

ANALYSE DE VARIANCE

Plan du Chapitre 4

1. Analyse de variance à un facteur
2. Analyse de variance à deux facteurs
 - 2.1 Facteurs croisés : cas orthogonal
 - 2.2 Facteurs croisés : cas non orthogonal
 - 2.3 Facteurs hiérarchisés
3. Des exemples d'analyses plus complexes
4. Comparaison multiple de moyennes

Analyse de variance

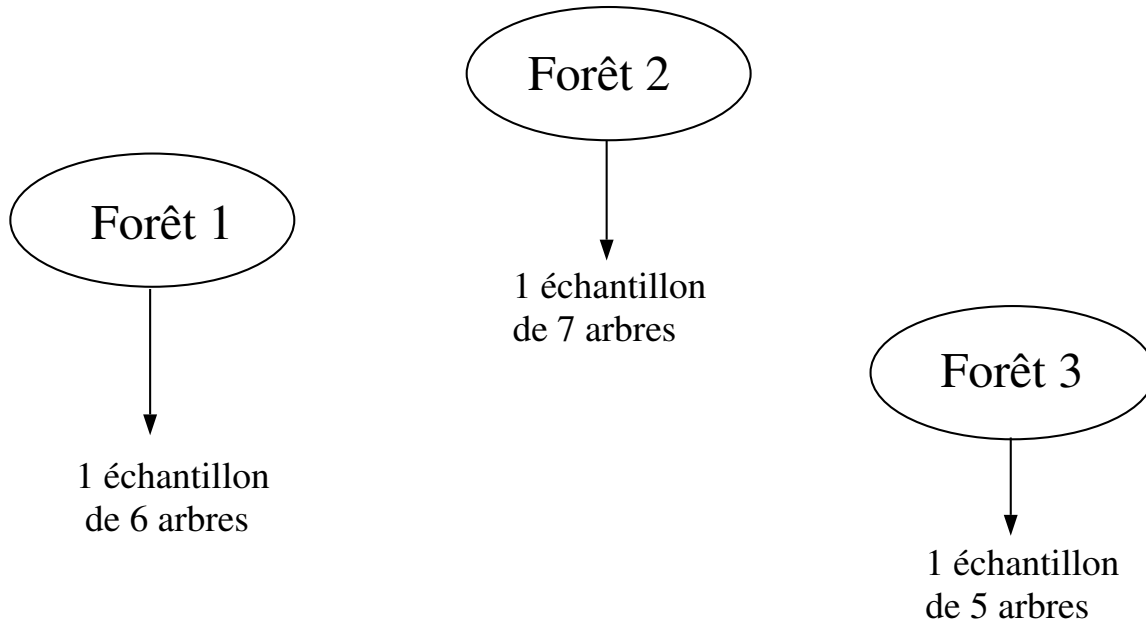


test d'une structuration des données

à l'aide de variables explicatives

de type qualitatif = facteurs

Analyse de variance à un facteur



Forêt 1	Forêt 2	Forêt 3
23.4	18.9	22.5
24.4	21.1	22.9
24.6	21.1	23.7
24.9	22.1	24.0
25.0	22.5	24.0
26.2	23.5	
	24.5	

Le vecteur des données

$$Y_n = \begin{pmatrix} Y_1 = 23.4 \\ Y_2 = 24.4 \\ Y_3 = 24.6 \\ Y_4 = 24.9 \\ Y_5 = 25.0 \\ Y_6 = 26.2 \\ Y_7 = 18.9 \\ Y_8 = 21.1 \\ Y_9 = 21.1 \\ Y_{10} = 22.1 \\ Y_{11} = 22.5 \\ Y_{12} = 23.5 \\ Y_{13} = 24.5 \\ Y_{14} = 22.5 \\ Y_{15} = 22.9 \\ Y_{16} = 23.7 \\ Y_{17} = 24.0 \\ Y_{18} = 24.0 \end{pmatrix} \rightarrow Y_{ir} = \begin{pmatrix} Y_{11} = 23.4 \\ Y_{12} = 24.4 \\ Y_{13} = 24.6 \\ Y_{14} = 24.9 \\ Y_{15} = 25.0 \\ Y_{16} = 26.2 \\ Y_{21} = 18.9 \\ Y_{22} = 21.1 \\ Y_{23} = 21.1 \\ Y_{24} = 22.1 \\ Y_{25} = 22.5 \\ Y_{26} = 23.5 \\ Y_{27} = 24.5 \\ Y_{31} = 22.5 \\ Y_{32} = 22.9 \\ Y_{33} = 23.7 \\ Y_{34} = 24.0 \\ Y_{35} = 24.0 \end{pmatrix}$$

Question posée

La structuration en forêts explique t-elle
la variabilité des données ?



Les forêts sont elles différentes ?

Si oui : quelles forêts sont différentes ?

Modèle	SCE	Ecriture du modèle
M_1 I paramètres	SCE_{M_1}	$\mu_n (= \mu_{ir}) = \mu_i = \mu + \alpha_i$



M_0 1 paramètre	SCE_{M_0}	$\mu_n (= \mu_{ir}) = \mu$
----------------------	-------------	----------------------------

Hypothèses testées

$$\begin{array}{l} \text{H}_1 \\ \exists i, \alpha_i \neq 0 \\ \exists(i, i') ; \mu_i \neq \mu_{i'} \\ \\ \forall i, \alpha_i = 0 \\ \forall(i, i') ; \mu_i = \mu_{i'} = \mu \\ \Leftrightarrow \mu_1 = \mu_2 = \dots \mu_I = \mu \\ \text{H}_0 \end{array}$$

Commandes et fichier sous SAS

```
data trv ;  
infile 'foret3' ;  
input foret hauteur ;  
run ;  
proc glm ;  
class foret ;  
model hauteur = foret ;  
run ;
```

Fichier des données

1	23.4
1	24.4
1	24.6
1	24.9
1	25.0
1	26.2
2	18.9
2	21.1
2	21.1
2	22.1
2	22.5
2	23.5
2	24.5
3	22.5
3	22.9
3	23.7
3	24.0
3	24.0

Sorties SAS

General Linear Models Procedure

Class Level Information

Class	Levels	Values
Foret	3	1 2 3

Number of observations in data set = 18

General Linear Models Procedure

Dependent Variable : HAUTEUR

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	2	25.30930159	12.65465079	7.30	0.0061
Error	15	26.00014286	1.73334286		
Corrected Total	17	51.30944444			
	R-Square	C.V.	Root MSE	HAUTEUR Mean	
	0.493268	5.651840	1.316565	23.29444	

General Linear Models Procedure

Dependent Variable : HAUTEUR

Source	DF	Type I SS	Mean Square	F Value	Pr > F
FORET	2	25.30930159	12.65465079	7.30	0.0061
Source	DF	Type III SS	Mean Square	F Value	Pr > F
FORET	2	25.30930159	12.65465079	7.30	0.0061

Tableau "Modèle"

General Linear Models Procedure

Class Level Information

Class	Levels	Values
Foret	3	1 2 3

Number of observations in data set = 18

General Linear Models Procedure

Dependent Variable : HAUTEUR

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	2	25.30930159	12.65465079	7.30	0.0061
Error	15	26.00014286	1.73334286		
Corrected Total	17	51.30944444			
R-Square		C.V.	Root MSE	HAUTEUR Mean	
0.493268		5.651840	1.316565	23.29444	

Model	I-1	$SCE_{M_0} - SCE_{M_1}$	$\frac{SCE_{M_0} - SCE_{M_1}}{I-1}$	$\frac{(SCE_{M_0} - SCE_{M_1}) / I-1}{SCE_{M_1} / N-I}$
Error	N-I	SCE_{M_1}	$\frac{SCE_{M_1}}{N-I}$	
Corrected Total	N-1	SCE_{M_0}		
R-Square		C.V.	Root MSE	HAUTEUR Mean
$\frac{SCE_{M_0} - SCE_{M_1}}{SCE_{M_0}}$		100x(Root MSE)/Hauteur Mean	$\sqrt{\frac{SCE_{M_1}}{N-I}}$	Y..


Tableau "Facteurs"

General Linear Models Procedure

Dependent Variable : HAUTEUR

Source	DF	Type I SS	Mean Square	F Value	Pr > F
FORET	2	25.30930159	12.65465079	7.30	0.0061
Source	DF	Type III SS	Mean Square	F Value	Pr > F
FORET	2	25.30930159	12.65465079	7.30	0.0061

FORET	I-1	$SCE_{M_0} - SCE_{M_1}$	$\left(\frac{SCE_{M_0} - SCE_{M_1}}{SCE_{M_1} / N-I} \right) / I-1$
-------	-----	-------------------------	--



$$SCE_{\text{totale}} = SCE_{\text{facteur}} + SCE_{\text{résiduelle}}$$

$$SCE_{\text{totale}} = \sum_n (Y_n - Y_{..})^2$$

$$SCE_{\text{facteur}} = \sum_i \sum_r (Y_{i.} - Y_{..})^2 = \text{variabilité inter - classes}$$

$$SCE_{\text{résiduelle}} = \sum_i \sum_r (Y_{ir} - Y_{i.})^2 = \text{variabilité intra - classe}$$


$SCE_{\text{totale}} = SCE_{M_0}$: variabilité totale

$SCE_{\text{facteur}} = SCE_{M_0} - SCE_{M_1}$: variabilité inter – classe

$SCE_{\text{résiduelle}} = SCE_{M_1}$: variabilité intra – classe

d'où

$$F = \frac{SCE_{\text{facteur}} / I - 1}{SCE_{\text{résiduelle}} / N - I} = \frac{(SCE_{M_0} - SCE_{M_1}) / I - 1}{SCE_{M_1} / N - I}$$



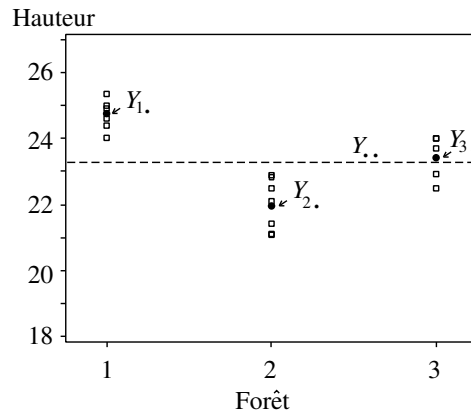
$$Y_1 = 24.75$$

$$Y_2 = 21.96$$

$$Y_3 = 23.42$$

$$(Y_1 + Y_2 + Y_3)/3 = 23.38$$

H_0 ou H_1 ?




$$Y_1 = 24.75$$

$$Y_2 = 21.96$$

$$Y_3 = 23.42$$

$$(Y_1 + Y_2 + Y_3)/3 = 23.38$$


H_0 ou H_1 ?



$$SCE_T = SCE_F + SCE_R$$

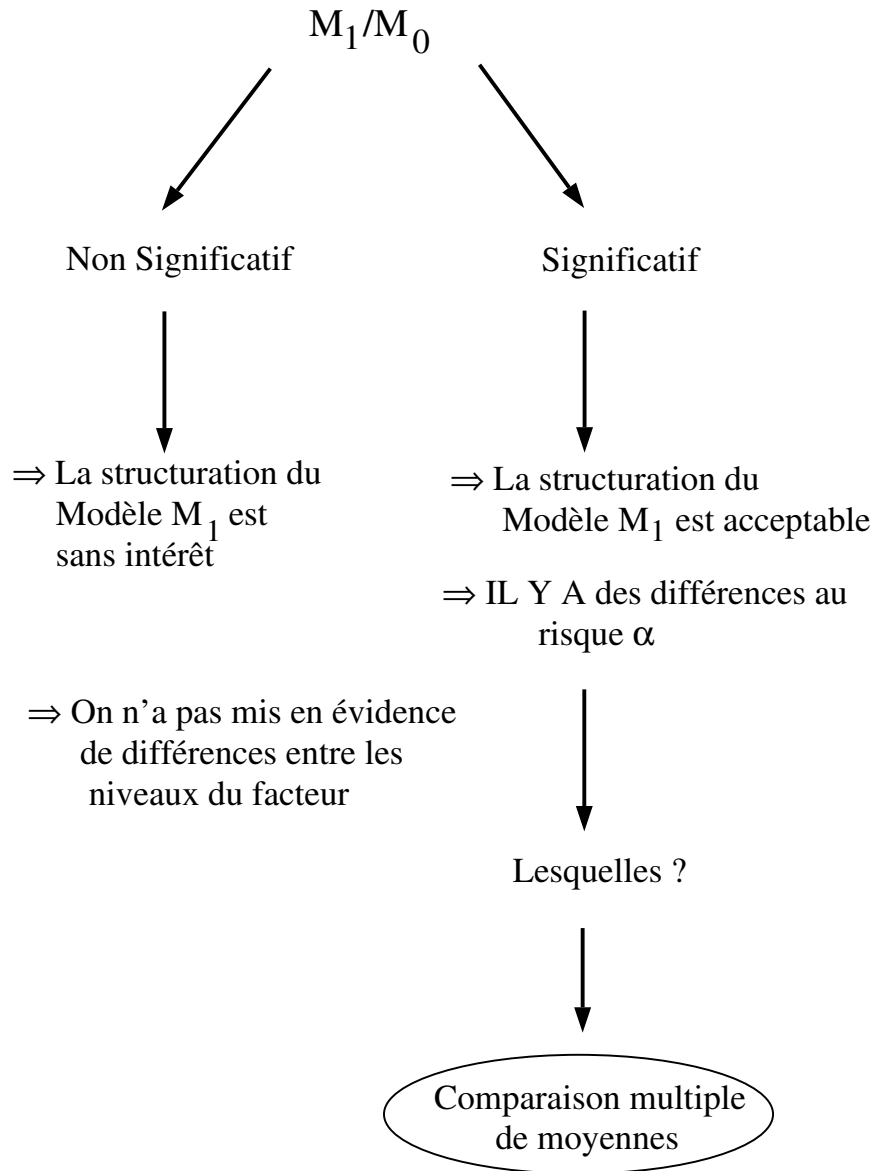
si $SCE_F \gg SCE_R \Rightarrow H_1$

si $SCE_F \simeq SCE_R \Rightarrow H_0$

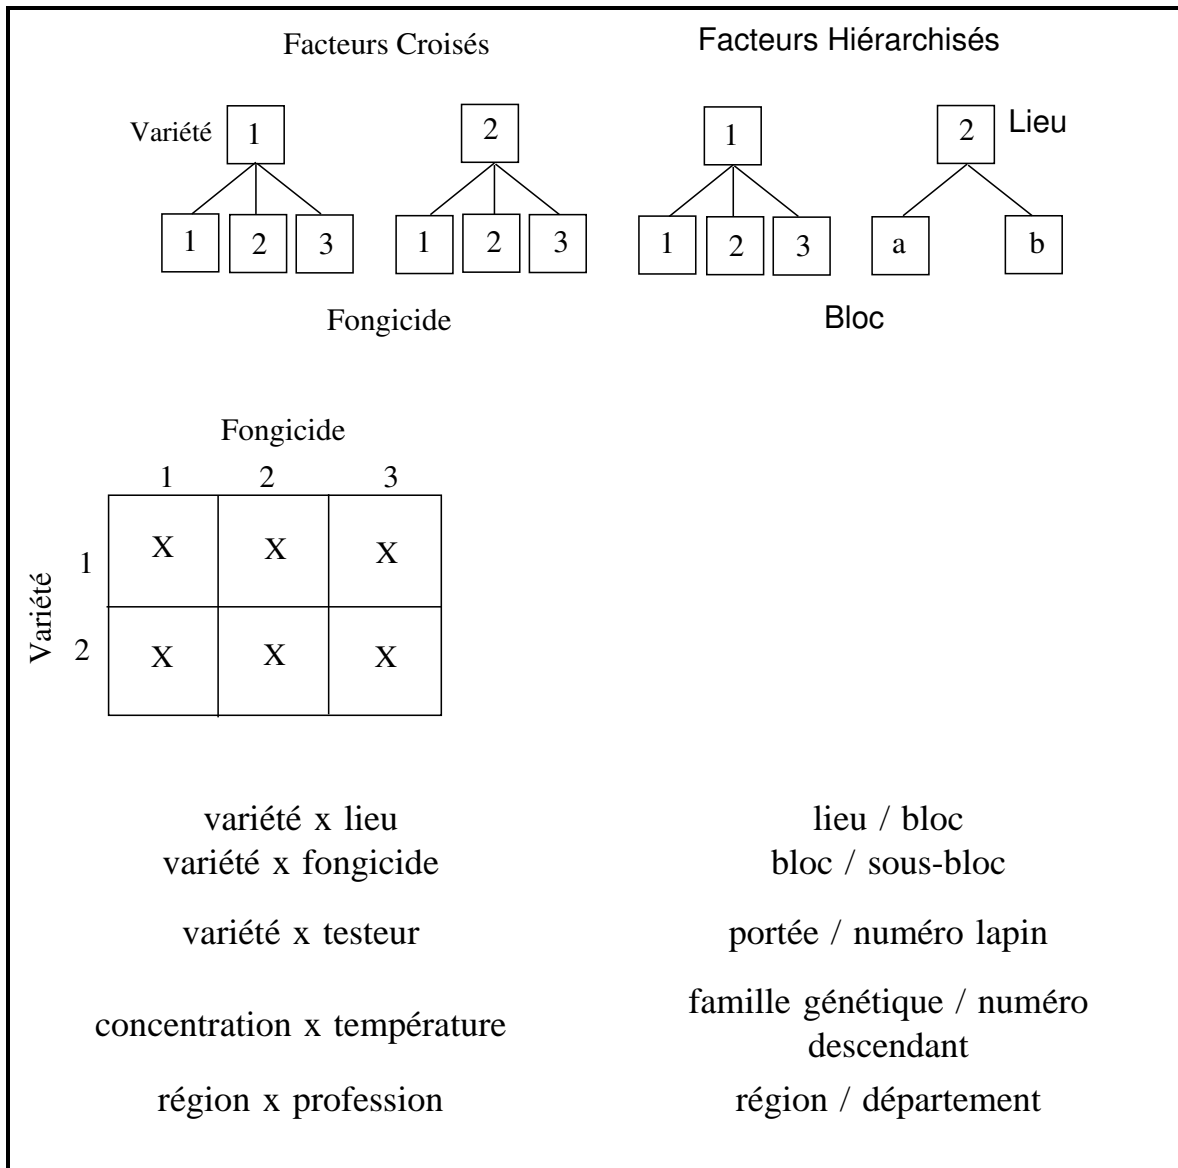



Analyse de Variance à un facteur Synthèse

TEST F modèle / ss modèle



Analyse de Variance à deux facteurs




Analyse de Variance à deux facteurs croisés

Facteur A, I niveaux

Facteur B, J niveaux

		facteurs croisés		
		Fongicide		
Variété		1	2	3
		1	X	X
2	X	X	X	

les IJ combinaisons des niveaux des facteurs A et B peuvent être étudiées



Étude du nombre de jours avant germination pour des variétés de carottes

Y_{ijk}	Variété 1	Variété 2	Variété 3
Sol 1	6 10 11	13 15	14 22
Sol 2	12 19 15 18	31	18 9 12



ex : dispositif déséquilibré

Étude de la teneur en huile de populations de tournesol

Origine	AFRIQUE	HONGRIE	MAROC
testeur 1	43.54 45.30	44.25 42.55	47.28 49.40
testeur 2	47.21 47.73	44.34 46.49	47.75 49.47

ex : dispositif équilibré

Illustration géométrique



Analyse de Variance à deux facteurs croisés cas orthogonal

Exemple d'Applications de l'Analyse de la Variance dans le cas équirépété

Etude de la teneur en huile de populations de tournesol

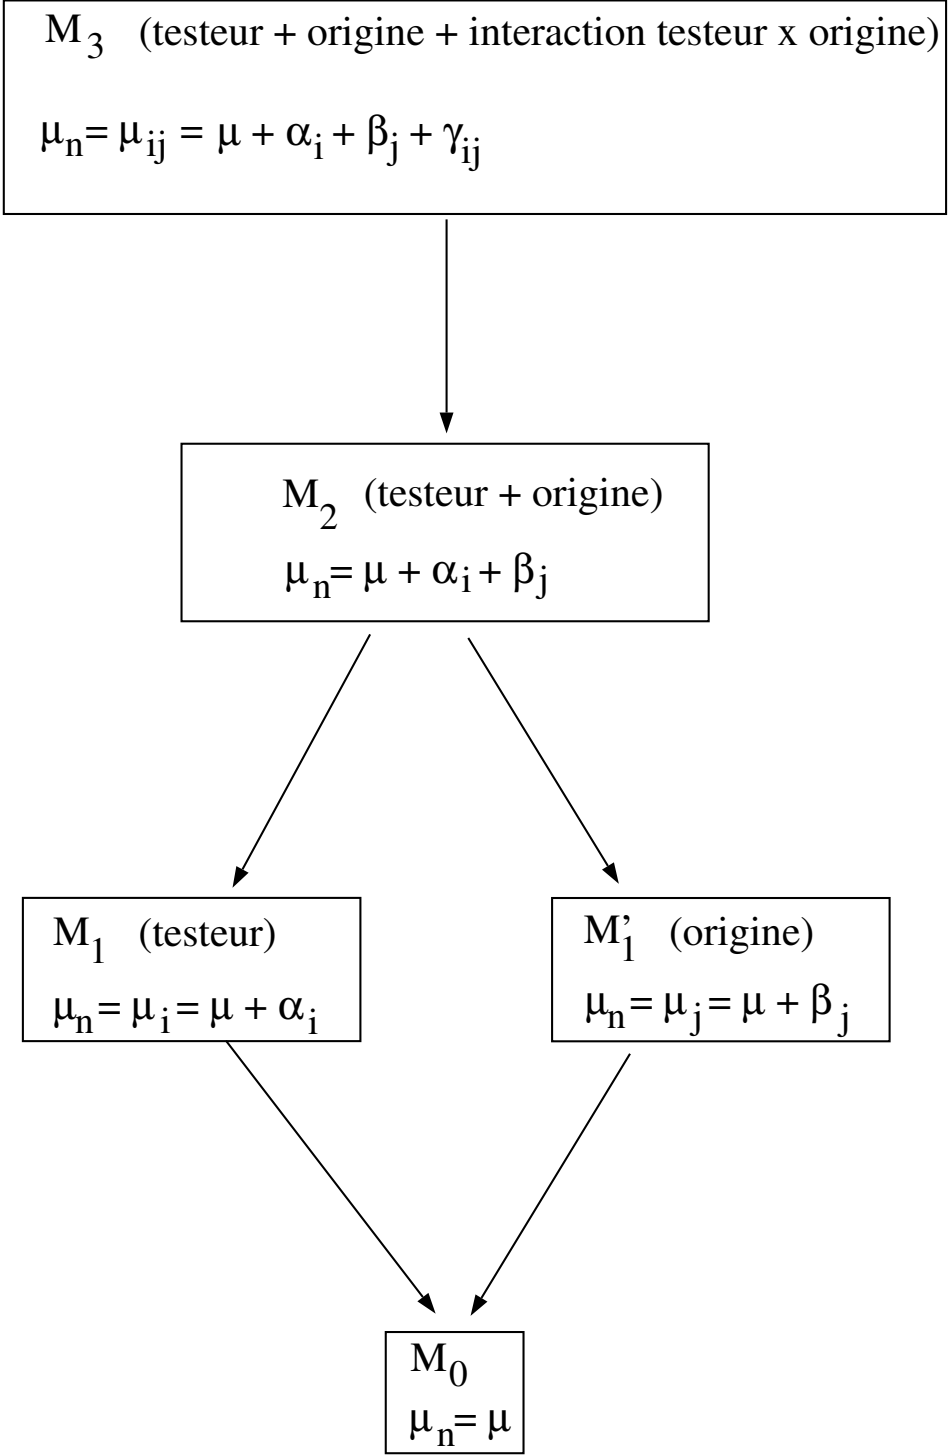
Données expérimentales

Origine	AFRIQUE	HONGRIE	MAROC
testeur 1	43.54	44.25	47.28
	45.30	42.55	49.40
testeur 2	47.21	44.34	47.75
	47.73	46.49	49.47

Facteur A = testeur, I = 2 niveaux

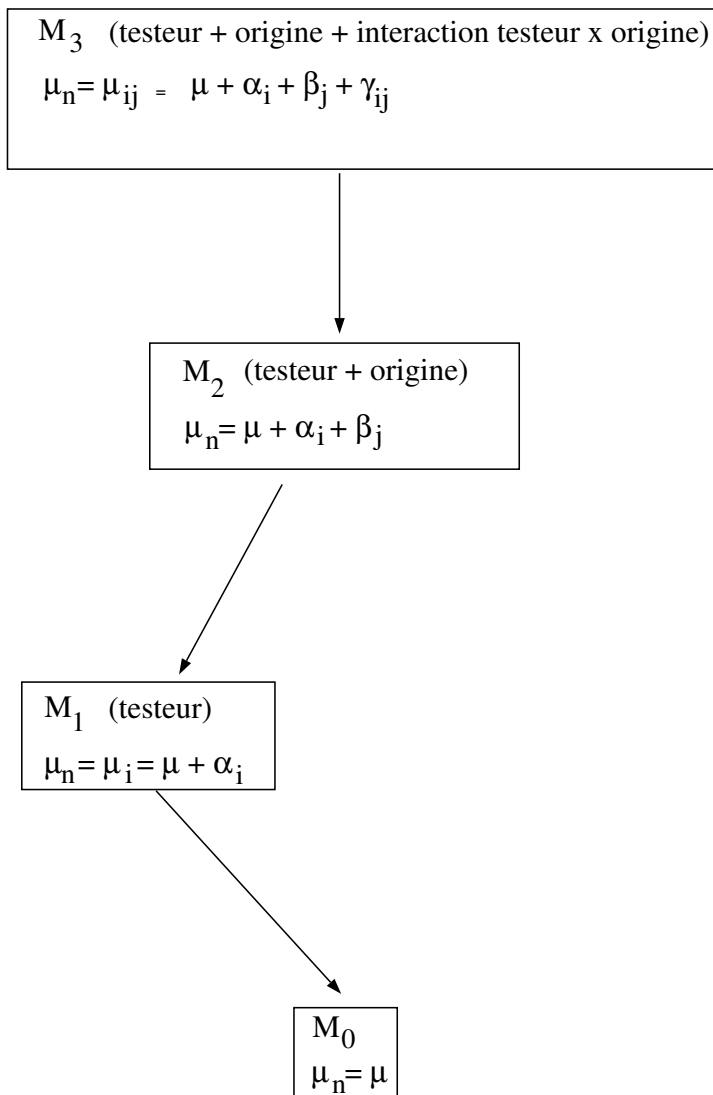
Facteur B = origine, J = 3 niveaux

répétitions par combinaison AB, r = 2



Fichier des données et Commandes SAS

```
1 1 43.54      data trv ;
1 1 45.30      infile 'tourn' ;
1 2 44.25      input testeur origine huile ;
1 2 42.55      run ;
1 3 47.28      proc glm ;
1 3 49.40      class testeur origine ;
2 1 47.21      model huile = testeur origine testeur*origine ;
2 1 47.73      run ;
2 2 44.34
2 2 46.49
2 3 47.75
2 3 49.47
```



Sortie SAS

General Linear Models Procedure

Class Level Information

Class	Levels	Values
Testeur	2	1 2
Origine	3	1 2 3

Number of observations in data set = 12

General Linear Models Procedure

Dependent Variable : HUILE

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	5	47.18144167	9.43628833	6.18	0.0233
Error	6	9.16665000	1.52777500		
Corrected Total	11	56.34809167			
	R-Square	C.V.	Root MSE	HUILE Mean	
	0.837321	2.671010	1.236032	46.27583	

General Linear Models Procedure

Dependent Variable : HUILE

Source	DF	Type I SS	Mean Square	F Value	Pr > F
TESTEUR	1	9.48740833	9.48740833	6.21	0.0470
ORIGINE	2	33.74581667	16.87290833	11.04	0.0097
TESTEUR*ORIGINE	2	3.94821667	1.97410833	1.29	0.3415
Source	DF	Type III SS	Mean Square	F Value	Pr > F
TESTEUR	1	9.48740833	9.48740833	6.21	0.0470
ORIGINE	2	33.74581667	16.87290833	11.04	0.0097
TESTEUR*ORIGINE	2	3.94821667	1.97410833	1.29	0.3415