

Chapitre 4 : Régression linéaire multiple (RLM)

Économétrie (ECON0212)

Natalia Bermúdez

HEC Liège

October 2026

Aujourd'hui — Régression Linéaire Multiple


Au programme

- Plusieurs variables explicatives dans le modèle
- Le biais de variable omise
- Interprétation : variables quantitatives et variables indicatrices
- Le piège de la collinéarité parfaite
- Le R^2 ajusté

i Point de départ : taille de la classe et performance des élèves

- Données d'Angrist et Lavy (1999) : classes de CM2 en Israël.
- Avec une **régression linéaire simple** (chapitre 2), la taille de la classe était *positivement associée* aux scores en mathématiques et en lecture.

Régression simple : taille de la classe et score en maths



```
regress avgmath classize
```

avgmath	Coefficient	Std. err.	t	P> t	[95% conf. interval]	
classize	.3174906	.0317774	9.99	0.000	.2551707	.3798105
_cons	57.79392	.9736486	59.36	0.000	55.88445	59.70338

$$\widehat{\text{score}}_i = 57.79 + 0.32 \times \text{taille}_i$$

Un résultat surprenant

- **Chapitre 2 (Régression simple)** : un élève de plus dans la classe est associé à **+0.32 point** en maths.
- **Chapitre 3 (STAR project - *traitement aléatoire*)** : « être assigné à une petite classe » était **aléatoire**, et il **augmentait** les scores (environ +9 points en maths en maternelle).

math	Coefficient	Std. err.	t	P> t	[95% conf. interval]	
small	8.922239	1.676867	5.32	0.000	5.634457	12.21002
_cons	484.4145	1.14938	421.46	0.000	482.1609	486.668


Comment réconcilier les deux ? La régression simple **n'est pas une expérience aléatoire** : les grandes et les petites classes diffèrent peut-être par **autre chose** que leur taille (*par exemple, des caractéristiques observables et non observables*).

- Ex. **La localisation** : les grandes classes sont plus fréquentes dans les villes riches, les petites dans les régions rurales plus pauvres (**plus d'élèves défavorisés**). Elle peut influencer à la fois la taille des classes et les scores.

Un facteur confondant : l'origine sociale des élèves


La localisation n'est pas observée, mais **disadvantaged** (% d'élèves issus de milieux défavorisés, plus élevé dans les régions pauvres) en mesure une dimension clé. Est-il lié **à la fois** à x et à y ?

Lien avec x (taille de la classe)



👉 Plus de défavorisés → classes **plus petites**.

Lien avec y (score en maths)



👉 Plus de défavorisés → scores **plus faibles**.

Vers la régression multiple

On veut l'effet de la taille de la classe sur le score en contrôlant pour le % d'élèves défavorisés.

⇒ On inclut **les deux** variables comme régresseurs :

$$\text{score}_i = \beta_0 + \beta_1 \text{taille}_i + \beta_2 \text{défavorisés}_i + e_i$$

- β_1 : relation entre taille et score **à % de défavorisés donné**, c'est-à-dire *purgée* de l'effet de **disadvantaged**.
- C'est une **régression linéaire multiple**.

Plan du cours

1. **Le modèle de régression linéaire multiple (RLM)**
2. Le biais de variable omise
3. Variables quantitatives et variables indicatrices
4. R^2 ajusté

Le modèle de régression linéaire multiple

Objectif : enrichir le modèle pour prendre en compte les facteurs qui sont **simultanément liés** à y_i et à x_{i1} .

Dans la **population**, on suppose la relation linéaire :

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \cdots + \beta_k x_{ik} + e_i$$

- y_i : variable dépendante (ex. score moyen en maths de la classe i)
- $x_{i1}, \dots, x_{ik}$: les k variables explicatives (ex. taille de la classe, % de défavorisés).
- β_0 : constante ; $\beta_1, \dots, \beta_k$: les k pentes $\Rightarrow$ **$k + 1$ paramètres inconnus**.
- e_i : terme d'erreur, regroupe tous les facteurs **non inclus** dans le modèle.
- Le modèle est **linéaire dans les paramètres** (comme au chapitre 2).

Estimation de la RLM par MCO

Comme au chapitre 2, on choisit les estimateurs $b_0, b_1, \dots, b_k$ qui **MINIMISENT LA SOMME DES CARRÉS DES RÉSIDUS** :

$$\min_{b_0, b_1, \dots, b_k} \sum_{i=1}^n \hat{e}_i^2 = \sum_{i=1}^n (y_i - b_0 - b_1 x_{i1} - \dots - b_k x_{ik})^2$$

- Le problème est plus complexe : $k + 1$ **paramètres** $\Rightarrow k + 1$ **estimateurs** $(b_0, b_1, \dots, b_k)$, obtenus à partir de $k + 1$ **conditions du premier ordre**.
- Il n'y a plus de formule « simple » du type cov/var pour chaque pente : **Stata** résout le système pour nous.

On obtient ensuite, comme avant :

- les **valeurs prédites** : $\hat{y}_i = b_0 + b_1 x_{i1} + \dots + b_k x_{ik}$
- les **résidus** : $\hat{e}_i = y_i - \hat{y}_i$

Interprétation : le cas $k = 2$

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + e_i$$

Étape 1. On régresse x_{i1} sur x_{i2} (et une constante), et on garde le résidu $\hat{r}_{i1}$:

$$x_{i1} = \gamma_0 + \gamma_1 x_{i2} + r_{i1}, \quad \hat{r}_{i1} = x_{i1} - \hat{\gamma}_0 - \hat{\gamma}_1 x_{i2}$$

$\hat{r}_{i1}$ = la partie de x_{i1} qui **n'est pas expliquée** par x_{i2} .

Étape 2. L'estimateur MCO de β_1 dans la régression multiple est :

$$b_1 = \frac{\sum_{i=1}^n \hat{r}_{i1} y_i}{\sum_{i=1}^n \hat{r}_{i1}^2}$$

$\Rightarrow b_1$ est la pente de la régression simple de y_i sur $\hat{r}_{i1}$:

$$y_i = \alpha_0 + \beta_1 \hat{r}_{i1} + v_i$$

Le théorème de Frisch–Waugh–Lovell

Le résultat précédent se généralise à **chaque variable explicative** x_j :

$$b_j = \frac{\sum_{i=1}^n \hat{r}_{ij} y_i}{\sum_{i=1}^n \hat{r}_{ij}^2}, \quad j = 1, \dots, k$$

où $\hat{r}_{ij}$ est le résidu de la régression de x_j sur toutes les autres variables explicatives (et une constante).

- **Théorème de Frisch–Waugh–Lovell** : b_j mesure la relation entre y et x_j **une fois que l'on a retiré (“netting out”) de x_j , la variation expliquée par les autres variables** du modèle.
- C’est ce qui justifie l’interprétation « **en maintenant les autres régresseurs constants** », au sens statistique.
- La constante s’obtient ensuite par : $b_0 = \bar{y} - b_1 \bar{x}_1 - b_2 \bar{x}_2 - \dots - b_k \bar{x}_k$

Interprétation ($k = 2$): toutes choses égales par ailleurs

$$\hat{y} = b_0 + b_1 x_1 + b_2 x_2 \implies \Delta \hat{y} = b_1 \Delta x_1 + b_2 \Delta x_2$$

Si x_2 est maintenu constant ($\Delta x_2 = 0$) :

- **Constante b_0** : valeur prédite de y quand **tous** les régresseurs valent 0.
- **Pente b_j** : variation prédite de y **associée** à une augmentation d'**une unité** de x_j , **en maintenant tous les autres régresseurs constants**.
 - *Effet marginal sur la valeur prédite*, ou une interprétation «**toutes choses égales par ailleurs**» (TCEPA, *ceteris paribus*).

$$\Delta \hat{y} = b_1 \Delta x_1 \implies b_1 = \frac{\Delta \hat{y}}{\Delta x_1}$$

⚠ **Attention** : seuls les régresseurs **inclus** sont maintenus constants. Les facteurs **non inclus** (dans e_i) peuvent encore être corrélés avec x_j et biaiser l'estimation → **biais de variable omise**.

Une nuance dans l'interprétation : les formes non linéaires

La RLM permet aussi de modéliser une relation **non linéaire**. Exemple (Wooldridge, éq. 3.4) : consommation et revenu des ménages.

$$\text{cons}_i = \beta_0 + \beta_1 \text{inc}_i + \beta_2 \text{inc}_i^2 + e_i$$

- Un seul facteur observé (le revenu $\rightarrow$ inc), mais **deux régresseurs** : $x_{i1} = \text{inc}_i$ et $x_{i2} = \text{inc}_i^2$.
 - **Trois paramètres**, estimés par MCO. Le modèle reste **linéaire dans les paramètres**.
- **⚠** L'interprétation **TCEPA ne s'applique pas** : on ne peut pas faire varier **inc** en gardant **inc²** constant !
- L'effet marginal (ex. **propension marginale à consommer**) dépend du revenu :

$$\frac{\Delta \text{cons}}{\Delta \text{inc}} \approx \beta_1 + 2 \beta_2 \text{inc}$$

Application : taille de la classe et milieu social

regress avgmath classize disadvantaged

avgmath	Coefficient	Std. err.	t	P> t	[95% conf. interval]	
classize	.0716782	.0301848	2.37	0.018	.0124816	.1308748
disadvantaged	-.3395788	.014675	-23.14	0.000	-.3683585	-.3107991
_cons	69.94438	1.012486	69.08	0.000	67.95875	71.93001

$$\widehat{\text{score}}_i = 69.94 + 0.07 \text{taille}_i - 0.34 \text{défav}_i$$

- $b_0 = 69.94$: score prédit pour une classe de **0 élève** et **0 %** de défavorisés (pas d'interprétation concrète).
- $b_1 = 0.07$: **à % de défavorisés constant**, un élève de plus est associé, en moyenne, à **+0.07 point** en maths.
- $b_2 = -0.34$: **à taille de classe constante**, une hausse de **1 point de pourcentage** de défavorisés est associée, en moyenne, à **-0.34 point** en maths.

Pourquoi b_1 a-t-il changé ?

	Régression simple	Régression multiple
Coefficient de classsize	0.32	0.07
disadvantaged inclus ?	non	oui

- Le coefficient de la taille de la classe **chute de 0.32 à 0.07** quand on contrôle pour le % de défavorisés.
 - C'était attendu : une partie de l'association positive venait du fait que **les grandes classes comptent moins d'élèves défavorisés (en pourcentage)**.
 - La régression simple attribuait à la taille de la classe un effet qui venait en partie de la **composition sociale** :
 - Les grandes classes, qui comptent moins d'élèves défavorisés, auraient obtenu de meilleurs scores *même si elles avaient été plus petites*.
- Formalisons ce mécanisme : le **biais de variable omise**.

Plan du cours

1. Le modèle de régression linéaire multiple (RLM)
2. **Le biais de variable omise**
3. Variables quantitatives et variables indicatrices
4. R^2 ajusté

Biais de variable omise (*Omitted Variable Bias, OVB*)

Variable omise (z) : variable qui affecte y , qui est corrélée avec x , mais qui **n'est pas incluse** dans la régression. Elle se retrouve alors dans le terme d'erreur.

Trois régressions :

1. « **Vrai** » **modèle** (régression multiple) : $y_i = \beta_0 + \beta_1 x_i + \beta_2 z_i + e_i$
2. **Modèle estimé** (régression simple, z omise) : $\hat{y}_i = \tilde{b}_0 + \tilde{b}_1 x_i$
3. **Variable omise sur le régresseur** : $\hat{z}_i = \tilde{\delta}_0 + \tilde{\delta}_1 x_i$

$$E(\tilde{b}_1 \mid x, z) = \beta_1 + \underbrace{\beta_2 \times \tilde{\delta}_1}_{\text{biais de variable omise}}$$

[Démonstration] Biais de variable omise

L'estimateur de la régression simple est (chapitre 2) : $\tilde{b}_1 = \sum_{i=1}^n (x_i - \bar{x}) y_i / \sum_{i=1}^n (x_i - \bar{x})^2$

On remplace y_i par le vrai modèle $y_i = \beta_0 + \beta_1 x_i + \beta_2 z_i + e_i$. Comme $\sum_i (x_i - \bar{x}) = 0$ et $\sum_i (x_i - \bar{x}) x_i = \sum_i (x_i - \bar{x})^2$:

$$\tilde{b}_1 = \beta_1 + \beta_2 \underbrace{\frac{\sum_{i=1}^n (x_i - \bar{x}) z_i}{\sum_{i=1}^n (x_i - \bar{x})^2}}_{= \tilde{\delta}_1} + \frac{\sum_{i=1}^n (x_i - \bar{x}) e_i}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

On prend l'espérance conditionnellement aux x_i et aux z_i . Sous l'hypothèse $E(e_i | x, z) = 0$ (H3 du chapitre 2, mais avec deux régresseurs), le dernier terme s'annule:

$$E(\tilde{b}_1 | x, z) = \beta_1 + \beta_2 \tilde{\delta}_1 \quad \implies \quad \text{Biais} = E(\tilde{b}_1 | x, z) - \beta_1 = \beta_2 \tilde{\delta}_1$$

Biais de variable omise : le signe du biais

$$\text{Biais} = \underbrace{\beta_2}_{\text{pente de la régression de } y \text{ sur } z \text{ (à } x \text{ donné)}} \times \underbrace{\tilde{\delta}_1}_{\text{pente de la régression de } z \text{ sur } x}$$

$$\tilde{\delta}_1 > 0$$

$$\tilde{\delta}_1 < 0$$

$$\beta_2 > 0$$

biais **positif**

biais **négatif**

$$\beta_2 < 0$$

biais **négatif**

biais **positif**

- Si z est **observée** : on obtient la **magnitude** du biais (mais alors on l'inclut dans la régression !).
- En pratique, z est souvent **inobservée** : on peut quand même raisonner sur le **signe** du biais.

Exemple

Salaire et années d'études. Variable omise : les **capacités** (*ability*). Elles augmentent le salaire ($\beta_2 > 0$) et les personnes plus capables font en moyenne plus d'études ($\tilde{\delta}_1 > 0$) $\Rightarrow$ biais **positif**.

Biais de variable omise : notre exemple

(1) Régression simple (z omise) :

$$\widehat{\text{score}} = 57.79 + \tilde{b}_1 \text{ taille},$$

$$\tilde{b}_1 = 0.317$$

(2) Régression multiple :

$$\widehat{\text{score}} = 69.94 + b_1 \text{ taille} + b_2 \text{ défav}$$

$$b_1 = 0.072, \quad b_2 = -0.340$$

(3) Variable omise sur x :

$$\widehat{\text{défav}} = 35.78 + \tilde{\delta}_1 \text{ taille}$$

$$\tilde{\delta}_1 = -0.724$$

Interprétation du biais :

- $b_2 < 0$: plus de défavorisés $\Rightarrow$ scores plus faibles.
- $\tilde{\delta}_1 < 0$: les grandes classes ont moins de défavorisés.
- $\Rightarrow \text{biais} = (-) \times (-) > 0$.

$$\underbrace{0.317}_{\tilde{b}_1} = \underbrace{0.072}_{b_1} + \underbrace{(-0.340)}_{b_2} \times \underbrace{(-0.724)}_{\tilde{\delta}_1}$$

La régression simple **surestimait** l'association entre taille de la classe et score.

Exercice 1

10:00

On utilise maintenant le score en **lecture** (**avgverb**) comme variable dépendante.

1. Ouvrir la base **grade5.dta** dans **Stata**.
2. Régresser **avgverb** sur **classsize** et **disadvantaged**. Interpréter les coefficients et les comparer avec ceux obtenus pour les maths. Comparer ensuite le coefficient de **classsize** avec celui de la régression simple (sans **disadvantaged**).
3. Quelles autres variables disponibles pourrait-on ajouter ? Estimer la régression avec ces variables et discuter le **signe** et la **magnitude** des coefficients.
4. On contrôle maintenant pour **religious** au lieu de **disadvantaged**. Quel est le **signe** du biais de variable omise lié à **religious** dans la régression simple ? Calculer sa **magnitude** et l'interpréter.
(Indice : régresser **religious** sur **classsize** pour obtenir $\tilde{\delta}_1$.)

Plan du cours

1. Le modèle de régression linéaire multiple (RLM)
2. Le biais de variable omise
3. **Variables quantitatives et variables indicatrices**
4. R^2 ajusté

Variables quantitatives et variables qualitatives

Jusqu'ici, les régresseurs étaient quantitatifs : « +1 unité » a un sens.

- **Discrète** : l'ensemble des valeurs possibles est **fini ou dénombrable** (on peut les énumérer). Ex. : taille de la classe $\in \{1, 2, 3, \dots\}$.
- **Continue** : X peut prendre n'importe quelle valeur d'un intervalle. Ex. : revenu, durée, % d'élèves défavorisés

Mais certaines variables sont qualitatives (ex. catégorielles) : type de classe (**small**), type d'école, région, **religion**, genre...

- **Variables indicatrices** (*dummy*), qui valent **1** si une condition est vraie et **0** sinon. Une indicatrice est une variable discrète binaire (valeurs 0 et 1).

⚠ Le **codage numérique** d'une variable catégorielle est **arbitraire** (ex. **school** : 1 = centre-ville, 2 = rural, 3 = périurbain, 4 = urbain). « +1 unité » n'a pas de sens !

Variable indicatrice : interprétation

$$\text{score}_i = \beta_0 + \beta_1 \text{taille}_i + \beta_2 \text{religieuse}_i + e_i$$

religious = 1 si l'école est religieuse, 0 sinon. **regress avgmath classize religious** :


avgmath	Coefficient	Std. err.	t	P> t	[95% conf. interval]	
classize	.2311258	.0334519	6.91	0.000	.165522	.2967296
religious	-3.780027	.5096029	-7.42	0.000	-4.77943	-2.780623
_cons	61.3092	1.07138	57.22	0.000	59.20807	63.41033

- $b_0 = 61.31$: score prédit dans une école **non religieuse** avec une classe de **0** élève.
- $b_1 = 0.23$: à statut religieux constant, un élève de plus est associé, en moyenne, à **+0.23 point**.
- $b_2 = -3.78$: à taille de classe constante, les écoles religieuses ont en moyenne un score **inférieur de 3.78 points** à celui des écoles non religieuses.
- $b_0 + b_2$: score prédit dans une école **religieuse** avec une classe de 0 élève.

→ Le coefficient d'une indicatrice est une **différence de moyennes** par rapport à la **catégorie de référence** (**religious** = 0). Démonstrations : voir l'**annexe**.



Variable indicatrice : graphiquement



Pas de collinéarité parfaite

Condition : aucun régresseur ne peut être une **combinaison linéaire exacte** des autres (ni de la constante). Sinon, les MCO ne peuvent pas séparer leurs effets.

Exemple : le piège des indicatrices. On crée `is_religious` et `is_notreligious` et on les met **toutes les deux** dans la régression :

```
1 gen is_religious = religious == 1
2 gen is_notreligious = religious == 0
3 reg avgmth is_religious is_notreligious classize
```

avgmth	Coefficient	Std. err.	t	P> t	[95% conf. interval]	
is_religious	-3.780027	.5096029	-7.42	0.000	-4.77943	-2.780623
is_notreligious	0	(omitted)				
classize	.2311258	.0334519	6.91	0.000	.165522	.2967296
_cons	61.3092	1.07138	57.22	0.000	59.20807	63.41033

Pour chaque école : `is_religious` + `is_notreligious` = 1 = la constante.

⇒ **collinéarité parfaite** : **Stata** supprime automatiquement une variable (*omitted*).

⚠ **Règle** : avec G catégories, on inclut $G - 1$ **indicatrices**. La catégorie omise est la **référence** ; les coefficients se lisent par rapport à elle.

Exercice 2 : le piège des indicatrices

08:00

Données `star_data.dta` (chapitre 3). Supprimer les observations avec des valeurs manquantes.

1. Créer trois indicatrices : `small` (petite classe), `regular` (classe normale) et `regular_plus` (classe normale + aide). Que vaut `small + regular + regular_plus` pour chaque élève ?
2. Régresser `math` sur `small`, `regular` et `regular_plus`. Que se passe-t-il ? Quelle est la catégorie de référence ?
3. Comparer avec `regress math i.star`. Les résultats sont-ils cohérents ?

Plan du cours

1. Le modèle de régression linéaire multiple (RLM)
2. Le biais de variable omise
3. Variables quantitatives et variables indicatrices
4. R^2 ajusté

R^2 et R^2 ajusté

Comme au chapitre 2 : $R^2 = \frac{SCE}{SCT} = 1 - \frac{SCR}{SCT} \in [0, 1]$

- Le R^2 **augmente toujours** (ou reste constant) quand on ajoute un régresseur, même inutile.
- Un R^2 faible ne veut pas dire que le modèle est mauvais, et ne dit **rien** sur l'interprétation **causale** des coefficients.

Le R^2 ajusté pénalise l'ajout de régresseurs :

$$\bar{R}^2 = 1 - \frac{n-1}{n-k-1} \frac{SCR}{SCT} = 1 - \frac{n-1}{n-k-1} (1 - R^2)$$

où n = nombre d'observations et k = nombre de régresseurs (hors constante).

[Propriétés] R^2 ajusté

$$\bar{R}^2 = 1 - \frac{n-1}{n-k-1}(1 - R^2)$$

1. Le R^2 ajusté est **toujours inférieur ou égal** au R^2 :

$$\bar{R}^2 \leq R^2$$

2. **Que se passe-t-il lorsqu'on ajoute une variable explicative ?**

- Le R^2 **ne peut pas diminuer**, même si la nouvelle variable apporte très peu d'information.
- Le $\bar{R}^2$ tient compte du **nombre de variables explicatives** :
 - Il **augmente** si la nouvelle variable améliore suffisamment l'ajustement.
 - Il **diminue** si l'amélioration est trop faible

Exercice 3 : récapitulatif (révision à la maison)

On utilise les données STAR (`star_data.dta`) pour réviser les points précédents.

1. Garder les élèves de 2^e année (`grade`). Régresser `math` sur `i.school` (regarder d'abord `tab school`). Interpréter les coefficients. Quelle est la catégorie de référence ? Quelle pourrait être une variable omise ?
2. Calculer la part d'élèves bénéficiant d'un repas gratuit (`lunch` = "free") par `school` . Qu'observez-vous ? Ajouter `lunch` à la régression précédente. Comment les coefficients changent-ils ?
3. Régresser `math` sur `i.star` , puis ajouter `gender` , `ethnicity` , `lunch` , `degree` , `experience` et `school` . Comme STAR est une expérience aléatoire, le coefficient de `star` devrait-il beaucoup changer ? Qu'en concluez-vous sur la randomisation ?
4. Quel est le R^2 ajusté de cette dernière régression ? Comment l'interpréter ?

Annexe

Variable indicatrice : démonstrations

Annexe Variable indicatrice : b_0 et b_1

$$\widehat{\text{score}} = b_0 + b_1 \text{ taille} + b_2 \text{ religieuse}$$

Constante. Pour une école non religieuse avec une classe de taille 0 :

$$\widehat{\text{score}}(\text{religieuse} = 0, \text{taille} = 0) = b_0 + b_1 \times 0 + b_2 \times 0 = b_0$$

Pente de la taille. À statut religieux $R \in \{0, 1\}$ fixé, comparons une classe de taille $n_1 + 1$ et une classe de taille n_1 :

$$\widehat{\text{score}}(R, n_1 + 1) - \widehat{\text{score}}(R, n_1) = [b_0 + b_1(n_1 + 1) + b_2 R] - [b_0 + b_1 n_1 + b_2 R] = b_1$$

$\Rightarrow b_1$ = variation prédite du score associée à **un élève de plus**, à statut religieux constant (la même pour les deux types d'écoles).

← Retour à la diapositive « Variable indicatrice : interprétation »

Annexe Variable indicatrice : b_2

À taille de classe T fixée, comparons une école religieuse et une école non religieuse :

$$\widehat{\text{score}}(\text{religieuse} = 1, T) = b_0 + b_1 T + b_2$$

$$\widehat{\text{score}}(\text{religieuse} = 0, T) = b_0 + b_1 T$$

$$\widehat{\text{score}}(1, T) - \widehat{\text{score}}(0, T) = b_2$$

$\Rightarrow b_2 =$ **différence de score prédit** entre écoles religieuses et non religieuses, **à taille de classe constante**.

Et $b_0 + b_2 =$ score prédit dans une école **religieuse** avec une classe de taille 0.

← Retour à la diapositive « Variable indicatrice : interprétation »