

Analyse du modèle à 1 effet aléatoire

①

$$Y_{ij} = \mu + A_i + E_{ij}$$

$$i = 1, I$$

$$j = 1, n_i$$

$$A_i \sim N(0, \sigma_A^2)$$

$$E_{ij} \sim N(0, \sigma_E^2)$$

→ $n_i = \text{cte}$: équilibré (balanced) $\left\{ \begin{array}{l} A_i \perp E_{ij} \\ E_{ij} \text{ iid.} \end{array} \right.$

→ $n_i \neq \text{cte}$.

→ Modèle le plus simple dans lequel on peut faire "tous" les calculs.

- Objectifs:
- estimer μ : OLS? GLS?
 - estimer σ_A^2, σ_E^2 : ANOVA, LM, REML?
 - "estimer" / prédire A_i
 - tester l'effet aléatoire.

Notations Matricielles :

$\mathbf{1}_n =$ vecteur $(n \times 1)$ rempli de 1 : $\mathbf{J}_n = \mathbf{1}_n \mathbf{1}_n'$

Produit Tensoriel : $A \otimes B = \begin{bmatrix} a_{11} B & \dots & a_{1c} B \\ \vdots & & \vdots \\ a_{n1} B & \dots & a_{nc} B \end{bmatrix}$
 $A = (a_{ij})_{\substack{i=1, \dots, n \\ j=1, \dots, c}}$


Somme directe : $A \oplus B = \begin{bmatrix} A & 0 \\ 0 & B \end{bmatrix}$

Identités utiles :

$$\begin{cases} (A \otimes B)' = A' \otimes B' \\ (A \otimes B)^{-1} = (A^{-1}) \otimes (B^{-1}) \\ \text{tr}(A \otimes B) = \text{tr}(A) \text{tr}(B) \end{cases}$$

• Pour les individus du niveau i

$$Y_i = \begin{bmatrix} Y_{i1} \\ \vdots \\ Y_{in_i} \end{bmatrix} = \mu \times \mathbf{1}_{n_i} + \mathbf{1}_{n_i} \times A_i + E_i$$



$$\begin{bmatrix} \mathbb{1}_{m_2} & 0 \\ 0 & \mathbb{1}_{m_I} \end{bmatrix} = \left[\text{Id}_I \otimes \mathbb{1}_{n_i} \right]$$

$$\hookrightarrow Y = \mathbb{1}_N \mu + \left[\text{Id}_I \otimes \mathbb{1}_{m_i} \right]_i \cdot A + E$$

$$Y = X\mu + ZA + E$$

→ Si on considère les A comme des paramètres

$$\beta = [\mu, A_1, \dots, A_I]$$

$$X = \begin{bmatrix} \mathbb{1}_N & \mathbb{1}_{m_2} & \dots & \mathbb{1}_{m_I} \end{bmatrix} = \begin{bmatrix} X_\mu & X_A \end{bmatrix}$$

↑ design μ
↑ design A_i

$$Y = X\beta + E$$

↳ écriture "classique" mais pas homosédastique

$$\rightarrow V(Y) = V(X\beta + E) = V(ZA + E) = ZV(A)Z' + V(E)$$

$$= \sigma_A^2 \left\{ \mathbb{J}_{m_i} \right\}_i + \sigma^2 \left\{ \text{Id}_{m_i} \right\}_i$$

Corrélation intra bloc

$$\rightarrow \text{le "Bloc" } i = \begin{bmatrix} \sigma_A^2 + \sigma_E^2 & & \\ & \sigma_A^2 & \\ \sigma_A^2 & & \sigma_A^2 + \sigma_E^2 \end{bmatrix}$$

variance totale

Estimation du paramètre d'espérance.

(4)

On est dans le cas $Y = X\beta + \varepsilon$, $V(Y) = V$

on suppose V connue. et $\beta = \mu \Rightarrow$ un seul paramètre d'espérance.

Rappel: Estimateur OLS: $S(\beta) = \|Y - X\beta\|^2$

On choisit $\hat{\beta}$ qui minimise $S(\beta)$.

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

↳ GLS: Generalized Least Square.

↳ On généralise l'approche OLS au cas V connue.

$$S(\beta) = \|Y - X\beta\|_{V^{-1}}^2$$

$$\hat{\beta}_{GLS} = (X'V^{-1}X)^{-1} X'V^{-1}Y.$$

Idee: on "normalise" les résidus, $V^{-1/2}Y = V^{-1/2}X\beta + V^{-1/2}\varepsilon$

$$\tilde{Y} = V^{-1/2}Y$$

$$\tilde{X} = V^{-1/2}X$$

$$\tilde{\varepsilon} = V^{-1/2}\varepsilon$$

$$\tilde{Y} = \tilde{X}\beta + \tilde{\varepsilon}$$

→ V est une matrice de variance symétrique semi-définie positive \Rightarrow On peut la diagonaliser

Rappel sur l'estimateur OLS.

(4) bis.

$$S(\beta) = \|Y - E(Y)\|^2 = \|Y - X\beta\|^2.$$

$\hat{\beta}$ OLS minimise $S(\beta) \Rightarrow$

$$\hat{\beta} = \underset{\beta \in \mathbb{R}^p}{\text{Argmin}} \|Y - X\beta\|^2.$$

$$\left\{ \begin{array}{l} \frac{\partial S(\beta)}{\partial \beta} = -2X^t(Y - X\beta) = 0 \Rightarrow \boxed{X^t X \hat{\beta} = X^t Y} \\ \frac{\partial^2 S(\beta)}{\partial \beta^2} = 2X^t X. \end{array} \right. \quad \text{Rappel: } \left\{ \begin{array}{l} \frac{\partial}{\partial x} (a^t x) = a \quad (a, x \in \mathbb{R}^d) \\ \frac{\partial}{\partial x} (x^t A x) = 2Ax \end{array} \right.$$

\rightarrow si $\text{rg}(X) = p$ (plein rg), alors $(X^t X)$ est inversible
et $\hat{\beta} = (X^t X)^{-1} X^t Y$.

• Interprétation géométrique $\mathcal{L}(X) =$ EV engendré par les colonnes de X

\hookrightarrow tt. élément de $\mathcal{L}(X)$ s'écrit \hat{c} une comb.
lin. des $X^{(j)}$ $X = \{X^{(1)} \dots X^{(p)}\}$

$$\min_{\beta \in \mathbb{R}^p} \|Y - X\beta\|^2 = \min_{O \in \mathcal{L}(X)} \|Y - O\|^2$$

le solut^o $\hat{\beta}$ a la propriété \perp de Y sur $\mathcal{L}(X)$

$$\hat{Y} = X\hat{\beta} = PY \quad \text{et} \quad P = X(X^t X)^{-1} X^t$$

(5)

$$V = P^{-1} \Lambda P = P^{-1} \begin{bmatrix} \lambda_1 & & \\ & \ddots & \\ & & \lambda_n \end{bmatrix} P$$

$$\Lambda^{-1/2} = \begin{bmatrix} 1/\sqrt{\lambda_1} & & \\ & \ddots & \\ & & 1/\sqrt{\lambda_n} \end{bmatrix} \rightarrow V^{-1/2} = \Lambda^{-1/2} P$$

$$V(\tilde{Y}) = V(\Lambda^{-1/2} P Y) = \Lambda^{-1/2} P P^{-1} \Lambda P P^{-1} \Lambda^{-1/2} \times \sigma^2$$

→ critique de cette approche: $V^{-1/2} \times X$: interprétation?
 V doit être inversée!

→ Inversion de V dans le cas Compound Symmetry
 utilise la relation:

$$\left(\underset{\substack{\uparrow \\ \neq 0}}{a} I_n + \underset{\substack{\uparrow \\ a \neq -nb}}{b} J_n \right)^{-1} = \frac{1}{a} \left(I_n - \frac{b}{a+nb} J_n \right)$$

$$4 \quad V(Y)^{-1} = \left(\frac{1}{\sigma_e^2} \left(I_{ni} - \frac{\sigma_A^2}{\sigma_e^2 + n_i \sigma_A^2} J_{ni} \right) \right)_i$$

(Bloc i)

Application à l'estimation de μ .

$$\bullet \hat{\mu}_{OLS} = \underbrace{\left(\mathbb{1}_n' \mathbb{1}_n \right)^{-1}}_{1/n} \underbrace{\mathbb{1}_n' Y}_{\sum_{ij} Y_{ij}} = \frac{1}{n} \sum_i n_i Y_{i\cdot}$$

ou note $Y_{i\cdot} = \sum_j Y_{ij}$
 $Y_{i\cdot} = \frac{1}{n_i} \sum_j Y_{ij}$

$$\rightarrow \hat{\mu}_{OLS} = \frac{1}{n} \sum_i n_i Y_{i\cdot}$$

$$\bullet \hat{\mu}_{GLS} = \left(\mathbb{1}_n' V^{-1} \mathbb{1}_n \right)^{-1} \mathbb{1}_n' V^{-1} Y$$

$$\begin{aligned} \mathbb{1}_n' V^{-1} \mathbb{1}_n &= \sum_{i=1}^I \mathbb{1}_{m_i}' \left(\frac{1}{\sigma_e^2} \left[\text{Id}_{n_i} - \frac{\sigma_A^2}{\sigma_e^2 + n_i \sigma_A^2} J_{n_i} \right] \right) \mathbb{1}_{n_i} \\ &= \frac{1}{\sigma_e^2} \left(\sum_i \underbrace{\mathbb{1}_{m_i}' \mathbb{1}_{n_i}}_{m_i} - \frac{\sigma_A^2}{\sigma_e^2 + n_i \sigma_A^2} \underbrace{\mathbb{1}_{m_i}' J_{n_i} \mathbb{1}_{n_i}}_{m_i} \right) \\ &= \frac{1}{\sigma_e^2} \sum_i m_i \left(1 - \frac{\sigma_A^2 n_i}{\sigma_e^2 + n_i \sigma_A^2} \right) \\ &= \sum_i \frac{m_i}{\sigma_e^2 + \sigma_A^2 n_i} \end{aligned}$$

$$\mathbb{1}'_n V^{-1} Y = \frac{1}{\sigma_e^2} \sum_i \mathbb{1}'_{m_i} \left(\mathbb{I}_{d_{n_i}} - \frac{\sigma_A^2}{\sigma_e^2 + n_i \sigma_A^2} J_{n_i} \right) Y_i \quad (7)$$

$$= \frac{1}{\sigma_e^2} \sum_i \left(Y_{i0} - \frac{n_i Y_{i0} \sigma_A^2}{\sigma_e^2 + n_i \sigma_A^2} \right)$$

$$= \sum_i \left(\frac{n_i Y_{i0}}{\sigma_e^2 + n_i \sigma_A^2} \right) \rightarrow w_i$$

$$\hat{\mu}_{GLS} = \frac{\sum_i w_i Y_{i0}}{\sum_i w_i} = \text{moyenne pondérée.}$$

↳ Quelle interprétation pour $w_i = \frac{n_i}{\sigma_e^2 + n_i \sigma_A^2}$?

$$Y_{ij} = \mu + A_i + E_{ij}$$

$$\sum_j Y_{ij} = n_i \mu + n_i A_i + \sum_j E_{ij}$$

$$\frac{1}{n_i} \sum_j Y_{ij} = \mu + A_i + \frac{1}{n_i} \sum_j E_{ij}$$

$$V(Y_{i0}) = V(A_i + E_{i0}) = \sigma_A^2 + \frac{1}{n_i} \sigma_e^2$$

$$\frac{1}{V(Y_{i0})} = \frac{n_i}{\sigma_e^2 + n_i \sigma_A^2}$$

$$\bullet \mathbb{E}(\hat{\mu}_{OLS}) = \mathbb{E}(\hat{\mu}_{GLS}) = \mu$$

↳ les deux estimateurs sont sans biais.

$$\bullet V(\hat{\mu}_{GLS}) = \left(\sum_i \frac{n_i}{\sigma_e^2 + n_i \sigma_K^2} \right)^{-1}$$

$$\left\{ \begin{array}{l} \hat{\mu}_{OLS} = \frac{1}{n} \sum_i m_i Y_{i0} \Rightarrow V(\hat{\mu}_{OLS}) = \frac{1}{n^2} \sum_i m_i^2 V(Y_{i0}) \\ \hat{\mu}_{GLS} = \frac{1}{\sum_i w_i} \sum_i w_i Y_{i0} \Rightarrow V(\hat{\mu}_{GLS}) = \frac{1}{(\sum_i w_i)^2} \sum_i w_i^2 V(Y_{i0}) \end{array} \right.$$

Rq: quand $n_i = \text{cte}$ (cas équilibré)

$$\hat{\mu}_{OLS} = \hat{\mu}_{GLS}!$$

Propriété: si on note $\hat{\mu}_w = \frac{\sum w_i Y_{i0}}{\sum w_i}$ un estimateur avec "pondération" w_i

$$\text{alors } V(\hat{\mu}_{GLS}) \leq V(\hat{\mu}_w)$$

$$\text{et on a aussi } V(\hat{\mu}_{GLS}) \leq V(\hat{\mu}_{OLS})$$

→ dans le modèle à effet aléatoire (1 fact.) $\hat{\mu}_{GLS}$ est l'estimateur pondéré ayant la plus petite variance parmi tous les estimateurs pondérés fondés sur Y_{i0} .

Estimation des paramètres de variance par la Table d'ANOVA.

- On cherche à estimer $\sigma_{\mu}^2, \sigma_e^2$.
- On utilise la table d'Analyse de la Variance.
- Principe: on identifie $E(SS)$ avec les paramètres de variance.
 - ↳ Estimateur de type moment.

Table d'ANOVA. 1Way Design.

Source de Variation	ddl	SS	MS	F
Facteur	I-1	SS _A	SS _A /I-1	$\frac{MS_A}{MS_E}$
Residu	n-I	SS _E	SS _E /n-I	
Total	n-1	SS _T	SS _T /n-1	

→ $SS_T = SS_A + SS_E$

$$\sum_{i=1}^I \sum_j (Y_{ij} - \bar{Y}_{..})^2 = \underbrace{\sum_j (Y_{ij} - \bar{Y}_{i.})^2}_{\text{Inter Groupes}} + \underbrace{\sum_i n_i (\bar{Y}_{i.} - \bar{Y}_{..})^2}_{\text{Intra Groupe}}$$

→ On souhaite calculer $E(SS_A)$, $E(SS_R)$

$$SS_A = \sum_{i=1}^I n_i (Y_{i.} - Y_{..})^2 = m_0 \sum_i (Y_{i.} - Y_{..})^2$$

↳ On prend le cas équilibré : $m = I \times m_0$.

$$Y_{i.} = \sum_j Y_{ij} / m_0 = \mu + A_i + \bar{E}_{i.}$$

$$Y_{..} = \frac{1}{I} \sum_i Y_{i.} = \mu + A_{..} + \bar{E}_{..}$$

$$\begin{aligned} SS_A &= m_0 \sum_i \left((\mu + A_i + \bar{E}_{i.}) - (\mu + A_{..} + \bar{E}_{..}) \right)^2 \\ &= m_0 \sum_i \left((A_i - A_{..}) + (\bar{E}_{i.} - \bar{E}_{..}) \right)^2 \end{aligned}$$

ou $E((X+Y)^2) = EX^2 + EY^2$ quand $X \perp Y$

$$E(SS_A) = m_0 \sum_i \left(\underbrace{E(A_i - A_{..})^2}_{V(A_i - A_{..})} + \underbrace{E(\bar{E}_{i.} - \bar{E}_{..})^2}_{V(\bar{E}_{i.} - \bar{E}_{..})} \right)$$

$$\begin{aligned} V(A_i - A_{..}) &= V(A_i) + V(A_{..}) - 2\text{cov}(A_i, A_{..}) \\ &= \sigma_A^2 + \frac{\sigma_A^2}{I} - \frac{2\sigma_A^2}{I} \end{aligned}$$

$$V(\bar{E}_{i.} - \bar{E}_{..}) = \frac{\sigma_E^2}{m_0} + \frac{\sigma_E^2}{m_0 \times I} - \frac{2 m_0 \sigma_E^2}{m_0 I m_0}$$

$$\begin{aligned} E(SS_A) &= (I-1) \left(m_0 \sigma_A^2 + \sigma_E^2 \right) \\ E(MS_A) &= m_0 \sigma_A^2 + \sigma_E^2 \end{aligned}$$

Estimateurs de type ANOVA.

$$\begin{cases} E \text{ SSA} = (I-1) (n_0 \sigma_A^2 + \sigma_e^2) \\ E \text{ SSE} = I (n_0 - 1) \sigma_e^2. \end{cases} \text{ Seele P60.}$$

Estimateurs :

$$\begin{cases} \hat{\sigma}_E^2 = \frac{\text{SSE}}{(n_0 - 1) I} \\ \hat{\sigma}_A^2 = \frac{\text{SSA} - \text{MSE}}{n_0} \end{cases}$$

- Ce sont des estimateurs sans biais pour $\hat{\sigma}_e^2$ mais
- très faibles à calculer. des biais pour $\hat{\sigma}_A^2$. ($\mathbb{P}(\hat{\sigma}_A^2 < 0)$).
- $\hat{\sigma}_A^2$ peut être négatif : modélisation variance / corrélation directement?
- pas besoin d'hyp. de normalité.
- ↳ Si on a un modèle, on peut calculer $\mathbb{P}(\hat{\sigma}_A^2 < 0)$.

↳ comment faire quand $\hat{\sigma}_A^2 < 0$.

↳ peut être indicatif de l'utilisation d'un mauvais modèle.

↳ On met souvent les valeurs négatives à 0.

→ $Y_{ij} = \mu + \epsilon_{ij} \Rightarrow \hat{\sigma}_E^2 = \frac{1}{(In_0 - 1)} \text{SST}$

↳ Autre technique (ML, REML).

Estimateurs du Maximum de vraisemblance.

↳ On considère le modèle $Y \sim N(\mu, V)$

$$\text{avec } V = \left\{ \sigma_A^2 J_{n_i} + \sigma_e^2 I_{n_i} \right\}_i.$$

→ correspond au modèle $A_i \sim N(0, \sigma_A^2)$.

$$V(A_i) = \sigma_A^2$$

$$V(Y) = Z V(A) Z' + V(E)$$

→ on considère la vraisemblance d'un vecteur gaussien

$$L(\mu, \sigma_A^2, \sigma_e^2; Y) = \left(\frac{1}{2\pi} \right)^{-n/2} |V|^{-1/2} \exp\left(-\frac{1}{2} \|Y - \mathbb{1}\mu\|_{V^{-1}}^2 \right).$$

• Elements du calcul $|V|^{-1/2}$, $\|Y - \mathbb{1}\mu\|_{V^{-1}}^2$

• obj: maximiser $\log L(\mu, \sigma_A^2, \sigma_e^2; Y)$

→ V est structurée et on donne $|V|^{-1/2}$.

$$|V| = \prod_{i=1}^I \sigma_e^2 \left(\sigma_e^2 + m_i \sigma_A^2 \right)$$

$$|a I_n + b J_n| = a^{n-1} (a + bn).$$

Calcul de $\|Y - \mu\|_{V^{-1}}^2$.

$$\|Y - \mu\|_{V^{-1}}^2 = {}^t (Y - \mu) V^{-2} (Y - \mu)$$

• On raisonne d'abord sur le bloc i .

$$V_i^{-1} = \left(I_{n_i} - \frac{\sigma_A^2}{\sigma_e^2 + n_i \sigma_A^2} J_{n_i} \right) \times \frac{1}{\sigma_e^2}$$

$$\sigma_e^2 \left\{ \|Y - \mu\|_{V^{-1}}^2 \right\}_i = \underbrace{{}^t (Y - \mu) (Y - \mu)}_{\sum_j (Y_{ij} - \mu)^2} - \frac{\sigma_A^2}{\sigma_e^2 + n_i \sigma_A^2} \underbrace{{}^t () J_{n_i} ()}_{\left(\sum_j Y_{ij} - \mu \right) (Y_{i\cdot} - n_i \mu)}$$

$$\sigma_e^2 \times \|Y - \mu\|_{V^{-1}}^2 = \sum_{ij} (Y_{ij} - \mu)^2 - \sum_i \frac{\sigma_A^2}{\sigma_e^2 + n_i \sigma_A^2} \underbrace{(Y_{i\cdot} - n_i \mu)^2}_{\frac{n_i^2 \sigma_A^2}{\sigma_e^2 + n_i \sigma_A^2} (Y_{i\cdot} - \mu)^2}$$

• On cherche à faire apparaître SS_A et SS_E dans l'expression de $\|Y - \mu\|_{V^{-1}}^2$

$$\begin{cases} SS_E = \sum (Y_{ij} - Y_{i\cdot})^2 \\ SS_A = \sum (Y_{i\cdot} - Y_{\cdot\cdot})^2 \end{cases} \quad \left(\text{On fait le } \begin{array}{l} \text{ces équilibres} \\ n_0 = n_i. \end{array} \right).$$

$$\begin{aligned} \rightarrow \sum_{ij} (Y_{ij} - \mu)^2 &= \sum_{ij} (Y_{ij} - Y_{i\cdot} + Y_{i\cdot} - \mu)^2 \\ \sum_i (Y_{i\cdot} - \mu)^2 &= \sum_i (Y_{i\cdot} - Y_{\cdot\cdot} + Y_{\cdot\cdot} - \mu)^2 \end{aligned}$$

$$\|Y - \mu\|_{V^{-1}}^2 = \frac{1}{\sigma_e^2} \left[SSE + \frac{\sigma_e^2}{\sigma_e^2 + m_0 \sigma_A^2} \left[SSA + I n_0 (\bar{y}_{..} - \mu)^2 \right] \right] \quad (14)$$

→ On a une expression de la log $\mathcal{L}(\mu, \sigma_A^2, \sigma_e^2; Y)$.

$$= -\frac{n}{2} \log(2\pi) - \frac{1}{2} \log |V| - \frac{1}{2} \|Y - \mu\|_{V^{-1}}^2$$

$$-2 \log \mathcal{L}(\mu, \sigma_A^2, \sigma_e^2; Y) \pm \text{cte} + \underbrace{\log |V|}_{\downarrow} + \|Y - \mu\|_{V^{-1}}^2$$

$$\sum_i (n_i - 1) \log \sigma_e^2 + \sum_i \log(\sigma_e^2 + n_i \sigma_A^2)$$

→ On dérive par rapport @ $\mu, \sigma_A^2, \sigma_e^2$: (solu^o de la cas équilibré)

$$\left\{ \begin{array}{l} \hat{\mu}_{ML} = \bar{y}_{..} \\ \hat{\sigma}_A^2 ML = \frac{(1 - 1/I) MSA - MSE}{m_0} \rightarrow \text{peut être } < 0. \\ \hat{\sigma}_e^2 ML = MSE = \frac{SSE}{n_0 I} \end{array} \right. \quad \begin{array}{l} \nearrow SSA / (I-1) \\ \hookrightarrow \text{On n'a pas} \\ \text{max. avec contrainte} \\ \text{de support.} \end{array}$$

Comparaison avec $\sigma_A^2(\text{ANOVA}) = \frac{1}{n_0} (MSA - MSE)$.

- Motivation :
- historiquement ML n'était pas trop utilisé pour de raisons computationnelles (maximisation de V , lenteur de convergence).
 - en plus MLE biaisé pour les paramètres.
 - KETTL (1971): garder l'avantage de MLE mais corriger le biais.

Illustration :

$$Y = X\beta + E \quad E \sim N(0, I_n \sigma^2)$$

β de taille p .

$$\left\{ \begin{array}{l} \hat{\sigma}_{ML}^2 = \frac{1}{n} \|Y - X\hat{\beta}\|^2 \\ \hat{\sigma}_{REML}^2 = \frac{1}{n-p} \|Y - X\hat{\beta}\|^2 \end{array} \right. \quad E(\hat{\sigma}_{ML}^2 - \sigma^2) = -\sigma^2 \frac{p}{n}$$

↳ le biais augmente avec p .
 ↳ devient critique qd n est petit.

→ Idée : utiliser une vraisemblance fondée sur les résidus plutôt que sur les obs.

- prendre en compte la perte de ddl associée à l'estimation des effets fixes en maximisant une vraisemblance qui sépare les parties Exp / variance.

→ Calculer d'abord les est. des effets fixes, prendre les résidus et estimer les paramètres d'après ces résidus.

Dans le cas équilibré :

→ étant donné que $\hat{\mu} \perp SSA, SSE,$

on peut écrire :

$$L(\mu, \sigma_e^2, \sigma_A^2; y) = L(\mu; y_{00}) \times L(\sigma_e^2, \sigma_A^2; SSA, SSE)$$

↙
vraisemblance pour μ
étant donné le stat
résumative y_{00} .

↘
vraisembl. de
 σ_e^2, σ_A^2 étant
donné le stat exh.
 SSA, SSE .

↳ Pour l'estimateur REML, on maximise

$$L(\sigma_e^2, \sigma_A^2; SSA, SSE).$$

$$\begin{cases} \hat{\sigma}_e^2 = \frac{SSE}{I_0(m_0 - 1)} \\ \hat{\sigma}_A^2 = \frac{1}{n_0} (MSA - MSE). \end{cases}$$

$$\left(MSA = \frac{SSA}{I-1} \right)$$

Recapitulation: 3 méthodes d'estimation: pour σ_e^2 et σ_A^2
ANOVA, ML, REML.

• On a fait les calculs pour le cas équilibré.

	ANOVA	ML	REML
$\hat{\sigma}_e^2$	$\frac{SSE}{I(n_0-1)}$	$\frac{SSE}{I(n_0-1)}$	$\frac{SSE}{I(n_0-1)}$
$\hat{\sigma}_A^2$	$\frac{MSA - MSE}{n_0}$	$\frac{(1 - 1/I) MSA - MSE}{n_0}$	$\frac{MSA - MSE}{n_0}$

$MSA = \frac{SSA}{(I-1)}$

$MSE = \frac{SSE}{I(n_0-1)}$

$MSA = \frac{SSA}{I-1}$

• les estimateurs ANOVA et REML sont les mêmes dans le cas équilibré.

• les conditions pour lesquelles $\hat{\sigma}_A^2 < 0$ ne sont pas les mêmes pour ML et REML.

↳ vient du fait que pour REML $\Rightarrow \frac{SSA}{(I-1)}$ et pas I . (ML)

- Bias:
 - ANOVA: non biaisé pour σ_e^2 et non biaisé pour σ_A^2 .
 - ML: non biaisé pour σ_e^2 et biaisé pour σ_A^2 .
 - REML: non biaisé pour σ_e^2 et non biaisé pour σ_A^2 .

Hypothèse de normalité et test sur les paramètres.

(12)

- On peut dériver certains estimateurs sous le modèle Gaussien (ANOVA).
- Si on veut E et W pour les estimateurs il faut choisir un modèle
- idem pour tester les effets de facteurs.

Modèle Gaussien: $Y_i = \mu + A_i + \varepsilon_{ij}$
 $A_i \sim N(0, \sigma_A^2) \quad A_i \perp \varepsilon_{ij}$
 $\varepsilon_{ij} \sim N(0, \sigma_e^2)$

• loi des sommes de Carré.

- $\frac{SSA}{n_0 \sigma_d^2 + \sigma_e^2} \sim \chi^2(I-1)$
- $\frac{SSE}{\sigma_e^2} \sim \chi^2 I(n_0-1)$

on déduit que

$$SSA \perp SSE$$

(Th. de Cochran)

Test de l'effet du facteur Aléatoire.

→ Dans un modèle à effets fixes

$$H_0 = \{ \alpha_1 = \alpha_2 = \dots = \alpha_I \}$$

↳ tous les niveaux sont égaux → pour des niveaux choisis et fixes.

→ Dans un modèle à effet Aléatoire on n'échantillonne qu'un ensemble possible.

↳ Ai n'est pas intéressant en soi

↳ c'est la variabilité liée à l'effet qui nous intéresse :

$$H_0 = \{ \sigma_A^2 = 0 \}$$

→ Modèle à effet fixe: $E(SS_A) = (I-1) \sigma_e^2$

$$F_A = \frac{SSA / I - 1}{SSE / I(n_0 - 1)} \sim \overline{F}_{I-1, (n_0-1)I}$$

Stat. de Fisher pour tester l'effet fixe α . $\frac{SSA}{\sigma_e^2} \sim \chi^2(I-1)$

→ Modèle à effet Aléatoire: $E(SSA) = (I-1)(n_0 \sigma_A^2 + \sigma_e^2)$

$$F_A = \frac{MSA / (n_0 \sigma_A^2 + \sigma_e^2)}{MSE / \sigma_e^2} \sim \overline{F}_{(I-1), (n_0-1)I}$$

Stat de Fisher pour tester l'effet Aléatoire A

→ Mais sous $\mathcal{H}_0 : \sigma_A^2 = 0$.

$$F_A = \frac{\sigma_e^2}{\sigma_e^2 + n_0 \sigma_A^2} \quad F_\alpha = F_\alpha \quad !!!$$

↳ les lois sont les m^me sous \mathcal{H}_0 mais pas sous \mathcal{H}_1 !

→ Au test de effets, c'est quand on a une des effets fixes et sélectionnés que la modélisation en effets mixtes devienne intéressante car on teste les effets fixes par rapport à d'autres variabilités que la variabilité résiduelle.

→ On peut aussi construire des IC pour $\sigma_e^2, \frac{\sigma_A^2}{\sigma_e^2 + \sigma_A^2}, \frac{\sigma_A^2}{\sigma_e^2}$.

$$IC(\sigma_e^2) = \left[\frac{SSE}{\chi^2_{I(n_0-1), U}}, \frac{SSE}{\chi^2_{I(n_0-1), L}} \right]$$

↳ pour σ_A^2 .
on utilise plutôt $\sigma_A^2 / (\sigma_A^2 + \sigma_e^2) =$ corrélation intra classe.