

Chap 2 / Plan à un facteur à plusieurs niveaux

I / Introduction.

Sans ce chapitre, nous allons étudier un plan à un seul facteur X , et X a k niveaux notés x_1, \dots, x_k .

Pour chaque niveau x_i de X , n_i essais sont réalisés la matrice des données est alors donnée sous la forme

niveau essai	x_1	x_2	...	x_k
1	y_{11}	y_{21}		y_{k1}
...				
n_i	y_{i1}	y_{i2}		y_{ik}

n_i pour $i=1, k = n$ le nombre d'essais au niveau x_i .

y_{ij} est la réponse au niveau x_i pour le $j^{\text{ème}}$ essai

On note par $n = \sum_{i=1}^k n_i$ la taille globale de l'échantillon réponse.

Le problème est de vérifier si le facteur a un effet sur le phénomène étudié.

L'étude consiste alors de comparer les moyennes de différents niveaux du facteur X .

Le modèle mathématique : $y_{ij} = \mu_i + \epsilon_{ij}$ $i=1, k$ $j=1, n_i$

y_{ij} est la réponse du $i^{\text{ème}}$ niveau au $j^{\text{ème}}$ essai

μ_i est la moyenne du $i^{\text{ème}}$ niveau

ϵ_{ij} est une erreur aléatoire

Rq: En pratique $(\epsilon_{ij})_{i,j}$ est généralement supposée être indépendantes, de moyenne nulle et de variance $\sigma^2 < \infty$ et $\epsilon_{ij} \sim N(0, \sigma)$

II / Estimation des paramètres du modèle

Pour estimer les paramètres $\mu_i, i=1, k$ (moyenne), on utilise le critère des moindres carrés (CMC) qui consiste à minimiser la somme des erreurs quadratiques

$$\epsilon_{ij} = y_{ij} - \mu_i$$

Pb min Δ avec

$$\Delta = \sum_{i=1}^k \sum_{j=1}^{n_i} \varepsilon_{ij}^2 = \sum_{i=1}^k \sum_{j=1}^{n_i} (y_{ij} - \mu_i)^2$$

On désigne par $\alpha_i = \mu_i - \mu$ l'écart existant entre la moyenne au $i^{\text{ème}}$ niveau et la moyenne globale $\mu = \frac{1}{n} \sum_{i=1}^k n_i \mu_i$. α_i est l'effet du facteur au $i^{\text{ème}}$ niveau sur la réponse y .

Ainsi
$$\Delta = \sum_{i=1}^k \sum_{j=1}^{n_i} (y_{ij} - \mu_i - \mu)^2$$

II. 1/ Estimation de la moyenne globale μ

$$\frac{\partial \Delta}{\partial \mu} = 0 \Leftrightarrow -2 \sum_{i=1}^k \sum_{j=1}^{n_i} (y_{ij} - \alpha_i - \mu) = 0$$

$$\Leftrightarrow \sum_{i=1}^k \sum_{j=1}^{n_i} y_{ij} - \sum_{i=1}^k n_i \alpha_i - \mu \sum_{i=1}^k n_i = 0$$

On a:
$$\sum_{i=1}^k n_i \alpha_i = \sum_{i=1}^k n_i (\mu_i - \mu) = 0$$

D'où
$$\hat{\mu} = \frac{1}{n} \sum_{i=1}^k \sum_{j=1}^{n_i} y_{ij} = \bar{y}_{\cdot\cdot} = \bar{y}$$

II. 2/ Estimation des effets α_i

$$\frac{\partial \Delta}{\partial \alpha_i} = 0 \Leftrightarrow -2 \sum_{j=1}^{n_i} (y_{ij} - \alpha_i - \mu) = 0 \text{ pour le } i^{\text{ème}} \text{ niveau}$$

$$\Leftrightarrow \sum_{j=1}^{n_i} y_{ij} - n_i \alpha_i - n_i \mu = 0$$

$$\Leftrightarrow \hat{\alpha}_i = \frac{1}{n_i} \sum_{j=1}^{n_i} y_{ij} - \hat{\mu} = \bar{y}_{i\cdot} - \bar{y}$$

On a $\mu_i = \alpha_i + \mu \Rightarrow \hat{\mu}_i = \hat{\alpha}_i + \hat{\mu} = \bar{y}_{i\cdot}$

II. 3/ Estimation de la variance σ^2

La variance est estimée par la méthode du maximum de vraisemblance sous l'hypothèse $\varepsilon_{ij} \sim N(0, \sigma^2)$

Donc $y_{ij} \sim N(\mu_i, \sigma)$

La fonction de vraisemblance L est donnée par

$$L(y, \sigma) = \prod_{i=1}^k \prod_{j=1}^{n_i} f_{y_j} (y_{ij}) \quad y = (y_{11}, \dots, y_{kn_k})$$

$$\begin{aligned} \ln L(y, \sigma) &= \sum_{i=1}^k \sum_{j=1}^{n_i} \ln f_{y_j} (y_{ij}) \\ &= \sum_{i=1}^k \sum_{j=1}^{n_i} \ln \left[\frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2\sigma^2} (y_{ij} - \mu_i)^2} \right] \\ &= -n \ln(2\pi\sigma) - \frac{1}{2\sigma^2} \sum_{i=1}^k \sum_{j=1}^{n_i} (y_{ij} - \mu_i)^2 \end{aligned}$$

$$\frac{\partial \ln L(y, \sigma)}{\partial \sigma} = 0 \quad (\Rightarrow) -n\sigma^{-1} + \frac{1}{\sigma^3} \sum_{i=1}^k \sum_{j=1}^{n_i} (y_{ij} - \mu_i)^2 = 0$$

$$(\Rightarrow) -n\sigma^2 + \sum_{i=1}^k \sum_{j=1}^{n_i} (y_{ij} - \mu_i)^2 = 0$$

$$\boxed{\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^k \sum_{j=1}^{n_i} (y_{ij} - \hat{\mu}_i)^2}$$

III / Loi des estimateurs

III.1 / Loi de $\hat{\mu} = \bar{y}$

$$y_{ij} \sim N(\mu_i, \sigma) \Rightarrow \sum_{i=1}^k \sum_{j=1}^{n_i} y_{ij} \sim N(n\mu, \sqrt{n}\sigma)$$

$$\Rightarrow \bar{y} \sim N\left(\mu, \frac{\sigma}{\sqrt{n}}\right) \quad E(\bar{y}) = \mu \quad \bar{y} \text{ sans biais}$$

III.2 / Loi de $\hat{\mu}_i = \bar{y}_{i\cdot}$

$$y_{ij} \sim N(\mu_i, \sigma) \quad \sum_{j=1}^{n_i} y_{ij} \sim N(n_i \mu_i, \sqrt{n_i} \sigma)$$

$$\text{d'où } \bar{y}_{i\cdot} \sim N\left(\mu_i, \frac{\sigma}{\sqrt{n_i}}\right) \quad E(\bar{y}_{i\cdot}) = \mu_i \quad \bar{y}_{i\cdot} \text{ sans biais}$$

III.3 / Loi de $\hat{\sigma}^2$

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^k \sum_{j=1}^{n_i} (y_{ij} - \bar{y}_{i\cdot})^2$$

$$\text{on a } \frac{n \hat{\sigma}^2}{\sigma^2} = \sum_{i=1}^k \sum_{j=1}^{n_i} \left(\frac{y_{ij} - \bar{y}_{i\cdot}}{\sigma} \right)^2 \sim \chi_{n-k}^2$$

$$E \left(\sum_{i=1}^k \sum_{j=1}^{n_i} \left[\frac{y_{ij} - \bar{y}_{i\cdot}}{\sigma} \right]^2 \right) = n - k$$

$$\Rightarrow \frac{1}{n-k} \sum_{i=1}^k \sum_{j=1}^{n_i} (y_{ij} - \bar{y}_{i\cdot})^2 \text{ est sans biais}$$

IV / Validation du modèle.

On utilise l'analyse de la variance qui consiste à

Test : $H_0 : \mu_1 = \dots = \mu_k$ vs $H_1 : \exists i \neq j / \mu_i \neq \mu_j$

Test de pas d'effet du facteur contre il ya un effet ce qui signifie

Test : $H_0 : \alpha_i = 0 \quad i=1, k$ vs $H_1 : \exists i \mu_i \neq 0$

IV.1 / Equation de l'analyse de la variance.

On a

$$\sum_{i=1}^k \sum_{j=1}^{n_i} (y_{ij} - \bar{y})^2 = \sum_{i=1}^k \sum_{j=1}^{n_i} (y_{ij} - \bar{y}_{i\cdot} + \bar{y}_{i\cdot} - \bar{y})^2$$

$$= \sum_{i=1}^k \sum_{j=1}^{n_i} (y_{ij} - \bar{y}_{i\cdot})^2 + \sum_{i=1}^k \sum_{j=1}^{n_i} (\bar{y}_{i\cdot} - \bar{y})^2 + 2 \sum_{i=1}^k \sum_{j=1}^{n_i} (y_{ij} - \bar{y}_{i\cdot})(\bar{y}_{i\cdot} - \bar{y})$$

$$= \sum_{i=1}^k \sum_{j=1}^{n_i} (y_{ij} - \bar{y}_{i\cdot})^2 + \sum_{i=1}^k n_i (\bar{y}_{i\cdot} - \bar{y})^2 + 2 \sum_{i=1}^k n_i (\bar{y}_{i\cdot} - \bar{y}) \underbrace{\sum_{j=1}^{n_i} (y_{ij} - \bar{y}_{i\cdot})}_{=0}$$

A'ou

$$\frac{1}{n} \sum_{i=1}^k \sum_{j=1}^{n_i} (y_{ij} - \bar{y})^2 = \frac{1}{n} \sum_{i=1}^k \sum_{j=1}^{n_i} (y_{ij} - \bar{y}_{i\cdot})^2 + \frac{1}{n} \sum_{i=1}^k n_i (\bar{y}_{i\cdot} - \bar{y})^2$$

$$S_T^2 = S_R^2 + S_X^2$$

variance totale = variance résiduelle + variance due au facteur

IV.2 Calcul de $E(S_T^2)$, $E(S_X^2)$ et $E(S_R^2)$

On a $\sum_{i=1}^k \sum_{j=1}^{n_i} (y_{ij} - \bar{y})^2 \sim \chi_{n-1}^2$

$$E\left(\frac{1}{n} \sum_{i=1}^k \sum_{j=1}^{n_i} (y_{ij} - \bar{y})^2\right) = \frac{1}{n} (n-1)$$

$$\Rightarrow \frac{1}{n} \sum_{i=1}^k \sum_{j=1}^{n_i} (y_{ij} - \bar{y})^2 = \frac{(n-1)\sigma^2}{n} = E(S_T^2)$$

ET $\frac{n S_T^2}{\sigma^2} \sim \chi_{n-1}^2$

$$E(S_X^2) = \frac{1}{n} \sum_{i=1}^k n_i E(\bar{y}_{i\cdot} - \bar{y})^2$$

$$\sum_{i=1}^k n_i \left(\frac{\bar{y}_{i\cdot} - \bar{y}}{\sigma}\right)^2 \sim \chi_{k-1}^2$$

$$E(S_X^2) = \frac{1}{n} \frac{k-1}{\sigma^2}$$

$$\sum_{i=1}^k \sum_{j=1}^{n_i} \left(\frac{y_{ij} - \bar{y}_{i\cdot}}{\sigma} \right)^2 \sim \chi_{n-k}^2$$

$$E(S_R^2) = \frac{1}{n} \sigma^2 E(\chi_{n-k}^2) = \frac{n-k}{n} \sigma^2$$

$$E(S_X^2) = E(S_T^2) - E(S_R^2) \\ = \frac{(n-1)}{n} \sigma^2 - \frac{n-k}{n} \sigma^2 = \frac{\sigma^2}{n} (k-1)$$

Rq: Sous H_0 $S_R^2 \perp S_X^2$

Et donc

$$\frac{\sum_{i=1}^k n_i \left(\frac{\bar{y}_{i\cdot} - \bar{y}_{\cdot\cdot}}{\sigma} \right)^2 / (k-1)}{\sum_{i=1}^k \sum_{j=1}^{n_i} \left(\frac{y_{ij} - \bar{y}_{i\cdot}}{\sigma} \right)^2 / (n-k)} = \frac{S_X^2 / (k-1)}{S_R^2 / (n-k)} \sim F(k-1, n-k)$$

IV.3 / Tableau d'ANOVA

Source de variabilité	d.L	CM	F_{exp}	F_{Tab}
Variance due au facteur X S_X^2	$k-1$	$S_X^2 / (k-1)$	$\frac{S_X^2 / (k-1)}{S_R^2 / (n-k)}$	$k\alpha$ lu sur la table $F_{\alpha}(k-1, n-k)$
Variance résiduelle S_R^2	$n-k$	$S_R^2 / (n-k)$		
Variance totale S_T^2	$n-1$			

$$Rc = \left[\frac{\frac{S_X^2}{k-1}}{\frac{S_R^2}{n-k}} > k\alpha \right] \text{ d'un seuil fixe!}$$