


# Analyse de la Variance à un facteur

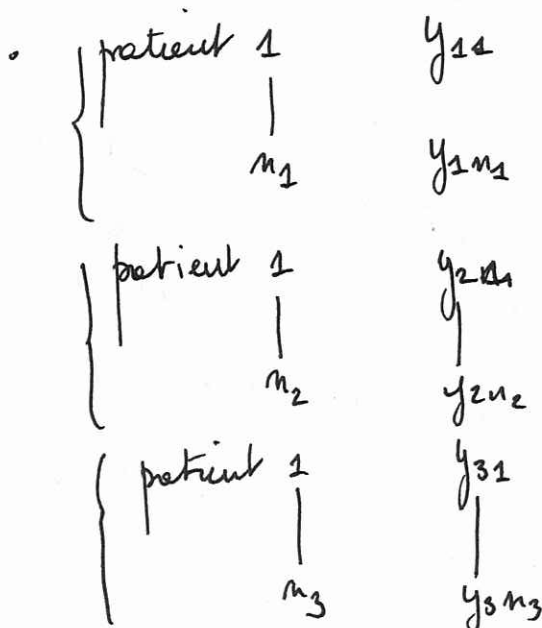
- permet de généraliser le démarche du test de Student à plus de 2 groupes, et aussi à plusieurs types de facteurs.



- plus généralement permet l'analyse et la mise au point d'exp. basées sur du matériel exp. variable.

→ Retour sur les médicaments:

patients: peuvent soit med A, B, C ou 1, 2, 3  
 $n_1, n_2, n_3$



$y_{ij}$  → indice de répétition  
 $j = 1 \dots n_i$

indice du traitement contrôlé  
↓  
effet fixe.

- Facteur: médicament
- Niveau: 1, 2, 3

$y_{ij}$  = charge orale pour le  $i^e$  pat. qui prend le medoc de type  $i$ .

Modèle :

$$Y_{ij} \sim N(\mu_i, \sigma^2)$$

ANOVA

$$Y_{ij} = \underbrace{\mu_i}_{\text{espérance}} + \underbrace{\varepsilon_{ij}}_{\substack{\text{erreur électronique} \\ - i.i.d \\ - N(0, \sigma^2), \sigma^2 \text{ cste.}}}$$

• Si on refait la même démarche que Student :

$$H_0 = \{ \mu_i = \mu_{i'} \}$$

↳ Répond à la question : les types  $i$  et  $i'$  ont-ils le même effet ?

↳ Or on peut poser 2 types de questions :

- effet O/N
- lequel ? a le + fort effet.

La Représentation :

$$\mu_i = \mu + \alpha_i$$

effet  
général

effet due  
médicament  
de type  $i$ .

• on rajoute un paramètre

→ on gagne en interprétation

→ On perd quelque chose :  $\mu$  et  $\alpha_i$  n'ont pas vraiment de sens en eux-mêmes, ce n'est que  $\mu + \alpha_i$  qui en a un.

• Paramètres du modèle : de 2 types :

$$\left\{ \begin{array}{l} \theta = (\mu, \alpha_1, \alpha_2, \alpha_3) = \text{paramètres de l'épave} \\ \sigma^2 = \text{variance résiduelle.} \end{array} \right.$$

• Notation matricielle  $Y = X\theta + E$

• Notation  $Y_{it}, Y_{io}$

• La Table d'Analyse de la Variance.

⚠ Important de distinguer un facteur de ses niveaux :


- Facteur = source de variabilité
- Niveau = modalités du facteur.

- Idée de l'Analyse de la Variance : étudier les différentes sources de variabilité.

SCT =  $\sum_{ij} (Y_{ij} - Y_{00})^2$  : Variance totale  
: comme si il n'y a pas de groupe

SCM =  $\sum_{ij} (Y_{io} - Y_{00})^2$  : si on resume l'info par la moyenne des groupes.

Between Var.



Variance expliquée par le modèle.

SCR =  $\sum_{ij} (Y_{ij} - Y_{io})^2$  : somme des carrés résiduelle.  
= Within Variance.

# Représentation Graphique.



Source	df	SS	MS	
Modèle	I-1	SCM	SCM / I-1	$\sigma^2 \chi^2 (I-1)$
Resid	n-I	SCR	SCR / n-I	$\sigma^2 \chi^2 (n-I)$
Total	n-1	SCT	SCT / n-1	$\sigma^2 \chi^2 (n-1)$

1<sup>ère</sup> Question : la variabilité expliquée par le modèle est-elle plus grande que la résiduelle ?

$$\frac{SCM / (I-1)}{SCR / (n-I)} \sim F_{I-1, n-I}$$

↳ Si ce test n'est pas significatif, alors ce n'est pas la peine de regarder la suite.

⇒ Ce correspond à tester l'hypothèse nulle  $H_0 = \{ \mu_1 = \dots = \mu_I \}$ .

2<sup>ème</sup> Question : la part de variabilité expliquée par le modèle.

$$R^2 = \frac{SCM}{SCT} = \text{pouvoir explicatif / prédictif}$$

→ Interprétation.

Estimation des paramètres.

$$S(\mu, \alpha) = \sum_{ij} (Y_{ij} - (\mu + \alpha_i))^2$$

$$\begin{cases} \frac{\partial S}{\partial \mu} = 0 \\ \frac{\partial S}{\partial \alpha} = 0 \end{cases} \Rightarrow \begin{cases} Y_{++} - n\hat{\mu} - \sum_i n_i \alpha_i = 0 \\ Y_{i+} - n_i \hat{\mu} - n_i \hat{\alpha}_i = 0 \end{cases}$$

→ Il faut mettre une contrainte pour inverser le système.

→  $\alpha_I = 0$  : Contrainte "utile" d'un point de vue numérique.

$$\hat{\mu} = Y_{I\cdot} \quad \hat{\alpha}_i = Y_{i\cdot} - Y_{I\cdot}$$

les estimateurs s'interprètent  
Comme les écarts à un groupe de ref  
qui est choisi arbitrairement à la  
dernière.

→  $\sum \alpha_i = 0$  : elle suppose que les effets se compensent globalement.

si  $n_i = \text{cte}$ , des ponts équilibrés.

$$\begin{array}{ccc} \hat{\mu} = Y_{\cdot\cdot} & \hat{\alpha}_i = Y_{i\cdot} - Y_{\cdot\cdot} \\ \downarrow & \downarrow \\ \text{Moyenne} & \text{écart à la} \\ \text{générale} & \text{Moyenne générale} \end{array}$$

- si déséquilibre.

$$\hat{\mu} = \frac{1}{I} \sum Y_i.$$

$$\hat{\alpha}_i = Y_i - \hat{\mu}.$$

difficile à interpréter.

$$\rightarrow \sum n_i \alpha_i = 0 \quad \hat{\mu} = Y_{..} \quad , \quad \hat{\alpha}_i = Y_i - Y_{..}.$$

↳ redonne les estimateurs naturels.

↳ les valeurs des estimateurs des paramètres dépendent des contraintes.

→ Mais certaines contr. lui, sont invariantes = CL Est.

↳ De manière générale,  $\hat{\mu}_i = \hat{\mu} + \hat{\alpha}_i = \text{predict}$ , invariants  
↳ rassurant!.

• autre exemple :  $\hat{\alpha}_i - \hat{\alpha}_{i'} = Y_i - Y_{i'}$

↳ la comparaison des groupes est II de la contrainte.

⇒ faire des tests sur les paramètres ( $\alpha_i$ ) de perdre des contraintes, alors que faire des tests sur  $\alpha_i - \alpha_{i'}$  non.

paramètre	$H_0$	$H_0$
	$\mu + \alpha_i$	$\mu_i$
$\mu$	$\mu = 0$	$\mu_3 = 0$
$\alpha_1$	$\alpha_1 = 0$	$\mu_1 = \mu_3$
$\alpha_2$	$\alpha_2 = 0$	$\mu_2 = \mu_3$
$\alpha_3$	$\alpha_3 = 0$	$0 = 0$

avec  $(\alpha_3 = 0)$ .

$\Rightarrow$  le sens de l'hypothèse dépend de la contrainte dans le modèle  $\mu + \alpha_i$  alors qu'il n'en dépend pas dans  $\mu_i$ .

$\Rightarrow \Delta$  Faire un test sur les paramètres du modèle peut être dangereux.

$\hookrightarrow$  Mais en général, ce qui nous intéresse c'est la comparaison de groupes.

Comparaison de groupes :

$\rightarrow$  Student:  $T = \frac{Y_{i0} - Y_{i'0}}{\hat{\sigma} \sqrt{\frac{1}{n_i} + \frac{1}{n_{i'}}}} \sim \mathcal{C}(n_i + n_{i'} - 2)$

le puissance augmente avec  $n_i + n_{i'} - 2$ .

$\rightarrow$  dans l'Anova, on augmente le puissance en utilisant une distinction de la variance fondée sur l'ensemble des groupes.

$\hookrightarrow$  sous  $\bar{y}_j$  si  $\sigma^2 = \text{cte}$   $T \sim \mathcal{C}(n-1)$ .

• les Comparaisons Multiples .

• si on compare  $I$  groupes  $\Rightarrow I(I-1)/2$  tests

Proof:  $\alpha^* \leq \alpha \times I(I-1)/2$  .

• Analyse des résidus .