


# Plans d'expériences

## M2 Chimie ICAP Arômes - Parfums - Cosmétiques

Elodie Brunel

Université de Montpellier – Faculté des Sciences

2024-2025



## Séance 2 : Analyse de la Variance

## Données - Exemple

- ▶ Analyse sensorielles de plusieurs produits (parfums) par des juges (experts)
- ▶ Score attribué à chaque produit pour différents critères (l'intensité, la durée, la qualité, la note de tête, la note de cœur et la note de fond).

Juge	Produit	intensité	durée	qualité	...
J1	P4	4	3	2	...
J1	P1	8	5	2	...
⋮	⋮	⋮	⋮	⋮	⋮
J2	P4	7	2	1	...
J2	P2	4	3	5	...

## Données - Exemple

Exemple : 2 produits, 2 juges et 2 répétitions.

	J1	J2	moyenne
Prod. 1	4	3	4
	5	4	
Prod. 2	2	1	2
	2	3	
moyenne	3.25	2.75	3

Juge	Prod.	Score
J1	P1	4
J1	P1	5
J1	P2	2
J1	P2	2
J2	P1	3
J2	P1	4
J2	P2	1
J2	P2	3

## Notations

- ▶  $Y$  variable réponse quantitative (Score)
- ▶  $X_1, X_2$  facteurs ou variables qualitatives à  $I$  et  $J$  modalités ou niveaux ( $X_1$  : Produit 1 ou 2;  $X_2$  : Juge 1 ou 2)
- ▶  $n_{ij}$  : nombre de répétitions pour le couple  $(i, j)$ .

obs	$X_1$ : Produit $i$	$X_2$ : Juge $j$	$Y$ : Score $y_{ijk}$
1	1	1	$y_{111} = 4$
2	1	1	$y_{112} = 5$
3	1	2	$y_{121} = 2$
4	1	2	$y_{122} = 2$
5	2	1	$y_{211} = 3$
6	2	1	$y_{212} = 4$
7	2	2	$y_{221} = 1$
8	2	2	$y_{222} = 3$

$y_{ijk}$  : observation  $k$  du score du juge  $i$  pour le produit  $j$ .

On cherche à savoir :

- ▶ s'il existe un effet "produit" sur le score.
- ▶ s'il existe un effet "juge" sur la note.
- ▶ s'il existe une interaction entre les deux facteurs.

**Interaction** : l'effet d'un facteur sur  $Y$  diffère selon les modalités de l'autre.

Exemple :

**pas d'interaction** : l'écart entre les scores de deux juges reste constant quel que soit le produit évalué.

**présence d'interaction** : selon le produit l'écart de scores entre deux juges varie.

## Modèle d'Analyse de la variance à deux facteurs avec interaction :

Pour  $i = 1, \dots, I$ ,  $j = 1, \dots, J$  et  $k = 1, \dots, n_{ij}$ , le modèle s'écrit :

$$Y_{ijk} = \mu + \alpha_i + \beta_j + \gamma_{ij} + \varepsilon_{ijk}$$

avec  $\varepsilon_{ijk} \sim \mathcal{N}(0, \sigma^2)$

et  $\varepsilon_{ijk}$  non corrélés.

- $\mu$  moyenne globale de  $Y$  (du score) quel que soit le juge ou le produit
- $\alpha_i$  effet du niveau  $i$  du facteur  $X_1$  (effet "produit")
- $\beta_j$  effet du niveau  $j$  du facteur  $X_2$  (effet "juge")
- $\gamma_{ij}$  effet de l'interaction des facteurs  $X_1$  et  $X_2$  sur les niveaux  $i$  et  $j$ .
- $\varepsilon_{ijk}$  erreur du modèle de variance commune  $\sigma^2$ .

Le modèle linéaire va fournir un cadre statistique qui permet de mettre en place des tests d'hypothèse pour tester les effets des facteurs.



## Modèle d'Analyse de la variance à deux facteurs avec interaction :

Ecriture du modèle pour notre exemple avec **interaction** :

$$\left\{ \begin{array}{l} y_{111} = \mu + \alpha_1 + \beta_1 + \gamma_{11} + \varepsilon_{111} \\ y_{112} = \mu + \alpha_1 + \beta_1 + \gamma_{11} + \varepsilon_{112} \\ y_{121} = \mu + \alpha_1 + \beta_2 + \gamma_{12} + \varepsilon_{121} \\ y_{122} = \mu + \alpha_1 + \beta_2 + \gamma_{12} + \varepsilon_{122} \\ y_{211} = \mu + \alpha_2 + \beta_1 + \gamma_{21} + \varepsilon_{211} \\ y_{212} = \mu + \alpha_2 + \beta_1 + \gamma_{21} + \varepsilon_{212} \\ y_{221} = \mu + \alpha_2 + \beta_2 + \gamma_{22} + \varepsilon_{221} \\ y_{222} = \mu + \alpha_2 + \beta_2 + \gamma_{22} + \varepsilon_{222} \end{array} \right.$$

Ecriture matricielle du modèle **avec interaction** :

$$\underbrace{\begin{pmatrix} y_{111} \\ y_{112} \\ y_{121} \\ y_{122} \\ y_{211} \\ y_{212} \\ y_{221} \\ y_{222} \end{pmatrix}}_Y = \underbrace{\begin{pmatrix} 1 & 1 & 0 & 1 & 0 & 1 & 0 & 0 & 0 \\ 1 & 1 & 0 & 1 & 0 & 1 & 0 & 0 & 0 \\ 1 & 1 & 0 & 0 & 1 & 0 & 1 & 0 & 0 \\ 1 & 1 & 0 & 0 & 1 & 0 & 1 & 0 & 0 \\ 1 & 0 & 1 & 1 & 0 & 0 & 0 & 1 & 0 \\ 1 & 0 & 1 & 1 & 0 & 0 & 0 & 1 & 0 \\ 1 & 0 & 1 & 0 & 1 & 0 & 0 & 0 & 1 \\ 1 & 0 & 1 & 0 & 1 & 0 & 0 & 0 & 1 \end{pmatrix}}_X \underbrace{\begin{pmatrix} \mu \\ \alpha_1 \\ \alpha_2 \\ \beta_1 \\ \beta_2 \\ \gamma_{11} \\ \gamma_{12} \\ \gamma_{21} \\ \gamma_{22} \end{pmatrix}}_{\beta} + \underbrace{\begin{pmatrix} \varepsilon_{111} \\ \varepsilon_{112} \\ \varepsilon_{121} \\ \varepsilon_{122} \\ \varepsilon_{211} \\ \varepsilon_{212} \\ \varepsilon_{221} \\ \varepsilon_{222} \end{pmatrix}}_{\varepsilon}$$

c'est-à-dire :

$$Y = X\beta + \varepsilon \text{ avec } \mathbb{E}(\varepsilon) = 0 \text{ et } \text{Var}(\varepsilon) = \sigma^2 I_8$$

# Contraintes

Il y a  $1 + I + J + IJ$  paramètres mais seulement  $IJ$  paramètres "libres", par ajout de contraintes pour l'identifiabilité du modèle :

effet du facteur  $X_1$  :

$$\sum_{i=1}^I \alpha_i = 0$$

effet du facteur  $X_2$  :

$$\sum_{j=1}^J \beta_j = 0$$

interactions :

$$\forall i, \sum_{j=1}^J \gamma_{ij} = 0 \text{ et } \forall j, \sum_{i=1}^I \gamma_{ij} = 0$$

## Contraintes sur l'exemple :

Il y a 9 paramètres dans le modèle avec les contraintes suivantes :

effet du facteur  $X_1$  :

$$\alpha_1 + \alpha_2 = 0 \iff \alpha_1 = -\alpha_2$$

effet du facteur  $X_2$  :

$$\beta_1 + \beta_2 = 0 \iff \beta_1 = -\beta_2$$

interactions :

$$\begin{cases} \gamma_{11} + \gamma_{12} = 0 \\ \gamma_{21} + \gamma_{22} = 0 \\ \gamma_{11} + \gamma_{21} = 0 \\ \gamma_{12} + \gamma_{22} = 0 \end{cases} \iff \begin{cases} \gamma_{11} = -\gamma_{12} = -\gamma_{21} \\ \gamma_{21} = -\gamma_{22} = \gamma_{12} \end{cases}$$

Donc seulement 4 paramètres à estimer :  $\mu$ ,  $\alpha_1$ ,  $\beta_1$ ,  $\gamma_{11}$  (les autres se déduisent).

Avec ces contraintes, le modèle devient :

$$\underbrace{\begin{pmatrix} y_{111} \\ y_{112} \\ y_{121} \\ y_{122} \\ y_{211} \\ y_{212} \\ y_{221} \\ y_{222} \end{pmatrix}}_Y = \underbrace{\begin{pmatrix} 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & -1 \\ 1 & 1 & -1 & -1 \\ 1 & 1 & -1 & 1 \\ 1 & -1 & 1 & 1 \\ 1 & -1 & 1 & -1 \\ 1 & -1 & -1 & -1 \\ 1 & -1 & -1 & 1 \end{pmatrix}}_X \underbrace{\begin{pmatrix} \mu \\ \alpha_1 \\ \beta_1 \\ \gamma_{11} \end{pmatrix}}_{\beta} + \underbrace{\begin{pmatrix} \varepsilon_{111} \\ \varepsilon_{112} \\ \varepsilon_{121} \\ \varepsilon_{122} \\ \varepsilon_{211} \\ \varepsilon_{212} \\ \varepsilon_{221} \\ \varepsilon_{222} \end{pmatrix}}_{\varepsilon}$$

# Estimation des paramètres du modèle

On cherche à minimiser la somme des carrés des erreurs du modèle ;

$$\sum_{i,j,k} \varepsilon_{ijk} = (Y - X\beta)' (Y - X\beta)$$

La solution de ce problème est obtenue en résolvant :

$$X'Y = X'X\beta$$

- ▶ si  $X'X$  est une matrice inversible, l'estimateur des moindres carrés de  $\beta$  est :

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

- ▶ Propriétés :  $\mathbb{E}(\hat{\beta}) = \beta$  (sans biais),  $\text{Var}(\hat{\beta}) = \sigma^2(X'X)^{-1}$  et  $\hat{\beta} - \beta \sim \mathcal{N}(0, \sigma^2(X'X)^{-1})$ .

# Calcul des estimateurs des paramètres du modèle

On note :

- moyenne globale  $\bar{Y} = \frac{1}{n} \sum_{i,j} y_{ij}$  moyenne de tous les  $y_{ij}$ .

$$\bar{Y} = \frac{1}{8}(4 + 5 + 2 + 2 + 3 + 4 + 1 + 3) = 3$$

- moyennes marginales de  $X_1$  :

- ▶  $\bar{Y}_{1.} = \frac{1}{n_{1.}} \sum_j y_{1j}$  moyenne de tous les  $y_{1j}$  (tous les scores du produit P1)

$$\bar{Y} = \frac{1}{4}(4 + 5 + 3 + 4) = 4$$

- ▶  $\bar{Y}_{2.} = \frac{1}{n_{2.}} \sum_j y_{2j}$  moyenne de tous les  $y_{2j}$  (tous les scores de produit P2)

$$\bar{Y}_{2.} = \frac{1}{4}(2 + 2 + 1 + 3) = 2$$

# Calcul des estimateurs des paramètres du modèle

– moyennes marginales de  $X_2$  :

- ▶  $\bar{Y}_{.1} = \frac{1}{n_{.1}} \sum_i y_{i1}$  moyenne de tous les  $y_{i1}$  (tous les scores du Juge  $J1$ )

$$\bar{Y}_{.1} = \frac{1}{4}(4 + 5 + 2 + 2) = 3.25$$

- ▶  $\bar{Y}_{.2} = \frac{1}{n_{.2}} \sum_i y_{i2}$  moyenne de tous les  $y_{i2}$  (tous les scores du Juge  $J2$ )

$$\bar{Y}_{.2} = \frac{1}{4}(3 + 4 + 1 + 3) = 2.75$$



Toutes ces formules peuvent se visualiser à l'aide d'un tableau :

$X_1$  : facteur 1 = Produit

$X_2$  : facteur 2 = Juge

score $Y$	J1	J2	moyenne (en lignes)
Prod. 1	4	3	$\bar{Y}_{1.} = 4$
	5	4	
Prod. 2	2	1	$\bar{Y}_{2.} = 2$
	2	3	
moyenne (en colonnes)	$\bar{Y}_{.1} = 3.25$	$\bar{Y}_{.2} = 2.75$	$\bar{Y} = 3$

## Calcul des estimateurs des paramètres du modèle

On estime :

$$\mu \text{ par } \hat{\mu} = \bar{Y}$$

$$\alpha_1 \text{ par } \hat{\alpha}_1 = \bar{Y}_{1.} - \bar{Y}$$

$$\beta_1 \text{ par } \hat{\beta}_1 = \bar{Y}_{.1} - \bar{Y}$$

Dans notre exemple, cela donne :

$$\begin{cases} \hat{\mu} = 3 \\ \hat{\alpha}_1 = 4 - 3 = 1 \text{ (et } \hat{\alpha}_2 = -1 \text{ )} \\ \hat{\beta}_1 = 4 - 3.75 = 0.25 \text{ (et } \hat{\beta}_2 = -0.25 \text{ )} \end{cases}$$

Enfin pour estimer l'interaction  $\gamma_{11}$ ,

on écrit :

$$\bar{Y}_{11} = \bar{Y} + \hat{\alpha}_1 + \hat{\beta}_1 + \hat{\gamma}_{11}$$

$$4.5 = 3 + 1 + 0.25 + \hat{\gamma}_{11}$$

D'où,  $\hat{\gamma}_{11} = 0.25$

# Tableau récapitulatif des formules des paramètres estimés

Attention!!! Cas particulier du plan équilibré complet équilibré : on a fait toutes les "expériences" possibles (tous les juges ont donné une note à tous les produits) et le nombre de répétitions est identique = 2 pour chaque expérience.

- ▶  $\hat{\mu} = \bar{Y}$
- ▶  $\hat{\alpha}_i = \bar{Y}_{i.} - \bar{Y}$
- ▶  $\hat{\beta}_j = \bar{Y}_{.j} - \bar{Y}$
- ▶  $\hat{\gamma}_{ij} = \bar{Y}_{ij} - \bar{Y}_{i.} - \bar{Y}_{.j} + \bar{Y}$

## Avec R

On peut faire tous les calculs avec R et tester la significativité des facteurs :

```
model<- lm(score~ produit*juge, data= D)
```

Coefficients:

	Estimate	Std. Error	t value	Pr(> t )	
(Intercept)	3.0000	0.3062	9.798	0.000608	***
produit1	1.0000	0.3062	3.266	0.030906	*
juge1	0.2500	0.3062	0.816	0.460051	
produit1:juge1	0.2500	0.3062	0.816	0.460051	

On retrouve bien les estimations des paramètres calculés "à la main" :

$$\underbrace{\hat{\mu} = 3}_{\text{"intercept"}} ; \hat{\alpha}_1 = 1 ; \hat{\beta}_1 = 0.25 ; \hat{\gamma}_{11} = 0.25 .$$

## Décomposition de la variabilité

Cas complet et équirépété : les sommes des carrés s'additionnent :

$$SCT = SC_1 + SC_2 + SC_{12} + SCR$$

$$\begin{aligned} SCT &= \sum_{i,j,k} (y_{ijk} - \bar{Y})^2 = \underbrace{\sum_{i,j,k} (\bar{Y}_{i.} - \bar{Y})^2}_{SC_1: \text{facteur 1}} \\ &+ \underbrace{\sum_{i,j,k} (\bar{Y}_{.j} - \bar{Y})^2}_{SC_2: \text{facteur 2}} \\ &+ \underbrace{\sum_{i,j,k} (\bar{Y}_{ij} - \bar{Y}_{i.} - \bar{Y}_{.j} + \bar{Y})^2}_{SC_{12}: \text{interaction}} \\ &+ \underbrace{\sum_{i,j,k} (Y_{ijk} - \bar{Y}_{ij})^2}_{SCR: \text{résidus}} \end{aligned}$$

# Test global d'un effet : test de Fisher


Exemple Test du facteur  $X_1$  :

- ▶  $\mathcal{H}_0$  : tous les  $\alpha_i = 0$  contre  $\mathcal{H}_1$  : au moins un  $\alpha_i \neq 0$
- ▶ statistique de test :

$$F = \frac{SC_1/ddl_1}{SCR/ddl_R}$$

avec  $ddl_1$  le degré de liberté du facteur  $X_1$  soit  $ddl_1 = l - 1$  et  $ddl_R$  le degré de liberté des résidus.

- ▶ Si  $\mathcal{H}_0$  est vraie alors la loi de  $F$  est une Fisher  $\mathcal{F}(ddl_1, ddl_R)$
- ▶ Si  $F > f_{1-\alpha}$  ou si la p-value  $< \alpha$  on rejette  $\mathcal{H}_0$  au risque  $\alpha$ .



Valeurs d'une Fisher F(8,7)

# Test "ANOVA" de Fisher : tableau d'ANOVA avec formules

**Table ANOVA à deux facteurs avec interaction**

Source	Degrés de liberté	Somme des Carrés	Carrés Moyens	F - statistique de test	p-value
facteur 1	$I - 1$	$SC_1$	$\frac{SC_1}{I-1}$	$F_{1,obs}$	p-value
facteur 2	$J - 1$	$SC_2$	$\frac{SC_2}{J-1}$	$F_{2,obs}$	p-value
inter 1-2	$(I - 1)(J - 1)$	$SC_{12}$	$\frac{SC_{12}}{(I-1)(J-1)}$	$F_{12,obs}$	p-value
Résidus	$ddl_R$	$SCR$	$\frac{SCR}{n-K}$		

avec  $ddl_R = n - K - 1$  et  $K$  est la somme de tous les autres ddl.

↪ voir exercice d'application du TD.

# Test "ANOVA" de Fisher : exemple

**Table ANOVA à deux facteurs avec interaction**

Source	Degrés de liberté	Somme des Carrés	Carrés Moyens	statistique de test $F$	$p$ -value
produit	1	$SC_1 = 8$	$\frac{SC_1}{I-1} = 8$	$F_{1,obs} = 10.6667$	0.03091 *
juge	1	$SC_2 = 0.5$	$\frac{SC_2}{J-1} = 0.5$	$F_{2,obs} = 0.6667$	0.46005
interaction	1	$SC_{12} = 0.5$	$\frac{SC_{12}}{(I-1)(J-1)} = 0.5$	$F_{12,obs} = 0.6667$	0.46005
Résidus	4	$SCR = 3$	$\frac{SCR}{n-K} = 0.75$		

avec  $ddl_R = 8 - 3 - 1 = 4$ .

↔ voir exercice d'application du TD.



## Test "ANOVA" de Fisher : avec R

On peut obtenir la Table ANOVA avec tous les tests des effets avec R en tapant les deux lignes de commandes suivantes :

```
model<- lm(score~ produit*juge, data= D)
anova(model)
```

### Analysis of Variance Table

Response: score

	Df	Sum Sq	Mean Sq	F value	Pr(>F)	
produit	1	8.0	8.00	10.6667	0.03091	*
juge	1	0.5	0.50	0.6667	0.46005	
produit:juge	1	0.5	0.50	0.6667	0.46005	
Residuals	4	3.0	0.75			

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

- Tout ceci à condition que les hypothèses du modèle soient valides :
- Vérifier la normalité de la variable d'intérêt.
  - Vérifier l'égalité des variances dans les groupes définis par les facteurs ...
  - Vérifier la non-corrélation des erreurs ...

↔ voir comment faire en pratique en TP...