

Analyse de Variance

Analyse de Variance à 1 Facteur

L'objectif de l'analyse de variance à 1 facteur est de tester l'égalité des moyennes théoriques d'une variable quantitative de différents groupes ou de différents niveaux du facteur considéré.

Les observations sont sous la forme :

Groupe 1	Groupe K
$x_{1,1}$	$x_{1,K}$
.	.	.
.	.	.
.	.	.
.	.	.
.	.	.
$x_{n_1,1}$	$x_{n_K,K}$
T_1		T_K
$m_1 = \frac{T_1}{n_1}$		$m_K = \frac{T_K}{n_K}$

Le modèle de cette analyse est le suivant :

$$x_{ij} = \mu + \alpha_i + e_{ij}$$

Les hypothèses testées :

H_0 : égalité des moyennes, les groupes sont homogènes ou tous les α_i prennent pour valeur 0

H_1 : les groupes ne sont pas homogènes ou au moins un des α_i est différent des autres

Les conditions d'applications :

Tous les x_{ij} suivent des lois Normales de même variance σ^2 (estimée par s_e^2), ou, ce qui est identique, les e_{ij} sont "Normaux", indépendants et de même variance σ^2 (estimée par s_e^2).

Le tableau d'Analyse de Variance est le suivant :

Origine	Σ des carrés (a)	ddl (b)	Variance (a)/(b)	F
Intergroupe	$\sum_{i=1}^K \frac{T_i^2}{n_i} - \frac{T_g^2}{N}$	K-1	S^2	$\frac{S^2}{s_e^2}$
Intragroupe	$\sum_{i=1}^K \sum_{j=1}^{n_i} x_{ji}^2 - \sum_{i=1}^K \frac{T_i^2}{n_i}$	N-K	s_e^2	
Totale	$\sum_{i=1}^K \sum_{j=1}^{n_i} x_{ji}^2 - \frac{T_g^2}{N}$	N-1		

Un programme d'ANOVA avec MATLAB :

```
function [F,F0,Pvalue] = ANOVA1(x,k);
% [F,F0,Pvalue] = ANOVA1(x,k)
%
% ANOVA oneway (10/01/2001)
%   x : data matrix
%   k : number of observation by groupe
%   soit x est une matrice de "size(n K)", avec K groupe et n
%       observations par groupe (ie chaque groupe dans une colonne)
%   soit x est un vecteur et k indique la repartition des observations
%   dans les K groupes (e.g. k(1) observation pour le premier groupe
%                       k(length(k)) observation pour le Keme groupe)
%   F : F value
%   F0 : Fseuil pour alpha = 0.05
%   Pvalue
%
% ATTENTION : Dans le cas de decomposition orthogonale de la variance,
% ===== il faudrait utiliser "la variance intra" calculee avec
%           toutes les datas => MODIFICATION de la FONCTION de
%           facon a introduire "varintra" et "df2"
%
%
N = length(x(:));
[n K] = size(x);
somx2 = sum(x(:).^2);

if K==1
    n = k;
    K = length(n);
    na = 1;
    nb = 0;
    for i=1:K
        if i>1
            na = na + n(i-1);
        end
        nb = nb + n(i);
        Ti(i) = sum(x(na:nb));
    end
    Tg = sum(Ti);
    somCinter = sum(Ti.^2./n) - Tg^2/N;
    somCintra = somx2 - sum(Ti.^2./n);
else
    [n K] = size(x);
    Ti = sum(x);
    Tg = sum(Ti);
    somCinter = sum(Ti.^2/n) - Tg^2/N;
    somCintra = somx2 - sum(Ti.^2/n);
end
somCtotal = somx2 - Tg^2/N;

%
% somCintra = -999 si varintra est donnee
% df2 = N-K ou df2 = df2
%

df1 = K-1;
df2 = N-K;

varinter = somCinter / df1;
varintra = somCintra / df2;
vartotal = somCtotal / (N-1);

F = varinter/varintra;
F0 = qf(0.95,df1,df2);
Pvalue = 1-pf(F,df1,df2);

clc;
fprintf('\n\n');
fprintf('=====\n');
fprintf(' Analysis of Variance Table \n');
```

```
fprintf('=====\n');
fprintf(' Source      d.f.      Sums of Squares      Variances      F\n');
fprintf('-----\n');
fprintf(' Inter          %2.0f          %8.2f          %8.2f
%6.3f\n',df1,somCinter,varinter,F);
fprintf(' Intra          %2.0f          %8.2f          %8.2f\n',df2,somCintra,varintra
);
fprintf(' Total          %2.0f          %8.2f          %8.2f\n',N-
1,somCtotal,vartotal);
fprintf('=====\n');
fprintf(' F          Fseuil          Pvalue\n');
fprintf('-----\n');
fprintf(' %6.3f      %6.3f          %4.7f\n',F,F0,Pvalue);
fprintf('=====\n\n\n');
```

Exercices :

```
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%
% =====
% ANALYSE DE VARIANCE
% =====
%
%
% FONCTIONS UTILISEES :
% =====
% ANOVA1.m  Bartlett.m
%
% UTILISER "help name_function" pour obtenir des informations
% sur les fonctions utilisees
%
%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%
% Exercice 1 :
% -----
% On mesure le nombre de colonies bactériennes en fonction de 5 milieux de
% culture différents (k=5). Pour chaque milieu de culture on a fait 10
% comptages (ni=10). Les caractéristiques des milieux de culture ont-ils une
% influence sur le nombre de bactéries qui se développent ? Répondre à la
% question précédente avec un seul test statistique.
%
%   A    B    C    D    E
%  10   11   7    12   7
%  12   18   14   9    6
%  8    12   10   11   10
%  10   15   11   10   7
%  6    13   9    7    7
%  13   8    10   8    5
%  9    15   9    13   6
%  10   16   11   14   7
%  8    9    7    10   9
%  9    13   9    11   6
%
%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%
% Exercice 2 :
% -----
% Dans une étude sur la pollution par insecticides dans les grands lacs
% américains, on a suivi l'évolution de la concentration de pesticides
% contenue dans des poissons carnivores (perches, sandres et brochets).
% Les résultats exprimés en mg/g (DDT, DDD et DDE) en fonction de l'âge des
% poissons sont les suivants :
%
%   2 ans    3 ans    4 ans    5 ans    6 ans
%  0.144    0.285    0.418    0.675    1.13
```


Plans Factoriels

A/ Blocs Complets

On considère 2 facteurs A et B dont les nombres de niveaux respectifs sont K_A et K_B . En fonction du nombre d'observations que l'on possède pour chaque couple de niveaux des facteurs A et B, on utilise différentes méthodes. Ce type d'analyse permet de tester l'égalité des moyennes théoriques d'une variable quantitative pour chaque niveau du facteur A et du facteur B (et éventuellement de l'interaction entre ces facteurs).

A1/ Blocs Complets avec répétitions (r répétitions)

Les observations sont sous la forme :

			Facteur B		
	niveau	1		K_B	TOTAL
	1	$x_{1,1,1}$ · · $x_{r,1,1}$	$x_{1,K_B,1}$ · · $x_{r,K_B,1}$	$T_{A,1}$
Facteur A	· · · · ·	· · · · ·	· · · · ·	· · · · ·	· · · · ·
	K_A	$x_{1,1,K_A}$ · · $x_{r,1,K_A}$	x_{1,K_B,K_A} · · x_{r,K_B,K_A}	T_{A,K_A}
	TOTAL	$T_{B,1}$		T_{B,K_B}	T_g

Le modèle de cette analyse est le suivant :

$$x_{ijk} = \mu + \alpha_i + \beta_j + \gamma_{ij} + e_{ijk}$$

Les hypothèses testées :

H_0 : égalité des moyennes des K_A niveaux du facteur A ou les effets du facteur A sont nuls, tous les α_i prennent pour valeur 0

H_0' : égalité des moyennes des K_B niveaux du facteur A ou les effets du facteur B sont nuls, tous les β_j prennent pour valeur 0
 H_0'' : les effets de l'interactions entre les niveaux du facteur A et les niveaux du facteurs B sont nuls, tous les γ_{ij} prennent pour valeur 0
 H_1 : au moins un des α_i est différent de 0
 H_1' : au moins un des β_j est différent de 0
 H_1'' : au moins un des γ_{ij} est différent de 0

Les conditions d'applications :

Tous les x_{ijk} suivent des lois Normales de même variance σ^2 (estimée par s_e^2), ou, ce qui est identique, les e_{ijk} sont "Normaux", indépendants et de même variance σ^2 (estimée par s_e^2).

Le tableau d'Analyse de Variance est le suivant :

Origine	Σ des carrés (a)	ddl (b)	Variance (a)/(b)	F
Totale (A)	$\sum_{i=1}^{K_A} \sum_{j=1}^{K_B} \sum_{l=1}^r x_{lji}^2 - \frac{T_g^2}{N}$	N-1		
Σ des Groupes (B)	$\sum_{i=1}^{K_A} \sum_{j=1}^{K_B} \frac{T_{i,j}^2}{r} - \frac{T_g^2}{N}$	$K_A K_B - 1$	S^2	$\frac{S^2}{s_e^2}$
Intragroupe (C)	(A) - (B)	$N - K_A K_B$	s_e^2	
InterA (D)	$\sum_{i=1}^{K_A} \frac{T_{A,i}^2}{r K_B} - \frac{T_g^2}{N}$	$K_A - 1$	S_A^2	$\frac{S_A^2}{s_e^2}$
InterB (E)	$\sum_{j=1}^{K_B} \frac{T_{B,j}^2}{r K_A} - \frac{T_g^2}{N}$	$K_B - 1$	S_B^2	$\frac{S_B^2}{s_e^2}$
InterAB (F)	(B) - (D) - (E)	$(K_A - 1)(K_B - 1)$	S_{AB}^2	$\frac{S_{AB}^2}{s_e^2}$

Exercice :

```

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%
% =====
% ANALYSE DE VARIANCE
% =====
%
%
% FONCTIONS UTILISEES :
% =====
% ANOVA1.m   Bartlett.m   ANOVA2.m
%
% UTILISER "help name_function" pour obtenir des informations
% sur les fonctions utilisees
%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%
% Exercice 1 :
% -----
% Lors d'une étude portant sur la consommation d'oxygène de 2 types
% d'organisme en fonction de la salinité de l'eau de mer. L'expérimentation
% a été effectuée a 22°C et 8 répétitions ont été effectuée pour chaque
% organisme et chaque salinité :
%
% salinité 1 (100%) espèce 1 : 10.5 12.9 11.2 10.1  9.0 10.9 13.6 10.3
% salinité 1 (100%) espèce 2 :  6.6  8.9 11.4 10.4  7.8  8.2  8.1  6.0
% salinité 2 ( 75%) espèce 1 :  6.9  9.8  9.9  8.4  6.6  8.9  9.1  6.5
% salinité 2 ( 75%) espèce 2 :  7.3  6.5  5.6  8.9  7.0  7.7  7.4  8.3
% salinité 3 ( 50%) espèce 1 : 12.3 12.9  9.9 13.5 12.9  9.4 11.9 12.6
% salinité 3 ( 50%) espèce 2 : 10.3 12.7 10.3 14.7 13.8 12.0 12.1 13.7
%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

```

Les observations sont sous la forme :

			Facteur B		
	niveau	1		K_B	TOTAL
	1	$x_{1,1}$	$x_{K_B,1}$	$T_{A,1}$
Facteur A

	K_A	x_{1,K_A}	x_{K_B,K_A}	T_{A,K_A}
	TOTAL	$T_{B,1}$		T_{B,K_B}	T_g

Le modèle de cette analyse est le suivant :

$$x_{ij} = \mu + \alpha_i + \beta_j + e_{ij}$$

Les hypothèses testées :

- H_0 : égalité des moyennes des K_A niveaux du facteur A ou les effets du facteur A sont nuls, tous les α_i prennent pour valeur 0
- H_0' : égalité des moyennes des K_B niveaux du facteur A ou les effets du facteur B sont nuls, tous les β_j prennent pour valeur 0
- H_1 : au moins un des α_i est différent de 0
- H_1' : au moins un des β_j est différent de 0

Les conditions d'applications :

Tous les x_{ij} suivent des lois Normales de même variance σ^2 (estimée par s_e^2), ou, ce qui est identique, les e_{ij} sont "Normaux", indépendants et de même variance σ^2 (estimée par s_e^2).

Le tableau d'Analyse de Variance est le suivant :

Origine	Σ des carrés (a)	ddl (b)	Variance (a)/(b)	F
Totale (A)	$\sum_{i=1}^{K_A} \sum_{j=1}^{K_B} x_{ij}^2 - \frac{T_g^2}{N}$	N-1		
InterA (B)	$\sum_{i=1}^{K_A} \frac{T_{A,i}^2}{K_B} - \frac{T_g^2}{N}$	K_A-1	S_A^2	$\frac{S_A^2}{S_e^2}$
InterB (C)	$\sum_{j=1}^{K_B} \frac{T_{B,j}^2}{K_A} - \frac{T_g^2}{N}$	K_B-1	S_B^2	$\frac{S_B^2}{S_e^2}$
Intragroupe (D)	(A) - (B) - (C)	$N-K_A-K_B+1$	S_e^2	

Exercice :

```

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%
% Exercice 2 :
% -----
% On souhaite analyser la qualité des eaux de 20 petits bassins versants en
% fonction d'un indice de qualité (qui intègre différentes mesures) et ce, en
% fonction de 4 périodes de l'année. Peut-on considérer qu'il existe des
% différences entre bassins versants ? Existe-t-il un effet de la période à
% laquelle est effectuée la séries de mesures ?
% Les observations sont les suivantes :
% data = [46,38,42,47,48,40,43,43,42,49,45,51,47,52,50,48,47,47,47,45
%         46,42,44,39,49,38,47,45,47,55,50,42,47,51,45,47,50,47,44,48
%         47,42,42,51,54,40,49,46,45,47,39,51,45,49,45,49,49,44,45,51
%         48,47,44,45,51,44,47,48,47,57,49,55,48,48,46,48,54,54,44,48];
% chaque ligne correspond à une période avec les indices des 20 bassins versants.
% Comparer les résultats obtenus avec un ANOVA à un facteur (bassins versants
% et/ou période) à ceux d'une ANOVA à deux facteurs.
%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

```

B/ Blocs Incomplets

Les observations ont sous la forme :

			Facteur B		
	niveau	1		K_B	TOTAL
	1	$x_{1,1}$	$x_{K_B,1}$	$T_{A,1}$
Facteur A

	K_A	x_{1,K_A}	x_{K_B,K_A}	T_{A,K_A}
	TOTAL	$T_{B,1}$		T_{B,K_B}	T_g

mais toutes les cases ne seront pas remplies, par exemple :

niveau	1	2	3	4	5	Total
1	x_{11}				x_{12}	T_{A1}
2		x_{21}	x_{22}			T_{A2}
3			x_{31}	x_{32}		T_{A3}
4	x_{41}	x_{42}				T_{A4}
5				x_{51}	x_{52}	T_{A5}
Total	T_{B1}	T_{B2}	T_{B3}	T_{B4}	T_{B5}	T_g

Le modèle de cette analyse est le suivant :

$$x_{ij} = \mu + \alpha_i + \beta_j + e_{ij}$$

Les hypothèses testées :

- H_0 : égalité des moyennes des K_A niveaux du facteur A ou les effets du facteur A sont nuls, tous les α_i prennent pour valeur 0
- H_0' : égalité des moyennes des K_B niveaux du facteur A ou les effets du facteur B sont nuls, tous les β_j prennent pour valeur 0
- H_1 : au moins un des α_i est différent de 0
- H_1' : au moins un des β_j est différent de 0

Les conditions d'applications :

