

MATH 60604
Modélisation statistique
§ 6d - Ordonnée à l'origine aléatoire

HEC Montréal
Département de sciences de la décision

Le modèle de régression linéaire mixte suivant n'a qu'une seule composante aléatoire (une ordonnée à l'origine par groupe). L'équation de la moyenne est

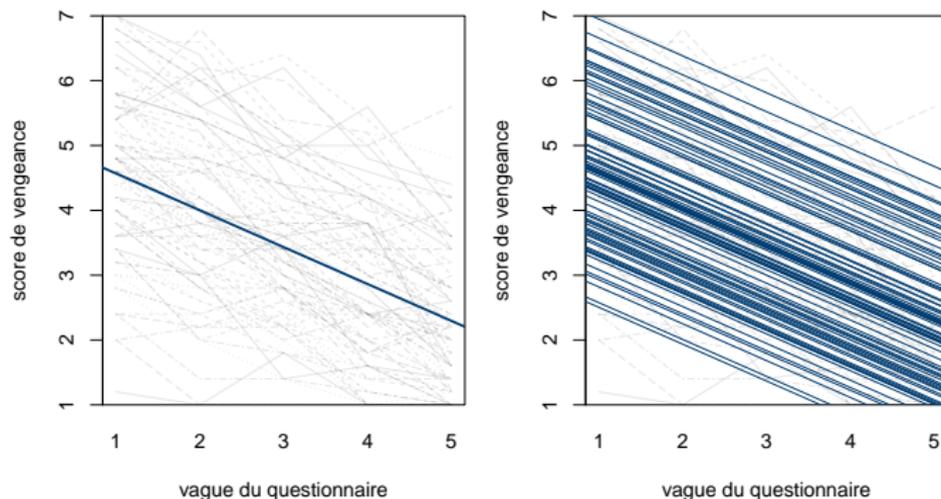
$$Y_{ij} = (\beta_0 + b_i) + \beta_1 X_{ij1} + \cdots + \beta_p X_{ijp} + \varepsilon_{ij}, \quad \varepsilon_i \sim \text{No}(\mathbf{0}, \mathbf{R}_i)$$

pour $i = 1, \dots, m$ et $j = 1, \dots, n_i$ et où Y_{ij} est l'observation j du groupe i . L'**ordonnée à l'origine** du groupe i est désormais $\beta_0 + b_i$. Elle est composée

- d'un effet fixe commun à tous les groupes, β_0 ;
- d'un effet aléatoire spécifique au groupe i , b_i .

Illustration de l'effet aléatoire

On montre l'impact de l'effet aléatoire pour les données vengeance avec covariance AR(1) et t comme variable explicative continue.



Modèle sans effet aléatoire (gauche) et avec effet aléatoire pour id (droite).

Soit l'équation du modèle,

$$Y_{ij} = (\beta_0 + b_i) + \beta_1 X_{ij1} + \beta_2 X_{ij2} + \cdots + \beta_p X_{ijp} + \varepsilon_{ij}$$

- Les effets aléatoires b_1, \dots, b_m sont supposés indépendants des termes d'aléas ε et des variables explicatives
- On postule pour le moment
 - $b_i \stackrel{\text{iid}}{\sim} \text{No}(0, \sigma_b^2)$ ($i = 1, \dots, m$).
 - $\varepsilon_{ij} \stackrel{\text{iid}}{\sim} \text{No}(0, \sigma^2)$ ($i = 1, \dots, m; j = 1, \dots, n_i$).

Comme il est aléatoire, le terme b_i introduit de la **corrélacion intra-groupe** dans le modèle. Puisque ε_{ij} est indépendant de b_i pour tout i, j , la variance (conditionnelle) d'une observation est

$$\text{Var} (Y_{ij} \mid \mathbf{X}_i) = \text{Var} (b_i) + \text{Var} (\varepsilon_{ij}) = \sigma_b^2 + \sigma^2$$

La covariance entre deux individus d'un même groupe est

$$\text{Cov} (Y_{ij}, Y_{ik} \mid \mathbf{X}_i) = \sigma_b^2, \quad j \neq k.$$

Par conséquent, la corrélation entre deux individus d'un même groupe est

$$\text{Corr} (Y_{ij}, Y_{ik} \mid \mathbf{X}_i) = \frac{\sigma_b^2}{\sigma^2 + \sigma_b^2}, \quad j \neq k.$$

Cette quantité est habituellement appelée **corrélacion intra-groupe**.

Les coefficients β_j et les covariables ne sont pas aléatoires, ce qui fait que

$$\begin{aligned}\text{Cov}(Y_{ij}, Y_{ik} \mid \mathbf{X}_i) &= \text{Co}(\beta_0 + b_i + \beta_1 X_{ij1} + \cdots + \varepsilon_{ij}, \\ &\quad \beta_0 + b_i + \beta_1 X_{ik1} + \cdots + \varepsilon_{ik} \mid \mathbf{X}_i) \\ &= \text{Cov}(b_i + \varepsilon_{ij}, b_i + \varepsilon_{ik}) \\ &= \text{Var}(b_i) + \text{Cov}(\varepsilon_{ij}, \varepsilon_{ik}) \\ &= \sigma_b^2 + \sigma^2 \mathbf{1}_{j=k}.\end{aligned}$$

où la dernière étape vient de l'indépendance entre b_i et ε et puisque $\text{Cov}(Y_{ij}, Y_{ij}) = \text{Var}(Y_{ij})$.

De manière équivalente, on peut écrire

$$\begin{aligned}\text{Var}(Y_i | \mathbf{X}_i) &= \text{Var}(b_i \mathbf{1}_{n_i}) + \text{Var}(\varepsilon_i) \\ &= \sigma_b^2 \mathbf{1}_{n_i} \mathbf{1}_{n_i}^\top + \sigma^2 \mathbf{I}_{n_i} \\ &= \begin{pmatrix} \sigma_b^2 & \sigma_b^2 & \cdots & \sigma_b^2 \\ \sigma_b^2 & \sigma_b^2 & \cdots & \sigma_b^2 \\ \vdots & \ddots & \ddots & \vdots \\ \sigma_b^2 & \sigma_b^2 & \cdots & \sigma_b^2 \end{pmatrix} + \begin{pmatrix} \sigma^2 & 0 & \cdots & 0 \\ 0 & \sigma^2 & \ddots & 0 \\ \vdots & \ddots & \ddots & \vdots \\ 0 & 0 & \cdots & \sigma^2 \end{pmatrix}.\end{aligned}$$

Structure d'équicorrélation avec ordonnée à l'origine aléatoire

- Quand les aléas ε_j sont indépendants et homoscedastiques, soit $\text{Var}(\varepsilon_j) = \sigma^2 \mathbf{I}_{n_j}$, introduire un effet aléatoire pour l'ordonnée à l'origine fait en sorte que la corrélation intra-groupe est constante.
- Dans ce cas précis, la matrice de covariance conditionnelle de Y_i est donc la même que si on considérait une régression linéaire sans effet aléatoire avec une structure d'équicorrélation pour $\text{Var}(\varepsilon_j)$.
- La différence ici est que la corrélation doit être non-négative. Ce n'est généralement pas une limitation, car les corrélations intra-groupe ont tendance à être positives.

Ajout d'un effet aléatoire avec la commande `random`

- La commande `repeated` nous permettait de spécifier la structure de covariance des erreurs avec `proc mixed`.
- Si on utilise pas la commande `repeated`, les erreurs sont postulées indépendantes.

Code SAS pour ajuster un modèle avec ordonnée à l'origine aléatoire avec erreurs indépendantes

```
proc mixed data=modstat.mobilisation;  
class idunite;  
model mobilisation = sexe anciennete agegest nunite / solution;  
random intercept / subject=idunite v=1 vcorr=1;  
run;
```

L'inclusion d'une ordonnée à l'origine aléatoire **induit** une structure d'équicorrélation pour les réponses. Il n'est donc pas nécessaire de spécifier une structure de covariance pour les erreurs.

Matrice de covariance du modèle avec ordonnée à l'origine aléatoire

Matrice V estimée pour idunite 1

Ligne	Col1	Col2	Col3	Col4	Col5	Col6	Col7	Col8	Col9
1	1.3709	0.2448	0.2448	0.2448	0.2448	0.2448	0.2448	0.2448	0.2448
2	0.2448	1.3709	0.2448	0.2448	0.2448	0.2448	0.2448	0.2448	0.2448
3	0.2448	0.2448	1.3709	0.2448	0.2448	0.2448	0.2448	0.2448	0.2448
4	0.2448	0.2448	0.2448	1.3709	0.2448	0.2448	0.2448	0.2448	0.2448
5	0.2448	0.2448	0.2448	0.2448	1.3709	0.2448	0.2448	0.2448	0.2448
6	0.2448	0.2448	0.2448	0.2448	0.2448	1.3709	0.2448	0.2448	0.2448
7	0.2448	0.2448	0.2448	0.2448	0.2448	0.2448	1.3709	0.2448	0.2448
8	0.2448	0.2448	0.2448	0.2448	0.2448	0.2448	0.2448	1.3709	0.2448
9	0.2448	0.2448	0.2448	0.2448	0.2448	0.2448	0.2448	0.2448	1.3709

Valeur estimée du paramètre de covariance		
Param. de cov.	Sujet	Estimation
Intercept	idunite	0.2448
Residual		1.1261

- L'estimé de la variance de l'effet aléatoire est $\hat{\sigma}_b^2 = 0,2448$, tandis que l'estimé de la variance des erreurs est $\hat{\sigma}^2 = 1,1261$.
- Conséquemment, la corrélation intra-unité est

$$\hat{\rho} = \frac{\hat{\sigma}_b^2}{\hat{\sigma}_b^2 + \sigma^2} = 0,1785.$$

- C'est exactement la même corrélation que celle rapportée pour le modèle d'équicorrélation intra-unité des erreurs (commande `repeated`).

Solution pour effets fixes					
Effet	Estimation	Erreur type	DDL	Valeur du test t	Pr > t
Intercept	13.7633	0.3955	97	34.80	<.0001
sexe	0.5622	0.06835	914	8.23	<.0001
anciennete	-0.4722	0.006015	914	-78.50	<.0001
agegest	0.01929	0.006801	97	2.84	0.0056
nunite	0.006470	0.02019	97	0.32	0.7493

L'effet des variables explicatives (et leurs erreurs-types) sont exactement les même que pour le modèle d'équicorrélation des erreurs — les deux modèles sont équivalents pour la réponse si la corrélation intra-unité est positive.