$  est notée  $f(x_1, x_2, \dots, x_n) = P(X_1 = x_1, X_2 = x_2, \dots, X_n = x_n)$ .
- Ces  $n$  variables aléatoires sont indépendantes si  $f(x_1, x_2, \dots, x_n) = f(x_1)f(x_2) \dots f(x_n)$ .

# Fonction de densité de probabilité

- La fonction de densité de probabilité (pdf) de  $X$  résume l'information concernant les différents résultats possibles de  $X$  et ses probabilités correspondantes:

$$f(x_j) = p_j, j = 1, 2, \dots, k$$

avec  $f(x) = 0$  pour toutes les valeurs de  $x$  hors de  $\{x_1, x_2, \dots, x_k\}$ .

- La fonction de distribution jointe de  $n$  variables aléatoires discrètes  $X_j, j = 1, 2, \dots, n$  est notée  $f(x_1, x_2, \dots, x_n) = P(X_1 = x_1, X_2 = x_2, \dots, X_n = x_n)$ .
- Ces  $n$  variables aléatoires sont indépendantes si  $f(x_1, x_2, \dots, x_n) = f(x_1)f(x_2) \dots f(x_n)$ .
- Ceci s'étend évidemment aux variables aléatoires continues.



# Fonction de densité de probabilité

- La fonction de densité de probabilité (pdf) de  $X$  résume l'information concernant les différents résultats possibles de  $X$  et ses probabilités correspondantes:

$$f(x_j) = p_j, j = 1, 2, \dots, k$$

avec  $f(x) = 0$  pour toutes les valeurs de  $x$  hors de  $\{x_1, x_2, \dots, x_k\}$ .

- La fonction de distribution jointe de  $n$  variables aléatoires discrètes  $X_j, j = 1, 2, \dots, n$  est notée  $f(x_1, x_2, \dots, x_n) = P(X_1 = x_1, X_2 = x_2, \dots, X_n = x_n)$ .
- Ces  $n$  variables aléatoires sont indépendantes si  $f(x_1, x_2, \dots, x_n) = f(x_1)f(x_2) \dots f(x_n)$ .
- Ceci s'étend évidemment aux variables aléatoires continues.
- Un exemple courant est la distribution normale.

# MV pour une régression linéaire

- Posons  $y_t = \beta' x_t + \epsilon_t$ , ( $t = 1, \dots, n$ ) avec  $\epsilon_t \sim \text{i.N}(0, \sigma^2)$ .
- Par l'indépendance, la distribution jointe des  $\epsilon_t$  est

$$f(\epsilon_1, \epsilon_2, \dots, \epsilon_n | \beta, \sigma^2) = \prod_{t=1}^n f(\epsilon_t | \beta, \sigma^2), \quad (1)$$

où  $f(\epsilon_t | \beta, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{\epsilon_t^2}{2\sigma^2}\right)$ .

- $\epsilon_t$  n'étant pas observé, on peut le remplacer par  $y_t - \beta' x_t$ . Autrement dit,  $y_t | x_t \sim N(\beta' x_t, \sigma^2)$ , et la distribution de probabilité jointe de l'échantillon est :

$$f(y_1, y_2, \dots, y_n | \beta, \sigma^2) = \prod_{t=1}^n \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(y_t - \beta' x_t)^2}{2\sigma^2}\right). \quad (2)$$

# Fonction de vraisemblance : idée

- La fonction de vraisemblance (FV) d'un échantillon  $y_1, y_2, \dots, y_n$  est la distribution de probabilité jointe de cet échantillon, vue comme fonction des paramètres du modèle ( $\beta$  et  $\sigma^2$ ).

# Fonction de vraisemblance : idée

- La fonction de vraisemblance (FV) d'un échantillon  $y_1, y_2, \dots, y_n$  est la distribution de probabilité jointe de cet échantillon, vue comme fonction des paramètres du modèle ( $\beta$  et  $\sigma^2$ ).
- Pour une valeur donnée de  $\beta$  et  $\sigma^2$ , on peut calculer (2) : le résultat nous donne la "probabilité" d'observer l'échantillon en question  $y_1, y_2, \dots, y_n$  pour une valeur donnée des paramètres.

# Fonction de vraisemblance : idée

- La fonction de vraisemblance (FV) d'un échantillon  $y_1, y_2, \dots, y_n$  est la distribution de probabilité jointe de cet échantillon, vue comme fonction des paramètres du modèle ( $\beta$  et  $\sigma^2$ ).
- Pour une valeur donnée de  $\beta$  et  $\sigma^2$ , on peut calculer (2) : le résultat nous donne la "probabilité" d'observer l'échantillon en question  $y_1, y_2, \dots, y_n$  pour une valeur donnée des paramètres.
- Pour une valeur différente de  $\beta$  et  $\sigma^2$ , on obtiendra une probabilité différente.

# Fonction de vraisemblance : idée

- La fonction de vraisemblance (FV) d'un échantillon  $y_1, y_2, \dots, y_n$  est la distribution de probabilité jointe de cet échantillon, vue comme fonction des paramètres du modèle ( $\beta$  et  $\sigma^2$ ).
- Pour une valeur donnée de  $\beta$  et  $\sigma^2$ , on peut calculer (2) : le résultat nous donne la "probabilité" d'observer l'échantillon en question  $y_1, y_2, \dots, y_n$  pour une valeur donnée des paramètres.
- Pour une valeur différente de  $\beta$  et  $\sigma^2$ , on obtiendra une probabilité différente.
- **L'ESTIMATEUR MV (EMV)** est la valeur des paramètres qui maximise la FV; c'est-à-dire que ce sont les valeurs de  $\beta$  et  $\sigma^2$  pour lesquelles l'échantillon a la plus grande probabilité d'être observé.

# Fonction de vraisemblance : notations

- L'expression  $L(\beta, \sigma^2 | y_1, y_2, \dots, y_n)$  désigne la FV, où les arguments de la fonction sont  $\beta$  et  $\sigma^2$ , et non les données observées  $y_1, y_2, \dots, y_n$ . Formellement :

$$L(\beta, \sigma^2 | y_1, y_2, \dots, y_n) = f(y_1, y_2, \dots, y_n | \beta, \sigma^2). \quad (3)$$

$L(\beta, \sigma^2 | y_1, y_2, \dots, y_n) : \mathbb{R}^k \times (0, \infty) \rightarrow \mathbb{R}_+$ , alors que  
 $f(y_1, y_2, \dots, y_n | \beta, \sigma^2) : \mathbb{R}^n \rightarrow \mathbb{R}_+$ .

- Quand on peut identifier la nature exacte des données, on écrit même  $L(\beta, \sigma^2)$  au lieu de  $L(\beta, \sigma^2 | y_1, y_2, \dots, y_n)$ .
- On utilise aussi les notations plus synthétiques et génériques  $L(\theta)$  et  $L(\theta | y)$  :  $\theta$  pour les paramètres (donc  $\theta = (\beta', \sigma^2)$  dans une régression), et  $y$  pour l'échantillon de taille  $n$ .

# Étapes de l'estimation MV

Estimer les paramètres d'un modèle par MV demande deux étapes :

- étape 1 : obtenir l'expression de la FV à partir de la formulation du modèle et des hypothèses.



# Étapes de l'estimation MV

Estimer les paramètres d'un modèle par MV demande deux étapes :

- étape 1 : obtenir l'expression de la FV à partir de la formulation du modèle et des hypothèses.
- étape 2 : trouver la valeur des paramètres maximisant cette fonction.

Il faut donc solutionner le problème de maximisation :

$$\max_{\theta \in \Theta} L(\theta|y),$$

où  $\Theta$  est l'ensemble des valeurs des paramètres acceptables  $\theta$ .

# Solutionner la maximisation

- Il est beaucoup plus aisé, et équivalent de résoudre

$$\max_{\theta \in \Theta} l(\theta|y),$$

où  $l(\theta|y) = \log L(\theta|y)$  (logarithme népérien). Puisque  $L(\theta|y) = \prod_{t=1}^n f(y_t|\theta)$ , l'expression donne en logarithme  $l(\theta|y) = \sum_{t=1}^n \log f(y_t|\theta) = \sum_{t=1}^n l_t(\theta)$ .

# Solutionner la maximisation

- Il est beaucoup plus aisé, et équivalent de résoudre

$$\max_{\theta \in \Theta} l(\theta|y),$$

où  $l(\theta|y) = \log L(\theta|y)$  (logarithme népérien). Puisque  $L(\theta|y) = \prod_{t=1}^n f(y_t|\theta)$ , l'expression donne en logarithme  $l(\theta|y) = \sum_{t=1}^n \log f(y_t|\theta) = \sum_{t=1}^n l_t(\theta)$ .

- Pour l'exemple de la régression linéaire, on doit résoudre

$$\max_{\beta \in \mathbb{R}^k, \sigma^2 > 0} \left( -\frac{n}{2} \log \sigma^2 - \frac{1}{2\sigma^2} \sum_{t=1}^n (y_t - \beta' x_t)^2 \right),$$

où le terme  $-n \log(\sqrt{2\pi})$  fut négligé car il ne dépend ni de  $\beta$  ni de  $\sigma^2$ .

# Conditions de premier ordre

- Si  $l(\theta)$  est différentiable,  $\theta$ , l'EMV, est la solution du système des conditions de premier ordre (CPO)

$$q(\theta) = 0 \quad \text{où} \quad q(\theta) = \frac{\partial l(\theta)}{\partial \theta},$$

pour autant que les conditions de second ordre sont satisfaites, c'est-à-dire que la matrice des dérivées secondes, évaluée à la solution des CPO, est définie négative.

NB:  $q(\theta)$  est appelé la fonction score.

- Appelons  $\hat{\theta}$  la solution des CPO : alors,  $\hat{\theta}$  est l'EMV si

$$q(\hat{\theta}) = 0 \quad \text{et} \quad H(\hat{\theta}) < 0.$$

où  $H(\hat{\theta})$  est la matrice Hessienne  $\frac{\partial^2 l(\theta)}{\partial \theta \partial \theta'}$  évaluée à  $\hat{\theta}$ .

# CPO pour $\beta$

- Dans l'exemple de la régression linéaire, les CPO sont

$$\frac{1}{\sigma^2} \sum_{t=1}^n x_t (y_t - \beta' x_t) = 0 \quad (k \text{ équations}) \quad (4)$$

$$-\frac{n}{2\sigma^2} + \frac{1}{2(\sigma^2)^2} \sum_{t=1}^n (y_t - \beta' x_t)^2 = 0 \quad (1 \text{ equation}) \quad (5)$$

- La solution de (4) ne dépend pas de  $\sigma^2$  et est la solution de  $\sum_{t=1}^n x_t (y_t - \beta' x_t) = 0$  : c'est le système des "équations normales" de l'estimation MCO. Donc,  $\hat{\beta} = b$ : l'EMV, en supposant la normalité du terme d'erreurs, est identique à celui des MCO.

# CPO pour $\sigma^2$

- Ayant résolu (4), il reste à solutionner

$$-\frac{n}{2\sigma^2} + \frac{1}{2(\sigma^2)^2} \sum_{t=1}^n (y_t - \hat{\beta}'x_t)^2 = 0,$$

qui donne

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{t=1}^n (y_t - \hat{\beta}'x_t)^2 = \frac{1}{n} \sum_{t=1}^n e_t^2. \quad (6)$$

- L'EMV de  $\sigma^2$  n'est pas l'estimateur habituel

$$s^2 = \frac{1}{n-k} \sum_{t=1}^n e_t^2,$$

mais si  $n$  est grand, la différence est petite.

# Conditions de second ordre

- Les calculs donnent

$$H(\hat{\beta}, \hat{\sigma}^2) = \begin{pmatrix} -\frac{\sum_{t=1}^n x_t x_t'}{\hat{\sigma}^2} & 0 \\ 0' & -\frac{n}{2\hat{\sigma}^4} \end{pmatrix} = \begin{pmatrix} -\frac{X'X}{\hat{\sigma}^2} & 0 \\ 0' & -\frac{n}{2\hat{\sigma}^4} \end{pmatrix},$$

qui est définie négative puisque  $X'X$  est définie positive (si  $X$  est de rang  $k$ ).

# Conditions de second ordre

- Les calculs donnent

$$H(\hat{\beta}, \hat{\sigma}^2) = \begin{pmatrix} -\frac{\sum_{t=1}^n x_t x_t'}{\hat{\sigma}^2} & 0 \\ 0' & -\frac{n}{2\hat{\sigma}^4} \end{pmatrix} = \begin{pmatrix} -\frac{X'X}{\hat{\sigma}^2} & 0 \\ 0' & -\frac{n}{2\hat{\sigma}^4} \end{pmatrix},$$

qui est définie négative puisque  $X'X$  est définie positive (si  $X$  est de rang  $k$ ).

- $b$  et  $\hat{\sigma}^2$  sont les EMV de  $\beta$  et  $\sigma^2$ .



# Propriétés de l'EMV

- On note l'EMV de  $\theta$  par  $\hat{\theta}_n$  pour insister sur sa dépendance à la taille de l'échantillon. Les propriétés générales sont vérifiées asymptotiquement (càd qu'on laisse  $n$  tendre vers  $\infty$ ). Pour rappel,  $\hat{\theta}_n$  à une distribution d'échantillon puisqu'il dépend d'un échantillon de v.a. qui suivent un processus stochastique (le PGD).

NB : les propriétés exactes en échantillon fini dépendent du modèle considéré et sont obtenues sur une base de cas par cas quand c'est possible.

# Propriétés de l'EMV

- On note l'EMV de  $\theta$  par  $\hat{\theta}_n$  pour insister sur sa dépendance à la taille de l'échantillon. Les propriétés générales sont vérifiées asymptotiquement (càd qu'on laisse  $n$  tendre vers  $\infty$ ). Pour rappel,  $\hat{\theta}_n$  à une distribution d'échantillon puisqu'il dépend d'un échantillon de v.a. qui suivent un processus stochastique (le PGD).  
NB : les propriétés exactes en échantillon fini dépendent du modèle considéré et sont obtenues sur une base de cas par cas quand c'est possible.
- Les propriétés asymptotiques générales sont satisfaites sous un ensemble de "conditions de régularité". Elles assurent soit l'existence de l'estimateur, soit la convergence et la normalité asymptotique. Pour les séries temporelles, ces conditions sont du type : le DGP est stationnaire et faiblement dépendant.

# Propriétés de l'EMV

- Convergence :  $\hat{\theta}_n \xrightarrow{p} \theta$  où  $\theta$  est la valeur du paramètre dans le PGD (appelé "vraie valeur").

# Propriétés de l'EMV

- Convergence :  $\hat{\theta}_n \xrightarrow{p} \theta$  où  $\theta$  est la valeur du paramètre dans le PGD (appelé "vraie valeur").
- Normalité asymptotique : on procède comme si  $\hat{\theta}_n \sim N(\theta, \hat{V})$  si  $n$  est grand, sachant que plus  $n$  est grand, meilleure est l'approximation.

# Propriétés de l'EMV

- Convergence :  $\hat{\theta}_n \xrightarrow{p} \theta$  où  $\theta$  est la valeur du paramètre dans le PGD (appelé "vraie valeur").
- Normalité asymptotique : on procède comme si  $\hat{\theta}_n \sim N(\theta, \hat{V})$  si  $n$  est grand, sachant que plus  $n$  est grand, meilleure est l'approximation.
- $\hat{V}$  est un estimateur de la matrice de variance-covariances exacte  $V$  car cette dernière dépend généralement de paramètres inconnus (en particulier, mais pas exclusivement, du vrai  $\theta$ ). Il n'existe pas de choix unique pour  $\hat{V}$  mais les choix habituels (slide suivant) sont fournis dans les logiciels économétriques (comme OxMetrics, TSP, EVIEWS, RATS, SAS, STATA, etc.).

# Formules pour $\hat{V}$

- Basée sur la matrice Hessienne :

$$\hat{V}_H = -[H(\hat{\theta})]^{-1} = -\left[\sum_{t=1}^n H_t(\hat{\theta})\right]^{-1},$$

où  $H_t(\hat{\theta}) = \frac{\partial^2 l_t(\theta)}{\partial \theta \partial \theta'}$  est évalué à  $\hat{\theta}$ .

# Formules pour $\hat{V}$

- Basée sur la matrice Hessienne :

$$\hat{V}_H = -[H(\hat{\theta})]^{-1} = -\left[\sum_{t=1}^n H_t(\hat{\theta})\right]^{-1},$$

où  $H_t(\hat{\theta}) = \frac{\partial^2 l_t(\theta)}{\partial \theta \partial \theta'}$  est évalué à  $\hat{\theta}$ .

- Basée sur la contribution aux scores :

$$\hat{V}_G = \left[\sum_{t=1}^n q_t(\hat{\theta})q_t(\hat{\theta})'\right]^{-1},$$

où  $q_t(\hat{\theta}) = \frac{\partial l_t(\theta)}{\partial \theta}$  est évalué à  $\hat{\theta}$  et constitue la contribution de l'observation  $t$  à la fonction score.

**NB:**  $q(\theta) = \sum_{t=1}^n q_t(\theta)$ .

# Test de Wald avec l'EMV

- Etant donné que  $\hat{\theta}_n \sim N(\theta, \hat{V})$ , on peut tester des restrictions (linéaires ou non) par des tests de Wald en  $\chi^2$ . Par exemple :  
 $H_0 : R\theta = r$  est testé par la statistique  
 $(R\hat{\theta} - r)'(R\hat{V}R')^{-1}(R\hat{\theta} - r) \sim \chi^2(m)$  sous  $H_0$ .



# Test de Wald avec l'EMV

- Etant donné que  $\hat{\theta}_n \sim N(\theta, \hat{V})$ , on peut tester des restrictions (linéaires ou non) par des tests de Wald en  $\chi^2$ . Par exemple :  
 $H_0 : R\theta = r$  est testé par la statistique  
 $(R\hat{\theta} - r)'(R\hat{V}R')^{-1}(R\hat{\theta} - r) \sim \chi^2(m)$  sous  $H_0$ .
- La statistique de test pour  $H_0 : \theta_3 = 0$  est  $\hat{\theta}_3^2/\hat{v}_{33} \sim \chi^2(1)$ . Elle peut être remplacée par  $\hat{\theta}_3/\sqrt{\hat{v}_{33}} \sim N(0, 1)$  si on désire un test unilatéral.

# Test du rapport des vraisemblances

Sous les conditions de régularité, une manière alternative de tester les restrictions, disons  $H_0 : R\theta = r$  existe :

- Etape 1 : estimer le modèle par MV sans imposer les contraintes. Sauver  $l(\hat{\theta})$ , la valeur de la FV à l'optimum.

# Test du rapport des vraisemblances

Sous les conditions de régularité, une manière alternative de tester les restrictions, disons  $H_0 : R\theta = r$  existe :

- Etape 1 : estimer le modèle par MV sans imposer les contraintes. Sauver  $l(\hat{\theta})$ , la valeur de la FV à l'optimum.
- Etape 2 : estimer le modèle (par MV) en imposant les restrictions. Sauver  $l(\tilde{\theta})$ , la valeur de la FV à l'optimum contraint. Donc,  $\tilde{\theta} = \arg \max_{\theta} l(\theta)$  sous contraintes  $R\theta = r$ .

# Test du rapport des vraisemblances

Sous les conditions de régularité, une manière alternative de tester les restrictions, disons  $H_0 : R\theta = r$  existe :

- Etape 1 : estimer le modèle par MV sans imposer les contraintes. Sauver  $l(\hat{\theta})$ , la valeur de la FV à l'optimum.
- Etape 2 : estimer le modèle (par MV) en imposant les restrictions. Sauver  $l(\tilde{\theta})$ , la valeur de la FV à l'optimum contraint. Donc,  $\tilde{\theta} = \arg \max_{\theta} l(\theta)$  sous contraintes  $R\theta = r$ .
- Calculer le rapport des vraisemblances (RV)

$$LR = 2[l(\hat{\theta}) - l(\tilde{\theta})].$$

Rejeter  $H_0$  au seuil  $\alpha$  si la  $p$ -valeur du  $RV$  est inférieure à  $\alpha$ , où la  $p$ -valeur est obtenue en utilisant la  $\chi^2(m)$ . Par construction,  $RV \geq 0$ .

# Problèmes possibles avec MV

- Résoudre analytiquement les CPO, comme dans l'exemple de la régression linéaire, n'est généralement pas possible. Des méthodes numériques sont implémentées dans les logiciels.

# Problèmes possibles avec MV

- Résoudre analytiquement les CPO, comme dans l'exemple de la régression linéaire, n'est généralement pas possible. Des méthodes numériques sont implémentées dans les logiciels.
- L'EMV n'est pas toujours unique : le système des CPO peut avoir plusieurs solutions. Si ce problème est suspecté, on doit chercher numériquement plusieurs maxima et choisir le global.

# Problèmes possibles avec MV

- Résoudre analytiquement les CPO, comme dans l'exemple de la régression linéaire, n'est généralement pas possible. Des méthodes numériques sont implémentées dans les logiciels.
- L'EMV n'est pas toujours unique : le système des CPO peut avoir plusieurs solutions. Si ce problème est suspecté, on doit chercher numériquement plusieurs maxima et choisir le global.
- Cas extrême : l'EMV n'existe pas (ou infinité de solutions : problème d'identification). Exemple : la régression linéaire quand  $X$  n'est pas de rang plein.

# Problèmes possibles avec MV

- Résoudre analytiquement les CPO, comme dans l'exemple de la régression linéaire, n'est généralement pas possible. Des méthodes numériques sont implémentées dans les logiciels.
- L'EMV n'est pas toujours unique : le système des CPO peut avoir plusieurs solutions. Si ce problème est suspecté, on doit chercher numériquement plusieurs maxima et choisir le global.
- Cas extrême : l'EMV n'existe pas (ou infinité de solutions : problème d'identification). Exemple : la régression linéaire quand  $X$  n'est pas de rang plein.
- L'EMV peut être à la frontière de l'espace des paramètres.  $\Rightarrow$  Normalité asymptotique non valable  $\Rightarrow$  RV non asymptotiquement distribué selon une  $\chi^2$ .



# Forces et faiblesses du MV

- Forces : si les hypothèses sont correctes, l'EMV est l'estimateur le plus efficace asymptotiquement, au sens qu'il est non-biaisé asymptotiquement et possède la plus petite variance. Intuitivement, MV utilise au mieux l'information des données pour estimer les paramètres.

# Forces et faiblesses du MV

- Forces : si les hypothèses sont correctes, l'EMV est l'estimateur le plus efficace asymptotiquement, au sens qu'il est non-biaisé asymptotiquement et possède la plus petite variance. Intuitivement, MV utilise au mieux l'information des données pour estimer les paramètres.
- Faiblesses : MV nécessite de choisir la distribution de probabilité. Quelles sont donc les conséquences d'une hypothèse erronée sur la distribution de probabilité des  $y_t$ ?

# Forces et faiblesses du MV

- Forces : si les hypothèses sont correctes, l'EMV est l'estimateur le plus efficace asymptotiquement, au sens qu'il est non-biaisé asymptotiquement et possède la plus petite variance. Intuitivement, MV utilise au mieux l'information des données pour estimer les paramètres.
- Faiblesses : MV nécessite de choisir la distribution de probabilité. Quelles sont donc les conséquences d'une hypothèse erronée sur la distribution de probabilité des  $y_t$  ?
- La réponse à cette question est :
  - dans certains cas, l'EMV n'est même pas convergent,
  - dans d'autres cas, il est toujours convergent et asymptotiquement normal mais la matrice  $\hat{V}$  est différente de celle fournie précédemment.

# Modèles à choix discrets

# Modèles Logit et Probit



$y_i = 0$  si le ménage  $i$  ne possède pas de voiture,  
 $y_i = 1$  sinon.

# Modèles Logit et Probit



$y_i = 0$  si le ménage  $i$  ne possède pas de voiture,  
 $y_i = 1$  sinon.

- Dans ce cas un modèle linéaire n'est pas approprié pour étudier les déterminants de  $y$ .

# Modèles Logit et Probit

$y_i = 0$  si le ménage  $i$  ne possède pas de voiture,  
 $y_i = 1$  sinon.

- Dans ce cas un modèle linéaire n'est pas approprié pour étudier les déterminants de  $y$ .
- Dans un modèle de choix discret, l'intérêt se porte sur l'estimation de

$$P(y = 1|\mathbf{x}) = P(y = 1|x_1, x_2, \dots, x_k),$$

où par exemple  $x_1$  est le niveau d'éducation,  $x_2$  le nombre d'enfants, etc.

# Modèles Logit et Probit

- Pour s'assurer que cette probabilité est toujours entre 0 et 1, on considère le plus souvent une classe de modèles du type suivant:

$$P(y = 1|\mathbf{x}) = G(\beta_0 + \beta_1x_1 + \beta_2x_2 + \dots + \beta_kx_k) = G(\beta_0 + \mathbf{x}\mathbf{B}),$$

où  $G$  est une fonction prenant des valeurs entre 0 et 1, c-à-d  $0 < G(z) < 1$  pour tout nombre réel  $z$ .



# Modèles Logit et Probit

- Pour s'assurer que cette probabilité est toujours entre 0 et 1, on considère le plus souvent une classe de modèles du type suivant:

$$P(y = 1|\mathbf{x}) = G(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k) = G(\beta_0 + \mathbf{x}\mathbf{B}),$$

où  $G$  est une fonction prenant des valeurs entre 0 et 1, c-à-d  $0 < G(z) < 1$  pour tout nombre réel  $z$ .

- Modèle logit:  $G(z) = \frac{\exp(z)}{1 + \exp(z)} = \Lambda(z)$ , c-à-d la fonction cumulative d'une variable aléatoire logistique de variance unitaire.

# Modèles Logit et Probit

- Pour s'assurer que cette probabilité est toujours entre 0 et 1, on considère le plus souvent une classe de modèles du type suivant:

$$P(y = 1 | \mathbf{x}) = G(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k) = G(\beta_0 + \mathbf{x}\mathbf{B}),$$

où  $G$  est une fonction prenant des valeurs entre 0 et 1, c-à-d  $0 < G(z) < 1$  pour tout nombre réel  $z$ .

- Modèle logit:  $G(z) = \frac{\exp(z)}{1 + \exp(z)} = \Lambda(z)$ , c-à-d la fonction cumulative d'une variable aléatoire logistique de variance unitaire.
- Modèle Probit:  $G(z) = \Phi(z) \equiv \int_{-\infty}^z \phi(v) dv$ , où  $\phi(z)$  est la densité normale standard  $\phi(z) = (2\pi)^{-1/2} \exp(-z^2/2)$ .

# Modèles Logit et Probit



- Pour s'assurer que cette probabilité est toujours entre 0 et 1, on considère le plus souvent une classe de modèles du type suivant:

$$P(y = 1 | \mathbf{x}) = G(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k) = G(\beta_0 + \mathbf{x}\mathbf{B}),$$

où  $G$  est une fonction prenant des valeurs entre 0 et 1, c-à-d  $0 < G(z) < 1$  pour tout nombre réel  $z$ .

- Modèle logit:  $G(z) = \frac{\exp(z)}{1 + \exp(z)} = \Lambda(z)$ , c-à-d la fonction cumulative d'une variable aléatoire logistique de variance unitaire.
- Modèle Probit:  $G(z) = \Phi(z) \equiv \int_{-\infty}^z \phi(v) dv$ , où  $\phi(z)$  est la densité normale standard  $\phi(z) = (2\pi)^{-1/2} \exp(-z^2/2)$ .
- Pour les deux modèles,  $G(z) \rightarrow 0$  quand  $z \rightarrow -\infty$  et  $G(z) \rightarrow 1$  quand  $z \rightarrow \infty$ .

$$G(z)$$



# Modèles Logit et Probit

- Les modèles Logit et Probit peuvent être dérivés d'un modèle sous-jacent à variable latente.

# Modèles Logit et Probit

- Les modèles Logit et Probit peuvent être dérivés d'un modèle sous-jacent à variable latente.
- Soit  $y^*$  une variable latente (ou non observable) définie par

$$y^* = \beta_0 + \mathbf{x}\mathbf{B} + e, y = 1[y^* > 0]$$

# Modèles Logit et Probit

- Les modèles Logit et Probit peuvent être dérivés d'un modèle sous-jacent à variable latente.
- Soit  $y^*$  une variable latente (ou non observable) définie par

$$y^* = \beta_0 + \mathbf{x}\mathbf{B} + e, y = 1[y^* > 0]$$

- La fonction  $1[.]$  est appelée fonction indicatrice.

# Modèles Logit et Probit

- Les modèles Logit et Probit peuvent être dérivés d'un modèle sous-jacent à variable latente.
- Soit  $y^*$  une variable latente (ou non observable) définie par

$$y^* = \beta_0 + \mathbf{x}\mathbf{B} + e, y = 1[y^* > 0]$$

- La fonction  $1[.]$  est appelée fonction indicatrice.
- $y = 1$  si  $y^* > 0$ , 0 sinon.



# Modèles Logit et Probit

- Les modèles Logit et Probit peuvent être dérivés d'un modèle sous-jacent à variable latente.
- Soit  $y^*$  une variable latente (ou non observable) définie par

$$y^* = \beta_0 + \mathbf{x}\mathbf{B} + e, y = 1[y^* > 0]$$

- La fonction  $1[.]$  est appelée fonction indicatrice.
- $y = 1$  si  $y^* > 0$ , 0 sinon.
- Nous supposons que  $e$  est indépendant de  $\mathbf{x}$  et que  $e$  a une distribution logistique standard ou  $N(0, 1)$ .

# Modèles Logit et Probit

- Les modèles Logit et Probit peuvent être dérivés d'un modèle sous-jacent à variable latente.
- Soit  $y^*$  une variable latente (ou non observable) définie par

$$y^* = \beta_0 + \mathbf{x}\mathbf{B} + e, y = 1[y^* > 0]$$

- La fonction  $1[.]$  est appelée fonction indicatrice.
- $y = 1$  si  $y^* > 0$ , 0 sinon.
- Nous supposons que  $e$  est indépendant de  $\mathbf{x}$  et que  $e$  a une distribution logistique standard ou  $N(0, 1)$ .
- $\rightarrow e$  est symétriquement distribué autour de 0.

# Modèles Logit et Probit

- Les modèles Logit et Probit peuvent être dérivés d'un modèle sous-jacent à variable latente.
- Soit  $y^*$  une variable latente (ou non observable) définie par

$$y^* = \beta_0 + \mathbf{x}\mathbf{B} + e, y = 1[y^* > 0]$$

- La fonction  $1[.]$  est appelée fonction indicatrice.
- $y = 1$  si  $y^* > 0$ , 0 sinon.
- Nous supposons que  $e$  est indépendant de  $\mathbf{x}$  et que  $e$  a une distribution logistique standard ou  $N(0, 1)$ .
- $\rightarrow e$  est symétriquement distribué autour de 0.
- $\rightarrow 1 - G(-z) = G(z)$ .

$$y^* = \beta_0 + \mathbf{x}\mathbf{B} + e, y = 1[y^* > 0]$$

$$\begin{aligned} P(y = 1|\mathbf{x}) &= P(y^* > 0|\mathbf{x}) = P[e > -(\beta_0 + \mathbf{x}\mathbf{B})|\mathbf{x}] \\ &= 1 - G[-(\beta_0 + \mathbf{x}\mathbf{B})] = G(\beta_0 + \mathbf{x}\mathbf{B}). \end{aligned}$$

$$y^* = \beta_0 + \mathbf{x}\mathbf{B} + e, y = 1[y^* > 0]$$

$$\begin{aligned} P(y = 1|\mathbf{x}) &= P(y^* > 0|\mathbf{x}) = P[e > -(\beta_0 + \mathbf{x}\mathbf{B})|\mathbf{x}] \\ &= 1 - G[-(\beta_0 + \mathbf{x}\mathbf{B})] = G(\beta_0 + \mathbf{x}\mathbf{B}). \end{aligned}$$

- Dans la plupart des analyses impliquant des modèles Logit ou Probit, l'objet premier est d'expliquer l'effet d'une variation de  $x_j$  sur  $P(y = 1|\mathbf{x})$ .

$$y^* = \beta_0 + \mathbf{x}\mathbf{B} + e, y = 1[y^* > 0]$$

$$\begin{aligned} P(y = 1|\mathbf{x}) &= P(y^* > 0|\mathbf{x}) = P[e > -(\beta_0 + \mathbf{x}\mathbf{B})|\mathbf{x}] \\ &= 1 - G[-(\beta_0 + \mathbf{x}\mathbf{B})] = G(\beta_0 + \mathbf{x}\mathbf{B}). \end{aligned}$$

- Dans la plupart des analyses impliquant des modèles Logit ou Probit, l'objet premier est d'expliquer l'effet d'une variation de  $x_j$  sur  $P(y = 1|\mathbf{x})$ .
- Il est important de noter que la direction de l'effet de  $x_j$  sur  $E(y^*|\mathbf{x}) = \beta_0 + \mathbf{x}\mathbf{B}$  et sur  $E(y|\mathbf{x}) = P(y = 1|\mathbf{x}) = G(\beta_0 + \mathbf{x}\mathbf{B})$  est toujours la même.

$$y^* = \beta_0 + \mathbf{x}\mathbf{B} + e, y = 1[y^* > 0]$$

$$\begin{aligned} P(y = 1|\mathbf{x}) &= P(y^* > 0|\mathbf{x}) = P[e > -(\beta_0 + \mathbf{x}\mathbf{B})|\mathbf{x}] \\ &= 1 - G[-(\beta_0 + \mathbf{x}\mathbf{B})] = G(\beta_0 + \mathbf{x}\mathbf{B}). \end{aligned}$$

- Dans la plupart des analyses impliquant des modèles Logit ou Probit, l'objet premier est d'expliquer l'effet d'une variation de  $x_j$  sur  $P(y = 1|\mathbf{x})$ .
- Il est important de noter que la direction de l'effet de  $x_j$  sur  $E(y^*|\mathbf{x}) = \beta_0 + \mathbf{x}\mathbf{B}$  et sur  $E(y|\mathbf{x}) = P(y = 1|\mathbf{x}) = G(\beta_0 + \mathbf{x}\mathbf{B})$  est toujours la même.
- Par contre l'amplitude de  $\beta_j$  n'est pas vraiment parlante.

$$y^* = \beta_0 + \mathbf{x}\mathbf{B} + e, y = 1[y^* > 0]$$

$$\begin{aligned} P(y = 1|\mathbf{x}) &= P(y^* > 0|\mathbf{x}) = P[e > -(\beta_0 + \mathbf{x}\mathbf{B})|\mathbf{x}] \\ &= 1 - G[-(\beta_0 + \mathbf{x}\mathbf{B})] = G(\beta_0 + \mathbf{x}\mathbf{B}). \end{aligned}$$

- Dans la plupart des analyses impliquant des modèles Logit ou Probit, l'objet premier est d'expliquer l'effet d'une variation de  $x_j$  sur  $P(y = 1|\mathbf{x})$ .
- Il est important de noter que la direction de l'effet de  $x_j$  sur  $E(y^*|\mathbf{x}) = \beta_0 + \mathbf{x}\mathbf{B}$  et sur  $E(y|\mathbf{x}) = P(y = 1|\mathbf{x}) = G(\beta_0 + \mathbf{x}\mathbf{B})$  est toujours la même.
- Par contre l'amplitude de  $\beta_j$  n'est pas vraiment parlante.
- Pour trouver l'effet partiel d'une variation d'une unité de  $x_j$  sur la probabilité de succès, c-à-d  $P(y = 1|\mathbf{x})$ , il faut effectuer quelques calculs.



# Effet partiel

- Si  $x_j$  est une variable continue, son effet partiel sur  $p(\mathbf{x}) = P(y = 1|\mathbf{x})$  est obtenu depuis la dérivée partielle suivante:

$$\frac{\partial p(\mathbf{x})}{\partial x_j} = g(\beta_0 + \mathbf{x}\mathbf{B})\beta_j,$$

où  $g(z) \equiv \frac{dG}{dz}(z)$ .

# Effet partiel

- Si  $x_j$  est une variable continue, son effet partiel sur  $p(\mathbf{x}) = P(y = 1|\mathbf{x})$  est obtenu depuis la dérivée partielle suivante:

$$\frac{\partial p(\mathbf{x})}{\partial x_j} = g(\beta_0 + \mathbf{x}\mathbf{B})\beta_j,$$

où  $g(z) \equiv \frac{dG}{dz}(z)$ .

- Comme  $G$  est la cdf d'une variable aléatoire continue,  $g$  est une fonction de densité de probabilité (pdf).

# Effet partiel

- Si  $x_j$  est une variable continue, son effet partiel sur  $p(\mathbf{x}) = P(y = 1|\mathbf{x})$  est obtenu depuis la dérivée partielle suivante:

$$\frac{\partial p(\mathbf{x})}{\partial x_j} = g(\beta_0 + \mathbf{x}\mathbf{B})\beta_j,$$

où  $g(z) \equiv \frac{dG}{dz}(z)$ .

- Comme  $G$  est la cdf d'une variable aléatoire continue,  $g$  est une fonction de densité de probabilité (pdf).
- Comme  $G(\cdot)$  est strictement croissante pour les modèles Logit et Probit,  $g(z) > 0 \forall z$ .

# Effet partiel

- Si  $x_j$  est une variable continue, son effet partiel sur  $p(\mathbf{x}) = P(y = 1|\mathbf{x})$  est obtenu depuis la dérivée partielle suivante:

$$\frac{\partial p(\mathbf{x})}{\partial x_j} = g(\beta_0 + \mathbf{x}\mathbf{B})\beta_j,$$

où  $g(z) \equiv \frac{dG}{dz}(z)$ .

- Comme  $G$  est la cdf d'une variable aléatoire continue,  $g$  est une fonction de densité de probabilité (pdf).
- Comme  $G(\cdot)$  est strictement croissante pour les modèles Logit et Probit,  $g(z) > 0 \forall z$ .
- Donc l'effet partiel de  $x_j$  sur  $p(\mathbf{x})$  dépend de  $\mathbf{x}$  de part la quantité  $g(\beta_0 + \mathbf{x}\mathbf{B})$ .

# Effet partiel

- Si  $x_j$  est une variable continue, son effet partiel sur  $p(\mathbf{x}) = P(y = 1|\mathbf{x})$  est obtenu depuis la dérivée partielle suivante:

$$\frac{\partial p(\mathbf{x})}{\partial x_j} = g(\beta_0 + \mathbf{x}\mathbf{B})\beta_j,$$

où  $g(z) \equiv \frac{dG}{dz}(z)$ .

- Comme  $G$  est la cdf d'une variable aléatoire continue,  $g$  est une fonction de densité de probabilité (pdf).
- Comme  $G(\cdot)$  est strictement croissante pour les modèles Logit et Probit,  $g(z) > 0 \forall z$ .
- Donc l'effet partiel de  $x_j$  sur  $p(\mathbf{x})$  dépend de  $\mathbf{x}$  de part la quantité  $g(\beta_0 + \mathbf{x}\mathbf{B})$ .
- Par contre l'effet a toujours de même signe que  $\beta_j$ .

$$\frac{\partial p(\mathbf{x})}{\partial x_j} = g(\beta_0 + \mathbf{x}\mathbf{B})\beta_j$$

- La conséquence est que l'effet relatif de deux variables explicatives continues ne dépend pas de  $\mathbf{x}$ .

$$\frac{\partial p(\mathbf{x})}{\partial x_j} = g(\beta_0 + \mathbf{x}\mathbf{B})\beta_j$$

- La conséquence est que l'effet relatif de deux variables explicatives continues ne dépend pas de  $\mathbf{x}$ .
- En effet le ratio des effets partiels pour  $x_j$  et  $x_h$  est  $\frac{\beta_j}{\beta_h}$ .

$$\frac{\partial p(\mathbf{x})}{\partial x_j} = g(\beta_0 + \mathbf{x}\mathbf{B})\beta_j$$

- La conséquence est que l'effet relatif de deux variables explicatives continues ne dépend pas de  $\mathbf{x}$ .
- En effet le ratio des effets partiels pour  $x_j$  et  $x_h$  est  $\frac{\beta_j}{\beta_h}$ .
- L'effet partiel est maximum lorsque  $\beta_0 + \mathbf{x}\mathbf{B} = 0$ . Pour le modèle Probit,  $g(z) = \phi(z)$  et donc  $g(0) = \phi(0) = \frac{1}{\sqrt{2\pi}} \approx 0.40$ .



$$\frac{\partial p(\mathbf{x})}{\partial x_j} = g(\beta_0 + \mathbf{x}\mathbf{B})\beta_j$$

- La conséquence est que l'effet relatif de deux variables explicatives continues ne dépend pas de  $\mathbf{x}$ .
- En effet le ratio des effets partiels pour  $x_j$  et  $x_h$  est  $\frac{\beta_j}{\beta_h}$ .
- L'effet partiel est maximum lorsque  $\beta_0 + \mathbf{x}\mathbf{B} = 0$ . Pour le modèle Probit,  $g(z) = \phi(z)$  et donc  $g(0) = \phi(0) = \frac{1}{\sqrt{2\pi}} \approx 0.40$ .
- Pour le Logit,  $g(z) = \frac{\exp(z)}{[1+\exp(z)]^2}$  et donc  $g(0) = 0.25$ .

# Variables binaires $x_j$

- Le calcul de l'effet partiel pour une variable binaire est différent.

# Variables binaires $x_j$

- Le calcul de l'effet partiel pour une variable binaire est différent.
- Si  $x_1$  est une variable explicative binaire, l'effet partiel d'un changement de  $x_1$  de 0 à 1, toutes choses restant égales par ailleurs est simplement

$$G(\beta_0 + \beta_1 + \beta_2 x_2 + \dots + \beta_k x_k) - G(\beta_0 + \beta_2 x_2 + \dots + \beta_k x_k).$$

# Variables binaires $x_j$

- Le calcul de l'effet partiel pour une variable binaire est différent.
- Si  $x_1$  est une variable explicative binaire, l'effet partiel d'un changement de  $x_1$  de 0 à 1, toutes choses restant égales par ailleurs est simplement

$$G(\beta_0 + \beta_1 + \beta_2 x_2 + \dots + \beta_k x_k) - G(\beta_0 + \beta_2 x_2 + \dots + \beta_k x_k).$$

- Encore une fois, l'effet dépend de  $\mathbf{x}$  mais connaître le signe de  $\beta_1$  donne une indication parfaite sur le signe de l'effet (et sa significativité).

# Variables binaires $x_j$

- Le calcul de l'effet partiel pour une variable binaire est différent.
- Si  $x_1$  est une variable explicative binaire, l'effet partiel d'un changement de  $x_1$  de 0 à 1, toutes choses restant égales par ailleurs est simplement

$$G(\beta_0 + \beta_1 + \beta_2 x_2 + \dots + \beta_k x_k) - G(\beta_0 + \beta_2 x_2 + \dots + \beta_k x_k).$$

- Encore une fois, l'effet dépend de  $\mathbf{x}$  mais connaître le signe de  $\beta_1$  donne une indication parfaite sur le signe de l'effet (et sa significativité).
- Egalement, si  $x_1$  est une variable discrète, comme le nombre d'enfants, le passage de la valeur  $c_1$  à  $1 + c_1$  (exemple 1 à 2) à un effet de

$$G(\beta_0 + \beta_1(1 + c_1) + \beta_2 x_2 + \dots + \beta_k x_k) - G(\beta_0 + \beta_1 c_1 + \beta_2 x_2 + \dots + \beta_k x_k).$$

# Variables du type $\log(x_j)$ et $x_j^2$

- Soit le modèle

$$P(y = 1|\mathbf{x}) = G(\beta_0 + \beta_1 x_1 + \beta_2 x_1^2 + \beta_3 \log(x_3)).$$

# Variables du type $\log(x_j)$ et $x_j^2$

- Soit le modèle

$$P(y = 1|\mathbf{x}) = G(\beta_0 + \beta_1 x_1 + \beta_2 x_1^2 + \beta_3 \log(x_3)).$$

- L'effet partiel de  $x_1$  sur  $P(y = 1|\mathbf{x})$  est

$$\frac{\partial P(y = 1|\mathbf{x})}{\partial x_1} = g(\beta_0 + \mathbf{x}\mathbf{B})(\beta_1 + 2\beta_2 x_1).$$

# Variables du type $\log(x_j)$ et $x_j^2$

- Soit le modèle

$$P(y = 1|\mathbf{x}) = G(\beta_0 + \beta_1 x_1 + \beta_2 x_1^2 + \beta_3 \log(x_3)).$$

- L'effet partiel de  $x_1$  sur  $P(y = 1|\mathbf{x})$  est

$$\frac{\partial P(y = 1|\mathbf{x})}{\partial x_1} = g(\beta_0 + \mathbf{x}\mathbf{B})(\beta_1 + 2\beta_2 x_1).$$

- L'effet partiel de  $x_3$  sur  $P(y = 1|\mathbf{x})$  est

$$\frac{\partial P(y = 1|\mathbf{x})}{\partial x_3} = g(\beta_0 + \mathbf{x}\mathbf{B}) \left( \frac{\beta_3}{x_3} \right).$$



# Estimation

- Les modèles Logit et Probit sont généralement estimés par MV.

# Estimation

- Les modèles Logit et Probit sont généralement estimés par MV.
- Supposons que nous disposons de  $n$  observations.

# Estimation

- Les modèles Logit et Probit sont généralement estimés par MV.
- Supposons que nous disposons de  $n$  observations.
- La distribution de  $y_i$  conditionnelle à  $\mathbf{x}_i$  est:

$$f(y|\mathbf{x}_i; \mathbf{B}) = [G(\mathbf{x}_i\mathbf{B})]^y [1 - G(\mathbf{x}_i\mathbf{B})]^{1-y} \text{ avec } y = 0, 1.$$

# Estimation

- Les modèles Logit et Probit sont généralement estimés par MV.
- Supposons que nous disposons de  $n$  observations.
- La distribution de  $y_i$  conditionnelle à  $\mathbf{x}_i$  est:

$$f(y|\mathbf{x}_i; \mathbf{B}) = [G(\mathbf{x}_i\mathbf{B})]^y [1 - G(\mathbf{x}_i\mathbf{B})]^{1-y} \text{ avec } y = 0, 1.$$

- Pour simplifier, l'intercept est inclus dans  $\mathbf{x}$ .

# Estimation

- Les modèles Logit et Probit sont généralement estimés par MV.
- Supposons que nous disposons de  $n$  observations.
- La distribution de  $y_i$  conditionnelle à  $\mathbf{x}_i$  est:

$$f(y|\mathbf{x}_i; \mathbf{B}) = [G(\mathbf{x}_i\mathbf{B})]^y [1 - G(\mathbf{x}_i\mathbf{B})]^{1-y} \text{ avec } y = 0, 1.$$

- Pour simplifier, l'intercept est inclus dans  $\mathbf{x}$ .
- Quand  $y = 1$   $f(y|\mathbf{x}_i; \mathbf{B}) = G(\mathbf{x}_i\mathbf{B})$  et quand  $y = 0$   
 $f(y|\mathbf{x}_i; \mathbf{B}) = 1 - G(\mathbf{x}_i\mathbf{B})$ .

# Estimation

- Les modèles Logit et Probit sont généralement estimés par MV.
- Supposons que nous disposons de  $n$  observations.
- La distribution de  $y_i$  conditionnelle à  $\mathbf{x}_i$  est:

$$f(y|\mathbf{x}_i; \mathbf{B}) = [G(\mathbf{x}_i\mathbf{B})]^y [1 - G(\mathbf{x}_i\mathbf{B})]^{1-y} \text{ avec } y = 0, 1.$$

- Pour simplifier, l'intercept est inclus dans  $\mathbf{x}$ .
- Quand  $y = 1$   $f(y|\mathbf{x}_i; \mathbf{B}) = G(\mathbf{x}_i\mathbf{B})$  et quand  $y = 0$   
 $f(y|\mathbf{x}_i; \mathbf{B}) = 1 - G(\mathbf{x}_i\mathbf{B})$ .
- La fonction de log-vraisemblance pour l'observation  $i$  est une fonction des paramètres  $\mathbf{B}$  et des données  $\mathbf{x}_i$ , c-à-d

$$l_i(\mathbf{B}) = y_i \log[G(\mathbf{x}_i\mathbf{B})] + (1 - y_i) \log[1 - G(\mathbf{x}_i\mathbf{B})].$$

# Estimation

- La log-vraisemblance pour l'échantillon de taille  $n$  est simplement  $L(\mathbf{B}) = \sum_{i=1}^n l_i(\mathbf{B})$ .

# Estimation

- La log-vraisemblance pour l'échantillon de taille  $n$  est simplement  $L(\mathbf{B}) = \sum_{i=1}^n l_i(\mathbf{B})$ .
- L'estimateur du MV est celui qui maximise  $L(\mathbf{B})$ .



# Estimation

- La log-vraisemblance pour l'échantillon de taille  $n$  est simplement  $L(\mathbf{B}) = \sum_{i=1}^n l_i(\mathbf{B})$ .
- L'estimateur du MV est celui qui maximise  $L(\mathbf{B})$ .
- De part la non-linéarité de  $G(\cdot)$ , il n'est pas possible de dériver des formules donnant la solution à ce problème de maximisation. On utilisera donc des outils d'optimisation numérique.

# Estimation

- La log-vraisemblance pour l'échantillon de taille  $n$  est simplement  $L(\mathbf{B}) = \sum_{i=1}^n l_i(\mathbf{B})$ .
- L'estimateur du MV est celui qui maximise  $L(\mathbf{B})$ .
- De part la non-linéarité de  $G(\cdot)$ , il n'est pas possible de dériver des formules donnant la solution à ce problème de maximisation. On utilisera donc des outils d'optimisation numérique.
- Chaque  $\hat{\beta}_j$  est reporté avec un écart-type (asymptotique).

# Estimation

- Nous cherchons à savoir si une nouvelle méthode d'enseignement de l'économie, le système personnalisé d'instruction (PSI), influait significativement sur les performances dans les cours de gestion.

# Estimation

- Nous cherchons à savoir si une nouvelle méthode d'enseignement de l'économie, le système personnalisé d'instruction (PSI), influait significativement sur les performances dans les cours de gestion.
- Variable dépendante:  $\text{GRADE} = 1$  si le résultat de l'étudiant dans un cours intermédiaire de gestion financière est plus élevé que dans un cours de base.

# Estimation

- Nous cherchons à savoir si une nouvelle méthode d'enseignement de l'économie, le système personnalisé d'instruction (PSI), influait significativement sur les performances dans les cours de gestion.
- Variable dépendante:  $GRADE = 1$  si le résultat de l'étudiant dans un cours intermédiaire de gestion financière est plus élevé que dans un cours de base.
- Autres variables:  $GPA$  = note moyenne de l'étudiant,  $TUCE$  = score à un pré-test qui renseigne sur la connaissance de l'étudiant et  $PSI = 1$  si l'étudiant a suivi la nouvelle méthode d'apprentissage.

# Output LOGIT

CS( 1) Modelling GRADE by LOGIT

The estimation sample is 1 - 32

	Coefficient	Std.Error	t-value	t-prob
Constant	-13.0213	4.931	-2.64	0.013
GPA	2.82611	1.263	2.24	0.033
TUCE	0.0951577	0.1416	0.672	0.507
PSI	2.37869	1.065	2.23	0.034

log-likelihood	-12.8896342	no. of states	2
no. of observations	32	no. of parameters	4
baseline log-lik	-20.59173	Test: Chi <sup>2</sup> ( 3)	15.404 [0.0015]**
AIC	33.7792684	AIC/n	1.05560214
mean(GRADE)	0.34375	var(GRADE)	0.225586

Newton estimation (eps1=0.0001; eps2=0.005): Strong convergence

	Count	Frequency	Probability	loglik
State 0	21	0.65625	0.65625	-6.015
State 1	11	0.34375	0.34375	-6.875
Total	32	1.00000	1.00000	-12.89

# Output PROBIT

CS( 2) Modelling GRADE by PROBIT

The estimation sample is 1 - 32

	Coefficient	Std.Error	t-value	t-prob
Constant	-7.45231	2.572	-2.90	0.007
GPA	1.62582	0.6897	2.36	0.026
TUCE	0.0517280	0.08119	0.637	0.529
PSI	1.42633	0.5870	2.43	0.022

log-likelihood	-12.8188041	no. of states	2
no. of observations	32	no. of parameters	4
zeroline log-lik	-22.18071	Test: Chi <sup>2</sup> ( 4)	18.724 [0.0009]**
AIC	33.6376081	AIC/n	1.05117525
mean(GRADE)	0.34375	var(GRADE)	0.225586

Newton estimation (eps1=0.0001; eps2=0.005): Strong convergence

	Count	Frequency	Probability	loglik
State 0	21	0.65625	0.65728	-6.010
State 1	11	0.34375	0.34272	-6.808
Total	32	1.00000	1.00000	-12.82

# Comparaison des résultats

- Les niveaux de significativités des 2 modèles sont très proches.



# Comparaison des résultats

- Les niveaux de significativités des 2 modèles sont très proches.
- Les coefficients estimés sont différents.

# Comparaison des résultats

- Les niveaux de significativités des 2 modèles sont très proches.
- Les coefficients estimés sont différents.
- C'est normal car l'effet partiel est fonction de  $g(.)\beta_j$  avec  $g(.)$  la fonction cdf de la logistique ou de la normale.

# Comparaison des résultats

- Les niveaux de significativités des 2 modèles sont très proches.
- Les coefficients estimés sont différents.
- C'est normal car l'effet partiel est fonction de  $g(.)\beta_j$  avec  $g(.)$  la fonction cdf de la logistique ou de la normale.
- Notons que nous avons vu que  $g(0) = \phi(0) \approx 0.4$  pour la normale et  $\frac{\exp(0)}{[1+\exp(0)]^2} = 0.25$  pour la logistique.

# Comparaison des résultats

- Les niveaux de significativités des 2 modèles sont très proches.
- Les coefficients estimés sont différents.
- C'est normal car l'effet partiel est fonction de  $g(.)\beta_j$  avec  $g(.)$  la fonction cdf de la logistique ou de la normale.
- Notons que nous avons vu que  $g(0) = \phi(0) \approx 0.4$  pour la normale et  $\frac{\exp(0)}{[1+\exp(0)]^2} = 0.25$  pour la logistique.
- Donc pour avoir des effet marginaux equivalents il faut

$$\frac{\phi(0)\beta_j^p}{\frac{\exp(0)}{[1+\exp(0)]^2}\beta_j^l} = 1.$$

# Comparaison des résultats

- Les niveaux de significativités des 2 modèles sont très proches.
- Les coefficients estimés sont différents.
- C'est normal car l'effet partiel est fonction de  $g(.)\beta_j$  avec  $g(.)$  la fonction cdf de la logistique ou de la normale.
- Notons que nous avons vu que  $g(0) = \phi(0) \approx 0.4$  pour la normale et  $\frac{\exp(0)}{[1+\exp(0)]^2} = 0.25$  pour la logistique.
- Donc pour avoir des effet marginaux equivalents il faut 
$$\frac{\phi(0)\beta_j^p}{\frac{\exp(0)}{[1+\exp(0)]^2}\beta_j^l} = 1.$$
- C-à-d  $\frac{0.4\beta_j^p}{0.25\beta_j^l} = 1$  ou encore  $\beta_j^l = 1.6\beta_j^p$ .

# Comparaison des résultats

- Les niveaux de significativités des 2 modèles sont très proches.
- Les coefficients estimés sont différents.
- C'est normal car l'effet partiel est fonction de  $g(.)\beta_j$  avec  $g(.)$  la fonction cdf de la logistique ou de la normale.
- Notons que nous avons vu que  $g(0) = \phi(0) \approx 0.4$  pour la normale et  $\frac{\exp(0)}{[1+\exp(0)]^2} = 0.25$  pour la logistique.
- Donc pour avoir des effet marginaux equivalents il faut 
$$\frac{\phi(0)\beta_j^p}{\frac{\exp(0)}{[1+\exp(0)]^2}\beta_j^l} = 1.$$
- C-à-d  $\frac{0.4\beta_j^p}{0.25\beta_j^l} = 1$  ou encore  $\beta_j^l = 1.6\beta_j^p.$
- Exemple pour PSI:  $\frac{2.37869}{1.42633} = 1.6677.$

# Exemple de LRT sur PSI

CS( 2) Modelling GRADE by PROBIT

The estimation sample is 1 - 32

	Coefficient	Std.Error	t-value	t-prob
Constant	-6.03435	2.166	-2.79	0.009
GPA	1.40958	0.6510	2.17	0.039
TUCE	0.0526670	0.07433	0.709	0.484
log-likelihood	-16.1521573	no. of states		2
no. of observations	32	no. of parameters		3
zeroline log-lik	-22.18071	Test: Chi^2( 3)		12.057 [0.0072]**
AIC	38.3043147	AIC/n		1.19700983
mean(GRADE)	0.34375	var(GRADE)		0.225586

→  $LRT = 2[-12.8188041 - (-16.1521573)] = 2 \times 3.33 = 6.66 \gg 3.86(\chi_{5\%}^2(1))$ .

Mais  $\chi_{1\%}^2(1) = 6.63$ .

Attention ce test est asymptotique alors que  $n = 32$ .

# Exemple de test de Wald

Test for linear restrictions ( $Rb=r$ ):

R matrix

Constant	GPA	TUCE	PSI
0.00000	0.00000	0.00000	1.00000

r vector

0.00000

LinRes Chi<sup>2</sup>(1) = 5.90506 [0.0151] \*

Attention ce test est également asymptotique alors que  $n = 32$ .



# Goodness-of-fit

- Une mesure fréquemment reportée lors de l'estimation de modèles Logit et Probit est le pourcentage de prédictions correctes.

# Goodness-of-fit

- Une mesure fréquemment reportée lors de l'estimation de modèles Logit et Probit est le pourcentage de prédictions correctes.
- Cette mesure s'apparente au  $R^2$  d'un modèle linéaire.

# Goodness-of-fit

- Une mesure fréquemment reportée lors de l'estimation de modèles Logit et Probit est le pourcentage de prédictions correctes.
- Cette mesure s'apparente au  $R^2$  d'un modèle linéaire.
- Soit  $\tilde{y}_i = 1$  si  $G(\hat{\beta}_0 + \mathbf{x}_i \hat{\mathbf{B}}) \geq 0.5$  et  $\tilde{y}_i = 0$  si  $G(\hat{\beta}_0 + \mathbf{x}_i \hat{\mathbf{B}}) < 0.5$ .

# Goodness-of-fit

- Une mesure fréquemment reportée lors de l'estimation de modèles Logit et Probit est le pourcentage de prédictions correctes.
- Cette mesure s'apparente au  $R^2$  d'un modèle linéaire.
- Soit  $\tilde{y}_i = 1$  si  $G(\hat{\beta}_0 + \mathbf{x}_i \hat{\mathbf{B}}) \geq 0.5$  et  $\tilde{y}_i = 0$  si  $G(\hat{\beta}_0 + \mathbf{x}_i \hat{\mathbf{B}}) < 0.5$ .
- Etant donné  $\{\tilde{y}_i : i = 1, 2, \dots, n\}$ , on peut voir la qualité de la prévision de  $y_i$ .

# Goodness-of-fit

- Une mesure fréquemment reportée lors de l'estimation de modèles Logit et Probit est le pourcentage de prédictions correctes.
- Cette mesure s'apparente au  $R^2$  d'un modèle linéaire.
- Soit  $\tilde{y}_i = 1$  si  $G(\hat{\beta}_0 + \mathbf{x}_i \hat{\mathbf{B}}) \geq 0.5$  et  $\tilde{y}_i = 0$  si  $G(\hat{\beta}_0 + \mathbf{x}_i \hat{\mathbf{B}}) < 0.5$ .
- Etant donné  $\{\tilde{y}_i : i = 1, 2, \dots, n\}$ , on peut voir la qualité de la prévision de  $y_i$ .
- Pour chaque  $i$ , la paire  $(\tilde{y}_i, y_i)$  peut prendre quatre valeurs:  $(0, 0)$ ,  $(0, 1)$ ,  $(1, 0)$  et  $(1, 1)$ .

# Goodness-of-fit

- Une mesure fréquemment reportée lors de l'estimation de modèles Logit et Probit est le pourcentage de prédictions correctes.
- Cette mesure s'apparente au  $R^2$  d'un modèle linéaire.
- Soit  $\tilde{y}_i = 1$  si  $G(\hat{\beta}_0 + \mathbf{x}_i \hat{\mathbf{B}}) \geq 0.5$  et  $\tilde{y}_i = 0$  si  $G(\hat{\beta}_0 + \mathbf{x}_i \hat{\mathbf{B}}) < 0.5$ .
- Etant donné  $\{\tilde{y}_i : i = 1, 2, \dots, n\}$ , on peut voir la qualité de la prévision de  $y_i$ .
- Pour chaque  $i$ , la paire  $(\tilde{y}_i, y_i)$  peut prendre quatre valeurs:  $(0, 0)$ ,  $(0, 1)$ ,  $(1, 0)$  et  $(1, 1)$ .
- Pour les paires  $(0, 0)$  et  $(1, 1)$ , la prévision est correcte.

# Goodness-of-fit

- Une mesure fréquemment reportée lors de l'estimation de modèles Logit et Probit est le pourcentage de prédictions correctes.
- Cette mesure s'apparente au  $R^2$  d'un modèle linéaire.
- Soit  $\tilde{y}_i = 1$  si  $G(\hat{\beta}_0 + \mathbf{x}_i \hat{\mathbf{B}}) \geq 0.5$  et  $\tilde{y}_i = 0$  si  $G(\hat{\beta}_0 + \mathbf{x}_i \hat{\mathbf{B}}) < 0.5$ .
- Etant donné  $\{\tilde{y}_i : i = 1, 2, \dots, n\}$ , on peut voir la qualité de la prévision de  $y_i$ .
- Pour chaque  $i$ , la paire  $(\tilde{y}_i, y_i)$  peut prendre quatre valeurs:  $(0, 0)$ ,  $(0, 1)$ ,  $(1, 0)$  et  $(1, 1)$ .
- Pour les paires  $(0, 0)$  et  $(1, 1)$ , la prévision est correcte.
- Le pourcentage de prédictions correctes est le %age de valeurs  $\tilde{y}_i = y_i$ .

# Output PROBIT and LOGIT

Table of actual and predicted

	State 0	State 1	Sum actual
State 0	18	3	21
State 1	3	8	11
Sum pred	21	11	32

$$\rightarrow \frac{18+8}{32} = 0.8125$$



# Goodness-of-fit

- Même si cette mesure est utile elle peut être trompeuse.

# Goodness-of-fit

- Même si cette mesure est utile elle peut être trompeuse.
- En effet, il est possible d'obtenir des pourcentages de prédictions correctes élevés même lorsque l'évènement le moins probable est très mal prédit.

# Goodness-of-fit

- Même si cette mesure est utile elle peut être trompeuse.
- En effet, il est possible d'obtenir des pourcentages de prédictions correctes élevés même lorsque l'évènement le moins probable est très mal prédit.
- Exemple:  $n = 200$ , 160 observations ont  $y_i = 0$  et hors de ces 160 observations 140 ont  $\tilde{y}_i = 0$ . Donc on prédit correctement dans 87.5% des cas les valeurs de  $y_i = 0$ .

# Goodness-of-fit

- Même si cette mesure est utile elle peut être trompeuse.
- En effet, il est possible d'obtenir des pourcentages de prédictions correctes élevés même lorsque l'évènement le moins probable est très mal prédit.
- Exemple:  $n = 200$ , 160 observations ont  $y_i = 0$  et hors de ces 160 observations 140 ont  $\tilde{y}_i = 0$ . Donc on prédit correctement dans 87.5% des cas les valeurs de  $y_i = 0$ .
- Même si aucune prévision n'est correcte pour  $y_i = 1$ , on prédit toujours correctement 70% des observations (140/200).

# Goodness-of-fit

- Même si cette mesure est utile elle peut être trompeuse.
- En effet, il est possible d'obtenir des pourcentages de prédictions correctes élevés même lorsque l'évènement le moins probable est très mal prédit.
- Exemple:  $n = 200$ , 160 observations ont  $y_i = 0$  et hors de ces 160 observations 140 ont  $\tilde{y}_i = 0$ . Donc on prédit correctement dans 87.5% des cas les valeurs de  $y_i = 0$ .
- Même si aucune prévision n'est correcte pour  $y_i = 1$ , on prédit toujours correctement 70% des observations (140/200).
- Il est souvent utile de pouvoir également prédire les évènements les moins probables.

# Goodness-of-fit

- Même si cette mesure est utile elle peut être trompeuse.
- En effet, il est possible d'obtenir des pourcentages de prédictions correctes élevés même lorsque l'évènement le moins probable est très mal prédit.
- Exemple:  $n = 200$ , 160 observations ont  $y_i = 0$  et hors de ces 160 observations 140 ont  $\tilde{y}_i = 0$ . Donc on prédit correctement dans 87.5% des cas les valeurs de  $y_i = 0$ .
- Même si aucune prévision n'est correcte pour  $y_i = 1$ , on prédit toujours correctement 70% des observations (140/200).
- Il est souvent utile de pouvoir également prédire les évènements les moins probables.
- Il est donc important de calculer ce %age pour chaque valeur de  $y_i$ , c-à-d 0 et 1.

# Goodness-of-fit

- Une autre mesure reportée par la plupart des logiciels économétriques est le pseudo- $R^2$  de McFadden.

# Goodness-of-fit

- Une autre mesure reportée par la plupart des logiciels économétriques est le pseudo- $R^2$  de McFadden.
- Ce pseudo- $R^2 = 1 - \frac{L_{nc}}{L_0}$ , où  $L_{nc}$  est la log-vraisemblance du modèle (non contraint) et  $L_0$  est celle du modèle contraint ne comportant qu'une constante.



# Goodness-of-fit

- Une autre mesure reportée par la plupart des logiciels économétriques est le pseudo- $R^2$  de McFadden.
- Ce pseudo- $R^2 = 1 - \frac{L_{nc}}{L_0}$ , où  $L_{nc}$  est la log-vraisemblance du modèle (non contraint) et  $L_0$  est celle du modèle contraint ne comportant qu'une constante.
- Pourquoi est-ce que cette mesure a du sens ?

# Goodness-of-fit

- Une autre mesure reportée par la plupart des logiciels économétriques est le pseudo- $R^2$  de McFadden.
- Ce pseudo- $R^2 = 1 - \frac{L_{nc}}{L_0}$ , où  $L_{nc}$  est la log-vraisemblance du modèle (non contraint) et  $L_0$  est celle du modèle contraint ne comportant qu'une constante.
- Pourquoi est-ce que cette mesure a du sens ?
- $L < 0$  donc  $\frac{L_{nc}}{L_0} = \frac{|L_{nc}|}{|L_0|}$ .

# Goodness-of-fit

- Une autre mesure reportée par la plupart des logiciels économétriques est le pseudo- $R^2$  de McFadden.
- Ce pseudo- $R^2 = 1 - \frac{L_{nc}}{L_0}$ , où  $L_{nc}$  est la log-vraisemblance du modèle (non contraint) et  $L_0$  est celle du modèle contraint ne comportant qu'une constante.
- Pourquoi est-ce que cette mesure a du sens ?
- $L < 0$  donc  $\frac{L_{nc}}{L_0} = \frac{|L_{nc}|}{|L_0|}$ .
- De plus  $|L_{nc}| \leq |L_0|$ .

# Goodness-of-fit

- Si les variables explicatives n'ont pas de pouvoir explicatif  $\frac{L_{nc}}{L_0} = 1$  et donc pseudo- $R^2 = 0$ .

# Goodness-of-fit

- Si les variables explicatives n'ont pas de pouvoir explicatif  $\frac{L_{nc}}{L_0} = 1$  et donc pseudo- $R^2 = 0$ .
- Généralement  $|L_{nc}| < |L_0|$  et donc  $1 - \frac{L_{nc}}{L_0} > 0$

# Goodness-of-fit

- Si les variables explicatives n'ont pas de pouvoir explicatif  $\frac{L_{nc}}{L_0} = 1$  et donc pseudo- $R^2 = 0$ .
- Généralement  $|L_{nc}| < |L_0|$  et donc  $1 - \frac{L_{nc}}{L_0} > 0$
- Si  $L_{nc} = 0$  le pseudo- $R^2 = 1$ .

# Goodness-of-fit: Alternative

- Soit  $\hat{y}_i = G(\hat{\beta}_0 + \mathbf{x}_i \hat{\mathbf{B}})$  les prévisions de probabilité du modèle Logit ou Probit.

# Goodness-of-fit: Alternative

- Soit  $\hat{y}_i = G(\hat{\beta}_0 + \mathbf{x}_i \hat{\mathbf{B}})$  les prévisions de probabilité du modèle Logit ou Probit.
- Comme ces prévisions sont aussi des prévisions de  $E(y_i | \mathbf{x}_i)$ , on peut calculer un genre de  $R^2$  en comparant  $\hat{y}_i$  et  $y_i$ .



# Goodness-of-fit: Alternative

- Soit  $\hat{y}_i = G(\hat{\beta}_0 + \mathbf{x}_i \hat{\mathbf{B}})$  les prévisions de probabilité du modèle Logit ou Probit.
- Comme ces prévisions sont aussi des prévisions de  $E(y_i | \mathbf{x}_i)$ , on peut calculer un genre de  $R^2$  en comparant  $\hat{y}_i$  et  $y_i$ .
- $\rightarrow$  reporter  $\text{corr}(\hat{y}_i, y_i)^2$ .

# Output Descriptive Statistics

Means, standard deviations and correlations

The sample is: 1 - 32

Means

P(State 1)	GRADE
0.34375	0.34375

Standard deviations (using T-1)

P(State 1)	GRADE
0.31690	0.48256

Correlation matrix:

	P(State 1)	GRADE
P(State 1)	1.0000	0.65263
GRADE	0.65263	1.0000

→ Exportez d'abord les probabilités estimées.

→  $\text{corr}(\text{GRADE}, P(\text{State}_1)) = 0.65263$

# Reporter des effets partiels

- On a vu que si  $x_j$  est une variable continue, son effet partiel sur  $p(\mathbf{x}) = P(y = 1|\mathbf{x})$  est obtenu depuis la dérivée partielle suivante:

$$\frac{\partial p(\mathbf{x})}{\partial x_j} = g(\beta_0 + \mathbf{x}\mathbf{B})\beta_j,$$

où  $g(z) \equiv \frac{dG}{dz}(z)$ .

# Reporter des effets partiels

- On a vu que si  $x_j$  est une variable continue, son effet partiel sur  $p(\mathbf{x}) = P(y = 1|\mathbf{x})$  est obtenu depuis la dérivée partielle suivante:

$$\frac{\partial p(\mathbf{x})}{\partial x_j} = g(\beta_0 + \mathbf{x}\mathbf{B})\beta_j,$$

où  $g(z) \equiv \frac{dG}{dz}(z)$ .

- Par conséquent

$$\nabla p(\hat{\mathbf{x}}) \approx g(\hat{\beta}_0 + \mathbf{x}\hat{\mathbf{B}})\hat{\beta}_j \nabla x_j,$$

pour des petites variations de  $x_j$ .

# Reporter des effets partiels

- On a vu que si  $x_j$  est une variable continue, son effet partiel sur  $p(\mathbf{x}) = P(y = 1|\mathbf{x})$  est obtenu depuis la dérivée partielle suivante:

$$\frac{\partial p(\mathbf{x})}{\partial x_j} = g(\beta_0 + \mathbf{x}\mathbf{B})\beta_j,$$

où  $g(z) \equiv \frac{dG}{dz}(z)$ .

- Par conséquent

$$\nabla p(\hat{\mathbf{x}}) \approx g(\hat{\beta}_0 + \mathbf{x}\hat{\mathbf{B}})\hat{\beta}_j \nabla x_j,$$

pour des petites variations de  $x_j$ .

- Mais l'effet partiel dépend de  $\mathbf{x}$ , où  $g(\hat{\beta}_0 + \mathbf{x}\hat{\mathbf{B}})$  est appelé facteur d'échelle. Que reporter ?

# Reporter des effets partiels

- Les logiciels économétriques reportent souvent des effets partiels ou le facteur d'échelle est évalué en  $\bar{\mathbf{x}}$ , c-à-d

$$g(\hat{\beta}_0 + \bar{\mathbf{x}}\hat{\mathbf{B}}) = g(\hat{\beta}_0 + \hat{\beta}_1\bar{x}_1 + \hat{\beta}_2\bar{x}_2 + \dots + \hat{\beta}_k\bar{x}_k).$$

# Reporter des effets partiels

- Les logiciels économétriques reportent souvent des effets partiels ou le facteur d'échelle est évalué en  $\bar{\mathbf{x}}$ , c-à-d

$$g(\hat{\beta}_0 + \bar{\mathbf{x}}\hat{\mathbf{B}}) = g(\hat{\beta}_0 + \hat{\beta}_1\bar{x}_1 + \hat{\beta}_2\bar{x}_2 + \dots + \hat{\beta}_k\bar{x}_k).$$

- En multipliant ce facteur d'échelle par  $\beta_j$  on obtient l'effet partiel de  $x_j$  pour la personne *moyenne*.

# Reporter des effets partiels

- Les logiciels économétriques reportent souvent des effets partiels ou le facteur d'échelle est évalué en  $\bar{\mathbf{x}}$ , c-à-d

$$g(\hat{\beta}_0 + \bar{\mathbf{x}}\hat{\mathbf{B}}) = g(\hat{\beta}_0 + \hat{\beta}_1\bar{x}_1 + \hat{\beta}_2\bar{x}_2 + \dots + \hat{\beta}_k\bar{x}_k).$$

- En multipliant ce facteur d'échelle par  $\beta_j$  on obtient l'effet partiel de  $x_j$  pour la personne *moyenne*.
- Qu'est-ce que l'individu moyen si par exemple  $x_1 = Male$  (1 si homme et 0 pour femme).



# Reporter des effets partiels

- Les logiciels économétriques reportent souvent des effets partiels ou le facteur d'échelle est évalué en  $\bar{\mathbf{x}}$ , c-à-d

$$g(\hat{\beta}_0 + \bar{\mathbf{x}}\hat{\mathbf{B}}) = g(\hat{\beta}_0 + \hat{\beta}_1\bar{x}_1 + \hat{\beta}_2\bar{x}_2 + \dots + \hat{\beta}_k\bar{x}_k).$$

- En multipliant ce facteur d'échelle par  $\beta_j$  on obtient l'effet partiel de  $x_j$  pour la personne *moyenne*.
- Qu'est-ce que l'individu moyen si par exemple  $x_1 = Male$  (1 si homme et 0 pour femme).
- Si on a 52.5% d'hommes  $\bar{x}_1 = 0.525$ . En quoi cela représente la presonne moyenne ?

# Reporter des effets partiels

- De plus si  $x_1$  est par exemple  $\log(\text{sales})$ . Doit-on évaluer l'impact moyen en  $\overline{\log(\text{sales})}$  ou  $\log(\overline{\text{sales}})$  ? Les logiciels économétriques reportent le premier.

# Reporter des effets partiels

- De plus si  $x_1$  est par exemple  $\log(sales)$ . Doit-on évaluer l'impact moyen en  $\overline{\log(sales)}$  ou  $\log(\overline{sales})$  ? Les logiciels économétriques reportent le premier.
- Une approche différente pour calculer le facteur d'échelle qui permettrait de régler ces problèmes est la suivante.

# Reporter des effets partiels

- De plus si  $x_1$  est par exemple  $\log(\text{sales})$ . Doit-on évaluer l'impact moyen en  $\overline{\log(\text{sales})}$  ou  $\log(\overline{\text{sales}})$  ? Les logiciels économétriques reportent le premier.
- Une approche différente pour calculer le facteur d'échelle qui permettrait de régler ces problèmes est la suivante.



$$n^{-1} \sum_{i=1}^n g(\hat{\beta}_0 + \mathbf{x}_i \hat{\mathbf{B}})$$

# Reporter des effets partiels

- De plus si  $x_1$  est par exemple  $\log(\text{sales})$ . Doit-on évaluer l'impact moyen en  $\overline{\log(\text{sales})}$  ou  $\log(\overline{\text{sales}})$  ? Les logiciels économétriques reportent le premier.
- Une approche différente pour calculer le facteur d'échelle qui permettrait de régler ces problèmes est la suivante.

$$n^{-1} \sum_{i=1}^n g(\hat{\beta}_0 + \mathbf{x}_i \hat{\mathbf{B}})$$

- → on prend la moyenne de la fonction linéaire et non la fonction linéaire évaluée en la moyenne.

# Reporter des effets partiels

- De plus si  $x_1$  est par exemple  $\log(\text{sales})$ . Doit-on évaluer l'impact moyen en  $\overline{\log(\text{sales})}$  ou  $\log(\overline{\text{sales}})$  ? Les logiciels économétriques reportent le premier.
- Une approche différente pour calculer le facteur d'échelle qui permettrait de régler ces problèmes est la suivante.

$$n^{-1} \sum_{i=1}^n g(\hat{\beta}_0 + \mathbf{x}_i \hat{\mathbf{B}})$$

- → on prend la moyenne de la fonction linéaire et non la fonction linéaire évaluée en la moyenne.
- Les deux méthodes peuvent donner des facteurs d'échelle assez différents.

# Reporter des effets partiels

- Si les variables explicatives comprennent des variables discrètes, ces formules ne sont pas valables.

# Reporter des effets partiels

- Si les variables explicatives comprennent des variables discrètes, ces formules ne sont pas valables.
- Pour un changement de  $x_1$  de  $c_1$  à  $1 + c_1$ , l'analogue discret de l'effet partiel est

$$G(\hat{\beta}_0 + \hat{\beta}_1(1 + c_1) + \dots + \hat{\beta}_k \bar{x}_k) - G(\hat{\beta}_0 + \hat{\beta}_1 c_1 + \dots + \hat{\beta}_k \bar{x}_k).$$



# Reporter des effets partiels

- Si les variables explicatives comprennent des variables discrètes, ces formules ne sont pas valables.
- Pour un changement de  $x_1$  de  $c_1$  à  $1 + c_1$ , l'analogue discret de l'effet partiel est

$$G(\hat{\beta}_0 + \hat{\beta}_1(1 + c_1) + \dots + \hat{\beta}_k \bar{x}_k) - G(\hat{\beta}_0 + \hat{\beta}_1 c_1 + \dots + \hat{\beta}_k \bar{x}_k).$$

- La moyenne des effets partiels est quant à elle donnée par

$$n^{-1} \sum_{i=1}^n \{ G(\hat{\beta}_0 + \hat{\beta}_1(1 + c_1) + \hat{\beta}_2 x_{i2} + \dots + \hat{\beta}_k x_{ik}) - G(\hat{\beta}_0 + \hat{\beta}_1 c_1 + \hat{\beta}_2 x_{i2} + \dots + \hat{\beta}_k x_{ik}) \}.$$

# Exemple: GRADE et PROBIT

Summary statistics for explanatory variables

State 0:

	#obs	min	mean	max	std.dev
Constant	21	1	1	1	0
GPA	21	2.06	2.9519	3.57	0.34861
TUCE	21	12	21.095	26	3.6892
PSI	21	0	0.28571	1	0.45175

State 1:


	#obs	min	mean	max	std.dev
Constant	11	1	1	1	0
GPA	11	2.39	3.4327	4	0.47972
TUCE	11	17	23.545	29	3.6021
PSI	11	0	0.72727	1	0.44536

All States:

	#obs	min	mean	max	std.dev
Constant	32	1	1	1	0
GPA	32	2.06	3.1172	4	0.45936
TUCE	32	12	21.938	29	3.8401
PSI	32	0	0.4375	1	0.49608

→  $\overline{GPA} = 3.1172$  et  $\overline{TUCE} = 21.938$ .

# Exemple: GRADE et PROBIT


$$\begin{aligned} & G(-7.452 + 1.626\overline{GPA} + 0.052\overline{TUCE} + 1.426) \\ - & G(-7.452 + 1.626\overline{GPA} + 0.052\overline{TUCE}) \\ = & 0.57273563 - 0.106997165 = 0.465738465. \end{aligned}$$

# Exemple: GRADE et PROBIT

$$\begin{aligned} & G(-7.452 + 1.626\overline{GPA} + 0.052\overline{TUCE} + 1.426) \\ - & G(-7.452 + 1.626\overline{GPA} + 0.052\overline{TUCE}) \\ = & 0.57273563 - 0.106997165 = 0.465738465. \end{aligned}$$

- Comment évalue ce différentiel en fonction de GPA ?

# Exemple: GRADE et PROBIT

$$\begin{aligned} & G(-7.452 + 1.626\overline{GPA} + 0.052\overline{TUCE} + 1.426) \\ - & G(-7.452 + 1.626\overline{GPA} + 0.052\overline{TUCE}) \\ = & 0.57273563 - 0.106997165 = 0.465738465. \end{aligned}$$

• Comment évalue ce différentiel en fonction de GPA ?

$$\begin{aligned} & G(-7.452 + 1.626GPA + 0.052\overline{TUCE} + 1.426) \\ - & G(-7.452 + 1.626GPA + 0.052\overline{TUCE}) \end{aligned}$$

# Exemple: GRADE et PROBIT

- $$\begin{aligned} & G(-7.452 + 1.626\overline{GPA} + 0.052\overline{TUCE} + 1.426) \\ & - G(-7.452 + 1.626\overline{GPA} + 0.052\overline{TUCE}) \\ & = 0.57273563 - 0.106997165 = 0.465738465. \end{aligned}$$

- Comment évalue ce différentiel en fonction de GPA ?

- $$\begin{aligned} & G(-7.452 + 1.626GPA + 0.052\overline{TUCE} + 1.426) \\ & - G(-7.452 + 1.626GPA + 0.052\overline{TUCE}) \end{aligned}$$

- **GRADE\_prob.xls**

# Output

Strong convergence using numerical derivatives

Function value = -401.302

	Coefficient	Std.Error	t-value	t-prob
Constant	0.270077	0.50860	0.5310	0.5956
NWIFEINC	-0.012024	0.0048399	-2.484	0.0132
EDUC	0.130905	0.025254	5.183	0.0000
EXPER	0.123347	0.018725	6.587	0.0000
EXPERSQ	-0.001887	0.00060040	-3.143	0.0017
AGE	-0.052853	0.0084772	-6.235	0.0000
KIDSLT6	-0.868327	0.11852	-7.326	0.0000
KIDSGE6	0.036005	0.043477	0.8281	0.4079

# PcGive

CS( 2) Modelling INLF by Probit

The estimation sample is 1 - 753

	Coefficient	Std.Error	t-value	t-prob
Constant	0.270077	0.5081	0.532	0.595
NWIFEINC	-0.0120237	0.004939	-2.43	0.015
EDUC	0.130905	0.02540	5.15	0.000
EXPER	0.123348	0.01876	6.58	0.000
EXBERSQ	-0.00188708	0.0005999	-3.15	0.002
AGE	-0.0528527	0.008463	-6.25	0.000
KIDSLT6	-0.868329	0.1184	-7.33	0.000
KIDSGE6	0.0360050	0.04403	0.818	0.414
log-likelihood	-401.302193	no. of states		2
no. of observations	753	no. of parameters		8
zeroline log-lik	-521.9398	Test: Chi <sup>2</sup> ( 8)		241.28 [0.0000]**
AIC	818.604386	AIC/n		1.08712402
mean(INLF)	0.568393	var(INLF)		0.245322
BFGS estimation (eps1=0.0001; eps2=0.005): Strong convergence				



# LR test

$H_0 : KIDSLT6 = 0, KIDSGE6 = 0$

Strong convergence using numerical derivatives

Function value = -432.809

	Coefficient	Std.Error	t-value	t-prob
Constant	-0.619011	0.41656	-1.486	0.1377
NWIFEINC	-0.011281	0.0046216	-2.441	0.0149
EDUC	0.105111	0.023991	4.381	0.0000
EXPER	0.125348	0.018194	6.890	0.0000
EXPERSQ	-0.002041	0.00059101	-3.453	0.0006
AGE	-0.028674	0.0068451	-4.189	0.0000

$LRT = 2 \times (-401.302193 + 432.809) = 63.018 \gg \chi^2(2)$ .

Indeed,

$\text{Chi}^2(2) = 63.018 [0.0000] **$

# Une application en marketing

- Quels sont les déterminants du choix entre deux marques de ketchup ?

# Une application en marketing

- Quels sont les déterminants du choix entre deux marques de ketchup ?
- 2798 observations concernant 300 individus.

# Une application en marketing

- Quels sont les déterminants du choix entre deux marques de ketchup ?
- 2798 observations concernant 300 individus.
- On ne sélectionne pas la dernière observation de chaque individu (laissée pour des prévisions out-of-sample) → 2498 observations dans l'estimation.

# Une application en marketing

- Quels sont les déterminants du choix entre deux marques de ketchup ?
- 2798 observations concernant 300 individus.
- On ne sélectionne pas la dernière observation de chaque individu (laissée pour des prévisions out-of-sample) → 2498 observations dans l'estimation.
- 2 marques: Heintz et Hunts.

# Une application en marketing

- Quels sont les déterminants du choix entre deux marques de ketchup ?
- 2798 observations concernant 300 individus.
- On ne sélectionne pas la dernière observation de chaque individu (laissée pour des prévisions out-of-sample) → 2498 observations dans l'estimation.
- 2 marques: Heintz et Hunts.
- 2226 achats de Heintz contre 265 pour Hunts.

# Une application en marketing

- Quels sont les déterminants du choix entre deux marques de ketchup ?
- 2798 observations concernant 300 individus.
- On ne sélectionne pas la dernière observation de chaque individu (laissée pour des prévisions out-of-sample) → 2498 observations dans l'estimation.
- 2 marques: Heintz et Hunts.
- 2226 achats de Heintz contre 265 pour Hunts.
- Variable endogène: Heintz = 1 si achat de Heintz, 0 sinon.

# Une application en marketing

- Quels sont les déterminants du choix entre deux marques de ketchup ?
- 2798 observations concernant 300 individus.
- On ne sélectionne pas la dernière observation de chaque individu (laissée pour des prévisions out-of-sample) → 2498 observations dans l'estimation.
- 2 marques: Heintz et Hunts.
- 2226 achats de Heintz contre 265 pour Hunts.
- Variable endogène: Heintz = 1 si achat de Heintz, 0 sinon.
- Variables explicatives: Display (tête de gondole) only, feature (folder) only, feature and display et la différence du log du prix de Heintz et Hunts.



# Une application en marketing

- Quels sont les déterminants du choix entre deux marques de ketchup ?
- 2798 observations concernant 300 individus.
- On ne sélectionne pas la dernière observation de chaque individu (laissée pour des prévisions out-of-sample) → 2498 observations dans l'estimation.
- 2 marques: Heintz et Hunts.
- 2226 achats de Heintz contre 265 pour Hunts.
- Variable endogène: Heintz = 1 si achat de Heintz, 0 sinon.
- Variables explicatives: Display (tête de gondole) only, feature (folder) only, feature and display et la différence du log du prix de Heintz et Hunts.
- Heintz1.in7

# Output Logit sur HEINZ

	Coefficient	Std.Error	t-value	t-prob
Constant	3.29016	0.1505	21.9	0.000
DISPLHEINZ	0.525596	0.2545	2.07	0.039
DISPLHUNTS	-0.650595	0.2539	-2.56	0.010
FEATHEINZ	0.474176	0.3196	1.48	0.138
FEATHUNTS	-1.03337	0.3605	-2.87	0.004
FEATDISPLHEINZ	0.472853	0.4889	0.967	0.334
FEATDISPLHUNTS	-1.98104	0.4791	-4.13	0.000
LPRICEHEINZ	-5.98750	0.4005	-14.9	0.000
log-likelihood	-601.238259	no. of states		2
no. of observations	2498	no. of parameters		8
baseline log-lik	-859.7672	Test: Chi <sup>2</sup> ( 7)		517.06 [0.0000]**
mean(HEINZ)	0.891113	var(HEINZ)		0.0970307

# Output Logit sur HEINZ

Table of actual and predicted

	State 0	State 1	Sum actual
State 0	71	201	272
State 1	28	2198	2226
Sum pred	99	2399	2498

# Output Probit sur HEINZ

	Coefficient	Std.Error	t-value	t-prob
Constant	1.84643	0.07503	24.6	0.000
DISPLHEINZ	0.270800	0.1288	2.10	0.036
DISPLHUNTS	-0.376042	0.1499	-2.51	0.012
FEATHEINZ	0.187592	0.1575	1.19	0.234
FEATHUNTS	-0.572908	0.1995	-2.87	0.004
FEATDISPLHEINZ	0.254583	0.2484	1.02	0.306
FEATDISPLHUNTS	-1.09385	0.2747	-3.98	0.000
LPRICEHEINZ	-3.27430	0.2119	-15.4	0.000
log-likelihood	-598.528353	no. of states		2
no. of observations	2498	no. of parameters		8
zeroline log-lik	-1731.482	Test: Chi <sup>2</sup> ( 8)		2265.9 [0.0000]**
mean(HEINZ)	0.891113	var(HEINZ)		0.0970307

# Output Probit sur HEINZ

Table of actual and predicted

	State 0	State 1	Sum actual
State 0	70	202	272
State 1	28	2198	2226
Sum pred	98	2400	2498

# Une application en marketing

- L'intercept est positif. Notons que  $\frac{\exp(3.29)}{1+\exp(3.29)} = 0.964$ .

# Une application en marketing

- L'intercept est positif. Notons que  $\frac{\exp(3.29)}{1+\exp(3.29)} = 0.964$ .
- Donc la probabilité d'achat de Heintz si les variables explicatives sont 0 est de 96.4%.

# Une application en marketing

- L'intercept est positif. Notons que  $\frac{\exp(3.29)}{1+\exp(3.29)} = 0.964$ .
- Donc la probabilité d'achat de Heintz si les variables explicatives sont 0 est de 96.4%.
- Notons que la probabilité inconditionnelle d'achat de Heintz est de 89.1%.



# Une application en marketing

- L'intercept est positif. Notons que  $\frac{\exp(3.29)}{1+\exp(3.29)} = 0.964$ .
- Donc la probabilité d'achat de Heintz si les variables explicatives sont 0 est de 96.4%.
- Notons que la probabilité inconditionnelle d'achat de Heintz est de 89.1%.
- Les trois variables relatives à Hunts sont d'ampleur plus importantes que celles de Heintz, sont négatives et largement significatives.

# Une application en marketing

- L'intercept est positif. Notons que  $\frac{\exp(3.29)}{1+\exp(3.29)} = 0.964$ .
- Donc la probabilité d'achat de Heintz si les variables explicatives sont 0 est de 96.4%.
- Notons que la probabilité inconditionnelle d'achat de Heintz est de 89.1%.
- Les trois variables relatives à Hunts sont d'ampleur plus importantes que celles de Heintz, sont négatives et largement significatives.
- Une politique de marketing agressive de la part de Hunts peut faire gagner des parts de marché même si Heintz reste le leader dans le domaine.

# Une application en marketing

- L'effet est le plus fort pour une promotion couplant la mise en évidence du produit Hunts (tête de gondole) et un affichage dans le folder promotionnel.

# Une application en marketing

- L'effet est le plus fort pour une promotion couplant la mise en évidence du produit Hunts (tête de gondole) et un affichage dans le folder promotionnel.
- Les variables promotion de Heintz ne sont pas très significatives (uniquement display mais au seuil de 4%).

# Une application en marketing

- L'effet est le plus fort pour une promotion couplant la mise en évidence du produit Hunts (tête de gondole) et un affichage dans le folder promotionnel.
- Les variables promotion de Heintz ne sont pas très significatives (uniquement display mais au seuil de 4%).
- Le coefficient de  $LPRICEHEINZ$  est significativement négatif et donc une augmentation de prix de Heintz réduit les ventes et donc une diminution du prix de Hunts permet d'augmenter les ventes de Hunts.

$$\frac{\partial p(\mathbf{x})}{\partial x_j} = g(\hat{\beta}_0 + \bar{\mathbf{x}}\hat{\mathbf{B}})\hat{\beta}_j \text{ pour le Logit}$$

Derivatives of probabilities at regressor means

Probabilities:

State 0                    0.036095

State 1                    0.96390

Derivatives:

	mean	State 0	State 1
Constant	1.0000	-0.11447	0.11447
DISPLHEINZ	0.16053	-0.018287	0.018287
DISPLHUNTS	0.037230	0.022636	-0.022636
FEATHEINZ	0.13090	-0.016498	0.016498
FEATHUNTS	0.038431	0.035954	-0.035954
FEATDISPLHEINZ	0.035228	-0.016452	0.016452
FEATDISPLHUNTS	0.010408	0.068925	-0.068925
LPRICEHEINZ	0.014010	0.20832	-0.20832

# Prévisions (Logit) avec 1 si $\hat{p}(x) > 0.5$

Predictions:

Table of actual and predicted

	State 0	State 1	Sum actual
State 0	4	31	35
State 1	1	264	265
Sum pred	5	295	300

→ 88% de bonnes prévisions de 1, 1.3% de bonnes prévisions de 0.

→ 10.3% de mauvaises prévisions de 0 et 0.33% de mauvaises prévisions de 1.

Pour  $\hat{p}(x) > c$  avec  $c \neq 0.5$  (par exemple  $E(\text{Heintz}) = 0.891$ )  
exportez les prévisions et faites le calcul en excel.

# Estimation par variables instrumentales et doubles moindres carrés : Chapitre 15



# Utilisation des variables instrumentales

L'utilisation de la méthode des variables instrumentales (VI) se justifie dans différents contextes :

- Variables explicatives endogènes.

# Utilisation des variables instrumentales

L'utilisation de la méthode des variables instrumentales (VI) se justifie dans différents contextes :

- Variables explicatives endogènes.
- Problème d'erreurs de mesures sur certaines variables.  
Exemple : revenu déclaré.

# Utilisation des variables instrumentales

L'utilisation de la méthode des variables instrumentales (VI) se justifie dans différents contextes :

- Variables explicatives endogènes.
- Problème d'erreurs de mesures sur certaines variables.  
Exemple : revenu déclaré.
- Problème d'omission de variables explicatives appropriées.

# Variables explicatives endogènes

- Dans ce contexte, l'utilisation de VI donne lieu à une nouvelle méthode d'estimation : les doubles moindres carrés.

# Variables explicatives endogènes

- Dans ce contexte, l'utilisation de VI donne lieu à une nouvelle méthode d'estimation : les doubles moindres carrés.
- Méthode très populaire, notamment pour estimer des modèles macroéconomiques à plusieurs équations.

# Variables explicatives endogènes

- Dans ce contexte, l'utilisation de VI donne lieu à une nouvelle méthode d'estimation : les doubles moindres carrés.
- Méthode très populaire, notamment pour estimer des modèles macroéconomiques à plusieurs équations.
- Des exemples spécifiques seront développés dans le Chapitre 16 : **modèles à équations simultanées**.

# Variables explicatives endogènes

- Dans ce contexte, l'utilisation de VI donne lieu à une nouvelle méthode d'estimation : les doubles moindres carrés.
- Méthode très populaire, notamment pour estimer des modèles macroéconomiques à plusieurs équations.
- Des exemples spécifiques seront développés dans le Chapitre 16 : **modèles à équations simultanées**.
- Exemple : Relation entre le taux de criminalité (meurtres) et la taille des forces de police. Le taux de criminalité dépend de la taille des forces de polices et la taille des forces de police dépend du taux de criminalité. **Problème de simultanété**.

# Erreurs de mesure

- Problème d'erreurs de mesures sur certaines variables explicatives.



# Erreurs de mesure

- Problème d'erreurs de mesures sur certaines variables explicatives.
- Exemple : revenu déclaré.

# Omission de variables explicatives

- L'omission de variables explicatives appropriées mène à un biais d'estimation des coefficients de régression.

# Omission de variables explicatives

- L'omission de variables explicatives appropriées mène à un biais d'estimation des coefficients de régression.
- Ce biais peut être éliminé si l'on dispose de variables proxy. Quid si pas de proxy.

# Omission de variables explicatives

- L'omission de variables explicatives appropriées mène à un biais d'estimation des coefficients de régression.
- Ce biais peut être éliminé si l'on dispose de variables proxy. Quid si pas de proxy.
- Dans un contexte de données de panel, élimination du biais par différenciation si variable omise est indépendante du temps.

# Omission de variables explicatives

- L'omission de variables explicatives appropriées mène à un biais d'estimation des coefficients de régression.
- Ce biais peut être éliminé si l'on dispose de variables proxy. Quid si pas de proxy.
- Dans un contexte de données de panel, élimination du biais par différenciation si variable omise est indépendante du temps.
- Quid si la variable omise dépend du temps, si l'intérêt se porte sur des variables qui ne varient pas dans le temps (éliminées par différenciation) ou si on ne dispose pas de données de panel ?

## Illustration : variables omises

# Exemple : relation salaire-éducation

- Le vrai modèle de régression est :

$$wage = \beta_0 + \beta_1 educ + \beta_2 abil + e.$$

# Exemple : relation salaire-éducation

- Le vrai modèle de régression est :

$$wage = \beta_0 + \beta_1 educ + \beta_2 abil + e.$$

- Problème : on n'observe pas *abil* (compétence).



# Exemple : relation salaire-éducation

- Le vrai modèle de régression est :

$$wage = \beta_0 + \beta_1 educ + \beta_2 abil + e.$$

- Problème : on n'observe pas *abil* (compétence).
- On peut utiliser le QI comme variable proxy de *abil*.  
→ Quid si indisponible ?

# Exemple : relation salaire-éducation

- Le vrai modèle de régression est :

$$wage = \beta_0 + \beta_1 educ + \beta_2 abil + e.$$

- Problème : on n'observe pas *abil* (compétence).
- On peut utiliser le QI comme variable proxy de *abil*.  
→ Quid si indisponible ?
- Si on ignore *abil*, le modèle de régression devient :

$$wage = \beta_0 + \beta_1 educ + u.$$

# Exemple : relation salaire-éducation

- Le vrai modèle de régression est :

$$wage = \beta_0 + \beta_1 educ + \beta_2 abil + e.$$

- Problème : on n'observe pas *abil* (compétence).
- On peut utiliser le QI comme variable proxy de *abil*.  
→ Quid si indisponible ?
- Si on ignore *abil*, le modèle de régression devient :

$$wage = \beta_0 + \beta_1 educ + u.$$

- →  $u = \beta_2 abil + e$ .
- →  $abil \in u$ .
- → Si *abil* est corrélé avec *educ*,  $E(u|x) \neq 0$ .
- → Estimateur de  $\beta_1$  par MCO biaisé car violation de l'hypothèse **SLR.3**.

# Modèle de régression simple

- Le modèle de régression s'écrit :

$$y = \beta_0 + \beta_1 x + u.$$

# Modèle de régression simple

- Le modèle de régression s'écrit :

$$y = \beta_0 + \beta_1 x + u.$$

- A cause de l'omission de certaines variables :

$$\text{Cov}(x, u) \neq 0.$$

→ Les MCO donnent des estimateurs biaisés.

# Modèle de régression simple

- Le modèle de régression s'écrit :

$$y = \beta_0 + \beta_1 x + u.$$

- A cause de l'omission de certaines variables :

$$\text{Cov}(x, u) \neq 0.$$

→ Les MCO donnent des estimateurs biaisés.

- Idée des VI → utiliser une information additionnelle sous la forme d'une variable observable  $z$  qui remplit 2 conditions.

# Modèle de régression simple

- Le modèle de régression s'écrit :

$$y = \beta_0 + \beta_1 x + u.$$

- A cause de l'omission de certaines variables :

$$Cov(x, u) \neq 0.$$

→ Les MCO donnent des estimateurs biaisés.

- Idée des VI → utiliser une information additionnelle sous la forme d'une variable observable  $z$  qui remplit 2 conditions.
- Condition 1 :  $Cov(z, u) = 0$ .

# Modèle de régression simple

- Le modèle de régression s'écrit :

$$y = \beta_0 + \beta_1 x + u.$$

- A cause de l'omission de certaines variables :

$$Cov(x, u) \neq 0.$$

→ Les MCO donnent des estimateurs biaisés.

- Idée des VI → utiliser une information additionnelle sous la forme d'une variable observable  $z$  qui remplit 2 conditions.
- Condition 1 :  $Cov(z, u) = 0$ .
- Condition 2 :  $Cov(z, x) \neq 0$ .



# Conditions 1 des VI

- **Condition 1.** Dans la population,

$$\text{Cov}(z, u) = 0.$$

# Conditions 1 des VI

- **Condition 1.** Dans la population,

$$Cov(z, u) = 0.$$

- $z$  est dite exogène dans le modèle de régression.

# Conditions 1 des VI

- **Condition 1.** Dans la population,

$$Cov(z, u) = 0.$$

- $z$  est dite exogène dans le modèle de régression.
- Il est difficile de tester cette hypothèse.  
→ Faire d'abord appel à la **théorie économique**.

# Conditions 2 des VI

- **Condition 2.**

$$\text{Cov}(z, x) \neq 0.$$

# Conditions 2 des VI

- **Condition 2.**

$$Cov(z, x) \neq 0.$$

- $z$  est corrélée avec la variable explicative  $x$ .

# Conditions 2 des VI

- **Condition 2.**

$$Cov(z, x) \neq 0.$$

- $z$  est corrélée avec la variable explicative  $x$ .

- On peut tester cette hypothèse :

$$x = \pi_0 + \pi_1 z + \nu.$$

# Conditions 2 des VI

- **Condition 2.**

$$Cov(z, x) \neq 0.$$

- $z$  est corrélée avec la variable explicative  $x$ .
- On peut tester cette hypothèse :

$$x = \pi_0 + \pi_1 z + \nu.$$

- Comme  $\pi_1 = Cov(z, x) / Var(z)$ , la Condition 2 tient **ssi** on rejette l'hypothèse  $H_0 : \pi_1 = 0$  contre l'hypothèse alternative  $H_1 : \pi_1 \neq 0$ .

# Exemples et contre-exemples de VI

Revenons à la relation salaire-éducation.

- Regardons quelques candidats de VI pour *educ*.  
→ trouver  $z$  tel que  $Cov(z, abil) = 0$  et  $Cov(z, educ) \neq 0$ .



# Exemples et contre-exemples de VI

Revenons à la relation salaire-éducation.

- Regardons quelques candidats de VI pour *educ*.  
→ trouver  $z$  tel que  $Cov(z, abil) = 0$  et  $Cov(z, educ) \neq 0$ .
- Derniers numéros de sécurité sociale de l'individu :  
Condition 1 OK; Condition 2 non remplie.

# Exemples et contre-exemples de VI

Revenons à la relation salaire-éducation.

- Regardons quelques candidats de VI pour *educ*.  
→ trouver  $z$  tel que  $Cov(z, abil) = 0$  et  $Cov(z, educ) \neq 0$ .
- Derniers numéros de sécurité sociale de l'individu :  
Condition 1 OK; Condition 2 non remplie.
- QI : Condition 2 OK mais Condition 1 violée car QI corrélé avec *abil* et donc  $u$ .

# Exemples et contre-exemples de VI

Condition 1 :  $Cov(z, abil) = 0$  et Condition 2 :  
 $Cov(z, educ) \neq 0$ .

- Education de la mère : Condition 2 OK (les parents éduqués ont plus de chance d'avoir des enfants éduqués); Condition 1 moins évidente car corrélation compétence-éducation de la mère pas claire.  
→ [Voir la théorie économique.](#)

# Exemples et contre-exemples de VI

Condition 1 :  $Cov(z, abil) = 0$  et Condition 2 :  
 $Cov(z, educ) \neq 0$ .

- Education de la mère : Condition 2 OK (les parents éduqués ont plus de chance d'avoir des enfants éduqués); Condition 1 moins évidente car corrélation compétence-éducation de la mère pas claire.  
→ [Voir la théorie économique.](#)
- Nombre de frères et soeurs pendant l'enfance.  
→ Condition 1 vraisemblable.  
→ Condition 2 aussi car certaines études ont montré que les familles nombreuses avaient un niveau d'éducation significativement plus faible.

# Estimation et Inférence par la méthode des variables instrumentales

# Estimateurs des VI

Si l'on dispose d'une bonne VI, on peut estimer de manière consistante l'équation  $y = \beta_0 + \beta_1 x + u$ .

- Les 2 conditions des VI permettent d'identifier  $\beta_1$ , c'est-à-dire d'écrire  $\beta_1$  en termes de moments des variables observables :

$$Cov(z, y) = Cov(z, \beta_0 + \beta_1 x + u) = \beta_1 Cov(z, x) + Cov(z, u).$$

# Estimateurs des VI

Si l'on dispose d'une bonne VI, on peut estimer de manière consistante l'équation  $y = \beta_0 + \beta_1 x + u$ .

- Les 2 conditions des VI permettent d'identifier  $\beta_1$ , c'est-à-dire d'écrire  $\beta_1$  en termes de moments des variables observables :

$$Cov(z, y) = Cov(z, \beta_0 + \beta_1 x + u) = \beta_1 Cov(z, x) + Cov(z, u).$$

- Voir pages 712-713 pour les propriétés de calcul des covariances.

# Estimateurs des VI

Si l'on dispose d'une bonne VI, on peut estimer de manière consistante l'équation  $y = \beta_0 + \beta_1 x + u$ .

- Les 2 conditions des VI permettent d'identifier  $\beta_1$ , c'est-à-dire d'écrire  $\beta_1$  en termes de moments des variables observables :

$$Cov(z, y) = Cov(z, \beta_0 + \beta_1 x + u) = \beta_1 Cov(z, x) + Cov(z, u).$$

- Voir pages 712-713 pour les propriétés de calcul des covariances.
- Si  $Cov(z, u) = 0$ , alors  $\beta_1 = \frac{Cov(z, y)}{Cov(z, x)}$  qui existe ssi  $Cov(z, x) \neq 0$ .



# Estimateurs des VI

- L'estimateur par VI de  $\beta_1$  :

$$\hat{\beta}_1 = \frac{\sum_{i=1}^n (z_i - \bar{z})(y_i - \bar{y})}{\sum_{i=1}^n (z_i - \bar{z})(x_i - \bar{x})}.$$

# Estimateurs des VI

- L'estimateur par VI de  $\beta_1$  :

$$\hat{\beta}_1 = \frac{\sum_{i=1}^n (z_i - \bar{z})(y_i - \bar{y})}{\sum_{i=1}^n (z_i - \bar{z})(x_i - \bar{x})}.$$

- Remarque : si  $x = z$  (cas de  $x$  exogène), alors on retrouve l'estimateur des MCO. Dans ce cas,  $x$  est son propre instrument.

# Estimateurs des VI

- L'estimateur par VI de  $\beta_1$  :

$$\hat{\beta}_1 = \frac{\sum_{i=1}^n (z_i - \bar{z})(y_i - \bar{y})}{\sum_{i=1}^n (z_i - \bar{z})(x_i - \bar{x})}.$$

- Remarque : si  $x = z$  (cas de  $x$  exogène), alors on retrouve l'estimateur des MCO. Dans ce cas,  $x$  est son propre instrument.
- L'estimateur de l'intercept est simplement :  $\hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x}$ .

# Estimateurs des VI

- L'estimateur par VI de  $\beta_1$  :

$$\hat{\beta}_1 = \frac{\sum_{i=1}^n (z_i - \bar{z})(y_i - \bar{y})}{\sum_{i=1}^n (z_i - \bar{z})(x_i - \bar{x})}.$$

- Remarque : si  $x = z$  (cas de  $x$  exogène), alors on retrouve l'estimateur des MCO. Dans ce cas,  $x$  est son propre instrument.
- L'estimateur de l'intercept est simplement :  $\hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x}$ .
- Sous les conditions 1 et 2,  $plim(\hat{\beta}_1) = \beta_1 \rightarrow \hat{\beta}_1$  est convergent.

# Inférence avec les estimateurs des VI

- Les estimateurs VI sont, comme les estimateurs MCO, asymptotiquement distribués normalement. Pour faire de l'inférence, on a donc besoin d'un estimateur de la variance de  $\hat{\beta}_0$  et  $\hat{\beta}_1$ .

# Inférence avec les estimateurs des VI

- Les estimateurs VI sont, comme les estimateurs MCO, asymptotiquement distribués normalement. Pour faire de l'inférence, on a donc besoin d'un estimateur de la variance de  $\hat{\beta}_0$  et  $\hat{\beta}_1$ .
- On fait l'hypothèse d'homoscédasticité :  
$$E(u^2|z) = \text{Var}(u) = \sigma^2.$$

# Inférence avec les estimateurs des VI

- Les estimateurs VI sont, comme les estimateurs MCO, asymptotiquement distribués normalement. Pour faire de l'inférence, on a donc besoin d'un estimateur de la variance de  $\hat{\beta}_0$  et  $\hat{\beta}_1$ .
- On fait l'hypothèse d'homoscédasticité :  
$$E(u^2|z) = Var(u) = \sigma^2.$$
- Sous les conditions 1 et 2 des VI et cette hypothèse, alors la variance asymptotique de  $\hat{\beta}_1$  est égale à  $\frac{\sigma^2}{n\sigma_x^2\rho_{x,z}^2}$   
où  $\rho_{xz}$  est la corrélation entre  $x$  et  $z$ .

# Inférence avec les estimateurs des VI

- Les estimateurs VI sont, comme les estimateurs MCO, asymptotiquement distribués normalement. Pour faire de l'inférence, on a donc besoin d'un estimateur de la variance de  $\hat{\beta}_0$  et  $\hat{\beta}_1$ .
- On fait l'hypothèse d'homoscédasticité :  
$$E(u^2|z) = Var(u) = \sigma^2.$$
- Sous les conditions 1 et 2 des VI et cette hypothèse, alors la variance asymptotique de  $\hat{\beta}_1$  est égale à  $\frac{\sigma^2}{n\sigma_x^2\rho_{x,z}^2}$  où  $\rho_{xz}$  est la corrélation entre  $x$  et  $z$ .
- Un estimateur consistant de  $\sigma^2$  peut s'obtenir comme pour les MCO, c-à-d  $\hat{\sigma}^2 = \frac{1}{n-2} \sum_{i=1}^n \hat{u}_i^2$ .



# Inférence avec les Estimateurs des VI

- La variance asymptotique de  $\beta_1$  peut également s'écrire :  $\frac{\hat{\sigma}^2}{SCT_x R_{x,z}^2}$ , où  $SCT_x = \sum_{i=1}^n x_i^2$ .

# Inférence avec les Estimateurs des VI

- La variance asymptotique de  $\beta_1$  peut également s'écrire :  $\frac{\hat{\sigma}^2}{SCT_x R_{x,z}^2}$ , où  $SCT_x = \sum_{i=1}^n x_i^2$ .
- Comparons avec la variance asymptotique de  $\beta_1$  estimé par MCO :  $\frac{\hat{\sigma}^2}{SCT_x}$ .

# Inférence avec les Estimateurs des VI

- La variance asymptotique de  $\beta_1$  peut également s'écrire :  $\frac{\hat{\sigma}^2}{SCT_x R_{x,z}^2}$ , où  $SCT_x = \sum_{i=1}^n x_i^2$ .
- Comparons avec la variance asymptotique de  $\beta_1$  estimé par MCO :  $\frac{\hat{\sigma}^2}{SCT_x}$ .
- On voit que plus  $R_{x,z}^2$  ( $R^2$  de la régression de  $X_i$  sur  $Z_i$ ) est faible (instruments faibles), plus la précision de l'estimateur des VI est faible.

# Inférence avec les Estimateurs des VI

- La variance asymptotique de  $\beta_1$  peut également s'écrire :  $\frac{\hat{\sigma}^2}{SCT_x R_{x,z}^2}$ , où  $SCT_x = \sum_{i=1}^n x_i^2$ .
- Comparons avec la variance asymptotique de  $\beta_1$  estimé par MCO :  $\frac{\hat{\sigma}^2}{SCT_x}$ .
- On voit que plus  $R_{x,z}^2$  ( $R^2$  de la régression de  $X_i$  sur  $Z_i$ ) est faible (instruments faibles), plus la précision de l'estimateur des VI est faible.
- Comme  $R_{x,z}^2 < 1$ , la variance des estimateurs VI et des DMC est toujours plus élevée que celle des MCO : le coût de l'estimation des VI se paye en termes de **précision de l'estimateur**.

# Illustration : mroz.in7

EQ(1) Modelling LWAGE by OLS-CS (using mroz.in7)

The estimation sample is: 1 to 428

	Coefficient	Std.Error	t-value	t-prob
Constant	-0.185197	0.1852	-1.00	0.318
EDUC	0.108649	0.01440	7.55	0.000
sigma	0.680032	RSS		197.001022
R <sup>2</sup>	0.117883	F(1,426) = 56.93	[0.000]**	
log-likelihood	-441.26	DW		1.98
no. of observations	428	no. of parameters		2
mean(LWAGE)	1.19017	var(LWAGE)		0.521793

→  $\log(wage) = \beta_0 + \beta_1 educ + u$ .

→ Hors si  $abil \in u$  et  $Cov(abil, educ) \neq 0$  → Rejet **SLR.3**.

→ VI : Education du père (*fathereduc*) ?

# Tester la Condition 2

EQ( 2) Modelling EDUC by OLS-CS (using mroz.in7)

The estimation sample is: 1 to 428

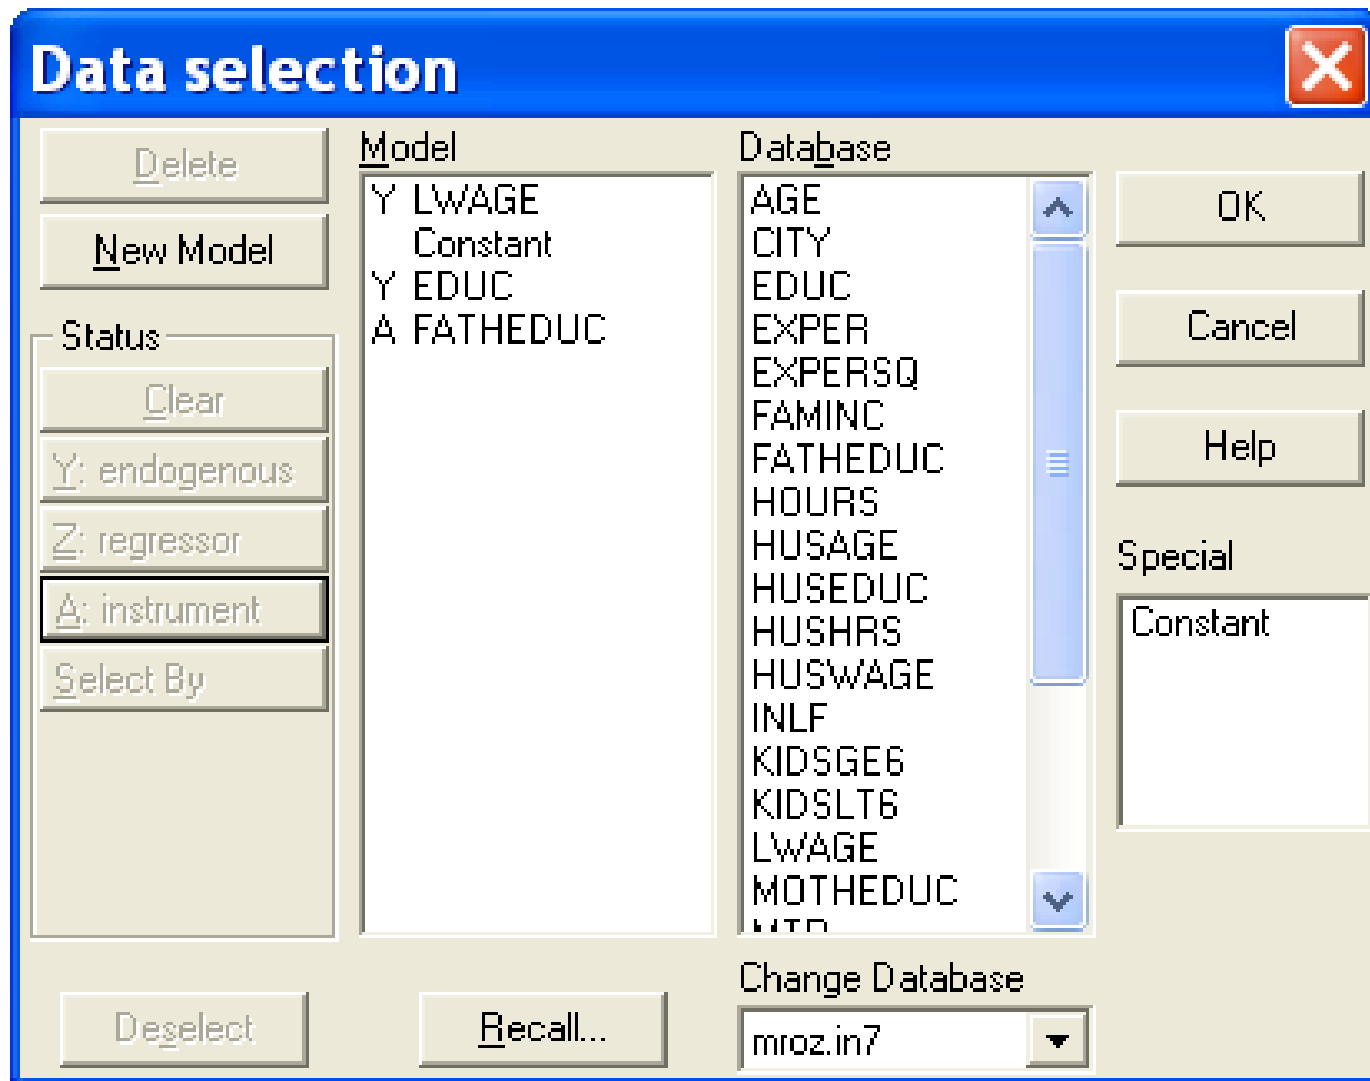
	Coefficient	Std.Error	t-value	t-prob	Part.R <sup>2</sup>
Constant	10.2371	0.2759	37.1	0.000	0.7636
FATHEDUC	0.269442	0.02859	9.43	0.000	0.1726
sigma	2.0813	RSS		1845.35428	
R <sup>2</sup>	0.17256	F(1,426) =	88.84	[0.000]**	
log-likelihood	-920.025	DW		1.92	
no. of observations	428	no. of parameters		2	
mean(EDUC)	12.6589	var(EDUC)		5.21074	

$$\rightarrow x = \pi_0 + \pi_1 z + \nu.$$

$$\rightarrow R^2 = 0.17256.$$

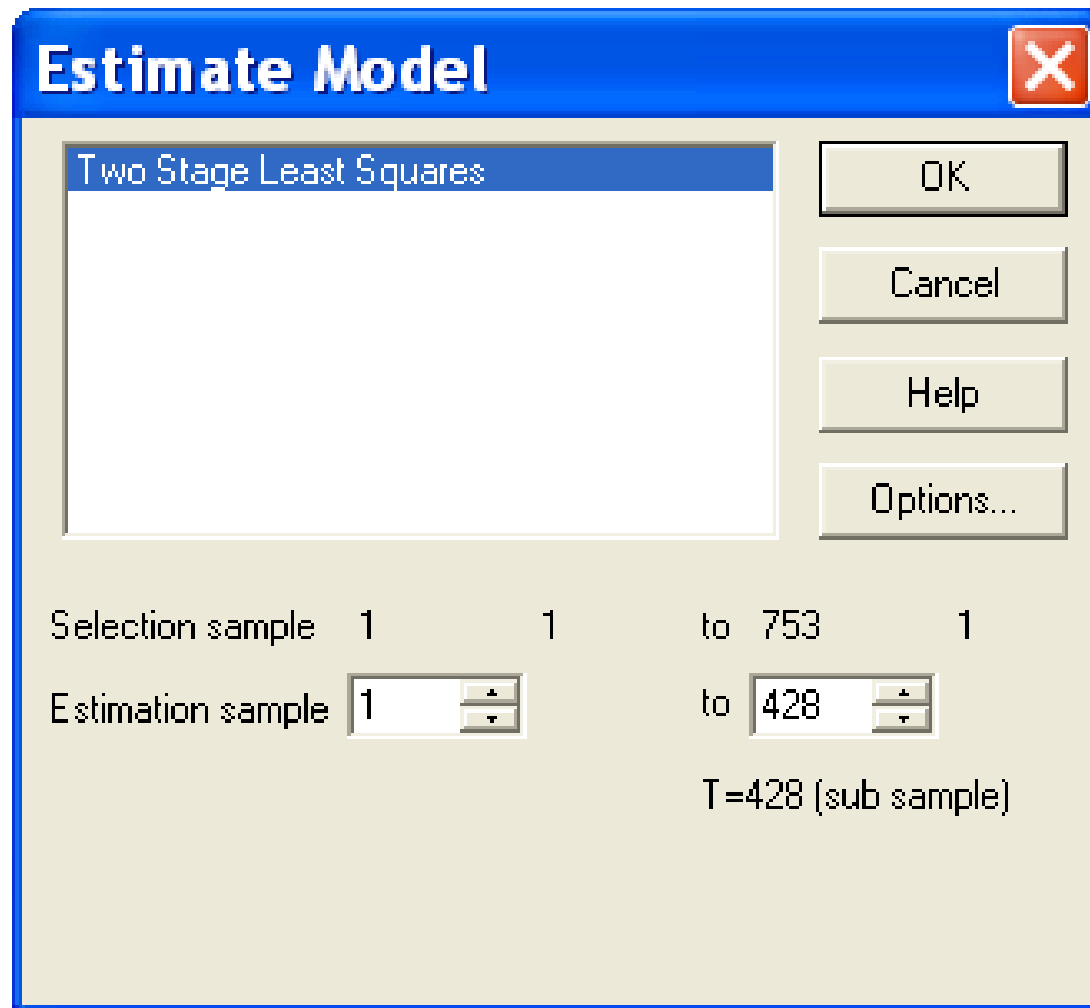
$$\rightarrow \text{t-stat de } \hat{\pi}_1 = 9.43 \rightarrow \text{rejet de } H_0 : \pi_1 = 0.$$

# PcGive : Sélection des variables



→ Sélectionner  $y$  en premier lieu. *EDUC* :  $Y$ .

# PcGive : Méthode





# Output PcGive : VI

EQ(3) Modelling LWAGE by IVE-CS (using mroz.in7)

The estimation sample is: 1 to 428

		Coefficient	Std.Error	t-value	t-prob
EDUC	Y	0.0591735	0.03514	1.68	0.093
Constant		0.441103	0.4461	0.989	0.323

sigma                      0.68939    RSS                      202.46008

Reduced form sigma      0.72186

no. of observations      428    no. of parameters      2

no. endogenous variables    2    no. of instruments      2

mean(LWAGE)              1.19017    var(LWAGE)              0.521793

Additional instruments:

[0] = FATHEDUC

Testing beta = 0:    Chi<sup>2</sup>(1) =    2.8354 [0.0922]

→ L'estimation par VI donne un impact plus faible (0.059 vs. 0.109) et des écart-types plus élevés que ceux obtenus par MCO (0.035 vs. 0.014).

→ Testing beta correspond au F-test  $H_0 : \beta_1 = \dots = \beta_k = 0$  et suit une  $\chi^2(k)$  sous  $H_0$ .

# Propriétés des VI avec VI faibles

- Instruments faibles = VI pour lesquelles la corrélation entre  $x$  et  $z$  est faible  $\rightarrow$  conséquences non désirables.

# Propriétés des VI avec VI faibles

- Instruments faibles = VI pour lesquelles la corrélation entre  $x$  et  $z$  est faible  $\rightarrow$  conséquences non désirables.
- Rappel pour les MCO :

$$\begin{aligned} \text{plim } \hat{\beta}_1 &= \beta_1 + \frac{\text{Cov}(x, u)}{\text{Var}(x)} \\ &= \beta_1 + \text{Corr}(x, u) \frac{\sigma_u}{\sigma_x} \\ &= \beta_1, \text{ si } \text{Corr}(x, u) = 0. \end{aligned}$$

# Propriétés des VI avec VI faibles

- Instruments faibles = VI pour lesquelles la corrélation entre  $x$  et  $z$  est faible  $\rightarrow$  conséquences non désirables.
- Rappel pour les MCO :

$$\begin{aligned} \text{plim } \hat{\beta}_1 &= \beta_1 + \frac{\text{Cov}(x, u)}{\text{Var}(x)} \\ &= \beta_1 + \text{Corr}(x, u) \frac{\sigma_u}{\sigma_x} \\ &= \beta_1, \text{ si } \text{Corr}(x, u) = 0. \end{aligned}$$

- Pour les VI :

$$\text{plim } \hat{\beta}_1 = \beta_1 + \left[ \frac{\text{Corr}(z, u)}{\text{Corr}(z, x)} \left( \frac{\sigma_u}{\sigma_x} \right) \right].$$

# Propriétés des VI avec VI faibles

- Si  $Corr(z, x)$  est faible  $\rightarrow$  estimateur largement inconsistant.

# Propriétés des VI avec VI faibles

- Si  $Corr(z, x)$  est faible  $\rightarrow$  estimateur largement inconsistant.
- Et ce, même si  $Corr(z, u)$  est faible.

# Propriétés des VI avec VI faibles

- Si  $Corr(z, x)$  est faible  $\rightarrow$  estimateur largement inconsistant.
- Et ce, même si  $Corr(z, u)$  est faible.
- En termes de consistance, les VI sont préférables aux MCO ssi  $\frac{Corr(z, u)}{Corr(z, x)} < Corr(x, u)$ .

# Propriétés des VI avec VI faibles

- Si  $Corr(z, x)$  est faible  $\rightarrow$  estimateur largement inconsistant.
- Et ce, même si  $Corr(z, u)$  est faible.
- En termes de consistance, les VI sont préférables aux MCO ssi  $\frac{Corr(z, u)}{Corr(z, x)} < Corr(x, u)$ .
- $\rightarrow$  Même en cas d'endogénéité, les MCO peuvent être préférables : tout dépend de la corrélation entre la VI et  $x$ .



# Illustration

- Relation entre le poids du bébé à la naissance et le nombre de cigarettes fumées par la mère.

# Illustration

- Relation entre le poids du bébé à la naissance et le nombre de cigarettes fumées par la mère.
- Exemple : **bwght.in7**.

# Illustration

- Relation entre le poids du bébé à la naissance et le nombre de cigarettes fumées par la mère.
- Exemple : `bwght.in7`.
- Problème : le nombre de cigarettes peut être corrélé avec des facteurs de santé non observés dans la régression → corrélation entre  $x$  et  $u$ .

# Illustration

- Relation entre le poids du bébé à la naissance et le nombre de cigarettes fumées par la mère.
- Exemple : **bwght.in7**.
- Problème : le nombre de cigarettes peut être corrélé avec des facteurs de santé non observés dans la régression → corrélation entre  $x$  et  $u$ .
- Idée de VI : prix des cigarettes dans la région d'habitation.

# Output PcGive : MCO

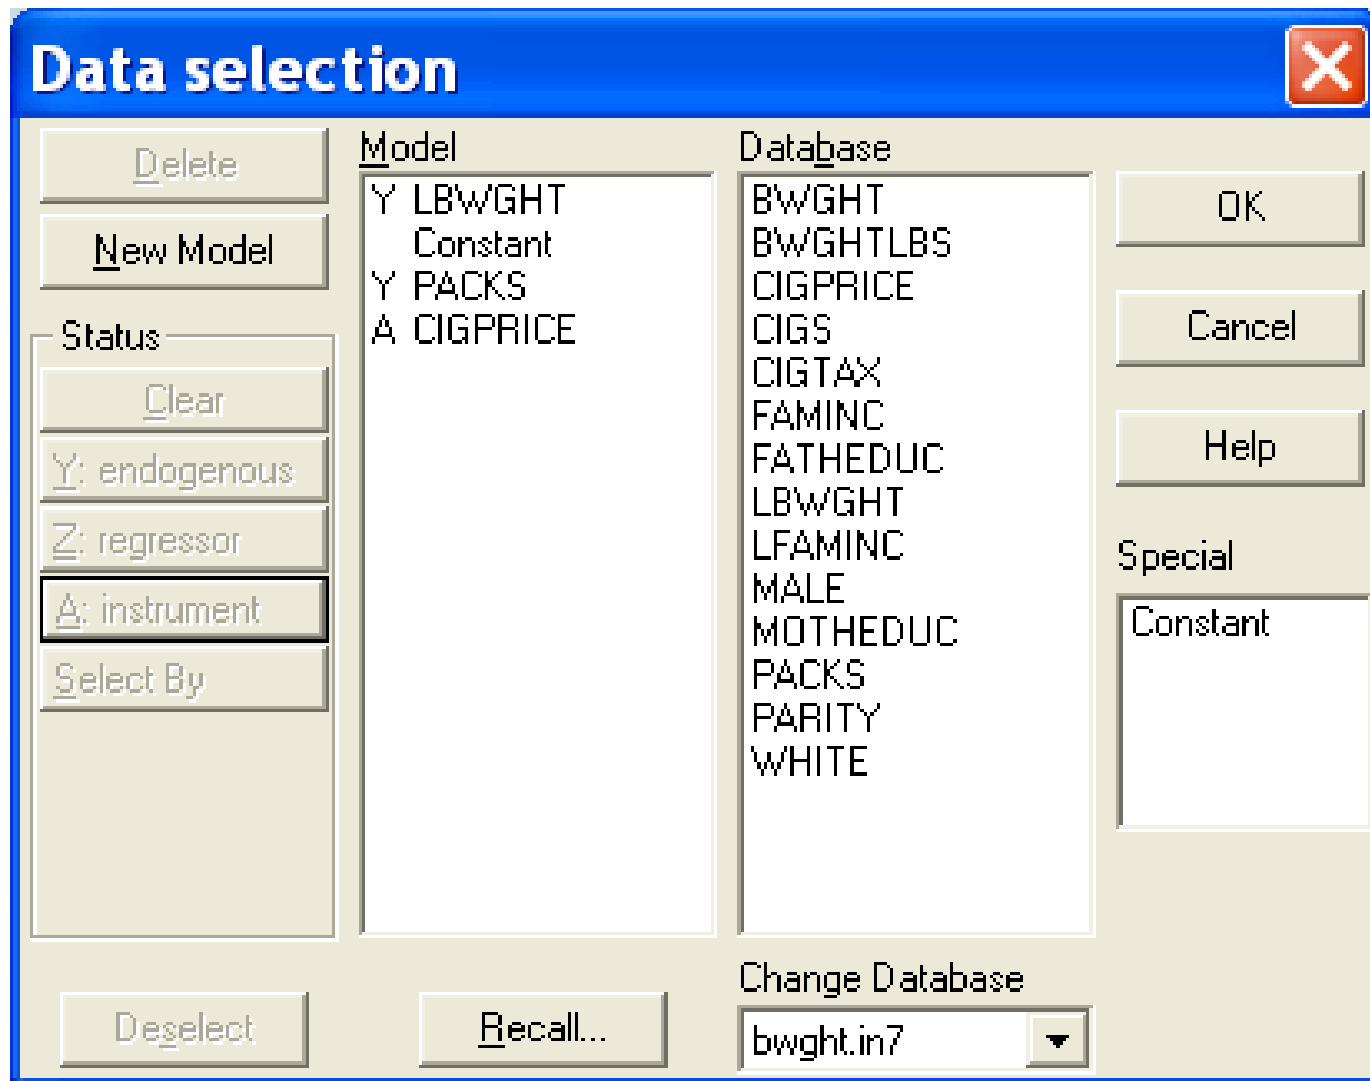
EQ(1) Modelling LBWGHT by OLS-CS (using bwght.in7)

The estimation sample is: 1 to 1388

	Coefficient	Std.Error	t-value	t-prob
Constant	4.76940	0.005369	888.	0.000
PACKS	-0.0898131	0.01698	-5.29	0.000
sigma	0.188834	RSS		49.4225599
R <sup>2</sup>	0.0197893	F(1,1386) = 27.98	[0.000]**	
log-likelihood	345.151	DW		1.93
no. of observations	1388	no. of parameters		2
mean(LBWGHT)	4.76003	var(LBWGHT)		0.0363259

→ Fumer à un effet négatif sur le poids des bébés.

# PcGive : Sélection des variables



# Output PcGive : $VI = CIGPRICE$

EQ(2) Modelling LBWGHT by IVE-CS (using bwght.in7)

The estimation sample is: 1 to 1388

		Coefficient	Std.Error	t-value	t-prob
PACKS	Y	2.98868	8.699	0.344	0.731
Constant		4.44814	0.9082	4.90	0.000

sigma                      0.938861    RSS                      1221.70415

Reduced form sigma      0.19053

no. of observations      1388    no. of parameters      2

no. endogenous variables    2    no. of instruments      2

mean(LBWGHT)            4.76003    var(LBWGHT)            0.0363259

Additional instruments:

[0] = CIGPRICE

Testing beta = 0:     $\text{Chi}^2(1) = 0.11804$  [0.7312]

→ Fumer à un effet positif mais non significatif sur le poids des bébés.

# Tester la Condition 2

EQ(3) Modelling CIGPRICE by OLS-CS (using bwght.in7)

The estimation sample is: 1 to 1388

	Coefficient	Std.Error	t-value	t-prob
Constant	130.524	0.2914	448.	0.000
PACKS	0.332897	0.9214	0.361	0.718
sigma	10.2477	RSS	145551.189	
R <sup>2</sup>	9.41712e-005	F(1,1386) =	0.1305	[0.718]
log-likelihood	-5198.44	DW		0.102
no. of observations	1388	no. of parameters		2
mean(CIGPRICE)	130.559	var(CIGPRICE)		104.874

$$\rightarrow x = \pi_0 + \pi_1 z + \nu.$$

$$\rightarrow R^2 = 9.41712e - 005.$$

$\rightarrow$  t-stat de  $\hat{\pi}_1 = 0.361 \rightarrow$  non-rejet de  $H_0 : \pi_1 = 0.$



# Autre exemple

- Estimation d'une fonction d'offre et de demande de poisson sur des données du 'Fulton Fish Market' à N-Y City.

# Autre exemple

- Estimation d'une fonction d'offre et de demande de poisson sur des données du 'Fulton Fish Market' à N-Y City.
- Fish: **Whiting** (merlan en français).

$$\text{S: QTY} = + 10.29 - 0.3986 \text{ PRICE}_t - 0.6429 \text{ WINDSPD}_t$$

(1.03)                      (0.193)                      (0.354)

$$\text{D: QTY} = 8.419 - 0.5409 \text{ PRICE}_t$$

(0.0762)                      (0.179)

# Autre exemple

- Estimation d'une fonction d'offre et de demande de poisson sur des données du 'Fulton Fish Market' à N-Y City.
- Fish: **Whiting** (merlan en français).

$$\text{S: QTY} = + 10.29 - 0.3986 \text{ PRICE}_t - 0.6429 \text{ WINDSPD}_t$$

(1.03)                      (0.193)                      (0.354)

$$\text{D: QTY} = 8.419 - 0.5409 \text{ PRICE}_t$$

(0.0762)                      (0.179)

- Les estimateurs MCO de l'équation d'offre sont incompatibles avec la théorie économique qui appelle une pente positive ou nulle de la fonction d'offre.

# Autre exemple

- Estimation d'une fonction d'offre et de demande de poisson sur des données du 'Fulton Fish Market' à N-Y City.
- Fish: **Whiting** (merlan en français).

$$\text{S: QTY} = + 10.29 - 0.3986 \text{ PRICE}_t - 0.6429 \text{ WINDSPD}_t$$

$(1.03) \quad (0.193) \quad (0.354)$

$$\text{D: QTY} = 8.419 - 0.5409 \text{ PRICE}_t$$

$(0.0762) \quad (0.179)$

- Les estimateurs MCO de l'équation d'offre sont incompatibles avec la théorie économique qui appelle une pente positive ou nulle de la fonction d'offre.

$$\text{D (IV avec WINDSPD): QTY} = - 1.265 \text{ PRICE}_t + 8.278$$

$(0.473) \quad (0.117)$

# Estimation par VI en régression multiple

# Régression multiple

- Exemple :  $\log(wage) = \beta_0 + \beta_1 educ + \beta_2 exper + u.$

# Régression multiple

- Exemple :  $\log(wage) = \beta_0 + \beta_1 educ + \beta_2 exper + u$ .
- $y_1 = \beta_0 + \beta_1 y_2 + \beta_2 z_1 + u_1$ .
  - Equation structurelle.
  - Objectif = estimation des  $\beta_j$ .

# Régression multiple

- Exemple :  $\log(wage) = \beta_0 + \beta_1 educ + \beta_2 exper + u$ .
- $y_1 = \beta_0 + \beta_1 y_2 + \beta_2 z_1 + u_1$ .
  - Equation structurelle.
  - Objectif = estimation des  $\beta_j$ .
- $y_1$  : variable **dépendante ou endogène** →  $\log(wage)$ .



# Régression multiple

- Exemple :  $\log(wage) = \beta_0 + \beta_1 educ + \beta_2 exper + u$ .
- $y_1 = \beta_0 + \beta_1 y_2 + \beta_2 z_1 + u_1$ .
  - Equation structurelle.
  - Objectif = estimation des  $\beta_j$ .
- $y_1$  : variable **dépendante ou endogène** →  $\log(wage)$ .
- $y_2$  : variable **explicative endogène** (corrélée avec  $u_1$ )
  - $educ$ .

# Régression multiple

- Exemple :  $\log(wage) = \beta_0 + \beta_1 educ + \beta_2 exper + u$ .
- $y_1 = \beta_0 + \beta_1 y_2 + \beta_2 z_1 + u_1$ .  
→ Equation structurelle.  
→ Objectif = estimation des  $\beta_j$ .
- $y_1$  : variable **dépendante ou endogène** →  $\log(wage)$ .
- $y_2$  : variable **explicative endogène** (corrélée avec  $u_1$ )  
→  $educ$ .
- $z_1$  : variable explicative **exogène** (non corrélée avec  $u_1$ )  
→  $exper$ .

# Régression multiple

- Exemple :  $\log(wage) = \beta_0 + \beta_1 educ + \beta_2 exper + u$ .
- $y_1 = \beta_0 + \beta_1 y_2 + \beta_2 z_1 + u_1$ .  
→ Equation structurelle.  
→ Objectif = estimation des  $\beta_j$ .
- $y_1$  : variable **dépendante ou endogène** →  $\log(wage)$ .
- $y_2$  : variable **explicative endogène** (corrélée avec  $u_1$ )  
→  $educ$ .
- $z_1$  : variable explicative **exogène** (non corrélée avec  $u_1$ )  
→  $exper$ .
- $E(u_1) = 0, Corr(u_1, z_1) = 0$  mais  $Corr(u_1, y_2) \neq 0$ .

# Régression multiple

- Exemple :  $\log(wage) = \beta_0 + \beta_1 educ + \beta_2 exper + u$ .
- $y_1 = \beta_0 + \beta_1 y_2 + \beta_2 z_1 + u_1$ .  
→ Equation structurelle.  
→ Objectif = estimation des  $\beta_j$ .
- $y_1$  : variable **dépendante ou endogène** →  $\log(wage)$ .
- $y_2$  : variable **explicative endogène** (corrélée avec  $u_1$ )  
→  $educ$ .
- $z_1$  : variable explicative **exogène** (non corrélée avec  $u_1$ )  
→  $exper$ .
- $E(u_1) = 0, Corr(u_1, z_1) = 0$  mais  $Corr(u_1, y_2) \neq 0$ .
- Si estimation par MCO : tous les  $\hat{\beta}_j$  seront biaisés.

# Régression multiple

- $z_1$  ne peut pas servir d'instrument pour  $y_2$  (car elle apparaît comme variable explicative) → recourt à  $z_2$ , une VI telle que  $Cov(z_2, u_1) = 0$  et  $Cov(z_2, y_2) \neq 0$ .

# Régression multiple

- $z_1$  ne peut pas servir d'instrument pour  $y_2$  (car elle apparaît comme variable explicative) → recourt à  $z_2$ , une VI telle que  $Cov(z_2, u_1) = 0$  et  $Cov(z_2, y_2) \neq 0$ .
- Hypothèses cruciales :  $E(u_1) = 0$ ,  $Cov(z_1, u_1) = 0$ ,  $Cov(z_2, u_1) = 0 \Rightarrow E(u_1) = E(z_1 u_1) = E(z_2 u_1) = 0$ .

# Régression multiple

- $z_1$  ne peut pas servir d'instrument pour  $y_2$  (car elle apparaît comme variable explicative) → recourt à  $z_2$ , une VI telle que  $Cov(z_2, u_1) = 0$  et  $Cov(z_2, y_2) \neq 0$ .
- Hypothèses cruciales :  $E(u_1) = 0$ ,  $Cov(z_1, u_1) = 0$ ,  $Cov(z_2, u_1) = 0 \Rightarrow E(u_1) = E(z_1 u_1) = E(z_2 u_1) = 0$ .
- Approche par la **méthode des moments** :

$$\sum_{i=1}^n (y_{i1} - \hat{\beta}_0 - \hat{\beta}_1 y_{i2} - \hat{\beta}_2 z_{i1}) = 0$$

$$\sum_{i=1}^n z_{i1} (y_{i1} - \hat{\beta}_0 - \hat{\beta}_1 y_{i2} - \hat{\beta}_2 z_{i1}) = 0$$

$$\sum_{i=1}^n z_{i2} (y_{i1} - \hat{\beta}_0 - \hat{\beta}_1 y_{i2} - \hat{\beta}_2 z_{i1}) = 0.$$

# Régression multiple

- 3 équations linéaires pour 3 inconnues  $(\beta_0, \beta_1, \beta_2)$ .



# Régression multiple

- 3 équations linéaires pour 3 inconnues  $(\beta_0, \beta_1, \beta_2)$ .
- Si  $z_2 = y_2$  (c-à-d  $y_2$  exogène), on retrouve les conditions du premier ordre des MCO.

# Régression multiple

- 3 équations linéaires pour 3 inconnues  $(\beta_0, \beta_1, \beta_2)$ .
- Si  $z_2 = y_2$  (c-à-d  $y_2$  exogène), on retrouve les conditions du premier ordre des MCO.
- La variable instrumentale  $z_2$  doit être conditionnellement corrélée avec  $y_2$  :

$$y_2 = \pi_0 + \pi_1 z_1 + \pi_2 z_2 + \nu_2.$$

Il s'agit d'un exemple d'**équation en forme réduite** : la variable endogène est exprimée exclusivement en termes de variables exogènes.

# Régression multiple

- 3 équations linéaires pour 3 inconnues  $(\beta_0, \beta_1, \beta_2)$ .
- Si  $z_2 = y_2$  (c-à-d  $y_2$  exogène), on retrouve les conditions du premier ordre des MCO.
- La variable instrumentale  $z_2$  doit être conditionnellement corrélée avec  $y_2$  :

$$y_2 = \pi_0 + \pi_1 z_1 + \pi_2 z_2 + \nu_2.$$

Il s'agit d'un exemple d'**équation en forme réduite** : la variable endogène est exprimée exclusivement en termes de variables exogènes.

- La condition d'identification (généralisation de la Condition 2 vue précédemment) est :  $\pi_2 \neq 0$ .

# Exemple de régression multiple : **card.in7**

- Lien éducation-salaire : 14 variables exogènes → expérience (*EXPER*), expérience au carré (*EXPER<sup>2</sup>*), une dummy pour noir (*BLACK*), une dummy pour zone urbaine (*SMSA*), une dummy pour zone urbaine en 1966 (*SMSA66*), une dummy pour état du sud (*SOUTH*) et 5 variables binaires régionales (*REG662 – REG669*).

# Exemple de régression multiple : **card.in7**

- Lien éducation-salaire : 14 variables exogènes → expérience (*EXPER*), expérience au carré (*EXPER<sup>2</sup>*), une dummy pour noir (*BLACK*), une dummy pour zone urbaine (*SMSA*), une dummy pour zone urbaine en 1966 (*SMSA66*), une dummy pour état du sud (*SOUTH*) et 5 variables binaires régionales (*REG662 – REG669*).
- Une variable explicative endogène : *EDUC*.

# Exemple de régression multiple : **card.in7**

- Lien éducation-salaire : 14 variables exogènes → expérience (*EXPER*), expérience au carré (*EXPER<sup>2</sup>*), une dummy pour noir (*BLACK*), une dummy pour zone urbaine (*SMSA*), une dummy pour zone urbaine en 1966 (*SMSA66*), une dummy pour état du sud (*SOUTH*) et 5 variables binaires régionales (*REG662 – REG669*).
- Une variable explicative endogène : *EDUC*.
- Une VI candidate pour *EDUC* : dummy pour habitation proche d'une école (*NEARC4*).

# Output PcGive : MCO

EQ(1) Modelling LWAGE by OLS-CS (using card.in7)

The estimation sample is: 1 to 3010

	Coefficient	Std.Error	t-value	t-prob
Constant	4.62081	0.07423	62.2	0.000
EDUC	0.0746933	0.003498	21.4	0.000
BLACK	-0.199012	0.01825	-10.9	0.000
EXPER	0.0848320	0.006624	12.8	0.000
EXPERSQ	-0.00228704	0.0003166	-7.22	0.000
SMSA	0.136385	0.02010	6.79	0.000
SOUTH	-0.147955	0.02598	-5.69	0.000
REG662	0.0963672	0.03590	2.68	0.007
...				
SMSA66	0.0262417	0.01945	1.35	0.177
sigma	0.37228	RSS		414.946049
R <sup>2</sup>	0.299836	F(15,2994) =	85.48	[0.000]**
log-likelihood	-1288.78	DW		1.88
no. of observations	3010	no. of parameters		16

# Tester la Condition 2

EQ(2) Modelling EDUC by OLS-CS (using card.in7)

The estimation sample is: 1 to 3010

	Coefficient	Std.Error	t-value	t-prob
Constant	16.6383	0.2406	69.1	0.000
BLACK	-0.935529	0.09373	-9.98	0.000
EXPER	-0.412533	0.03370	-12.2	0.000
EXPERSQ	0.000868574	0.001650	0.526	0.599
SMSA	0.402182	0.1048	3.84	0.000
SOUTH	-0.0516126	0.1354	-0.381	0.703
REG662	-0.0786363	0.1871	-0.420	0.674
...				
SMSA66	0.0254805	0.1058	0.241	0.810
NEARC4	0.319899	0.08786	3.64	0.000

→  $y_2 = \pi_0 + \pi_1 z_1 + \dots + \pi_{14} z_{14} + \pi_{15} z_{15} + \nu$ .

→ t-stat de  $\hat{\pi}_{15} = 3.64 \rightarrow$  rejet de  $H_0 : \pi_{15} = 0$ .



# Estimation par VI

EQ(3) Modelling LWAGE by IVE-CS (using card.in7)

The estimation sample is: 1 to 3010

		Coefficient	Std.Error	t-value	t-prob
EDUC	Y	0.131504	0.05496	2.39	0.017
Constant		3.66615	0.9248	3.96	0.000
BLACK		-0.146776	0.05390	-2.72	0.007
EXPER		0.108271	0.02366	4.58	0.000
...					
SMSA66		0.0185311	0.02161	0.858	0.391

Additional instruments:

[0] = NEARC4

Testing beta = 0: Chi<sup>2</sup>(15)= 765.11 [0.0000]\*\*

→ L'estimation par VI donne un rendement de l'éducation plus élevé que l'estimation par MCO (0.132 vs. 0.075) mais une plus grande incertitude (0.055 vs. 0.003).

# Doubles Moindres Carrés

# Variable explicative endogène unique

- Soit le modèle de régression :  $y_1 = \beta_0 + \beta_1 y_2 + \beta_2 z_1 + u$ .

# Variable explicative endogène unique

- Soit le modèle de régression :  $y_1 = \beta_0 + \beta_1 y_2 + \beta_2 z_1 + u$ .
- On dispose de 2 variables exogènes exclues :  $z_2$  et  $z_3$   
→ 2 restrictions d'exclusion.

# Variable explicative endogène unique

- Soit le modèle de régression :  $y_1 = \beta_0 + \beta_1 y_2 + \beta_2 z_1 + u$ .
- On dispose de 2 variables exogènes exclues :  $z_2$  et  $z_3$   
→ 2 restrictions d'exclusion.
- Si  $z_2$  et  $z_3$  sont corrélées avec  $y_2$ , on dispose de 2 VI potentielles.

# Variable explicative endogène unique

- Soit le modèle de régression :  $y_1 = \beta_0 + \beta_1 y_2 + \beta_2 z_1 + u$ .
- On dispose de 2 variables exogènes exclues :  $z_2$  et  $z_3$   
→ 2 restrictions d'exclusion.
- Si  $z_2$  et  $z_3$  sont corrélées avec  $y_2$ , on dispose de 2 VI potentielles.
- Dans ce cas, on va choisir la combinaison linéaire des variables exogènes  $z_1, z_2, z_3$  la plus corrélée avec  $y_2$  →  $y_2^*$ .

# Variable explicative endogène unique

- Soit l'équation en forme réduite :

$$y_2 = \pi_0 + \pi_1 z_1 + \pi_2 z_2 + \pi_3 z_3 + \nu_2.$$

# Variable explicative endogène unique

- Soit l'équation en forme réduite :

$$y_2 = \pi_0 + \pi_1 z_1 + \pi_2 z_2 + \pi_3 z_3 + \nu_2.$$

- Les hypothèses sont les suivantes :  $E(\nu_2) = 0$ ,  
 $Cov(z_1, \nu_2) = 0$ ,  $Cov(z_2, \nu_2) = 0$  et  $Cov(z_3, \nu_2) = 0$ .



# Variable explicative endogène unique

- Soit l'équation en forme réduite :  
$$y_2 = \pi_0 + \pi_1 z_1 + \pi_2 z_2 + \pi_3 z_3 + \nu_2.$$
- Les hypothèses sont les suivantes :  $E(\nu_2) = 0$ ,  
 $Cov(z_1, \nu_2) = 0$ ,  $Cov(z_2, \nu_2) = 0$  et  $Cov(z_3, \nu_2) = 0$ .
- $y_2^* = E(y_2 | z_1, z_2, z_3) = \hat{\pi}_0 + \hat{\pi}_1 z_1 + \hat{\pi}_2 z_2 + \hat{\pi}_3 z_3.$

# Variable explicative endogène unique

- Soit l'équation en forme réduite :  
$$y_2 = \pi_0 + \pi_1 z_1 + \pi_2 z_2 + \pi_3 z_3 + \nu_2.$$
- Les hypothèses sont les suivantes :  $E(\nu_2) = 0$ ,  
 $Cov(z_1, \nu_2) = 0$ ,  $Cov(z_2, \nu_2) = 0$  et  $Cov(z_3, \nu_2) = 0$ .
- $y_2^* = E(y_2 | z_1, z_2, z_3) = \hat{\pi}_0 + \hat{\pi}_1 z_1 + \hat{\pi}_2 z_2 + \hat{\pi}_3 z_3.$
- La condition d'identification devient :  $\pi_2 \neq 0$  ou  $\pi_3 \neq 0$ .  
Cette condition peut s'évaluer en testant  $H_0 : \pi_2 = 0$  et  $\pi_3 = 0$  à l'aide d'un F-test.

# Les doubles moindres carrés (DMC)

La méthode des DMC met en oeuvre ce qu'on vient de voir à travers 2 étapes ( $y_2 = \pi_0 + \pi_1 z_1 + \pi_2 z_2 + \pi_3 z_3 + \nu_2$ ).

- Étape 1 : On estime la meilleure combinaison linéaire des VI en régressant par MCO  $y_2$  sur  $z_1, z_2$  et  $z_3$   
 $\rightarrow \hat{y}_2 = \hat{\pi}_0 + \hat{\pi}_1 z_1 + \hat{\pi}_2 z_2 + \hat{\pi}_3 z_3 = y_2 - \hat{\nu}_2$ .

# Les doubles moindres carrés (DMC)

La méthode des DMC met en oeuvre ce qu'on vient de voir à travers 2 étapes ( $y_2 = \pi_0 + \pi_1 z_1 + \pi_2 z_2 + \pi_3 z_3 + \nu_2$ ).

- Étape 1 : On estime la meilleure combinaison linéaire des VI en régressant par MCO  $y_2$  sur  $z_1, z_2$  et  $z_3$   
 $\rightarrow \hat{y}_2 = \hat{\pi}_0 + \hat{\pi}_1 z_1 + \hat{\pi}_2 z_2 + \hat{\pi}_3 z_3 = y_2 - \hat{\nu}_2$ .
- Étape 2 : on utilise  $\hat{y}_2$  comme instrument de  $y_2$ . La **troisième condition des moments** devient :

$$\sum_{i=1}^n \hat{y}_{i2} (y_{i1} - \hat{\beta}_0 - \hat{\beta}_1 y_{i2} - \hat{\beta}_2 z_{i1}) = 0.$$

# Les doubles moindres carrés (DMC)

La méthode des DMC met en oeuvre ce qu'on vient de voir à travers 2 étapes ( $y_2 = \pi_0 + \pi_1 z_1 + \pi_2 z_2 + \pi_3 z_3 + \nu_2$ ).

- Étape 1 : On estime la meilleure combinaison linéaire des VI en régressant par MCO  $y_2$  sur  $z_1, z_2$  et  $z_3$   
 $\rightarrow \hat{y}_2 = \hat{\pi}_0 + \hat{\pi}_1 z_1 + \hat{\pi}_2 z_2 + \hat{\pi}_3 z_3 = y_2 - \hat{\nu}_2$ .
- Étape 2 : on utilise  $\hat{y}_2$  comme instrument de  $y_2$ . La **troisième condition des moments** devient :

$$\sum_{i=1}^n \hat{y}_{i2} (y_{i1} - \hat{\beta}_0 - \hat{\beta}_1 y_{i2} - \hat{\beta}_2 z_{i1}) = 0.$$

- L'étape 2 implique donc simplement d'utiliser  $\hat{y}_2$  obtenu en première étape comme régresseur :  
 $y_1 = \beta_0 + \beta_1 \hat{y}_2 + \beta_2 z_1 + \nu_2$ .

# Illustration des DMC

Reprenons l'exemple de la relation salaire-éducation  
([mroz.in7](#)).

● Equation structurelle :

$$\log(wage) = \beta_0 + \beta_1 educ + \beta_2 exper + \beta_3 exper^2 + u_1.$$

*exper* et *exper*<sup>2</sup> sont non corrélés avec  $u_1$ .

# Illustration des DMC

Reprenons l'exemple de la relation salaire-éducation ([mroz.in7](#)).

- Equation structurelle :

$$\log(wage) = \beta_0 + \beta_1 educ + \beta_2 exper + \beta_3 exper^2 + u_1.$$

*exper* et *exper*<sup>2</sup> sont non corrélés avec  $u_1$ .

- On va utiliser l'éducation des parents comme VI : *fatheduc* et *motheduc*.

# Illustration des DMC

Reprenons l'exemple de la relation salaire-éducation (*mroz.in7*).

- Equation structurelle :

$$\log(wage) = \beta_0 + \beta_1 educ + \beta_2 exper + \beta_3 exper^2 + u_1.$$

*exper* et *exper*<sup>2</sup> sont non corrélés avec  $u_1$ .

- On va utiliser l'éducation des parents comme VI : *fatheduc* et *motheduc*.

- L'équation en forme réduite s'écrit donc :  $educ = \pi_0 + \pi_1 exper + \pi_2 exper^2 + \pi_3 motheduc + \pi_4 fatheduc + \nu_2$ .



# Illustration des DMC

Reprenons l'exemple de la relation salaire-éducation ([mroz.in7](#)).

- Equation structurelle :

$$\log(wage) = \beta_0 + \beta_1 educ + \beta_2 exper + \beta_3 exper^2 + u_1.$$

$exper$  et  $exper^2$  sont non corrélés avec  $u_1$ .

- On va utiliser l'éducation des parents comme VI :  $fatheduc$  et  $motheduc$ .
- L'équation en forme réduite s'écrit donc :  $educ = \pi_0 + \pi_1 exper + \pi_2 exper^2 + \pi_3 motheduc + \pi_4 fatheduc + \nu_2$ .
- La condition d'identification requiert donc :  $\pi_3 \neq 0$  ou  $\pi_4 \neq 0$ , ce qui peut se tester par un test classique en  $F$ .

# Output PcGive : MCO

EQ(1) Modelling LWAGE by OLS-CS (using mroz.in7)

The estimation sample is: 1 to 428

	Coefficient	Std.Error	t-value	t-prob
Constant	-0.522041	0.1986	-2.63	0.009
EDUC	0.107490	0.01415	7.60	0.000
EXPER	0.0415665	0.01318	3.15	0.002
EXPERSQ	-0.000811193	0.0003932	-2.06	0.040
sigma	0.66642	RSS	188.305144	
R <sup>2</sup>	0.15682	F(3,424) = 26.29	[0.000]**	
log-likelihood	-431.599	DW	1.96	
no. of observations	428	no. of parameters	4	
mean(LWAGE)	1.19017	var(LWAGE)	0.521793	

# Condition d'indentification

EQ(2) Modelling EDUC by OLS-CS (using mroz.in7)

The estimation sample is: 1 to 753

	Coefficient	Std.Error	t-value	t-prob
Constant	8.36672	0.2667	31.4	0.000
EXPER	0.0853780	0.02555	3.34	0.001
EXBERSQ	-0.00185645	0.0008276	-2.24	0.025
FATHEDUC	0.184575	0.02450	7.53	0.000
MOTHEduc	0.185617	0.02599	7.14	0.000
sigma	1.9636	RSS	2884.0966	
R <sup>2</sup>	0.262387	F(4,748) = 66.52	[0.000]**	
log-likelihood	-1574.06	DW	2	
no. of observations	753	no. of parameters	5	
mean(EDUC)	12.2869	var(EDUC)	5.19262	

→ Equation en forme réduite.

# Condition d'indentification : F-test

Test for linear restrictions ( $Rb=r$ ):

R matrix

Constant	EXPER	EXBERSQ	FATHEDUC	MOTHEDEC
0.00000	0.00000	0.00000	1.0000	0.00000
0.00000	0.00000	0.00000	0.00000	1.0000

r vector

0.00000      0.00000

LinRes  $F(2,748) = 124.76 [0.0000]**$

→ Rejet de  $H_0 : \pi_3 = \pi_4 = 0$ .

# Output PcGive : DMC

EQ(3) Modelling LWAGE by IVE-CS (using mroz.in7)

The estimation sample is: 1 to 428

		Coefficient	Std.Error	t-value	t-prob
EDUC	Y	0.0613966	0.03144	1.95	0.051
Constant		0.0481003	0.4003	0.120	0.904
EXPER		0.0441704	0.01343	3.29	0.001
EXBERSQ		-0.000898970	0.0004017	-2.24	0.026

Additional instruments:

[0] = FATHEDUC

[1] = MOTHEduc

Specification test:  $\chi^2(1) = 0.37807$  [0.5386]

Testing beta = 0:  $\chi^2(3) = 24.422$  [0.0000]\*\*

→ La régression dans la forme structurelle par DMC donne un rendement de l'éducation des femmes (coefficient  $\hat{\beta}_1$ ) de 0.061 et à peine significatif (gonflement de l'écart-type 0.031).

## Extensions liées aux VI

# Variables endogènes multiples

- Cas de plusieurs variables endogènes. Exemple :  
 $y_1 = \beta_0 + \beta_1 y_2 + \beta_2 y_3 + \beta_3 z_1 + \beta_4 z_2 + u_1$ , où  $z_1$  et  $z_2$  sont des variables exogènes et  $y_2$  et  $y_3$  des variables endogènes.

# Variables endogènes multiples

- Cas de plusieurs variables endogènes. Exemple :  
 $y_1 = \beta_0 + \beta_1 y_2 + \beta_2 y_3 + \beta_3 z_1 + \beta_4 z_2 + u_1$ , où  $z_1$  et  $z_2$  sont des variables exogènes et  $y_2$  et  $y_3$  des variables endogènes.
- Condition nécessaire d'identification = **Condition d'ordre ou de rang**. → On a besoin d'au moins autant de variables exogènes exclues (de l'équation structurelle) que de variables endogènes présentes (dans l'équation structurelle).



# Variables endogènes multiples

- Cas de plusieurs variables endogènes. Exemple :  
 $y_1 = \beta_0 + \beta_1 y_2 + \beta_2 y_3 + \beta_3 z_1 + \beta_4 z_2 + u_1$ , où  $z_1$  et  $z_2$  sont des variables exogènes et  $y_2$  et  $y_3$  des variables endogènes.
- Condition nécessaire d'identification = **Condition d'ordre ou de rang**. → On a besoin d'au moins autant de variables exogènes exclues (de l'équation structurelle) que de variables endogènes présentes (dans l'équation structurelle).
- Dans l'exemple, l'identification requiert 2 variables exogènes  $z_3$  et  $z_4$  qui doivent être significatives dans l'équation en forme réduite.

# Erreurs de mesure

- Vrai modèle de régression :  $y_1 = \beta_0 + \beta_1 x_1^* + \beta_2 x_2 + u$ ,  
où  $x_1^*$  est observé avec erreur.  
→ on n'observe que  $x_1$  :  $x_1^* = x_1 + e_1$ .

# Erreurs de mesure

- Vrai modèle de régression :  $y_1 = \beta_0 + \beta_1 x_1^* + \beta_2 x_2 + u$ ,  
où  $x_1^*$  est observé avec erreur.  
→ on n'observe que  $x_1$  :  $x_1^* = x_1 + e_1$ .
- $y_1 = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + (u - \beta_1 e_1)$ .  
→ Ceci crée un problème d'endogénéité : corrélation  
entre  $x_1$  et le terme d'erreur  $(u - \beta_1 e_1)$  → MCO biaisés.

# Erreurs de mesure

- Vrai modèle de régression :  $y_1 = \beta_0 + \beta_1 x_1^* + \beta_2 x_2 + u$ ,  
où  $x_1^*$  est observé avec erreur.  
→ on n'observe que  $x_1$  :  $x_1^* = x_1 + e_1$ .
- $y_1 = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + (u - \beta_1 e_1)$ .  
→ Ceci crée un problème d'endogénéité : corrélation entre  $x_1$  et le terme d'erreur  $(u - \beta_1 e_1)$  → MCO biaisés.
- Solution : trouver une VI pour  $x_1$ . Dans le cas des problèmes de mesure, idée est de trouver une variable  $z_1$  corrélée avec  $x_1^*$  mais non corrélée avec  $e_1$ .

# Erreurs de mesure

Exemples :

- Salaire annuel reporté par travailleurs (erreurs de mesure) : VI = salaire reporté par l'employeur.

# Erreurs de mesure

Exemples :

- Salaire annuel reporté par travailleurs (erreurs de mesure) : VI = salaire reporté par l'employeur.
- Revenu annuel d'un ménage : VI = niveau annuel de l'épargne du ménage.

# Erreurs de mesure

Exemples :

- Salaire annuel reporté par travailleurs (erreurs de mesure) : VI = salaire reporté par l'employeur.
- Revenu annuel d'un ménage : VI = niveau annuel de l'épargne du ménage.
- Niveau d'éducation reporté par les travailleurs : VI = nombre d'années d'éducation reporté par le frère jumeau ou la soeur jumelle.

# Test d'endogénéité

- $y_1 = \beta_0 + \beta_1 y_2 + \beta_2 z_1 + \beta_3 z_2 + u_1 \rightarrow$  Supposons que  $z_1$  et  $z_2$  sont des variables exogènes et  $z_3$  et  $z_4$  des variables exclues.



# Test d'endogénéité

- $y_1 = \beta_0 + \beta_1 y_2 + \beta_2 z_1 + \beta_3 z_2 + u_1 \rightarrow$  Supposons que  $z_1$  et  $z_2$  sont des variables exogènes et  $z_3$  et  $z_4$  des variables exclues.
- Comment tester si  $y_2$  est endogène ?

# Test d'endogénéité

- $y_1 = \beta_0 + \beta_1 y_2 + \beta_2 z_1 + \beta_3 z_2 + u_1 \rightarrow$  Supposons que  $z_1$  et  $z_2$  sont des variables exogènes et  $z_3$  et  $z_4$  des variables exclues.
- Comment tester si  $y_2$  est endogène ?
- Test d'Hausman (1978) basé sur la comparaison entre valeurs estimées par MCO et par DMC.

# Test d'endogénéité

- $y_1 = \beta_0 + \beta_1 y_2 + \beta_2 z_1 + \beta_3 z_2 + u_1 \rightarrow$  Supposons que  $z_1$  et  $z_2$  sont des variables exogènes et  $z_3$  et  $z_4$  des variables exclues.
- Comment tester si  $y_2$  est endogène ?
- Test d'Hausman (1978) basé sur la comparaison entre valeurs estimées par MCO et par DMC.
- La statistique du test d'Hausman peut être calculée comme suit :

$$\zeta_H = (\hat{\beta}_{VI} - \hat{\beta}_{MCO})' [Var(\hat{\beta}_{VI}) - Var(\hat{\beta}_{MCO})]^{-1} (\hat{\beta}_{VI} - \hat{\beta}_{MCO}).$$

# Test d'endogénéité

- $y_1 = \beta_0 + \beta_1 y_2 + \beta_2 z_1 + \beta_3 z_2 + u_1 \rightarrow$  Supposons que  $z_1$  et  $z_2$  sont des variables exogènes et  $z_3$  et  $z_4$  des variables exclues.
- Comment tester si  $y_2$  est endogène ?
- Test d'Hausman (1978) basé sur la comparaison entre valeurs estimées par MCO et par DMC.
- La statistique du test d'Hausman peut être calculée comme suit :

$$\zeta_H = (\hat{\beta}_{VI} - \hat{\beta}_{MCO})' [Var(\hat{\beta}_{VI}) - Var(\hat{\beta}_{MCO})]^{-1} (\hat{\beta}_{VI} - \hat{\beta}_{MCO}).$$

- Sous  $H_0 : E(y_2, u_1) = 0$ ,  $\zeta_H \sim \chi^2(K)$ , où  $K$  est le nombre de coefficients estimés (c-à-d 4 dans l'exemple).

# Test LM d'endogénéité d'Hausman

- Test de Durbin, Wu et Hausman en 3 étapes, connu sous le nom de test LM d'Hausman.

# Test LM d'endogénéité d'Hausman

- Test de Durbin, Wu et Hausman en 3 étapes, connu sous le nom de test LM d'Hausman.
- Idée : reformuler l'hypothèse  $H_0 : E(y_2, u_1) = 0$  en terme d'un test de restriction de paramètres.

# Test LM d'endogénéité d'Hausman

- Test de Durbin, Wu et Hausman en 3 étapes, connu sous le nom de test LM d'Hausman.
- Idée : reformuler l'hypothèse  $H_0 : E(y_2, u_1) = 0$  en terme d'un test de restriction de paramètres.
- **Étape 1.** Estimation du modèle en forme réduite :  
$$y_2 = \pi_0 + \pi_1 z_1 + \pi_2 z_2 + \pi_3 z_3 + \pi_4 z_4 + \nu_2.$$

# Test LM d'endogénéité d'Hausman

- Test de Durbin, Wu et Hausman en 3 étapes, connu sous le nom de test LM d'Hausman.
- Idée : reformuler l'hypothèse  $H_0 : E(y_2, u_1) = 0$  en terme d'un test de restriction de paramètres.
- **Étape 1.** Estimation du modèle en forme réduite :  
$$y_2 = \pi_0 + \pi_1 z_1 + \pi_2 z_2 + \pi_3 z_3 + \pi_4 z_4 + \nu_2.$$
- Comme les variables  $z$  sont exogènes,  $E(z_i u_1) = 0$ ,  
 $\forall i = 1, \dots, 4.$



# Test LM d'endogénéité d'Hausman

- Test de Durbin, Wu et Hausman en 3 étapes, connu sous le nom de test LM d'Hausman.
- Idée : reformuler l'hypothèse  $H_0 : E(y_2, u_1) = 0$  en terme d'un test de restriction de paramètres.
- **Étape 1.** Estimation du modèle en forme réduite :  
$$y_2 = \pi_0 + \pi_1 z_1 + \pi_2 z_2 + \pi_3 z_3 + \pi_4 z_4 + \nu_2.$$
- Comme les variables  $z$  sont exogènes,  $E(z_i u_1) = 0$ ,  
 $\forall i = 1, \dots, 4.$
- Par conséquent, si  $y_2$  est également exogène ( $H_0$ ),  $\nu_2$  est non corrélé avec  $u_1$ .

# Test LM d'endogénéité d'Hausman

- Test de Durbin, Wu et Hausman en 3 étapes, connu sous le nom de test LM d'Hausman.
- Idée : reformuler l'hypothèse  $H_0 : E(y_2, u_1) = 0$  en terme d'un test de restriction de paramètres.
- **Étape 1.** Estimation du modèle en forme réduite :  
$$y_2 = \pi_0 + \pi_1 z_1 + \pi_2 z_2 + \pi_3 z_3 + \pi_4 z_4 + \nu_2.$$
- Comme les variables  $z$  sont exogènes,  $E(z_i u_1) = 0$ ,  $\forall i = 1, \dots, 4$ .
- Par conséquent, si  $y_2$  est également exogène ( $H_0$ ),  $\nu_2$  est non corrélé avec  $u_1$ .
- Pour tester l'exogénéité de  $y_2$ , écrivons  $u_1 = \delta_1 \nu_2 + e_1$ , où  $e_1$  est non corrélé à  $\nu_2$  et  $E(e_1) = 0$ . Si  $\delta_1 = 0$ ,  $E(\nu_2 u_1) = 0$ . Pour tester  $H_0$  il suffit donc d'ajouter  $\nu_2$  au modèle structurel et tester  $H_0 : \delta_1 = 0$ .

# Test LM d'endogénéité d'Hausman

- **Étape 2.** On récupère les résidus  $\hat{\nu}_2$ , contrepartie observable de  $\nu_2$  dans l'étape 1.

# Test LM d'endogénéité d'Hausman

- **Étape 2.** On récupère les résidus  $\hat{\nu}_2$ , contrepartie observable de  $\nu_2$  dans l'étape 1.
- **Étape 3.** On estime par MCO  $y_1 = \beta_0 + \beta_1 y_2 + \beta_2 z_1 + \beta_3 z_2 + \delta_1 \hat{\nu}_2 + \text{erreur}$  et on teste par un  $t$ -test  $H_0 : \delta_1 = 0$ . → On conclut à l'endogénéité de  $y_2$  si on rejette  $H_0$ .

# Test LM d'endogénéité d'Hausman

- Pourquoi test LM ?

# Test LM d'endogénéité d'Hausman

- Pourquoi test LM ?
- Extension: 2 variables explicatives endogènes  $y_2$  et  $y_3$ .

# Test LM d'endogénéité d'Hausman

- Pourquoi test LM ?
- Extension: 2 variables explicatives endogènes  $y_2$  et  $y_3$ .
- **Étape 1.** Estimation des 2 modèles en forme réduite :

$$y_2 = \pi_{0,2} + \pi_{1,2}z_1 + \pi_{2,2}z_2 + \pi_{3,2}z_3 + \pi_{4,2}z_4 + \nu_2 \text{ et}$$

$$y_3 = \pi_{0,3} + \pi_{1,3}z_1 + \pi_{2,3}z_2 + \pi_{3,3}z_3 + \pi_{4,3}z_4 + \nu_3.$$

# Test LM d'endogénéité d'Hausman

- Pourquoi test LM ?
- Extension: 2 variables explicatives endogènes  $y_2$  et  $y_3$ .
- **Étape 1.** Estimation des 2 modèles en forme réduite :  
$$y_2 = \pi_{0,2} + \pi_{1,2}z_1 + \pi_{2,2}z_2 + \pi_{3,2}z_3 + \pi_{4,2}z_4 + \nu_2$$
 et  
$$y_3 = \pi_{0,3} + \pi_{1,3}z_1 + \pi_{2,3}z_2 + \pi_{3,3}z_3 + \pi_{4,3}z_4 + \nu_3.$$
- Si il y a au moins une variable endogène  $y_2$  et/ou  $y_3$ ,  $\nu_2$  et/ou  $\nu_3$  sont/est corrélé(s) avec  $u_1$  et  $y_1$ .  
→ **Étape 2.** On récupère les résidus  $\hat{\nu}_2$  et  $\hat{\nu}_3$ , contrepartie observable de  $\nu_2$  et  $\nu_3$ .



# Test LM d'endogénéité d'Hausman

- Pourquoi test LM ?
- Extension: 2 variables explicatives endogènes  $y_2$  et  $y_3$ .
- **Étape 1.** Estimation des 2 modèles en forme réduite :  
$$y_2 = \pi_{0,2} + \pi_{1,2}z_1 + \pi_{2,2}z_2 + \pi_{3,2}z_3 + \pi_{4,2}z_4 + \nu_2$$
 et  
$$y_3 = \pi_{0,3} + \pi_{1,3}z_1 + \pi_{2,3}z_2 + \pi_{3,3}z_3 + \pi_{4,3}z_4 + \nu_3.$$
- Si il y a au moins une variable endogène  $y_2$  et/ou  $y_3$ ,  $\nu_2$  et/ou  $\nu_3$  sont/est corrélé(s) avec  $u_1$  et  $y_1$ .  
→ **Étape 2.** On récupère les résidus  $\hat{\nu}_2$  et  $\hat{\nu}_3$ , contrepartie observable de  $\nu_2$  et  $\nu_3$ .
- **Étape 3.** On estime par MCO  
$$y_1 = \beta_0 + \beta_1 y_2 + \beta_2 y_3 + \beta_3 z_1 + \beta_4 z_2 + \delta_1 \hat{\nu}_2 + \delta_2 \hat{\nu}_3 + \text{erreur}$$
 et on teste  $H_0 : \delta_1 = \delta_2 = 0$ . → On conclut à l'endogénéité de  $y_2$  ou  $y_3$  si on rejette  $H_0$ .

# Exemple de test d'endogénéité

On récupère les résidus  $\hat{\nu}_2$  (*res*) après l'estimation par MCO de :

$$educ = \pi_0 + \pi_1 exper + \pi_2 exper^2 + \pi_3 motheduc + \pi_4 fatheduc + \nu_2.$$

EQ(4) Modelling LWAGE by OLS-CS (using mroz.in7)

The estimation sample is: 1 to 428

	Coefficient	Std.Error	t-value	t-prob
EDUC	0.0639033	0.02921	2.19	0.029
Constant	-0.0114040	0.3592	-0.0317	0.975
EXPER	0.0463071	0.01344	3.45	0.001
EXPERSQ	-0.000944415	0.0004001	-2.36	0.019
res	0.0558771	0.03279	1.70	0.089
sigma	0.664929	RSS		187.021076
R <sup>2</sup>	0.16257	F(4,423) = 20.53	[0.000]**	
log-likelihood	-430.135	DW		1.93
no. of observations	428	no. of parameters		5

→ *t* - stat de  $\hat{\delta}_1 = 1.7$  [0.089] → Evidence limitée d'endogénéité de *educ*.

→ Dans le doute il est préférable d'utiliser conjointement MCO et DMC.

# Test de suridentification

- De manière générale, on ne peut pas tester la Condition 1 des VI, c-à-d  $Cov(z, u) = 0$ .

# Test de suridentification

- De manière générale, on ne peut pas tester la Condition 1 des VI, c-à-d  $Cov(z, u) = 0$ .
- Néanmoins il y a une exception importante : lorsque l'on dispose d'au moins 1 **restriction de suridentification**.

# Test de suridentification

- De manière générale, on ne peut pas tester la Condition 1 des VI, c-à-d  $Cov(z, u) = 0$ .
- Néanmoins il y a une exception importante : lorsque l'on dispose d'au moins 1 **restriction de suridentification**.
- Le nombre de restrictions de suridentification = nombre d'instruments excédentaires par rapport au nombre de variables endogènes.

# Test de suridentification

- De manière générale, on ne peut pas tester la Condition 1 des VI, c-à-d  $Cov(z, u) = 0$ .
- Néanmoins il y a une exception importante : lorsque l'on dispose d'au moins 1 **restriction de suridentification**.
- Le nombre de restrictions de suridentification = nombre d'instruments excédentaires par rapport au nombre de variables endogènes.
- Exemple :  $y_1 = \beta_0 + \beta_1 y_2 + \beta_2 z_1 + \beta_3 z_2 + u_1$ . Si on dispose de 2 VI  $z_3$  et  $z_4$ , on dispose d'1 condition de suridentification.

# Test de suridentification

- Pourquoi est-ce possible ? Idée : on peut estimer les  $\beta_j$  avec **une** VI (disons  $z_3$ ), récupérer les résidus et tester la corrélation par rapport à l'autre VI (c-à-d entre  $u_1$  et  $z_4$ ). → Pas possible si on ne dispose que d'une seule VI.

# Test de suridentification

- Pourquoi est-ce possible ? Idée : on peut estimer les  $\beta_j$  avec **une** VI (disons  $z_3$ ), récupérer les résidus et tester la corrélation par rapport à l'autre VI (c-à-d entre  $u_1$  et  $z_4$ ). → Pas possible si on ne dispose que d'une seule VI.
- 3 étapes.



# Test de suridentification

- Pourquoi est-ce possible ? Idée : on peut estimer les  $\beta_j$  avec **une** VI (disons  $z_3$ ), récupérer les résidus et tester la corrélation par rapport à l'autre VI (c-à-d entre  $u_1$  et  $z_4$ ). → Pas possible si on ne dispose que d'une seule VI.
- 3 étapes.
- **Étape 1.** Estimer l'équation structurelle par DMCO (→ la VI = combinaison linéaire de  $z_3$  et  $z_4$ ) et récupérer les résidus  $\hat{u}_1$ .

# Test de suridentification

- Pourquoi est-ce possible ? Idée : on peut estimer les  $\beta_j$  avec **une** VI (disons  $z_3$ ), récupérer les résidus et tester la corrélation par rapport à l'autre VI (c-à-d entre  $u_1$  et  $z_4$ ). → Pas possible si on ne dispose que d'une seule VI.
- 3 étapes.
- **Étape 1.** Estimer l'équation structurelle par DMCO (→ la VI = combinaison linéaire de  $z_3$  et  $z_4$ ) et récupérer les résidus  $\hat{u}_1$ .
- **Étape 2.** Régresser  $\hat{u}_1$  sur toutes les variables exogènes  $z_1, \dots, z_4$  et récupérer le R-carré  $R_1^2$ .

# Test de suridentification

- Tester  $H_0$  : toutes les variables  $z_1, \dots, z_4$  sont exogènes et donc non corrélées avec  $u_1$ .

# Test de suridentification

- Tester  $H_0$  : toutes les variables  $z_1, \dots, z_4$  sont exogènes et donc non corrélées avec  $u_1$ .
- **Étape 3.** Test LM. Sous  $H_0$ ,  $nR_1^2 \sim \chi_q^2$  (asymptotiquement), où  $q$  est le nombre de conditions de suridentification, c-à-d le nombre de VI hors du modèle – le nombre de variables explicatives endogènes.

# Test de suridentification

- Tester  $H_0$  : toutes les variables  $z_1, \dots, z_4$  sont exogènes et donc non corrélées avec  $u_1$ .
- **Étape 3.** Test LM. Sous  $H_0$ ,  $nR_1^2 \sim \chi_q^2$  (asymptotiquement), où  $q$  est le nombre de conditions de suridentification, c-à-d le nombre de VI hors du modèle – le nombre de variables explicatives endogènes.
- → Si  $nR_1^2$  excède la valeur critique (à 5% par exemple), on rejette la validité de la Condition 2 et on conclut qu'au moins une des 2 VI n'est pas exogène.

# Test de suridentification

- Tester  $H_0$  : toutes les variables  $z_1, \dots, z_4$  sont exogènes et donc non corrélées avec  $u_1$ .
- **Étape 3.** Test LM. Sous  $H_0$ ,  $nR_1^2 \sim \chi_q^2$  (asymptotiquement), où  $q$  est le nombre de conditions de suridentification, c-à-d le nombre de VI hors du modèle – le nombre de variables explicatives endogènes.
- → Si  $nR_1^2$  excède la valeur critique (à 5% par exemple), on rejette la validité de la Condition 2 et on conclut qu'au moins une des 2 VI n'est pas exogène.
- Ce test est connu sous le nom de **Test de Sargan de validité des instruments**.

# Exemple de test d'endogénéité

On récupère les résidus  $\hat{u}_1$  (*res*) après l'estimation du modèle  $\log(wage) = \beta_0 + \beta_1 educ + \beta_2 exper + \beta_3 exper^2 + u_1$  par DMC avec comme instruments *fatheduc* et *motheduc*.

EQ(5) Modelling res by OLS-CS (using mroz)

The estimation sample is: 1 to 428

	Coefficient	Std.Error	t-value	t-prob
Constant	0.0109641	0.1413	0.0776	0.938
EXPER	-1.83348e-005	0.01333	-0.00138	0.999
EXPERSQ	7.34138e-007	0.0003985	0.00184	0.999
FATHEDUC	0.00578226	0.01118	0.517	0.605
MOTHEDEC	-0.00660653	0.01189	-0.556	0.579

R<sup>2</sup> 0.000883344 F(4,423) = 0.0935 [0.984]

no. of observations 428 no. of parameters 5

→ Estimer par MCO :  $\hat{u}_1 = \gamma_0 + \gamma_1 exper + \gamma_2 exper^2 + \gamma_3 fatheduc + \gamma_4 motheduc + v$ .

→  $nR_1^2 = 428 \times 0.00088 = 0.3781[0.5386]$ .

→ Ces 2 instruments passent le test de suridentification.

# Output PcGive : Specification test

EQ(3) Modelling LWAGE by IVE-CS (using mroz.in7)

The estimation sample is: 1 to 428

		Coefficient	Std.Error	t-value	t-prob
EDUC	Y	0.0613966	0.03144	1.95	0.051
Constant		0.0481003	0.4003	0.120	0.904
EXPER		0.0441704	0.01343	3.29	0.001
EXPERSQ		-0.000898970	0.0004017	-2.24	0.026

Additional instruments:

[0] = FATHEDUC

[1] = MOTHEduc

Specification test:  $\chi^2(1) = 0.37807$  [0.5386]

Testing beta = 0:  $\chi^2(3) = 24.422$  [0.0000]\*\*



# Hétéroscédasticité

- Tout comme pour les MCO, la méthode des DMCO pose l'hypothèse d'homoscédasticité pour que l'inférence classique soit valide.

# Hétéroscédasticité

- Tout comme pour les MCO, la méthode des DMCO pose l'hypothèse d'homoscédasticité pour que l'inférence classique soit valide.
- → Tester cette hypothèse.

# Hétéroscédasticité

- Tout comme pour les MCO, la méthode des DMCO pose l'hypothèse d'homoscédasticité pour que l'inférence classique soit valide.
- → Tester cette hypothèse.
- → En cas de rejet de cette hypothèse, il faut utiliser des **écarts-type robustes** ou adapter la méthode des moindres carrés pondérés.

# Hétéroscédasticité

- Tout comme pour les MCO, la méthode des DMCO pose l'hypothèse d'homoscédasticité pour que l'inférence classique soit valide.
- → Tester cette hypothèse.
- → En cas de rejet de cette hypothèse, il faut utiliser des **écarts-type robustes** ou adapter la méthode des **moindres carrés pondérés**.
- Comment tester cette hypothèse ?

# Hétéroscédasticité

- Tout comme pour les MCO, la méthode des DMCO pose l'hypothèse d'homoscédasticité pour que l'inférence classique soit valide.
- → Tester cette hypothèse.
- → En cas de rejet de cette hypothèse, il faut utiliser des **écarts-type robustes** ou adapter la méthode des **moindres carrés pondérés**.
- Comment tester cette hypothèse ?
- Estimer le modèle par DMCO et sauver les résidus  $\hat{u}$ .

# Hétéroscédasticité

- Tout comme pour les MCO, la méthode des DMCO pose l'hypothèse d'homoscédasticité pour que l'inférence classique soit valide.
- → Tester cette hypothèse.
- → En cas de rejet de cette hypothèse, il faut utiliser des **écarts-type robustes** ou adapter la méthode des **moindres carrés pondérés**.
- Comment tester cette hypothèse ?
- Estimer le modèle par DMCO et sauver les résidus  $\hat{u}$ .
- Estimer par MCO le modèle
$$\hat{u}^2 = \gamma_0 + \gamma_1 z_1 + \dots + \gamma_m z_m + e.$$

# Hétéroscédasticité

- Tout comme pour les MCO, la méthode des DMCO pose l'hypothèse d'homoscédasticité pour que l'inférence classique soit valide.
- → Tester cette hypothèse.
- → En cas de rejet de cette hypothèse, il faut utiliser des **écarts-type robustes** ou adapter la méthode des **moindres carrés pondérés**.
- Comment tester cette hypothèse ?
- Estimer le modèle par DMCO et sauver les résidus  $\hat{u}$ .
- Estimer par MCO le modèle
$$\hat{u}^2 = \gamma_0 + \gamma_1 z_1 + \dots + \gamma_m z_m + e.$$
- Tester  $H_0 : \gamma_1 = \dots = \gamma_m = 0$  (c-à-d homoscédasticité) via un F-test.

# Output PcGive : DMCO

EQ(1) Modelling LWAGE by IVE-CS (using mroz.in7)

The estimation sample is: 1 to 428

		Coefficient	Std.Error	t-value	t-prob
EDUC	Y	0.0803918	0.02177	3.69	0.000
Constant		-0.186857	0.2854	-0.655	0.513
EXPER		0.0430973	0.01326	3.25	0.001
EXPERSQ		-0.000862797	0.0003962	-2.18	0.030

Additional instruments:

[0] = FATHEDUC

[1] = MOTHEduc

[2] = HUSEDUC

Specification test:  $\chi^2(2) = 1.1150$  [0.5726]

Testing beta = 0:  $\chi^2(3) = 34.574$  [0.0000]\*\*

res [1 to 428] saved to mroz.in7



# Output PcGive : Test d'homoscédasticité

EQ(2) Modelling res2 by OLS-CS (using mroz.in7)

The estimation sample is: 1 to 428

	Coefficient	Std.Error	t-value	t-prob
Constant	0.729764	0.2774	2.63	0.009
FATHEDUC	0.00879304	0.01781	0.494	0.622
EXPER	-0.0552427	0.02070	-2.67	0.008
EXPERSQ	0.00121010	0.0006190	1.95	0.051
MOTHEduc	0.0119529	0.01857	0.644	0.520
HUSEDUC	-0.00337671	0.01788	-0.189	0.850
sigma	1.04834	RSS	463.784598	
R <sup>2</sup>	0.0290988	F(5,422) =	2.53 [0.028]*	
log-likelihood	-624.489	DW	1.58	
no. of observations	428	no. of parameters	6	
mean(res2)	0.443773	var(res2)	1.11609	

→ Rejet de  $H_0$  au seuil de 5%.

# Modèles à équations simultanées : Chapitre 16

# Simultanéité

Dans le chapitre précédent, nous avons vu 2 raisons principales d'utiliser la méthode des VI.

- 1) Problème d'erreurs de mesure.

# Simultanéité

Dans le chapitre précédent, nous avons vu 2 raisons principales d'utiliser la méthode des VI.

- 1) Problème d'erreurs de mesure.
- 2) Problème d'omission de variables explicatives appropriées.

# Simultanéité

Dans le chapitre précédent, nous avons vu 2 raisons principales d'utiliser la méthode des VI.

- 1) Problème d'erreurs de mesure.
- 2) Problème d'omission de variables explicatives appropriées.
- → Dans chaque cas, le problème donne lieu à un problème d'endogénéité.

# Simultanéité

Dans le chapitre précédent, nous avons vu 2 raisons principales d'utiliser la méthode des VI.

- 1) Problème d'erreurs de mesure.
- 2) Problème d'omission de variables explicatives appropriées.
- → Dans chaque cas, le problème donne lieu à un problème d'endogénéité.
- Dans ce chapitre, on va étudier en détails une autre raison importante : le problème de **simultanéité**.

# Simultanéité

- Une ou plusieurs variables explicatives sont déterminées conjointement avec la variable dépendante, par exemple à travers une relation d'équilibre.

# Simultanéité

- Une ou plusieurs variables explicatives sont déterminées conjointement avec la variable dépendante, par exemple à travers une relation d'équilibre.
- → Modèles à équations simultanées (MES).



# Simultanéité

- Une ou plusieurs variables explicatives sont déterminées conjointement avec la variable dépendante, par exemple à travers une relation d'équilibre.
- → Modèles à équations simultanées (MES).
- → La méthode d'estimation des VI et des DMC s'applique pour estimer les MES alors que l'estimation par MCO génère des estimateurs biaisés.

# Simultanéité

- Une ou plusieurs variables explicatives sont déterminées conjointement avec la variable dépendante, par exemple à travers une relation d'équilibre.
- → Modèles à équations simultanées (MES).
- → La méthode d'estimation des VI et des DMC s'applique pour estimer les MES alors que l'estimation par MCO génère des estimateurs biaisés.
- → **Biais de simultanéité.**

# Caractéristiques des MES

- Exemple de MES : Offre et demande de travail.

# Caractéristiques des MES

- Exemple de MES : Offre et demande de travail.
- Equation d'offre de travail :  $h_s = \alpha_1 w + \beta_1 z_1 + u_1$ .

# Caractéristiques des MES

- Exemple de MES : Offre et demande de travail.
- Equation d'offre de travail :  $h_s = \alpha_1 w + \beta_1 z_1 + u_1$ .
- Equation structurelle avec  $h_s =$  offre de travail,  $w =$  salaire et  $z_1 =$  facteurs exogènes.

# Caractéristiques des MES

- Exemple de MES : Offre et demande de travail.
- Equation d'offre de travail :  $h_s = \alpha_1 w + \beta_1 z_1 + u_1$ .
- Equation structurelle avec  $h_s =$  offre de travail,  $w =$  salaire et  $z_1 =$  facteurs exogènes.
- Problème : la condition *Ceteris Paribus* n'est pas respectée.
  - Les variation de  $w$  ne sont pas exogènes car  $w_i$  est le salaire de l'individu  $i$  observé à l'équilibre.
  - $h_{id} = h_{is}$ , c-à-d demande de travail = offre de travail.

# Caractéristiques des MIES

- Equation de demande de travail :  $h_d = \alpha_2 w + \beta_2 z_2 + u_2$ .

# Caractéristiques des MES

- Equation de demande de travail :  $h_d = \alpha_2 w + \beta_2 z_2 + u_2$ .
- Equation structurelle avec  $h_d =$  demande de travail,  $w =$  salaire et  $z_2$  facteurs exogènes (de la demande).



# Caractéristiques des MES

- Equation de demande de travail :  $h_d = \alpha_2 w + \beta_2 z_2 + u_2$ .
- Equation structurelle avec  $h_d =$  demande de travail,  $w =$  salaire et  $z_2$  facteurs exogènes (de la demande).
- A l'équilibre, pour chaque individu  $i$ , on a :  
 $h_i = h_{id} = h_{is}$ , où  $h_i$  est le nombre d'heures travaillées (et donc observé).

# Caractéristiques des MES

- Equation de demande de travail :  $h_d = \alpha_2 w + \beta_2 z_2 + u_2$ .
- Equation structurelle avec  $h_d =$  demande de travail,  $w =$  salaire et  $z_2$  facteurs exogènes (de la demande).
- A l'équilibre, pour chaque individu  $i$ , on a :  
 $h_i = h_{id} = h_{is}$ , où  $h_i$  est le nombre d'heures travaillées (et donc observé).
- On obtient alors un MES :

$$h_i = h_{is} = \alpha_1 w_i + \beta_1 z_{i1} + u_{i1}$$

$$h_i = h_{id} = \alpha_2 w_i + \beta_2 z_{i2} + u_{i2}.$$

# Caractéristiques des MES

- Equation de demande de travail :  $h_d = \alpha_2 w + \beta_2 z_2 + u_2$ .
- Equation structurelle avec  $h_d =$  demande de travail,  $w =$  salaire et  $z_2$  facteurs exogènes (de la demande).
- A l'équilibre, pour chaque individu  $i$ , on a :  
 $h_i = h_{id} = h_{is}$ , où  $h_i$  est le nombre d'heures travaillées (et donc observé).
- On obtient alors un MES :

$$h_i = h_{is} = \alpha_1 w_i + \beta_1 z_{i1} + u_{i1}$$

$$h_i = h_{id} = \alpha_2 w_i + \beta_2 z_{i2} + u_{i2}.$$

- → MES à 2 équations dans leur forme structurelle.
- $h_i$  et  $w_i$  sont des variables endogènes.
- $z_{i1}$  et  $z_{i2}$  sont des variables exogènes telles que  
 $E(u_1 z_1) = E(u_2 z_2) = 0$ .

# Autres exemples de MIES

Relation taux de criminalité (meurtres) et taille des forces de polices.

- Equation explicative des meurtres par ville :

$$mur_{dpc} = \alpha_1 pol_{pc} + \beta_{10} + \beta_{11} inc_{pc} + u_1,$$

# Autres exemples de MIES

Relation taux de criminalité (meurtres) et taille des forces de polices.

- Equation explicative des meurtres par ville :

$$murdpc = \alpha_1 polpc + \beta_{10} + \beta_{11} incpc + u_1,$$

- où  $murdpc$  = taux de criminalité par habitant,  $polpc$  = nombre de policiers par habitant et  $incpc$  = revenu par habitant.

# Autres exemples de MIES

Relation taux de criminalité (meurtres) et taille des forces de polices.

- Equation explicative des meurtres par ville :

$$murdpc = \alpha_1 polpc + \beta_{10} + \beta_{11} incpc + u_1,$$

- où  $murdpc$  = taux de criminalité par habitant,  $polpc$  = nombre de policiers par habitant et  $incpc$  = revenu par habitant.

- Equation explicative du nombre de policiers :

$$polpc = \alpha_2 murdpc + \beta_{20} + \text{d'autres facteurs} + u_2.$$

# Autres exemples de MES

Relation taux de criminalité (meurtres) et taille des forces de polices.

- Equation explicative des meurtres par ville :

$$murdpc = \alpha_1 polpc + \beta_{10} + \beta_{11} incpc + u_1,$$

- où  $murdpc$  = taux de criminalité par habitant,  $polpc$  = nombre de policiers par habitant et  $incpc$  = revenu par habitant.

- Equation explicative du nombre de policiers :

$$polpc = \alpha_2 murdpc + \beta_{20} + \text{d'autres facteurs} + u_2.$$

- →  $polpc$  et  $murdpc$  sont 2 variables endogènes d'un MES à 2 équations.

# Biais de simultanéité

L'utilisation des MCO pour estimer les équations structurelles d'un MES donne lieu à un biais.

- Soit un MES à 2 équations :

$$y_1 = \alpha_1 y_2 + \beta_1 z_1 + u_1$$

$$y_2 = \alpha_2 y_1 + \beta_2 z_2 + u_2.$$



# Biais de simultanéité

L'utilisation des MCO pour estimer les équations structurelles d'un MES donne lieu à un biais.

- Soit un MES à 2 équations :

$$y_1 = \alpha_1 y_2 + \beta_1 z_1 + u_1$$

$$y_2 = \alpha_2 y_1 + \beta_2 z_2 + u_2.$$

- Trouvons la forme réduite de  $y_2$  :

$$y_2 = \alpha_2(\alpha_1 y_2 + \beta_1 z_1 + u_1) + \beta_2 z_2 + u_2.$$

# Biais de simultanéité

L'utilisation des MCO pour estimer les équations structurelles d'un MES donne lieu à un biais.

- Soit un MES à 2 équations :

$$y_1 = \alpha_1 y_2 + \beta_1 z_1 + u_1$$

$$y_2 = \alpha_2 y_1 + \beta_2 z_2 + u_2.$$

- Trouvons la forme réduite de  $y_2$  :

$$y_2 = \alpha_2(\alpha_1 y_2 + \beta_1 z_1 + u_1) + \beta_2 z_2 + u_2.$$

- Ceci se réécrit comme ceci :

$$y_2 = \pi_{21} z_1 + \pi_{22} z_2 + \nu_2,$$

$$\text{où } \pi_{21} = \frac{\alpha_2 \beta_1}{1 - \alpha_1 \alpha_2}, \pi_{22} = \frac{\beta_2}{1 - \alpha_1 \alpha_2} \text{ et } \nu_2 = \frac{\alpha_2 u_1 + u_2}{1 - \alpha_1 \alpha_2}.$$

# Biais de simultanéité

- On peut estimer par MCO de manière consistante cette **forme réduite** car  $z_1$  et  $z_2$  sont exogènes et donc non corrélés avec  $u_1$  et  $u_2$  et donc  $\nu_2$ .

# Biais de simultanéité

- On peut estimer par MCO de manière consistante cette **forme réduite** car  $z_1$  et  $z_2$  sont exogènes et donc non corrélés avec  $u_1$  et  $u_2$  et donc  $\nu_2$ .
- Par contre l'estimation de la **forme structurelle** par MCO donne lieu à des estimateur biaisé.

# Biais de simultanéité

- On peut estimer par MCO de manière consistante cette **forme réduite** car  $z_1$  et  $z_2$  sont exogènes et donc non corrélés avec  $u_1$  et  $u_2$  et donc  $\nu_2$ .
- Par contre l'estimation de la **forme structurelle** par MCO donne lieu à des estimateur biaisé.
- Exemple :  $y_1 = \alpha_1 y_2 + \beta_1 z_1 + u_1$ .  
→  $y_2$  est corrélé avec  $u_1$  car  $y_2 = \pi_{21} z_1 + \pi_{22} z_2 + \nu_2$  et  $u_1 \in \nu_2$ .

# Biais de simultanéité

- On peut estimer par MCO de manière consistante cette **forme réduite** car  $z_1$  et  $z_2$  sont exogènes et donc non corrélés avec  $u_1$  et  $u_2$  et donc  $\nu_2$ .
- Par contre l'estimation de la **forme structurelle** par MCO donne lieu à des estimateur biaisé.
- Exemple :  $y_1 = \alpha_1 y_2 + \beta_1 z_1 + u_1$ .  
→  $y_2$  est corrélé avec  $u_1$  car  $y_2 = \pi_{21} z_1 + \pi_{22} z_2 + \nu_2$  et  $u_1 \in \nu_2$ .
- Plus formellement :  $Cov(y_2, u_1) = Cov(\nu_2, u_1) = \left( \frac{\alpha_2}{1 - \alpha_1 \alpha_2} \right) E(u_1^2) = \left( \frac{\alpha_2}{1 - \alpha_1 \alpha_2} \right) \sigma_1^2$ .

# Biais de simultanéité

- On peut estimer par MCO de manière consistante cette **forme réduite** car  $z_1$  et  $z_2$  sont exogènes et donc non corrélés avec  $u_1$  et  $u_2$  et donc  $\nu_2$ .
- Par contre l'estimation de la **forme structurelle** par MCO donne lieu à des estimateur biaisé.
- Exemple :  $y_1 = \alpha_1 y_2 + \beta_1 z_1 + u_1$ .  
→  $y_2$  est corrélé avec  $u_1$  car  $y_2 = \pi_{21} z_1 + \pi_{22} z_2 + \nu_2$  et  $u_1 \in \nu_2$ .
- Plus formellement :  $Cov(y_2, u_1) = Cov(\nu_2, u_1) = \left( \frac{\alpha_2}{1 - \alpha_1 \alpha_2} \right) E(u_1^2) = \left( \frac{\alpha_2}{1 - \alpha_1 \alpha_2} \right) \sigma_1^2$ .
- Si  $\alpha_2 \neq 0$  (cas d'un MES), alors MCO biaisés car rejet de **MLR.3**.

# Biais de simultanéité

- Rappels :  $y_1 = \alpha_1 y_2 + \beta_1 z_1 + u_1$ .  
 $\rightarrow \text{plim } \hat{\alpha}_1 = \alpha_1 + \frac{\text{Cov}(y_2, u_1)}{\text{Var}(y_2)}$ .



# Biais de simultanéité

- Rappels :  $y_1 = \alpha_1 y_2 + \beta_1 z_1 + u_1$ .  
 $\rightarrow \text{plim } \hat{\alpha}_1 = \alpha_1 + \frac{\text{Cov}(y_2, u_1)}{\text{Var}(y_2)}$ .
- Le biais (asymptotique) de simultanéité aura le même signe que la covariance entre  $\nu_2$  et  $u_1$ .

# Biais de simultanéité

- Rappels :  $y_1 = \alpha_1 y_2 + \beta_1 z_1 + u_1$ .  
 $\rightarrow \text{plim } \hat{\alpha}_1 = \alpha_1 + \frac{\text{Cov}(y_2, u_1)}{\text{Var}(y_2)}$ .
- Le biais (asymptotique) de simultanéité aura le même signe que la covariance entre  $\nu_2$  et  $u_1$ .
- Le biais de simultanéité dépend des paramètres  $\alpha_2$  et  $\alpha_1$ .

# Biais de simultanéité

- Rappels :  $y_1 = \alpha_1 y_2 + \beta_1 z_1 + u_1$ .  
→  $plim \hat{\alpha}_1 = \alpha_1 + \frac{Cov(y_2, u_1)}{Var(y_2)}$ .
- Le biais (asymptotique) de simultanéité aura le même signe que la covariance entre  $\nu_2$  et  $u_1$ .
- Le biais de simultanéité dépend des paramètres  $\alpha_2$  et  $\alpha_1$ .
- Exemple : si  $\alpha_2 > 0$  et  $\alpha_1 \alpha_2 < 1$ , alors le biais asymptotique sera positif.  
→ L'effet de  $y_2$  sera surestimé.

# Identification d'un MES à 2 équations

Considérons le cas d'un MES à 2 équations.



$$\begin{aligned}y_1 &= \beta_{10} + \alpha_1 y_2 + z_1 \beta_1 + u_1 \\y_2 &= \beta_{20} + \alpha_2 y_1 + z_2 \beta_2 + u_2.\end{aligned}$$

# Identification d'un MES à 2 équations

Considérons le cas d'un MES à 2 équations.



$$\begin{aligned}y_1 &= \beta_{10} + \alpha_1 y_2 + z_1 \beta_1 + u_1 \\y_2 &= \beta_{20} + \alpha_2 y_1 + z_2 \beta_2 + u_2.\end{aligned}$$

- Les variables  $z_1$  et  $z_2$  représentent un ensemble de respectivement  $k_1$  et  $k_2$  variables exogènes (avec une possible intersection entre les 2) :

$$\begin{aligned}z_1 \beta_1 &= \beta_{11} z_{11} + \beta_{12} z_{12} + \dots + \beta_{1k_1} z_{1k_1} \\z_2 \beta_2 &= \beta_{21} z_{21} + \beta_{22} z_{22} + \dots + \beta_{2k_2} z_{2k_2}.\end{aligned}$$

# Identification d'un MES à 2 équations

- La présence ou non de ces variables  $z_i$  va permettre de définir des **restrictions d'exclusion** qui permettront de définir la condition d'identification de chaque équation.

# Identification d'un MES à 2 équations

- La présence ou non de ces variables  $z_i$  va permettre de définir des **restrictions d'exclusion** qui permettront de définir la condition d'identification de chaque équation.
- **Condition d'ordre pour l'identification d'une équation structurelle.**
  - La condition nécessaire pour identifier la première équation dans un MES à 2 équations est que la *seconde équation* contienne au moins une variable exogène exclue de la première équation.

# Identification d'un MES à 2 équations

- La présence ou non de ces variables  $z_i$  va permettre de définir des **restrictions d'exclusion** qui permettront de définir la condition d'identification de chaque équation.
- **Condition d'ordre pour l'identification d'une équation structurelle.**  
→ La condition nécessaire pour identifier la première équation dans un MES à 2 équations est que la *seconde équation* contienne au moins une variable exogène exclue de la première équation.
- **Condition de rang pour l'identification d'une équation structurelle.**  
→ La première équation dans un MES à 2 équations est identifiée **ssi** la *seconde équation* contient au moins une variable exogène avec un coefficient  $\beta_{2j}$  non nul qui est exclue de la première équation.



# Exemples d'identification

Modèle de demande et d'offre définit à l'équilibre

$$q = q_s = q_d.$$

- $q$  est la consommation de lait par habitant d'un pays et  
 $p$  est le prix moyen du lait par litre dans ce pays.

# Exemples d'identification

Modèle de demande et d'offre défini à l'équilibre

$$q = q_s = q_d.$$

- $q$  est la consommation de lait par habitant d'un pays et  $p$  est le prix moyen du lait par litre dans ce pays.
- Equation d'offre :  $q_s = \alpha_1 p + \beta_1 z_1 + u_1$ .
  - $z_1$  est le prix de l'alimentation du bétail = variable exogène.
  - $\Delta z_1$  doit faire  $\Delta$  l'offre de lait.


# Exemples d'identification

Modèle de demande et d'offre définit à l'équilibre

$$q = q_s = q_d.$$

- $q$  est la consommation de lait par habitant d'un pays et  $p$  est le prix moyen du lait par litre dans ce pays.
- Equation d'offre :  $q_s = \alpha_1 p + \beta_1 z_1 + u_1$ .
  - $z_1$  est le prix de l'alimentation du bétail = variable exogène.
  - $\Delta z_1$  doit faire  $\Delta$  l'offre de lait.
- Equation de demande :  $q_d = \alpha_2 p + u_2$ .
  - Pas de variable exogène.
  - $\Delta z_1$  ne doit pas faire  $\Delta$  la demande de lait.

# Déplacer l'équation d'offre



→ Dans ce MES, l'offre n'est pas identifiée (rejet de la condition d'ordre). Par contre, la condition d'ordre de la fonction de demande est remplie.

→ En effet, on peut utiliser  $z_1$  comme VI pour  $q_d$  mais pas pour  $q_s$ .

→ Déplacer  $q_s$  permet d'identifier  $q_d$ .

# Exemples d'identification

Modèle : offre de travail des femmes mariées.  
→ 2 équations structurelles.

● Equation d'offre de travail (heures travaillées) :

$$\begin{aligned} \text{hours} &= \alpha_1 \log(\text{wage}) + \beta_{10} + \beta_{11} \text{educ} \\ &+ \beta_{12} \text{age} + \beta_{13} \text{kidslt6} + \beta_{14} \text{nwifeinc} + u_1, \end{aligned}$$

où  $\text{kidslt6}$  = nombre d'enfants < 6 ans et  $\text{nwifeinc}$  = revenu non salarial de la femme mariée.

# Exemples d'identification

Modèle : offre de travail des femmes mariées.  
→ 2 équations structurelles.

- Equation d'offre de travail (heures travaillées) :

$$\begin{aligned} hours &= \alpha_1 \log(wage) + \beta_{10} + \beta_{11} educ \\ &+ \beta_{12} age + \beta_{13} kidslt6 + \beta_{14} nwifeinc + u_1, \end{aligned}$$

où  $kidslt6$  = nombre d'enfants < 6 ans et  $nwifeinc$  = revenu non salarial de la femme mariée.

- Equation de salaire :  $\log(wage) =$   
 $\alpha_2 hours + \beta_{20} + \beta_{21} educ + \beta_{22} exper + \beta_{23} exper^2 + u_2.$

# Exemples d'identification

Modèle : offre de travail des femmes mariées.  
→ 2 équations structurelles.

- Equation d'offre de travail (heures travaillées) :

$$\begin{aligned} hours &= \alpha_1 \log(wage) + \beta_{10} + \beta_{11} educ \\ &+ \beta_{12} age + \beta_{13} kidslt6 + \beta_{14} nwifeinc + u_1, \end{aligned}$$

où  $kidslt6$  = nombre d'enfants < 6 ans et  $nwifeinc$  = revenu non salarial de la femme mariée.

- Equation de salaire :  $\log(wage) = \alpha_2 hours + \beta_{20} + \beta_{21} educ + \beta_{22} exper + \beta_{23} exper^2 + u_2$ .
- La condition d'ordre de l'équation d'offre de travail est remplie ( $exper$  et  $exper^2$  sont exclues).

# Exemples d'identification

- A partir des équations structurelles, la condition de rang pour l'identification de l'équation d'offre de travail est :  
 $\beta_{22} \neq 0$  ou  $\beta_{23} \neq 0$ .



# Exemples d'identification

- A partir des équations structurelles, la condition de rang pour l'identification de l'équation d'offre de travail est :  
 $\beta_{22} \neq 0$  ou  $\beta_{23} \neq 0$ .
- On peut vérifier cette condition de rang via la forme réduite :

$$\begin{aligned} \log(wage) &= \pi_{20} + \pi_{21}educ + \pi_{22}age + \pi_{23}kidslt6 \\ &+ \pi_{24}nwifeinc + \pi_{25}exper + \pi_{26}exper^2 + \nu_2. \end{aligned}$$

# Exemples d'identification

- A partir des équations structurelles, la condition de rang pour l'identification de l'équation d'offre de travail est :  
 $\beta_{22} \neq 0$  ou  $\beta_{23} \neq 0$ .
- On peut vérifier cette condition de rang via la forme réduite :

$$\begin{aligned} \log(wage) &= \pi_{20} + \pi_{21}educ + \pi_{22}age + \pi_{23}kidslt6 \\ &+ \pi_{24}nwifeinc + \pi_{25}exper + \pi_{26}exper^2 + \nu_2. \end{aligned}$$

- → L'identification de l'équation de salaire requiert :  
 $\pi_{25} \neq 0$  ou  $\pi_{26} \neq 0$ .

# Exemples d'identification

- A partir des équations structurelles, la condition de rang pour l'identification de l'équation d'offre de travail est :

$$\beta_{22} \neq 0 \text{ ou } \beta_{23} \neq 0.$$

- On peut vérifier cette condition de rang via la forme réduite :

$$\begin{aligned} \log(wage) &= \pi_{20} + \pi_{21}educ + \pi_{22}age + \pi_{23}kidslt6 \\ &+ \pi_{24}nwifeinc + \pi_{25}exper + \pi_{26}exper^2 + \nu_2. \end{aligned}$$

- → L'identification de l'équation de salaire requiert :  
 $\pi_{25} \neq 0$  ou  $\pi_{26} \neq 0$ .
- → Tester  $H_0 : \pi_{25} = \pi_{26} = 0$  via un F-test.

# Exemples d'identification

- La condition d'ordre de l'équation de salaire est également remplie (*age*, *kidslt6* et *nwifeinc* sont exclues).

# Exemples d'identification

- La condition d'ordre de l'équation de salaire est également remplie (*age*, *kidslt6* et *nwifeinc* sont exclues).
- L'équation de salaire est identifiée si  $\beta_{12}$ ,  $\beta_{13}$  ou  $\beta_{14} \neq 0$ .  
→ Si  $\pi_{12}$ ,  $\pi_{13}$  ou  $\pi_{14} \neq 0$  (condition de rang) dans l'équation en forme réduite suivante :

$$\begin{aligned} \text{hours} &= \pi_{10} + \pi_{11}\text{educ} + \pi_{12}\text{age} + \pi_{13}\text{kidslt6} \\ &+ \pi_{14}\text{nwifeinc} + \pi_{15}\text{exper} + \pi_{16}\text{exper}^2 + \nu_1. \end{aligned}$$

# Estimation par DMC

- L'estimation par DMC peut se faire pour une équation identifiée.

# Estimation par DMC

- L'estimation par DMC peut se faire pour une équation identifiée.
- Dans ce cas, les VI sont simplement les variables exogènes de l'autre équation.

# Estimation par DMC

- L'estimation par DMC peut se faire pour une équation identifiée.
- Dans ce cas, les VI sont simplement les variables exogènes de l'autre équation.
- Exemple : Offre de travail des femmes mariées ([mroz.in7](#)).



# Estimation par DMC

- L'estimation par DMC peut se faire pour une équation identifiée.
- Dans ce cas, les VI sont simplement les variables exogènes de l'autre équation.
- Exemple : Offre de travail des femmes mariées ([mroz.in7](#)).
- Fonction d'offre de travail :

$$\begin{aligned} \text{hours} &= \alpha_1 \log(\text{wage}) + \beta_{10} + \beta_{11} \text{educ} \\ &+ \beta_{12} \text{age} + \beta_{13} \text{kidslt6} + \beta_{14} \text{nwifeinc} + u_1, \end{aligned}$$

# Estimation par DMC

- L'estimation par DMC peut se faire pour une équation identifiée.
- Dans ce cas, les VI sont simplement les variables exogènes de l'autre équation.
- Exemple : Offre de travail des femmes mariées ([mroz.in7](#)).
- Fonction d'offre de travail :

$$\begin{aligned} \text{hours} &= \alpha_1 \log(\text{wage}) + \beta_{10} + \beta_{11} \text{educ} \\ &+ \beta_{12} \text{age} + \beta_{13} \text{kidslt6} + \beta_{14} \text{nwifeinc} + u_1, \end{aligned}$$

- Equation de salaire :  $\log(\text{wage}) = \alpha_2 \text{hours} + \beta_{20} + \beta_{21} \text{educ} + \beta_{22} \text{exper} + \beta_{23} \text{exper}^2 + u_2.$

# Estimation : fonction d'offre de travail

EQ(1) Modelling HOURS by IVE-CS (using mroz)

The estimation sample is: 1 to 428

		Coefficient	Std.Error	t-value	t-prob
Constant		2225.66	574.6	3.87	0.000
LWAGE	Y	1639.56	470.6	3.48	0.001
EDUC		-183.751	59.10	-3.11	0.002
AGE		-7.80609	9.378	-0.832	0.406
KIDSLT6		-198.154	182.9	-1.08	0.279
NWIFEINC		-10.1696	6.615	-1.54	0.125

sigma                      1354.2    RSS                      773893120

Reduced form sigma        729.76

no. endogenous variables    2    no. of instruments            7

Additional instruments:

[0] = EXPER

[1] = EXPERSQ

Specification test:  $\chi^2(1) = 0.86220$  [0.3531]

Testing beta = 0:  $\chi^2(5) = 17.205$  [0.0041]\*\*

# Interprétation

- Pente positive de la fonction d'offre de travail. Le coefficient de  $\log(wage) = 1639.56$  et est très significatif.

# Interprétation

- Pente positive de la fonction d'offre de travail. Le coefficient de  $\log(wage) = 1639.56$  et est très significatif.
- *Ceteris Paribus*,  $\Delta \hat{hours} \approx 16.4(\% \Delta wage)$ .

# Interprétation

- Pente positive de la fonction d'offre de travail. Le coefficient de  $\log(wage) = 1639.56$  et est très significatif.
- *Ceteris Paribus*,  $\Delta \hat{hours} \approx 16.4(\% \Delta wage)$ .
- L'élasticité de l'offre de travail =  $1640/hours$  car

$$100(\Delta \hat{hours}/hours) \approx (1640/hours)(\% \Delta wage)$$

$$\% \Delta \hat{hours} \approx (1640/hours)(\% \Delta wage)$$

# Interprétation

- Pente positive de la fonction d'offre de travail. Le coefficient de  $\log(wage) = 1639.56$  et est très significatif.
- *Ceteris Paribus*,  $\Delta \hat{hours} \approx 16.4(\% \Delta wage)$ .
- L'élasticité de l'offre de travail =  $1640/hours$  car

$$100(\Delta \hat{hours}/hours) \approx (1640/hours)(\% \Delta wage)$$

$$\% \Delta \hat{hours} \approx (1640/hours)(\% \Delta wage)$$

- Si  $hours = \overline{hours} = 1303$ , l'élasticité de l'offre de travail  $\approx 1640/1303 = 1,26\% > 1\%$ .

# Interprétation

- Pente positive de la fonction d'offre de travail. Le coefficient de  $\log(wage) = 1639.56$  et est très significatif.
- *Ceteris Paribus*,  $\Delta \hat{hours} \approx 16.4(\% \Delta wage)$ .
- L'élasticité de l'offre de travail =  $1640/hours$  car

$$100(\Delta \hat{hours}/hours) \approx (1640/hours)(\% \Delta wage)$$

$$\% \Delta \hat{hours} \approx (1640/hours)(\% \Delta wage)$$

- Si  $hours = \overline{hours} = 1303$ , l'élasticité de l'offre de travail  $\approx 1640/1303 = 1,26\% > 1\%$ .
- Si  $hours = 800$  l'élasticité de l'offre de travail  $\approx 1640/800 = 2,05\%$ .



# Estimation par MCO

EQ(2) Modelling HOURS by OLS-CS (using mroz)

The estimation sample is: 1 to 428

	Coefficient	Std.Error	t-value	t-prob
Constant	1523.77	305.6	4.99	0.000
EDUC	-6.62187	18.12	-0.366	0.715
LWAGE	-2.04680	54.88	-0.0373	0.970
AGE	0.562254	5.140	0.109	0.913
KIDSLT6	-328.858	101.5	-3.24	0.001
NWIFEINC	-5.91846	3.683	-1.61	0.109
sigma	766.633	RSS		248020491
R <sup>2</sup>	0.0361062	F(5,422) = 3.162	[0.008]**	
log-likelihood	-3447.06	DW		2.03
no. of observations	428	no. of parameters		6
mean(HOURS)	1302.93	var(HOURS)		601194

→  $\hat{\alpha}_1 = -2,04680$  et est non significatif.

# Condition de rang pour *hours*

EQ(3) Modelling LWAGE by OLS-CS (using mroz.in7)

The estimation sample is: 1 to 428

	Coefficient	Std.Error	t-value	t-prob
Constant	-0.447161	0.2852	-1.57	0.118
EDUC	0.101111	0.01496	6.76	0.000
AGE	-0.00255613	0.005192	-0.492	0.623
KIDSLT6	-0.0532185	0.08844	-0.602	0.548
NWIFEINC	0.00555999	0.003310	1.68	0.094
EXPER	0.0418643	0.01324	3.16	0.002
EXPERSQ	-0.000762482	0.0004008	-1.90	0.058

LinRes F(2,421) = 9.3293 [0.0001]\*\*

$$\begin{aligned} \log(wage) &= \pi_{20} + \pi_{21}educ + \pi_{22}age + \pi_{23}kidslt6 \\ &+ \pi_{24}nwifeinc + \pi_{25}exper + \pi_{26}exper^2 + \nu_2. \end{aligned}$$

→ Rejet de  $H_0 : \pi_{25} = \pi_{26} = 0$ .

# Estimation par DMCO

EQ(1) Modelling HOURS by IVE-CS (using mroz)

The estimation sample is: 1 to 428

		Coefficient	Std.Error	t-value	t-prob
Constant		2225.66	574.6	3.87	0.000
LWAGE	Y	1639.56	470.6	3.48	0.001
EDUC		-183.751	59.10	-3.11	0.002
AGE		-7.80609	9.378	-0.832	0.406
KIDSLT6		-198.154	182.9	-1.08	0.279
NWIFEINC		-10.1696	6.615	-1.54	0.125

Additional instruments:

[0] = EXPER

[1] = EXPERSQ

Specification test:  $\text{Chi}^2(1) = 0.86220$  [0.3531]

Testing beta = 0:  $\text{Chi}^2(5) = 17.205$  [0.0041]\*\*

→ Les instruments passent le test de suridentification de Sargan (Specification test).

# Test d'endogénéité de $\log(wage)$

EQ(4) Modelling LWAGE by OLS-CS (using mroz)

The estimation sample is: 1 to 428

	Coefficient	Std.Error	t-value	t-prob	Part.R <sup>2</sup>
Constant	-0.447161	0.2852	-1.57	0.118	0.0058
EDUC	0.101111	0.01496	6.76	0.000	0.0979
AGE	-0.00255613	0.005192	-0.492	0.623	0.0006
KIDSLT6	-0.0532185	0.08844	-0.602	0.548	0.0009
NWIFEINC	0.00555999	0.003310	1.68	0.094	0.0067
EXPER	0.0418643	0.01324	3.16	0.002	0.0232
EXPERSQ	-0.000762482	0.0004008	-1.90	0.058	0.0085

res [1 to 428] saved to mroz

→ Estimer par MCO le modèle en forme réduite pour  $\log(wage)$ .

→  $\log(wage) = \pi_0 + \pi_1 educ + \pi_2 age + \pi_3 kidslt6 + \pi_4 nwifeinc + \pi_5 exper + \pi_6 exper^2 + v_2$ .

→ Sauver  $\hat{v}_2(res)$ .

# Test d'endogénéité de $\log(wage)$

EQ(5) Modelling HOURS by OLS-CS (using mroz)

The estimation sample is: 1 to 428

	Coefficient	Std.Error	t-value	t-prob
Constant	2225.66	310.0	7.18	0.000
EDUC	-183.751	31.88	-5.76	0.000
LWAGE	1639.56	253.9	6.46	0.000
AGE	-7.80609	5.059	-1.54	0.124
KIDSLT6	-198.154	98.69	-2.01	0.045
NWIFEINC	-10.1696	3.569	-2.85	0.005
res	-1714.36	259.4	-6.61	0.000

→ Estimer par MCO le modèle

$$hours = \beta_{10} + \beta_{11}educ + \beta_{12}age + \beta_{13}kidslt6 + \beta_{14}nwifeinc + \beta_{15}\log(wage) + \delta_1\hat{v}_2 + u_1.$$

→  $\hat{\delta}_1 = -1714.36$  et très significatif.

→ Endogénéité de  $\log(wage)$ .

# Estimation de la fonction de salaire

→ *hours* n'est pas significatif.

# MES à plus de 2 équations

Considérons le cas d'un MES à 3 équations



$$y_1 = \alpha_{12}y_2 + \alpha_{13}y_3 + \beta_{11}z_1 + u_1$$

$$y_2 = \alpha_{21}y_1 + \beta_{21}z_1 + \beta_{22}z_2 + \beta_{23}z_3 + u_2$$

$$y_3 = \alpha_{32}y_2 + \beta_{31}z_1 + \beta_{32}z_2 + \beta_{33}z_3 + \beta_{34}z_4 + u_3.$$

# MES à plus de 2 équations

Considérons le cas d'un MES à 3 équations



$$y_1 = \alpha_{12}y_2 + \alpha_{13}y_3 + \beta_{11}z_1 + u_1$$

$$y_2 = \alpha_{21}y_1 + \beta_{21}z_1 + \beta_{22}z_2 + \beta_{23}z_3 + u_2$$

$$y_3 = \alpha_{32}y_2 + \beta_{31}z_1 + \beta_{32}z_2 + \beta_{33}z_3 + \beta_{34}z_4 + u_3.$$

- Il n'est pas facile de déterminer les équations identifiées mais plus facile de déterminer les équations non identifiées.



# MES à plus de 2 équations

Considérons le cas d'un MES à 3 équations



$$y_1 = \alpha_{12}y_2 + \alpha_{13}y_3 + \beta_{11}z_1 + u_1$$

$$y_2 = \alpha_{21}y_1 + \beta_{21}z_1 + \beta_{22}z_2 + \beta_{23}z_3 + u_2$$

$$y_3 = \alpha_{32}y_2 + \beta_{31}z_1 + \beta_{32}z_2 + \beta_{33}z_3 + \beta_{34}z_4 + u_3.$$

- Il n'est pas facile de déterminer les équations identifiées mais plus facile de déterminer les équations **non identifiées**.
- L'équation expliquant  $y_3$  est clairement non identifiée car toutes les variables exogènes sont présentes.  
→ Il ne reste plus de VI pour estimer  $\alpha_{32}$ .

# MES à plus de 2 équations

- La condition d'ordre de l'équation décrivant  $y_1$  semble remplie car il y a 2 variables endogènes ( $y_2$  et  $y_3$ ) et on dispose de 3 instruments ( $z_2, z_3$  et  $z_4$ ).

# MES à plus de 2 équations

- La condition d'ordre de l'équation décrivant  $y_1$  semble remplie car il y a 2 variables endogènes ( $y_2$  et  $y_3$ ) et on dispose de 3 instruments ( $z_2, z_3$  et  $z_4$ ).
- Condition d'ordre pour l'identification.

# MES à plus de 2 équations

- La condition d'ordre de l'équation décrivant  $y_1$  semble remplie car il y a 2 variables endogènes ( $y_2$  et  $y_3$ ) et on dispose de 3 instruments ( $z_2, z_3$  et  $z_4$ ).
- Condition d'ordre pour l'identification.
- Une équation dans un MES respecte la condition d'ordre pour l'identification si le nombre de variables exogènes exclues de l'équation est plus grand ou égal au nombre de variables explicatives endogènes de l'équation.

# MES à plus de 2 équations

- La condition d'ordre de l'équation décrivant  $y_1$  semble remplie car il y a 2 variables endogènes ( $y_2$  et  $y_3$ ) et on dispose de 3 instruments ( $z_2, z_3$  et  $z_4$ ).
- Condition d'ordre pour l'identification.
- Une équation dans un MES respecte la condition d'ordre pour l'identification si le nombre de variables exogènes exclues de l'équation est plus grand ou égal au nombre de variables explicatives endogènes de l'équation.
- La condition d'ordre est une condition nécessaire mais non suffisante. → Les conditions suffisantes sont plus difficiles à déterminer.

# MES à plus de 2 équations

$$y_2 = \alpha_{21}y_1 + \beta_{21}z_1 + \beta_{22}z_2 + \beta_{23}z_3 + u_2.$$

- Pour identifier la seconde équation, on dispose d'un instrument ( $z_4$ ) pour une variable endogène ( $y_1$ ).  
→ La condition d'ordre est remplie. Mais il faut également que  $\beta_{34} \neq 0$ .

# MES à plus de 2 équations

$$y_2 = \alpha_{21}y_1 + \beta_{21}z_1 + \beta_{22}z_2 + \beta_{23}z_3 + u_2.$$

- Pour identifier la seconde équation, on dispose d'un instrument ( $z_4$ ) pour une variable endogène ( $y_1$ ).  
→ La condition d'ordre est remplie. Mais il faut également que  $\beta_{34} \neq 0$ .
- La première équation est **sur-identifiée** car on dispose de 3 VI ( $z_1, z_2, z_3$ ) pour 2 variables endogènes ( $y_2, y_3$ ).