

Modèles linéaires (un peu) mixtes

Cours: Joseph Salmon

Scribes: Mohamed Akli Rabia, Samuel Kaci, Ali Abed Alsater

1 Rappel sur le modèle

Le modèle est le suivant :

$$y_{i,j} = \mu + A_j + \varepsilon_{i,j} , \quad (1)$$

- μ est déterministe,
- $A_j \sim \mathcal{N}(0, \sigma_A^2)$ est un effet aléatoire,
- $\varepsilon_{i,j} \sim \mathcal{N}(0, \sigma_\varepsilon^2)$,
- $n = \sum_{j=1}^J n_j$, où n_j est le nombre d'observations ayant la modalité j .

Formulation Matricielle du modèle : On observe le vecteur :

$$y = \mu \mathbf{1} + ZA + \varepsilon , \quad (2)$$

avec

$$Z = [\mathbf{1}_{C_1}, \dots, \mathbf{1}_{C_J}], A = \begin{pmatrix} A_1 \\ A_2 \\ \vdots \\ A_J \end{pmatrix} \in \mathbb{R}^J, \varepsilon \in \mathbb{R}^n . \quad (3)$$

Comme dans les cours précédents on note :

$$\bar{y}_{:,j} = \frac{1}{n_j} \sum_{i=1}^{n_j} y_{i,j} . \quad (4)$$

Espérance de $\bar{y}_{:,j}$:

$$\mathbb{E}[\bar{y}_{:,j}] = \mu + 0 + 0 = \mu . \quad (5)$$

Variance de $\bar{y}_{:,j}$:

$$\text{Var}[\bar{y}_{:,j}] = \sigma_A^2 + \frac{\sigma_\varepsilon^2}{n_j} := \tau_j^2 . \quad (6)$$

Estimateur de μ :

$$\hat{\mu} = \sum_{j=1}^J w_j \bar{y}_{:j} \text{ est un estimateur possible de } \mu, \text{ avec } w_j = \frac{\frac{1}{\tau_j^2}}{\sum_{j'=1}^J \frac{1}{\tau_{j'}^2}} . \quad (7)$$

Remarque 1.1. Cas équilibré, $\forall j \in \llbracket 1, J \rrbracket, n_j = I$ et donc $n = IJ$.

$$\tau_j^2 = \sigma_A^2 + \frac{\sigma_\varepsilon^2}{I} \implies w_j = \frac{1}{n}, \forall j \in \llbracket 1, J \rrbracket . \quad (8)$$

Notons cependant que σ_A^2 et σ_ε^2 sont en général inconnues.

Théorème 1.1. Soient X_1, \dots, X_n des variables aléatoires indépendantes telles que $\mu = \mathbb{E}[X_1] = \dots = \mathbb{E}[X_n]$, parmi les estimateurs linéaires (en X_1, \dots, X_n), sans biais de μ , celui de variance minimale est donné par

$$\hat{\mu} = \frac{\sum_{i=1}^n \frac{1}{\text{Var}[X_i]} X_i}{\sum_{i'=1}^n \frac{1}{\text{Var}[X_{i'}]}} . \quad (9)$$

Démonstration.

$$\left\{ \begin{array}{l} \min_{\alpha_1, \dots, \alpha_n} \text{Var}[\sum_{i=1}^n \alpha_i X_i] \\ \text{s.c. : } \sum_{i=1}^n \alpha_i = 1 \end{array} \right\} \iff \left\{ \begin{array}{l} \min_{\alpha_1, \dots, \alpha_n} \sum_{i=1}^n \alpha_i^2 \underbrace{\text{Var}[X_i]}_{\sigma_i^2} \\ \text{s.c. : } \sum_{i=1}^n \alpha_i = 1 \end{array} \right\} \quad (10)$$

On obtient le Lagrangien :

$$\mathcal{L} = \frac{1}{2} \sum_{i=1}^n \alpha_i^2 \sigma_i^2 + \lambda \left(\sum_{i=1}^n \alpha_i - 1 \right) . \quad (11)$$

On résout alors :

$$\left\{ \begin{array}{l} \frac{\partial \mathcal{L}}{\partial \alpha_i} = 0 \\ \frac{\partial \mathcal{L}}{\partial \lambda} = 0 \end{array} \right\} \iff \left\{ \begin{array}{l} \alpha_i \sigma_i^2 + \lambda = 0 \\ \sum_{i=1}^n \alpha_i = 1 \end{array} \right.$$

Enfin le précédent système est équivalent à :

$$\left\{ \begin{array}{l} \alpha_i = \frac{-\lambda}{\sigma_i^2} \end{array} \right. \quad (12a)$$

$$\left\{ \begin{array}{l} \sum_{i=1}^n \alpha_i = 1 \end{array} \right. \quad (12b)$$

En remplaçant α_i dans (12b) on obtient : $-\sum_{i=1}^n \frac{\lambda}{\sigma_i^2} = 1$ d'où $\lambda = -\frac{1}{\sum_{i=1}^n \frac{1}{\sigma_i^2}}$

Au final :

$$\boxed{\alpha_i = \frac{\frac{1}{\sigma_i^2}}{\sum_{i'=1}^n \frac{1}{\sigma_{i'}^2}}} . \quad (13)$$

□

Il faut maintenant proposer des estimateurs de $\sigma_A^2, \sigma_\varepsilon^2$.

1.1 "Type 1" (Anova)

C'est une approche de type *pluggin / moments*.

$$\mathbb{E} \left[\frac{1}{n-J} \sum_{j=1}^J \sum_{i=1}^{n_j} (y_{i,j} - \bar{y}_{:,j})^2 \right] = \sigma_\varepsilon^2 \quad (\text{admis}) \quad (14)$$

(XXX il faut harmoniser les notations avec Anova.tex, somme $i=1..I$, puis de $j = 1..n_1$)

On peut donc proposer :

$$\widehat{\sigma}_\varepsilon^2 = \frac{1}{n-J} \sum_{j=1}^J \sum_{i=1}^{n_j} (y_{i,j} - \bar{y}_{:,j})^2 \quad (15)$$

$$\mathbb{E} \left[\frac{1}{J-1} \sum_{j=1}^J \sum_{i=1}^{n_j} (\bar{y}_{:,j} - \bar{y}_n)^2 \right] = \sigma_\varepsilon^2 + \frac{1}{n(J-1)} \left[n^2 - \sum_{i=1}^J n_j^2 \right] \sigma_A^2 \quad (\text{admis}) \quad (16)$$

Posons :

$$\widehat{S}^2 = \frac{1}{J-1} \sum_{j=1}^J \sum_{i=1}^{n_j} (\bar{y}_{:,j} - \bar{y}_n)^2 \quad (17)$$

On peut prendre comme estimateur (sans biais) de σ_A^2 :

$$\widehat{\sigma}_A^2 = \frac{(\widehat{S}^2 - \widehat{\sigma}_\varepsilon^2)}{n^2 - \sum_{j=1}^J n_j^2} n(J-1) \quad (18)$$

Est ce que cet estimateur est bien défini ?

$$n^2 = \left(\sum_{j=1}^J n_j \right)^2 = \sum_{j=1}^J n_j^2 + a \quad (19)$$

(XXX détailler la valeur explicite de a ci-dessus) donc $n^2 - (\sum n_j)^2 = a > 0$ (Sauf si $n_j = 0$).

Mais il est possible que $\widehat{\sigma}_A^2$ soit négatif, en général on le remplace par 0 dans ce cas. On a donc : $\widehat{\sigma}_A^2 \leftarrow \max(0, \widehat{\sigma}_A^2)$.

b) Maximum de vraisemblance

$$\begin{aligned} \text{Var}(y) &= \text{Var}(\mu + \mathbf{1}_n + ZA + \varepsilon) \\ &= \text{Var}(ZA) + \sigma_\varepsilon^2 + \text{Id}_n \\ &= ZZ^\top \sigma_A^2 + \sigma_\varepsilon^2 \text{Id}_n := V \end{aligned}$$

Ainsi, le vecteur y suit donc une loi gaussienne $y \sim \mathcal{N}(\mu \mathbf{1}_n, V)$: (XXX améliorer le texte ici)

$$\begin{aligned} L(y, \mu, \sigma_\varepsilon^2, \sigma_A^2) &= \frac{1}{(2\pi)^{\frac{n}{2}}} \frac{1}{\det(V)^{\frac{1}{2}}} \exp \left[-\frac{1}{2} [(y - \mathbf{1}_n \mu)^\top V^{-1} (y - \mathbf{1}_n \mu)] \right] \\ -\log(L) &= cte + \frac{1}{2} \log(\det(V)) + \frac{1}{2} (y - \mathbf{1}_n \mu)^\top V^{-1} (y - \mathbf{1}_n \mu) \quad . \end{aligned}$$

Pour trouver l'estimateur du maximum de vraisemblance il faut résoudre :

$$\arg \min_{\mu, \sigma_A^2, \sigma_\varepsilon^2 \in \mathbb{R}} -\log(L(y, \mu, \sigma_\varepsilon^2, \sigma_A^2)) \quad . \quad (20)$$

Optimisation en μ

Remarque 1.2. Calculer $\frac{1}{2}(y - (\mu + \delta)\mathbf{1}_n)^\top V^{-1} (y - (\mu + \delta)\mathbf{1}_n)$ avec $\delta \rightarrow 0$.

$$\begin{aligned} \frac{\partial(-\log L)}{\partial \mu} = 0 &\iff \mathbf{1}_n^\top V^{-1}(\hat{\mu}\mathbf{1}_n - y) = 0 \\ &\iff \hat{\mu}(\mathbf{1}_n^\top V^{-1}\mathbf{1}_n) = \mathbf{1}_n^\top V^{-1}y \\ &\iff \hat{\mu} = \frac{\mathbf{1}_n^\top V^{-1}y}{\mathbf{1}_n^\top V^{-1}\mathbf{1}_n} \quad . \end{aligned}$$

C'est l'estimateur $\hat{\mu}$ qu'on avait proposé avant.

Remarque 1.3. L'optimisation en σ_A^2 et en σ_ε^2 n'admet pas de formule explicite.

1.2 Modélisation linéaire mixte

On va maintenant mélanger effets fixes/effets aléatoires.

$$\begin{aligned} y &= X\beta + ZA + \varepsilon, \quad \text{avec } A \perp\!\!\!\perp \varepsilon \\ &= X\beta + \sum_{j=1}^J Z_j A_j + \varepsilon \quad . \end{aligned}$$

Avec $y \in \mathbb{R}^n, X \in \mathbb{R}^{n \times q}$ et $Z = [Z_1, \dots, Z_J] \in \mathbb{R}^{n \times q}, A = \begin{pmatrix} A_1 \\ A_2 \\ \vdots \\ A_J \end{pmatrix}$, puis pour tout $j \in \llbracket 1, J \rrbracket, A_j \sim \mathcal{N}(0, \sigma_j^2 \text{Id}_{q_j}), \varepsilon \sim \mathcal{N}(0, \sigma_\varepsilon^2 \text{Id}_n), q = q_1 + \dots + q_J, y \sim \mathcal{N}(X\beta, V)$ avec $V \in \mathbb{R}^{n \times n}$ donnée par

$$\begin{aligned} V &= \text{Var}(y) = \text{Var}(\varepsilon) + \text{Var}(ZA) \\ &= \sigma_\varepsilon^2 \text{Id}_n + \sum_{j=1}^J \text{Var}(z_j A_j) \\ &= \sigma_\varepsilon^2 \text{Id}_n + \sum_{j=1}^J \sigma_j^2 Z_j Z_j^\top \quad . \end{aligned}$$

De manière similaire :

$$-\log L(y, \beta, \sigma_\varepsilon^2, \sigma_1^2, \dots, \sigma_J^2) = \text{cst} + \log \det(V) + (y - X\beta)^\top V^{-1} (y - X\beta) \quad . \quad (21)$$

(XXX ajoute du texte ici.)

$$\hat{\beta} = \frac{\partial L}{\partial \beta} = 0 \iff (X^\top V^{-1} X)^{-1} X^\top V^{-1} y \quad (22)$$

Remarque 1.4. On peut utiliser un solveur de type descente "par coordonnées" (ou par bloc) pour obtenir les quantités $\hat{\sigma}_\varepsilon^2, \hat{\sigma}_1^2, \dots, \hat{\sigma}_J^2$ et $\hat{\beta}$ (XXX ajoute du texte ici.)