

# Introduction aux modèles linéaires mixtes

①

## Motivations et Objectifs

• Principe général de l'ANOVA: Analyse de la variabilité des données en étudiant la répartition de la variance observée.

↳ Au départ on se pose la question de la comparaison de moyennes, mais cette comparaison nécessite une bonne estimation de la ou des variances.

↳ Si on met un modèle (gaussien) on peut tester la significativité de la différence de moyennes entre certaines catégories.

• Modèles à effets aléatoires: souvent utilisés pour décrire les relations entre des variables réponse et des covariables pour des données structurées (groupées) selon un ou plusieurs facteurs: blocs, strates, analyse longitudinale....

↳ On introduit des effets aléatoires pour des obs. d'un  $i^{\text{e}}$  groupe  $\rightarrow$  modélise la covariance induite par le design.

Facteurs, niveaux, cellules, effets

On cherche à structurer la variabilité à différents caractéristiques des données.

Ex: Essai clinique, 3 drogues ABC, sur les hommes, mariés ou non.

↳ 3 descriptions : drogue, sexe, statut marital  
→ identifie 3 sources potentielles de variat.  
= Facteurs

|   | Marié |   |   | Non Marié |   |   |
|---|-------|---|---|-----------|---|---|
|   | A     | B | C | A         | B | C |
| ♂ |       |   |   |           |   |   |
| ♀ |       |   |   |           |   |   |

↳ Ces facteurs ont ≠ modalités → niveaux

↳ les sous-ensembles de données qui correspondent aux répétitions à un croisement de facteurs sont appelés cellules.

Objectifs de l'ANOVA : Quel est (sont) l'effet des différents niveaux des facteurs sur une variable d'intérêt?

l'effet peut concerner → la moyenne  
→ la variance.

• Effets fixes : Ils sont attribuables à un ensemble fini de niveaux d'un facteur.

• Ils sont présents parce que d'intérêt (en principe!).

• Effets Aléatoires : Attribuable à un ensemble infini de niveaux pour lesquels seul un sous ensemble a été échantillonné.

→ C'est aussi un choix de modélisation, donc discutable!  
} avant tout ?

Exemple de modèle à effets fixes.

• Agronomie : rendement de 24 plants de tomates  
• 6 plants x 4 variétés d'intérêt.

$y_{ij}$  = rendement du fruit de variété  $i$   
provenant du plant  $j$ .  
 $i = 1, 4$      $j = 1, 6$ .

• On suppose que l'espérance du rendement dépend de la variété :

$$E y_{ij} = \mu_i$$

On décompose  $\mu_i$  t.q.:

$$E Y_{ij} = \mu_i = \mu + \alpha_i$$

$\mu$  ← Moyenne Générale  
 $\alpha_i$  ← est dû à la variété  $i$

→  $j$  est l'indice de répétition

↳ Dans ce modèle  $\mu_i$  est considérée comme une constante.

↳ On souhaite comparer les magnitudes  $\mu_1 - \mu_2, \dots$  pour comparer les niveaux du facteur variété (et choisir le meilleur parcel).

↳ Si on ne s'intéresse qu'à ces 4 variétés → l'effet est fixe.

À partir du modèle  $E Y_{ij} = \mu + \alpha_i$   
On construit la déviation de  $Y_{ij}$  par rapport à  $E Y_{ij}$

$$Y_{ij} - E Y_{ij} = Y_{ij} - (\mu + \alpha_i)$$

Résidu : par construction centré :  $E E_{ij} = 0$ .  
défini.

↳ Structure au 2<sup>nd</sup> ordre?

- chq  $E_{ij}$  a  $m$  variance  $V(E_{ij}) = \sigma_e^2$
- $E_{ij}$  iid.  $\text{cov}(E_{ij}, E_{i'j'}) = 0$ .
- sauf pour  $i=i', j=j'$

Vers un modèle à effets mixtes.

• Essai clinique pour tester l'efficacité d'un placebo vs 3 trait<sup>ts</sup> pour réduire la pression artérielle.

• 24 hommes, âgés de 40-45 ans. Égayant des délais entre 100 et 250 k $\phi$ /cu.

• 6 hô pour chq type de drogue.

• mesure de la pression sanguine après 30j.

→ Effet traitement:  $i = 1, 4$  : ne sont pas issus d'une population + large de traitements.  
 $j = \text{hommes} = 1, 6$  : indice de répétitions

• Supposons que les essais sont faits dans des hôpitaux  $\neq$ .  
Choisis aléatoirement dans la ville de NYC avec 5 patients par traitement dans chq clinique (15 cliniques)

→ étude multicentris.

$i = 1, 4$ ,  $j = 1, 15$  cliniques,  $k = 1, 5$  (individus).

$$E(Y_{ijk}) = \mu + \alpha_i + \beta_j + \gamma_{ij}$$

↑  
effet clinique fixe?

→ plutôt aléatoire car les cliniques choisies sont un échantillon

→  $E(Y_{ijk}) = \mu + \alpha_i$  mais comment modéliser  $\beta_j$ ?

# Modèle à effets Aléatoires.

Exemple du modèle Animal en Agronomie / Génétique

• éleveurs font appel à des banques de semences pour "produire" des bovins, en vue d'avoir un bon rendement.

Ex: production laitière.

• les semenciers disposent de 80-150 taureaux qui sont considérés comme un échantillon aléatoire d'une population (ex: Holstein).

• on enregistre le rendement laitier de leurs descendants après 3 ans.

|   |  |
|---|--|
| $\left\{ \begin{array}{l} i = 1, I \\ j = 1, M_i \end{array} \right.$ | $i = 1, I$ : effet "père"                          |
|   | $j = 1, M_i$ : nombre de descendants du père $j$ . |

• On suppose que les deux sexes partageant le même père ont "partagé" une performance semblable.

↳ Connaissant leur père, l'espérance de leur rendement serait  $\mu_i$

$$E(Y_{ij} | A_i) = \mu_i = \mu + A_i$$

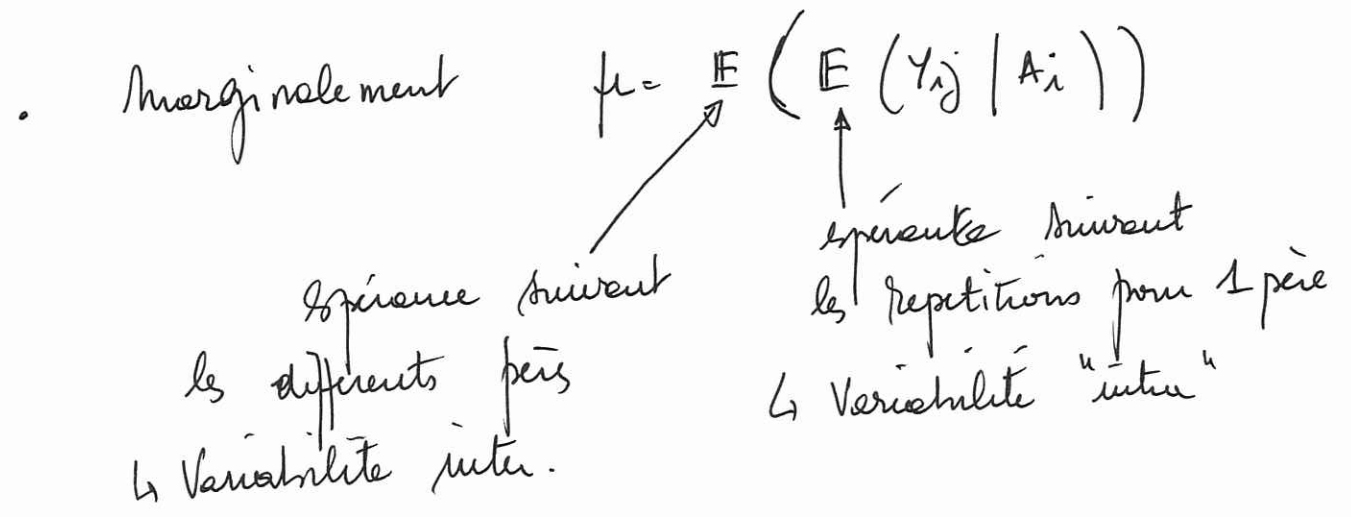
mais "marginement"  $E(Y_{ij}) = \mu$

• On suppose que l'effet du père est une réalisation d'une process stochastique (en général gaussien).

$$E(Y_{ij} | A_i = a_i) = \mu + a_i$$

$$\left\{ \begin{array}{l} A_i \sim N(0, \sigma_a^2) \\ \text{cov}(A_i, A_k) = 0 \end{array} \right. \quad (\text{les pères ne sont pas apparentés}).$$

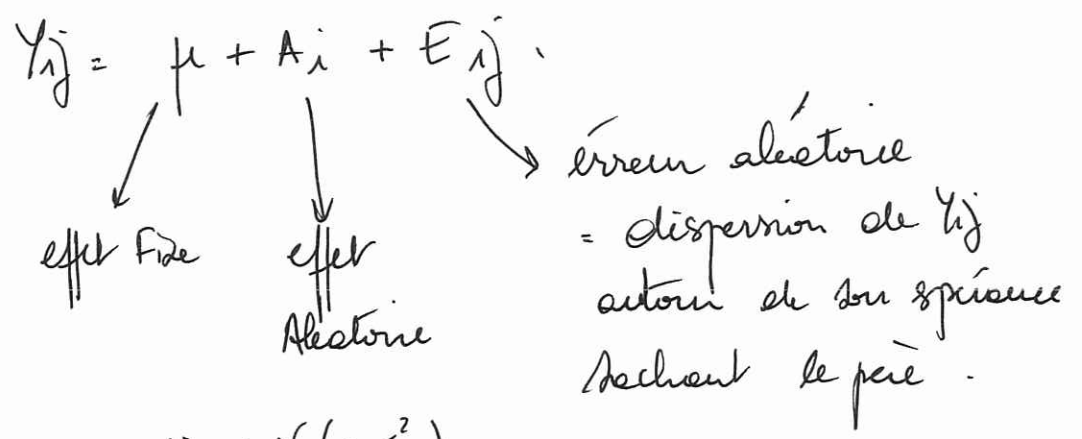
• Dans ce modèle  $(\mu + A_i)$  est stochastique et on n'en observe qu'une réalisation  $\mu + a_i$ .



Req: si  $A_i$  n'était pas centré, on pourrait mettre tout espérance dans  $\mu$ .

Dans le modèle 
$$E_{ij} = Y_{ij} - E(Y_{ij} | A_i)$$

$$= Y_{ij} - (\mu + A_i)$$



On suppose: 
$$\begin{cases} A_i \sim N(0, \sigma_A^2) \\ E_{ij} \sim N(0, \sigma_E^2) \\ A_i \perp E_{ij} \end{cases}$$

VARIANCE COMPONENT du rendement  $Y$ .

$$V(Y_{ij}) = V(A_i) + V(E_{ij}) = \sigma_A^2 + \sigma_E^2$$

$$\sigma_A^2 = \text{Cov}(Y_{ij}, Y_{ij}') = \text{Covariance entre le rendement de 2 vaches issues du m\u00eame p\u00e8re.}$$

On peut s'int\u00e9resser au ratio 
$$\left[ \frac{\sigma_A^2}{\sigma_A^2 + \sigma_E^2} \right] = \% \text{ de variance due au p\u00e8re}$$

$$\approx h^2 \text{ (h\u00e9r\u00e9dit\u00e9).}$$

en psychologie \u00e9ducationnel training s'interpr\u00e8te comme une fiabilit\u00e9.



# Prediction de effets Aleatoris

⑨.

→ Comment quantifier la Contribution du père  $i$ ? (sur le redt).

→ Comment sélectionner les "bons" pères?  
 $A_i$  = effet spécifique du père  $i$ .

→ la contribution exacte du père  $i$  est inconnue et différente d'une fille à une autre (transmission d'une moitié aleatoire de génome).

↳ Ce n'est pas un effet fixe contrôlé.

↳ On pourra quantifier  $E(A_i | Y) = \hat{A}_i$   
= prédiction de l'effet aleatoire ↗ des données.

→  $\hat{\mu} + \hat{A}_i$  permet de prédire le rendement d'un individu connaissant ses parents

→ pour sélectionner  $i$  vs  $i'$   $\hat{A}_{i'} < \hat{A}_i$

# Problématiques g n rales du mod le mixte.

- 1) - Estimer les composants de la variance.  
 ↳ permet de quantifier l'importance des effets al茅atoires par rapport   la r茅sidualle.

Plusieurs m茅thodes :  
 - m茅thode ANOVA, ML, REML.  
 - Algorithme EM pour ML.  
 - probl茅matique 茅quilibre / non 茅quilibre.

- 2) - Estimer les effets fixes. (GLS, ML, algo. EM pour ML).
- 3) - Pr dire les Effets Al茅atoires (BL, BLUP).
- 4) - Tests de facteurs (effets fixes, Al茅atoires).