

Analyse de la variance à deux facteurs

Cours: Joseph Salmon

Scribes: Mégane BOYER, Mathias GOUT et Emeline TOUSTOU

1 Cas sans interaction

Deux facteurs :

- Facteur 1 : I niveaux / I classes.
- Facteur 2 : J niveaux / J classes.

n_{ij} : nombre de répétitions / d'observations correspondant au facteur 1 dans la classe i et au facteur 2 dans la classe j .

On a alors les contraintes suivantes sur les observations totales :

$$n = \sum_{i=1}^I \sum_{j=1}^J n_{ij} . \quad (1)$$

Exemple: Des juges en œnologie mettent des notes sur 10 à des vins.

		Facteur 2 : D		
		Vin 1	Vin 2	Vin 3
Facteur 1 : C	Juge 1	[6, 7, 8] $n_{11} = 3$	[1, 2, 3, 5] $n_{12} = 4$	[1, 3] $n_{13} = 2$
	Juge 2	[3, 8, 9] $n_{21} = 3$	[1] $n_{22} = 1$	[1, 2, 3] $n_{23} = 3$
	Juge 3	[5, 7, 8] $n_{31} = 3$	[2, 5] $n_{32} = 2$	[2] $n_{33} = 1$

TABLE 1 – Notes attribuées aux vins par les juges.

Dans la Table 1, si le Facteur 1 est Juge 1 et le Facteur 2 est Vin 1, on a : $y_{111} = 6$, $y_{112} = 7$, $y_{113} = 8$.

Modèle : On a :

$$y_{i,j,k} \stackrel{iid}{\sim} \mathcal{N}(\mu_{ij}, \sigma^2), \quad \forall i \in \llbracket 1, I \rrbracket, \forall j \in \llbracket 1, J \rrbracket, \forall k \in \llbracket 1, n_{ij} \rrbracket \quad (2)$$

$$y_{i,j,k} = \mu + \alpha_i + \beta_j + \varepsilon_{i,j,k}. \quad (3)$$

Avec :

$$\text{Cov}(\varepsilon_{i,j,k}, \varepsilon_{i',j',k'}) = \sigma^2 \delta_{i,i'} \delta_{j,j'} \delta_{k,k'} \quad (4)$$

où $\mu \in \mathbb{R}$ représente l'effet moyen, α_i l'effet spécifique du niveau i pour le premier facteur, et β_j l'effet spécifique du niveau j pour le deuxième facteur.

△ : Si le plan d'expérience n'est pas équilibré (*i.e.*, les n_{ij} sont différents), l'analyse mathématique est ardue. Ici, on supposera donc pour faciliter l'analyse :

$$\boxed{\forall i \in \llbracket 1, I \rrbracket, \quad \forall j \in \llbracket 1, J \rrbracket, \quad n_{ij} = K} . \quad (5)$$

Ainsi on a donc au final $n = IJK$ observations.

En suivant une approche habituelle par moindres carrés on peut écrire le modèle sous forme matricielle :

$$X = [\mathbf{1}_n \quad \mathbf{1}_{C_1} \quad \dots \quad \mathbf{1}_{C_I} \quad \mathbf{1}_{D_1} \quad \dots \quad \mathbf{1}_{D_J}] \in \mathbb{R}^{n \times (1+I+J)} . \quad (6)$$

où $\text{rang}(X) = I + J + 1 - 2 = I + J - 1$ et $\mathbf{1}_n = (1, \dots, 1)^\top$.

Définition 1.1.

$$\begin{aligned} \arg \min_{(\mu, \alpha, \beta) \in \mathbb{R} \times \mathbb{R}^I \times \mathbb{R}^J} & \frac{1}{2} \sum_{i=1}^I \sum_{j=1}^J \sum_{k=1}^K (y_{i,j,k} - \mu - \alpha_i - \beta_j)^2 \\ \text{s.c.} & \sum_{i=1}^I \alpha_i = 0 , \\ & \sum_{j=1}^J \beta_j = 0 . \end{aligned} \quad (7)$$

On obtient pour ce problème le Lagrangien suivant :

$$\mathcal{L}(\mu, \alpha, \beta, \lambda_\alpha, \lambda_\beta) = \frac{1}{2} \sum_{i=1}^I \sum_{j=1}^J \sum_{k=1}^K (y_{i,j,k} - \mu - \alpha_i - \beta_j)^2 + \lambda_\alpha \left(\sum_{i=1}^I \alpha_i \right) + \lambda_\beta \left(\sum_{j=1}^J \beta_j \right) . \quad (8)$$

On cherche à résoudre le système suivant :

$$\left\{ \begin{array}{l} \frac{\partial \mathcal{L}}{\partial \mu} = 0 \\ \frac{\partial \mathcal{L}}{\partial \alpha} = 0 \\ \frac{\partial \mathcal{L}}{\partial \beta} = 0 \\ \frac{\partial \mathcal{L}}{\partial \lambda_\alpha} = 0 \\ \frac{\partial \mathcal{L}}{\partial \lambda_\beta} = 0 \end{array} \right.$$

On obtient ainsi les résultats suivants :

$$\frac{\partial \mathcal{L}}{\partial \mu} = 0 \implies n\hat{\mu} = \sum_{i=1}^I \sum_{j=1}^J \sum_{k=1}^K y_{i,j,k} \implies \hat{\mu} = \bar{y}_n . \quad (9)$$

$$\frac{\partial \mathcal{L}}{\partial \alpha} = 0 \implies \forall i \in \llbracket 1, I \rrbracket, \hat{\alpha}_i = \underbrace{\bar{y}_{i,:,:}}_{= \frac{1}{JK} \sum_{j=1}^J \sum_{k=1}^K y_{i,j,k}} - \hat{\mu} \quad (10)$$

$$\frac{\partial \mathcal{L}}{\partial \beta} = 0 \implies \forall j \in \llbracket 1, J \rrbracket, \hat{\beta}_j = \underbrace{\bar{y}_{:,j,:}}_{= \frac{1}{IK} \sum_{i=1}^I \sum_{k=1}^K y_{i,j,k}} - \hat{\mu} \quad (11)$$

Prédicteur associé :

$$\begin{aligned} \hat{y}_{ij} &= \hat{\mu} + \hat{\alpha}_i + \hat{\beta}_j \\ &= \bar{y}_{i,:,:} + \bar{y}_{:,j,:} - \hat{\mu} \\ &= \bar{y}_{i,:,:} + \bar{y}_{:,j,:} - \bar{y}_n \end{aligned}$$

Un estimateur (sans biais) de σ^2 est lui donné :

$$\hat{\sigma}^2 = \frac{1}{n - (I + J - 1)} \sum_{i=1}^I \sum_{j=1}^J \sum_{k=1}^K (\hat{y}_{ij} - y_{i,j,k})^2. \quad (12)$$

Remarque 1.1. *En effet, on peut vérifier facilement que*

$$\mathbb{E}(\hat{\sigma}^2) = \sigma^2. \quad (13)$$

Test global (d'influence d'un facteur) :

Facteur 1 : $H_0 : \alpha_1 = \alpha_2 = \dots = \alpha_I$.

Facteur 2 : $H_0 : \beta_1 = \beta_2 = \dots = \beta_J$.

Pour le facteur 1 :

$$F_{obs} = \frac{1}{\hat{\sigma}^2} \frac{KJ}{(I-1)} \sum_{i=1}^I (\bar{y}_{i,:,:} - \bar{y}_n)^2 \sim \mathcal{F}_{n-(I+J-1)}^{I-1}. \quad (14)$$

Test : Si $F_{obs} > \mathcal{F}_{n-(I+J-1)}^{I-1}(1-\alpha)$, on rejette H_0 (au niveau α). (XXX quantile de la loi de Fisher au niveau $1-\alpha$)