

Modèles Linéaires à Effets Mixtes

Pr Roch Giorgi

 roch.giorgi@univ-amu.fr

SESSTIM, Faculté de Médecine, Aix-Marseille Université, Marseille, France

<http://sesstim-orspaca.org>

<http://optim-sesstim.univ-amu.fr/>

Exemple Introductif (1)

- Etude de 15 visages de blancs et 15 visages de noirs
- Critère de jugement : échelle de -20 à +20
- 30 individus sollicités
- Question
 - ✓ Y a-t-il une différence dans la valeur du critère de jugement selon le visage ?
- Comment analyser ces données ?
 - ✓ Pour chaque individus, calcul du score de différence
 - ✓ Régression sur le score de différence

Exemple Introductif (2)

$$y_i = \alpha_0 + \varepsilon_i$$

y_i = score de différence de l'individu i

α_0 = intercept du modèle

ε_i = résidus de l'individu i

- Modèle linéaire simple
- Élimine problème de non-indépendance des résidus
- Fonction dans R
 - ✓ `lm(y ~ 1, data)`

Exemple Introductif (3)

- Remarques
 - ✓ Similaire à une ANOVA intra à 2 modalités
 - ✓ Faible possibilité de généraliser
 - Plus de 2 mesures ?
 - Effets individuels ?
- Autre solution statistique
 - ✓ Modéliser / Estimer les sources de non-indépendance (variabilité)
 - ⇒ Modèle mixte

Modèle Linéaire (1)

$$Y_i = \beta X_i + \varepsilon_i$$

$Y_i = n \times 1$ mesures du sujet i (continue)

$X_i = n \times p$ matrice de vecteur de covariables

$\beta = p \times 1$ paramètres pour les covariables


$\varepsilon_i = n \times 1$ résidus de l'individu i

- Hypothèses

- ✓ Observations indépendantes entre les sujets
- ✓ Observations non-indépendantes pour un même sujet
- ✓ Y suit une loi Normale de variance-covariance Σ constante pour tout X (homoscédasticité) : $\text{Var}(\varepsilon_i) = \sigma^2$

Modèle Linéaire (2)

Modèle linéaire



A $t=0$, il y a un point de départ moyen.
Le même pour tous les sujets

Modèle Linéaire – Estimation (1)

$$\text{Min}_{\beta} \sum_{i=1}^n \left[y_i - \sum_{k=1}^p \beta_k x_{ik} \right]^2$$

- Moindres carrés ordinaires : observations indépendantes

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

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

Indépendance des observation

$$\text{var}(\hat{\beta}) = \sigma_{\varepsilon}^2 (X'X)^{-1} \text{ meilleur estimateur linéaire non biaisé}$$

Modèle Linéaire – Estimation (2)

$$\text{Min}_{\beta} \sum_{i=1}^n \left[y_i - \sum_{k=1}^p \beta_k x_{ik} \right]^2$$

- Moindres carrés généralisés : observations non-indépendantes

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

$$\text{var}(\hat{\beta}) = (X' \Sigma^{-1} X)^{-1}$$

où

$\text{var}(Y) = \Sigma$ a une structure reflétant la corrélation

Modèle Linéaire

- Ne permet pas de modéliser de manière appropriée l'évolution d'une mesure au cours du temps (>2)
- Ne prend pas en compte variabilité individuelle
 - ✓ Par rapport à l'évolution moyenne
 - ✓ Selon le(s) facteur(s) étudié(s)
 - ✓ Au niveau des résidus

Modèle Mixte – Principe (1)

1. Existence d'effets identiques pour tous les sujets de la population (tendance moyenne)
2. Chaque sujet a un certain niveau de réponse par rapport à la population

- ✓ Avec 2 sources de variations aléatoires
 - Entre les sujets
 - Variation des mesures par sujet

1. Effets fixes

2. Effets aléatoires

- ✓ Permettent d'explicitier les différences entre les individus (les corrélations) sans observer les déterminants de cette variabilité interindividuelle

Modèle Mixte – Principe (2)

- Effets fixes
 - ✓ Effet d'une variable dont les niveaux peuvent être reproduits et forment un ensemble fini
- Effets aléatoires
 - ✓ Effet d'une variable dont les niveaux sont échantillonnés aléatoirement à partir d'une population plus importante

Modèle Mixte *vs* MANOVA

- Modélisation explicite du changement individuel au cours du temps
- Nombre de mesures différents par sujet
- Temps de mesures différents par sujet
- Temps continu
- Spécification flexible de la structure de covariance
- Covariables dépendantes ou non du temps
- Données manquantes
- Domaine des modèles multi-niveaux
- ...

Modèle Mixte – Formulation (1)

$$Y_i = \beta X_i + \gamma_i Z_i + \varepsilon_i$$

$Y_i = n_i \times 1$ mesures du sujet i (continue)

$X_i = n_i \times p$ matrice de vecteur pour les effets fixes

$\beta = p \times 1$ paramètres pour les effets fixes

$Z_i = n_i \times p$ matrice de vecteur pour les effets aléatoires

$\gamma_i = r \times 1$ paramètres pour les effets aléatoires

$\varepsilon_i = n_i \times 1$ résidus de l'individu i

Modèle Mixte – Formulation (2)

Evolution moyenne au
cours du temps

Déviations individuelles par
rapport à la moyenne

$$Y_i = \beta X_i + \gamma_i Z_i + \varepsilon_i$$

« Vraie valeur » (non observée)
dépourvue d'erreur de mesure

Modèle Mixte – Hypothèses (1)

$$Y_i = \beta X_i + \gamma_i Z_i + \varepsilon_i$$

Effets aléatoires et erreurs sont indépendants d'un sujet à l'autre

$$\gamma_i \perp \gamma_j, \forall i, j = 1, \dots, N$$

$$\varepsilon_i \perp \varepsilon_j, \forall i, j = 1, \dots, N$$

Erreurs sont indépendantes d'une mesure à l'autre chez un même sujet

$$\varepsilon_{ij} \perp \varepsilon_{ik}, \forall j, k = 1, \dots, n_i$$

Modèle Mixte – Hypothèses (2)

$$Y_i = \beta X_i + \gamma_i Z_i + \varepsilon_i$$

Effets aléatoires γ_i non estimés

$$\gamma_i \sim N(0, \Sigma_\gamma)$$

Erreur de mesure indépendante pour chaque observation

$$\varepsilon_i \sim N(0, \Sigma_i)$$

Estimation

- Conditionnellement au vecteur des effets aléatoires γ_i les mesures répétées sont indépendantes entre elles
- En supposant l'indépendance entre les sujets
- Ecriture de la vraisemblance du modèle
- Estimation du modèle (fixe, aléatoire) par la méthode du maximum de vraisemblance
 - ✓ Existe d'autres possibilités

Prédictions – Résidus

- Effets aléatoires individuels peuvent être estimés
- Marginalement aux effets aléatoires
 - ✓ Prédictions $\hat{Y}_i = E(Y) = \hat{\beta}X_i$
 - ✓ Résidus $Y - \hat{\beta}X_i$
- Spécifiquement aux effets aléatoires
 - ✓ Prédictions $\hat{Y}_i|\hat{\gamma}_i = E(Y|\hat{\gamma}_i) = \hat{\beta}X_i + \hat{\gamma}_iZ_i$
 - ✓ Résidus $Y_i - \hat{\beta}X_i - \hat{\gamma}_iZ_i$

Remarques

- Prédiction individuelle
 - ✓ Permet de repérer individus particuliers (écart entre profils individuels et profil moyen)
- Tests / Comparaisons de modèles
 - ✓ Rapport de vraisemblance, si modèles emboîtés

Modèle Mixte à Intercept Aléatoire (1)

Modèle linéaire

$$Y_i = \beta X_i + \varepsilon_i \Rightarrow y_i = \beta_0 + \beta t_i + \varepsilon_i \text{ avec } \varepsilon_i \sim N(0, \sigma^2)$$

$$y_i = (\beta_0 + \gamma_{0i}) + \beta t_i + \varepsilon_i$$


$$\varepsilon_i \sim N(0, \sigma^2)$$

$$\gamma_{0i} \sim N(0, \sigma_{\gamma_0}^2)$$

- 👉 β_0 et β = effets fixes
- γ_{0i} = effets aléatoires
- ε_i = résidus de l'individu i

- 👉 $\beta_0, \beta, \sigma, \text{ et } \sigma_{\gamma_0}$ sont à estimer

Modèle Mixte à Intercept Aléatoire (2)



A $t=0$, il y a un point de départ moyen de β_0
Chaque sujet peut varier de $\gamma_{0i} \sim N(0, \sigma_{\gamma_0}^2)$
sans déviation par rapport à l'évolution moyenne

Modèle Mixte à Pente Aléatoire (1)

Modèle linéaire

$$Y_i = \beta X_i + \varepsilon_i \Rightarrow y_i = \beta_0 + \beta t + \varepsilon_i \quad \text{avec} \quad \varepsilon_i \sim N(0, \sigma^2)$$

$$y_i = \beta_0 + (\beta + \gamma_i) t_i + \varepsilon_i$$


$$\varepsilon_i \sim N(0, \sigma^2)$$

$$\gamma_i \sim N(0, \sigma_\gamma^2)$$

- 👉 β_0 et β = effets fixes
- γ_i = effets aléatoires
- ε_i = résidus de l'individu i

- 👉 $\beta_0, \beta, \sigma, \text{ et } \sigma_\gamma$ sont à estimer

Modèle Mixte à Pente Aléatoire (2)



A $t=0$, il y a un point de départ moyen de β_0
qui est le même pour tous les sujets

L'évolution de chaque sujet peut varier de $\gamma_i \sim N(0, \sigma_\gamma^2)$
avec une déviation par rapport à l'évolution moyenne

Modèle Mixte à Intercept et Pente Aléatoire

Modèle linéaire

$$Y_i = \beta X_i + \varepsilon_i \Rightarrow y_i = \beta_0 + \beta t + \varepsilon_i \quad \text{avec} \quad \varepsilon_i \sim N(0, \sigma^2)$$

$$y_i = (\beta_0 + \gamma_{0i}) + (\beta + \gamma_i)t_i + \varepsilon_i$$

$$\varepsilon_i \sim N(0, \sigma^2)$$

$$\gamma_i \sim N(0, \sigma_\gamma^2) \quad \gamma_{0i} \sim N(0, \sigma_{\gamma_0}^2)$$

👉 β_0 et β = effets fixes
 γ_{0i} et γ_i = effets aléatoires
 ε_i = résidus de l'individu i

👉 $\beta_0, \beta, \sigma,$ et σ_γ sont à estimer

Effets Fixes : Interprétation

$$y_i = (\beta_0 + \gamma_{0i}) + (\beta + \gamma_i)t_i + \varepsilon_i$$

$$y_i = \underbrace{\beta_0 + \beta t_i}_{\text{effets fixes}} + \underbrace{\gamma_{0i} + \gamma_i t_i + \varepsilon_i}_{\text{effets aléatoires}}$$

- β_0 = Intercept (valeur estimée à $t=0$) ; niveau moyen
- β = Pente (changement de l'estimation quand augmentation d'une unité)
- Tout 2 peuvent être testés
 - ✓ $H_0 : \beta_0 = 0$
 - ✓ $H_0 : \beta = 0$

Effets Aléatoires : Interprétation

$$y_i = (\beta_0 + \gamma_{0i}) + (\beta + \gamma_i)t_i + \varepsilon_i$$

$$y_i = \underbrace{\beta_0 + \beta t_i}_{\text{effets fixes}} + \underbrace{\gamma_{0i} + \gamma_i t_i + \varepsilon_i}_{\text{effets aléatoires}}$$

- Pas d'estimation des paramètres
- Estimation de la variance des effets aléatoires
 - ✓ Pour l'intercept γ_{0i}
 - ✓ Pour la pente γ_i
 - ✓ Pour l'erreur résiduelle ε_i

Exemple : Orthodont

- Evolution de mesures orthodontic au cours du temps chez des enfants
- Mesure tous les 2 ans entre 8 et 14 ans de la distance (en millimètre, sur cliché radio) entre l'hypophyse et la fente pterygomaxillaire
- *Source : package `n1me` de R*

Descriptif (1)

```
> with(Orthodont, tapply(distance, age, summary))
```

```
$`8`
```

Min.	1st Qu.	Median	Mean	3rd Qu.	Max.
16.50	21.00	22.00	22.19	23.25	27.50

```
$`10`
```

Min.	1st Qu.	Median	Mean	3rd Qu.	Max.
19.00	21.50	23.00	23.17	24.50	28.00


```
$`12`
```

Min.	1st Qu.	Median	Mean	3rd Qu.	Max.
19.00	23.00	24.00	24.65	26.00	31.00

```
$`14`
```

Min.	1st Qu.	Median	Mean	3rd Qu.	Max.
19.50	25.00	26.00	26.09	27.75	31.50

Descriptif (2)



Modèle Mixte (lme)

$$y_i = \underbrace{\beta_0 + \beta t_i}_{\text{effets fixes}} + \underbrace{\gamma_{0i} + \gamma_i t_i}_{\text{effets aléatoires}} + \varepsilon_i$$

`lme(distance ~ 1 + agec,`

`random= ~ 1 + agec | Subject, data=Orthodont)`

Identique à

`lme(distance ~ agec, random=~ agec | Subject, data=Orthodont)`

Remarque : agec âge centré sur âge médian (11 ans)

Résultats (lme) (1)

```
> summary(lme1)
```

```
Linear mixed-effects model fit by REML
```

Méthode d'estimation

```
Data: Orthodont
```

	AIC	BIC	logLik
	454.6367	470.6173	-221.3183

```
Random effects:
```

```
Formula: ~agec | Subject
```

```
Structure: General positive-definite, Log-Cholesky  
parametrization
```

	StdDev	Corr
(Intercept)	2.1343289	(Intr)
agec	0.2264278	0.503
Residual	1.3100402	

```
...
```

Résultats (lme) (2)

```
> summary(lme1)
```

```
Linear mixed-effects model fit by REML
```

```
Data: Orthodont
```

AIC	BIC	logLik
454.6367	470.6173	-221.3183

Indices d'ajustement du modèle

```
Random effects:
```

```
Formula: ~agec | Subject
```

```
Structure: General positive-definite, Log-Cholesky  
parametrization
```

	StdDev	Corr
(Intercept)	2.1343289	(Intr)
agec	0.2264278	0.503
Residual	1.3100402	

```
...
```

Résultats (lme) (3)

```
> summary(lme1)
```

```
Linear mixed-effects model fit by REML
```

```
Data: Orthodont
```

```
          AIC          BIC      logLik
454.6367  470.6173 -221.3183
```

Random effects: Effets aléatoires

```
Formula: ~agec | Subject
```

```
Structure: General positive-definite, Log-Cholesky
parametrization
```

	StdDev	Corr
(Intercept)	2.1343289	(Intr)
agec	0.2264278	0.503
Residual	1.3100402	

Déviation standards estimées
des effets aléatoires σ .
(les moyennes = 0)

→ *Intercept*

→ *Pente*

→ *Résiduelle*

≠ ajustements appliqués aux
observations γ_{0i}, γ_i

Résultats (lme) (4)

```
> ranef(fm1)
```

	(Intercept)	age
M16	0.1888889	-0.11018519
M05	-3.1111111	0.18981481
M02	-1.9111111	0.11481481
M11	3.2888889	-0.33518519
M07	-1.8111111	0.13981481
...

ajustements appliqués aux observations γ_{0i}, γ_i
(Best Linear Unbiased Predictors BLUPS)

Pour observation M11, ajustement pour
intercept pente

Résultats (lme) (5)

```
> summary(lme1)
```

```
Linear mixed-effects model fit by REML
```

```
Data: Orthodont
```

	AIC	BIC	logLik
	454.6367	470.6173	-221.3183

```
Random effects:
```

```
Formula: ~agec | Subject
```

```
Structure: General positive-definite, Log-Cholesky  
parametrization
```

	StdDev	Corr
(Intercept)	2.1343289	(Intr)
agec	0.2264278	0.503
Residual	1.3100402	

**Corrélacion entre l'intercept
aléatoire et la pente aléatoire**

```
...
```

Résultats (lme) (6)

```
> summary(lme1)
```

```
...
```

```
Fixed effects: distance ~ agec Effets fixes
```

	Value	Std.Error	DF	t-value	p-value
(Intercept)	24.023148	0.4296601	80	55.91198	0
agec	0.660185	0.0712533	80	9.26533	0

```
Correlation:  
(Intr)  
agec 0.294
```

Prédiction pour une valeur 0 de agec
Pente : changement de la prédiction quand agec augmente de 1 unité

```
Standardized Within-Group Residuals:
```

Min	Q1	Med	Q3	Max
-3.22310	-0.49376	0.00731	0.47215	3.91603

```
Number of Observations: 108
```

```
Number of Groups: 27
```

Résultats (lme) (7)

```
> summary(lme1)
```

```
...
```

```
Fixed effects: distance ~ agec
```

	Value	Std.Error	DF	t-value	p-value
(Intercept)	24.023148	0.4296601	80	55.91198	0
agec	0.660185	0.0712533	80	9.26533	0

```
Correlation:
```

```
(Intr)
```

```
agec 0.294
```

↑
Test de l'effet de agec

```
Standardized Within-Group Residuals:
```

Min	Q1	Med	Q3	Max
-3.22310	-0.49376	0.00731	0.47215	3.91603

```
Number of Observations: 108
```

```
Number of Groups: 27
```

Résultats (lme) (8)

- Test des effets aléatoires : modèle à intercept et pente aléatoires versus
 - ✓ Modèle sans intercept
 - ✓ Modèle sans effet pente
- Comparés par une ANOVA

```
> # Test des effets aléatoires : intercept
> lme.1b <- update(lme1, random=~ -1 + agec|Subject)
> anova(lme1, lme.1b)
```

	Model	df	AIC	BIC	logLik	Test	L.Ratio	p-value
lme1	1	6	454.6367	470.6173	-221.3183			
lme.1b	2	4	517.1695	527.8233	-254.5848	1 vs 2	66.53281	<.0001

```
> # Test des effets aléatoires : pente
> lme.1a <- update(lme1, random=~ 1|Subject)
> anova(lme1, lme.1a)
```

	Model	df	AIC	BIC	logLik	Test	L.Ratio	p-value
lme1	1	6	454.6367	470.6173	-221.3183			
lme.1a	2	4	455.0025	465.6563	-223.5013	1 vs 2	4.36583	0.1127

Extension : Modèle Linéaire → Généralisé (1)

- Modèle linéaire

$$Y_i = \beta X_i + \varepsilon_i$$

ou $E(Y_i) = \mu_i = \beta X_i$

- Modèle linéaire généralisé (GLM)

$$g(E(Y_i)) = g(\mu_i) = \beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip} = \beta X_i$$

où g est appelée fonction de lien

partie droite de l'équation : prédicteur linéaire

Source : E. Cantoni. Colloque d'Epidémiologie Clinique et Biostatistique. 9 Juin 2009

Extension : Modèle Linéaire → Généralisé (2)

- Hypothèses
 - ✓ Y_i suit une distribution discrète ou continue dans la « famille exponentielle »
 - ✓ Distributions : binomiale, Poisson, exponentielle, Gamma
 - ✓ avec $E(Y_i) = \mu_i$ et $Var(Y_i) = \nu(\mu_i)$
- Estimation
 - ✓ Maximum de vraisemblance
- Inférence basée sur la vraisemblance (ou déviance)
 - ✓ Distribution asymptotique de l'estimateur (et donc de la variance)
 - ✓ Comparaison de modèles emboîtés (LRT)
 - ✓ Critère d'Akaike (AIC)

Source : E. Cantoni. Colloque d'Epidémiologie Clinique et Biostatistique. 9 Juin 2009

GLM pour Réponses Binaires

- Si $Y_i = 0$ ou 1
- Alors $E(Y_i) = \mu_i = p_i = P(Y_i = 1)$

$$Var(Y_i) = p_i(1 - p_i)$$

- Différentes possibilités pour g

Lien logit	$\ln\left(\frac{p_i}{1-p_i}\right) = \beta X_i$
Lien probit	$\phi(p_i) = \beta X_i$
Lien c-loglog	$\log(-\log(1-p_i)) = \beta X_i$

- Si Y_i est $Bin(n_i, p_i)$, on travaille avec les proportions Y_i/n_i

Source : E. Cantoni. Colloque d'Epidémiologie Clinique et Biostatistique. 9 Juin 2009

GLM pour Réponses Poisson

- Si $Y_i \sim P(\lambda_i)$
- Alors $E(Y_i) = \lambda_i$
 $Var(Y_i) = \lambda_i$
- Fonction de lien logarithmique $g : \log(\lambda_i) = \beta X_i$

Source : E. Cantoni. Colloque d'Epidémiologie Clinique et Biostatistique. 9 Juin 2009

GLM pour Réponses Gamma

- Si $Y_i \sim \text{Gamma}(\mu_i, \phi)$
- Alors $E(Y_i) = \mu_i$
$$\text{Var}(Y_i) = \mu_i^2 / \phi$$
- Fonction de lien logarithmique $g : \log(\lambda_i) = \beta X_i$

Source : E. Cantoni. Colloque d'Epidémiologie Clinique et Biostatistique. 9 Juin 2009

Modèle Linéaire Mixte Généralisé (1)

- Modèle linéaire mixte

$$Y_i = \beta X_i + \gamma_i Z_i + \varepsilon_i$$

- ✓ γ_i indépendants selon $N(0, \Sigma_\gamma)$
- ✓ $Y_i | \gamma_i$ indépendants selon une distribution de la famille exponentielle
- ✓ Avec $E(Y_i | \gamma_i) = \mu_i$ et $Var(Y_i | \gamma_i) = \phi v(\mu_i)$

- Modèle linéaire mixte généralisé (GLMM)

$$g(E(Y_i | \gamma_i)) = g(\mu_i) = \beta X_i + \gamma_i Z_i$$

où g est appelée fonction de lien

Source : E. Cantoni. Colloque d'Epidémiologie Clinique et Biostatistique. 9 Juin 2009

Modèle Linéaire Mixte Généralisé (2)

- Les effets aléatoires sont inclus dans le prédicteur linéaire
- Inférence/Interprétation de type spécifique aux sujets
- Nécessite l'utilisation de routines d'optimisation non-linéaire et d'algorithmes d'intégration numérique pour ajuster ces modèles

GLMM avec R

- Fonction `glmer` du package `lme4` de R

```
glmer(formula, data, family)
```

↓
Contient la partie aléatoire (...|...)

↓
Binomial, gaussian, poisson,...

Sources

- Pinheiro JC, Bates DM. Mixed-effects models in S and S-Plus. Springer 2000.
- Cantoni E. Modèles de régression pour variables réponses discrètes et continues asymétriques. Colloque d'Epidémiologie Clinique et Biostatistique. 9 Juin 2009 (www.unige.ch/ses/metri/cantoni)