

# Modèles Linéaires Mixtes

---

Christian Lavergne/ Catherine Trottier

Christian.Lavergne@math.univ-montp2.fr

Catherine.Trottier@math.univ-montp2.fr

web :

<http://www.univ-montp3.fr/miap/~lavergne>

## Le modèle linéaire gaussien à structure de covariance paramétrée et séparable ( $\beta \perp \theta$ )

**Définition**  $Y = X\beta + \epsilon$ , avec  $X$  de dimension  $n \times p$

$\epsilon \sim \mathcal{N}_{\mathbb{R}^N}(0, \Gamma_\theta)$  avec  $\theta$  paramètre inconnu de  $\mathbb{R}^K$ .

**La vraisemblance**

$$f(\beta, \theta; y) = \frac{1}{(2\pi)^{N/2}} |\Gamma_\theta|^{-1/2} \exp\left\{-\frac{1}{2}(y - X\beta)' \Gamma_\theta^{-1} (y - X\beta)\right\}$$

et

$$l(\beta, \theta) = -2 \log(f(\beta, \theta; y))$$

**Cas particulier : le modèle linéaire élémentaire.** Repose sur l'hypothèse d'erreur gaussienne et de structure de covariance  $\sigma_\epsilon^2 \Gamma$  avec  $\Gamma$  connue. Le cas le plus répandu étant  $\Gamma = \text{Id}_n$ .

## Le maximum de vraisemblance dans un modèle linéaire général

### Estimateur du maximum de vraisemblance : ML

$$\hat{\beta}_{ML} = \arg \min_{\beta} ((y - X\beta)' \Gamma_{\theta}^{-1} (y - X\beta))$$

$$\hat{\theta}_{ML} = \arg \min_{\theta} ((y - X\beta)' \Gamma_{\theta}^{-1} (y - X\beta) + \log(|\Gamma_{\theta}|))$$

### Fonction score

$$\begin{aligned} U_{\beta}(\hat{\theta}_{ML}) &= \left. \frac{\partial l(\beta, \theta)}{\partial \beta} \right|_{\theta = \hat{\theta}_{ML}} \\ &= -2 X' \Gamma_{\hat{\theta}_{ML}}^{-1} (y - X\beta) \Big|_{\theta = \hat{\theta}_{ML}} \end{aligned} \quad (1)$$

donc  $\hat{\beta}_{ML} = (X' \Gamma_{\hat{\theta}_{ML}}^{-1} X)^{-1} X' \Gamma_{\hat{\theta}_{ML}}^{-1} y.$

$$\begin{aligned}
U_{\theta}^{ML}(\hat{\beta}_{ML}) &= \left. \frac{\partial l(\beta, \theta)}{\partial \theta} \right|_{\beta=\hat{\beta}_{ML}} \\
&= \left. -(y - X\beta)' \Gamma_{\theta}^{-1} \frac{\partial \Gamma_{\theta}}{\partial \theta} \Gamma_{\theta}^{-1} (y - X\beta) + \text{tr}(\Gamma_{\theta}^{-1} \frac{\partial \Gamma_{\theta}}{\partial \theta}) \right|_{\beta=\hat{\beta}_{ML}} \\
&= -y' P_{\theta} \frac{\partial \Gamma_{\theta}}{\partial \theta} P_{\theta} y + \text{tr}(\Gamma_{\theta}^{-1} \frac{\partial \Gamma_{\theta}}{\partial \theta}) \tag{2}
\end{aligned}$$

où

- $P_{\theta} = \Gamma_{\theta}^{-1} (\text{Id} - X(X' \Gamma_{\theta}^{-1} X)^{-1} X' \Gamma_{\theta}^{-1})$ ,
- $u' A_{\theta} \frac{\partial \Gamma_{\theta}}{\partial \theta} A_{\theta} u =$  est le vecteur de composantes  $[u' A_{\theta} \frac{\partial \Gamma_{\theta}}{\partial \theta_j} A_{\theta} u]_{j=1, \dots, K}$
- resp.  $\text{tr}(A_{\theta} \frac{\partial \Gamma_{\theta}}{\partial \theta}) = [\text{tr}(A_{\theta} \frac{\partial \Gamma_{\theta}}{\partial \theta_j})]_{j=1, \dots, K}$

rappel :  $\frac{\partial \Gamma_{\theta}^{-1}}{\partial \theta_j} = -\Gamma_{\theta}^{-1} \frac{\partial \Gamma_{\theta}}{\partial \theta_j} \Gamma_{\theta}^{-1}$  et  $\frac{\partial \log(|\Gamma_{\theta}|)}{\partial \theta_j} = \text{tr}(\Gamma_{\theta}^{-1} \frac{\partial \Gamma_{\theta}}{\partial \theta_j})$

## Estimation du paramètre de dispersion $\sigma^2$ : cas $\Gamma_\theta = \sigma^2 \mathbf{Id}$

$\widehat{\sigma}^2 = \frac{1}{n-p} \|Y - X\widehat{\beta}\|^2$  est un estimateur sans biais de  $\sigma^2$  .

$$\begin{aligned}\|Y - X\widehat{\beta}\|^2 &= \|Y - X(tXX)^{-1}tXY\|^2 \\ &= \|[Id - X(tXX)^{-1}tX]Y\|^2 = \|MY\|^2 = {}^tY{}^tMMY\end{aligned}$$

Or  $M$  projecteur orthogonal sur  $\mathcal{X}^\perp$  donc :  ${}^tM = M$ ;  $M.M = M$  et  $MX = 0$ .

Donc

$$\|Y - X\widehat{\beta}\|^2 = {}^tYMY = {}^t(X\beta + \epsilon)M(X\beta + \epsilon) = {}^t\epsilon M\epsilon.$$

D'après le lemme :

$$E(\|Y - X\widehat{\beta}\|^2) = E({}^t\epsilon M\epsilon) = \sigma^2 \text{trace}M = \sigma^2(n-p) \bullet$$

## Estimation dans la cas $\text{Var}(\epsilon) = \sigma^2\Gamma$

- $\Gamma$  est une matrice symétrique, définie positive donc diagonalisable et à valeurs propres  $> 0$ .

$$\Gamma = {}^tU\Lambda U \quad \text{avec} \quad {}^tUU = Id$$

Posons  $\sqrt{\Lambda}$  la matrice diagonale des racines carrés des valeurs propres de  $\Gamma$  et le changement de variable  $Z = HY$  avec  $H = \sqrt{\Lambda}^{-1}U$  alors :  $\text{Var}(Z) = \sigma^2\text{Id}$  et on applique au modèle  $Z = HX\beta + \epsilon_z$  les résultats précédents.

## Interprétation géométrique ; propriété de W. Kruskal 1968

$$\hat{\beta} = (X'\Gamma^{-1}X)^{-1}X'\Gamma^{-1}Y = (X'X)^{-1}X'Y$$



l'espace  $\mathcal{X}$  est invariant par l'opérateur  $\Gamma$  ( $\Gamma X = X$ )

$$\hat{\sigma}^2 = \frac{1}{n} \|Y - X\hat{\beta}_{ML}\|_{\Gamma^{-1}}^2 = \frac{1}{n} \|Y - X\hat{\beta}_{Id}\|^2$$



les espaces  $\mathcal{X}$  et  $\mathcal{X}^\perp$  sont invariants par l'opérateur  $\Gamma$

## Théorème de Kruskal, démonstration

Les deux estimateurs  $\hat{\beta}_{\text{Id}}$  et  $\hat{\beta}_{\Gamma^{-1}}$  sont identiques si et seulement si  $\mathcal{X}$  est invariant par la matrice  $\Gamma$ .

$\hat{\beta}_{\text{Id}}$  est définie par :  $\langle y - X\hat{\beta}_{\text{Id}}, z \rangle_{\text{Id}} = 0, \forall z \in \mathcal{X};$

$\hat{\beta}_{\Gamma^{-1}}$  est définie par :  $\langle y - X\hat{\beta}_{\Gamma^{-1}}, z \rangle_{\Gamma^{-1}} = \langle y - X\hat{\beta}_{\Gamma^{-1}}, \Gamma^{-1}z \rangle_{\text{Id}} = 0.$

De plus  $\mathcal{X}$  invariant par la matrice  $\Gamma$  (ou  $\Gamma$  inv.)

$$\Leftrightarrow \Gamma\mathcal{X} = \mathcal{X} \Leftrightarrow \Gamma^{-1}\mathcal{X} = \mathcal{X} \Leftrightarrow \Gamma^{-1}z \in \mathcal{X}, \forall z \in \mathcal{X}.$$

a)  $\hat{\beta}_{\text{Id}} = \hat{\beta}_{\Gamma^{-1}} \Rightarrow \langle y - X\hat{\beta}_{\text{Id}}, \Gamma^{-1}z \rangle_{\text{Id}} = 0$ , donc  $\Gamma^{-1}z \in \mathcal{X}, \forall z \in \mathcal{X}.$

b)  $\mathcal{X}$  est invariant par  $\Gamma$  (ou  $\Gamma^{-1}$ ) alors la condition sur  $\hat{\beta}_{\Gamma^{-1}}$  :

$\langle y - X\hat{\beta}_{\Gamma^{-1}}, \Gamma^{-1}z \rangle_{\text{Id}} = 0$  se transforme en :  $\langle y - X\hat{\beta}_{\Gamma^{-1}}, z \rangle_{\text{Id}} = 0.$

De par l'unicité  $\hat{\beta}_{\text{Id}} = \hat{\beta}_{\Gamma^{-1}}.$

## Matrice d'information :

Posons  $\gamma = (\beta, \theta)$  et

$$\mathcal{I}_{\beta, \theta} = E_{\beta, \theta} \left[ -\frac{\partial^2 \log f(\beta, \theta; y)}{\partial \gamma \partial \gamma'} \right]$$

alors

$$\mathcal{I}_{\beta, \theta} = E_{\beta, \theta} \left[ \frac{1}{2} \frac{\partial^2 l(\beta, \theta)}{\partial \gamma \partial \gamma'} \right] = E_{\beta, \theta} \left[ \frac{1}{2} \begin{pmatrix} \frac{\partial U_{\beta}}{\partial \beta'} & \frac{\partial U_{\beta}}{\partial \theta'} \\ \frac{\partial U_{\theta}^{ML}}{\partial \beta'} & \frac{\partial U_{\theta}^{ML}}{\partial \theta'} \end{pmatrix} \right].$$

On vérifie aisément que  $\frac{\partial U_{\beta}}{\partial \beta'} = 2 X' \Gamma_{\theta}^{-1} X$  et que  $E_{\beta, \theta} \left[ \frac{\partial U_{\beta}}{\partial \theta'} \right] = 0$ .

D'autre part :

$$\begin{aligned} \left[ \frac{\partial U_{\theta}^{ML}}{\partial \theta'} \right]_{ij} &= \text{tr}(\Gamma_{\theta}^{-1} \left( \frac{\partial^2 \Gamma_{\theta}}{\partial \theta_i \partial \theta_j} - \frac{\partial \Gamma_{\theta}}{\partial \theta_i} \Gamma_{\theta}^{-1} \frac{\partial \Gamma_{\theta}}{\partial \theta_j} \right)) \\ &\quad - (y - X\beta)' \Gamma_{\theta}^{-1} \left( \frac{\partial^2 \Gamma_{\theta}}{\partial \theta_i \partial \theta_j} - 2 \frac{\partial \Gamma_{\theta}}{\partial \theta_i} \Gamma_{\theta}^{-1} \frac{\partial \Gamma_{\theta}}{\partial \theta_j} \right) \Gamma_{\theta}^{-1} (y - X\beta) \end{aligned}$$

Donc

$$\mathcal{I}_{\beta, \theta} = \begin{pmatrix} \mathcal{I}_{\beta} = X' \Gamma_{\theta}^{-1} X & 0 \\ 0 & \mathcal{I}_{\theta}^{ML} = \left[ \frac{1}{2} \text{tr}(\Gamma_{\theta}^{-1} \frac{\partial \Gamma_{\theta}}{\partial \theta_i} \Gamma_{\theta}^{-1} \frac{\partial \Gamma_{\theta}}{\partial \theta_j}) \right]_{i,j=1,\dots,K} \end{pmatrix}$$

## Le maximum de vraisemblance restreint : REML

**La vraisemblance restreinte** : c'est la vraisemblance marginale après intégration sur  $\beta$

$$f_{RE}(\theta; y) = \frac{1}{(2\pi)^{(N-p)/2}} |\Gamma_\theta|^{-1/2} |X' \Gamma_\theta^{-1} X|^{-1/2} \exp\left\{-\frac{1}{2} y' P_\theta y\right\}$$

et

$$l_{RE}(\theta) = -2 \log(f_{RE}(\theta; y))$$

## Estimateur maximum de vraisemblance restreinte

$$\hat{\theta}_{REML} = \arg \min_{\theta} (y' P_\theta y + \log(|\Gamma_\theta|) + \log(|X' \Gamma_\theta^{-1} X|))$$

## Fonction score

$$\begin{aligned} U_{\theta}^{REML} &= \frac{\partial l_{RE}(\theta)}{\partial \theta} \\ &= -y' P_{\theta} \frac{\partial \Gamma_{\theta}}{\partial \theta} P_{\theta} y + \text{tr}(\Gamma_{\theta}^{-1} \frac{\partial \Gamma_{\theta}}{\partial \theta}) \\ &\quad - \text{tr}((X' \Gamma_{\theta}^{-1} X)^{-1} X' \Gamma_{\theta}^{-1} \frac{\partial \Gamma_{\theta}}{\partial \theta} \Gamma_{\theta}^{-1} X) \\ &= -y' P_{\theta} \frac{\partial \Gamma_{\theta}}{\partial \theta} P_{\theta} y + \text{tr}(P_{\theta} \frac{\partial \Gamma_{\theta}}{\partial \theta}) \end{aligned} \tag{3}$$

et  $\hat{\beta}_{REML}$  est solution de l'équation  $U_{\beta}(\hat{\theta}_{REML}) = 0$ .

## Matrice d'information associée au vecteur $y$

Posons

$$\mathcal{I}_\theta^{REML} = E_\theta \left[ -\frac{\partial^2 \log f_{RE}(\theta; y)}{\partial \theta \partial \theta'} \right]$$

alors

$$\mathcal{I}_\theta^{REML} = E_\theta \left[ \frac{1}{2} \frac{\partial^2 l_{RE}(\theta)}{\partial \theta \partial \theta'} \right] = E_\theta \left[ \frac{1}{2} \frac{\partial U_\theta^{REML}}{\partial \theta'} \right].$$

Un calcul similaire au cas précédent

$$\mathcal{I}_\theta^{REML} = \left[ \frac{1}{2} \text{tr} \left( P_\theta \frac{\partial \Gamma_\theta}{\partial \theta_i} P_\theta \frac{\partial \Gamma_\theta}{\partial \theta_j} \right) \right]_{i,j=1,\dots,K}$$

## Remarque :

- En résumé :

$\hat{\theta}_{ML}$  est donc solution de la minimisation du critère :

$$\text{CritèreML} = y'P_{\theta}y + \log(|\Gamma_{\theta}|) ;$$

$\hat{\theta}_{REML}$  est solution de la minimisation du critère :

$$\text{CritèreREML} = \text{CritèreML} + \log(|X'\Gamma_{\theta}^{-1}X|)$$

et  $\hat{\beta}_{\cdot} = (X'\Gamma_{\hat{\theta}_{\cdot}}^{-1}X)^{-1}X'\Gamma_{\hat{\theta}_{\cdot}}^{-1}y$ .

- Remarquant que  $E_{\theta}(P_{\theta}y) = 0$  et  $P_{\theta}\Gamma_{\theta}P_{\theta} = P_{\theta}$  alors

$$E_{\theta}(y'P_{\theta}\frac{\partial\Gamma_{\theta}}{\partial\theta}P_{\theta}y) = \text{tr}(P_{\theta}\frac{\partial\Gamma_{\theta}}{\partial\theta}).$$

La fonction score  $U_{\theta}^{REML}$  est donc une statistique centrée contrairement à la fonction score  $U_{\theta}^{ML}$ .

**Critères de choix de modèles.** Les critères d'informations que l'on cherche à minimiser sont construits sur la log-vraisemblance en  $\hat{\beta}$  et  $\hat{\theta}_{ML}^2$  notée  $\mathcal{L}(\mathcal{M})$ . On désigne par  $q(\mathcal{M})$  le nombre de paramètres estimés dans le modèle ( $q(\mathcal{M}) = p + K$ ).

AIC : Akaike Information Criterium

$$-2\mathcal{L}(\mathcal{M}) + 2 * q(\mathcal{M})$$

BIC : Bayesian Information Criterium

$$-2\mathcal{L}(\mathcal{M}) + \ln(n) * q(\mathcal{M})$$