

People's Democratic Republic Of Algeria  
Ministry Of Higher Education And Scientific Research



Centre Univercitaire Abdelhafid Boussouf Mila



# Analyse de variance à un facteur (ANOVA)

Dans les cours précédents, on a vu le test d'écart réduit  $Z$  qui permet de comparer deux moyennes théorique  $\mu_1; \mu_2$  à partir de deux échantillons, ou pour comparer une moyenne observée et une moyenne théorique . Dans cette partie on va voir un nouveau test dite ANALYSE DE LA VARIANCE (ANOVA).

On va voir deux cas :

La comparaison de moyennes de plusieurs (deux ou plus) populations à partir d'échantillons de ces populations.

la compariason de variances de deux populations à partir de deux échantillons de ces populations.

### **Condition de validité du test :**

Les populations doivent être normales.

Les populations ayant la même variance.

On se limite à quatre variétés  $V_1, V_2, V_3, V_4$  qui offrent une bonne résistance aux maladies et sont donc fréquemment cultivées dans la région étudiée. On considère des haricots issus de sols comparables et de techniques culturales proche. On prélève des échantillons aléatoires de chacune des variétés et l'on observe les résultats indiqués sur le tableau suivant où sont mentionnés les diamètres en cm.

On donne :  $V_1 = 8.8; 7.1; 3.7; 4.5; 8.3; 9.2; 7.5; 4.9; 5.5; 5.5;$   
 $7.8; 10; 5.7; 8.1; 5.8; 7.3; 6.0; 8.6; 6.4; 6.8; 7.0$

$V_2 = 6.8; 3.5; 5.5; 6.2; 6.0; 8.0; 6.3; 6.3; 8.0; 7.7; 5.9; 8.2; 7.5$   
 $5.7; 6.2; 3.0; 7.0; 7.0; 3.5; 7.8; 4.0; 7.5; 4.2; 7.3; 4.3; 5.9;$   
 $4.4; 5.7; 4.6; 5.8; 4.8; 5.9; 5.0; 5.0; 6.1; 5.1$

$V_3 = 5.2; 6.3; 5.3; 6.4; 5.4; 6.5; 5.5; 6.6; 4.8; 6.7$   
 $; 5.0; 5.8; 5.3; 5.7; 5.5; 6.5; 5.6; 6.7; 3.2; 3.0; 3.1; 6.1; 6.8; 6.6; 8.6; 6.9; 6.9;$   
 $8.6; 7.6; 4.8; 5.7; 6.7; 7.7; 7.4; 4.1; 9.9; 8.8; 5.6; 5.9; 4.3; 7.7; 5.4$

$V_4 = 6.1; 6.8; 6.6; 8.6; 6.9; 6.9; 8.6; 7.6; 4.8; 5.7; 6.7; 7.7; 7.4; 4.1;$   
 $9.9; 8.8; 5.6; 5.9; 4.3; 7.7; 5.4; 6.0; 9.0; 8.0; 6.0; 5.0; 6.0; 10; 6.2; 8.0; 8.6; 6.4; 8.2$

On sait qu'une étude préalable a permis d'accepter l'hypothèse de la normalité ainsi que l'hypothèse de l'égalité des variances des variables aléatoires (diamètre des haricots verts) pour les quatre variétés. Peut-on considérer qu'en moyenne les quatre variétés ont le même diamètre ?

Notation générale.

$E_i (i = 1, 2, 3, 4)$  est un échantillon aléatoire de la population  $V_i$  de moyenne  $\mu_i$ .

Le nombre d'échantillons  $E_1, E_2, E_3$  et  $E_4$  est  $k = 4$ .

La taille de l'échantillon  $E_i (i = 1, 2, 3, 4)$  est noté  $N_i$  :

$$N_1 = 21, N_2 = 35, N_3 = 42, N_4 = 33$$

## Exemple

$x_{ij}$  est l'observation numéro  $j$  de l'échantillon numéro  $i$ , par exemple

$$\left[ \begin{array}{l} x_{11} = 8.8, x_{14} = 4.5, x_{121} = 7.0, x_{26} = 8.0 \\ x_{210} = 7.7, x_{32} = 6.3, x_{35} = 5.4, x_{45} = 5.0 \end{array} \right]$$

$\bar{X}_i (i = 1, 2, 3, 4)$  est la moyenne de l'échantillon  $E_i$  :

$$\bar{x}_i = \frac{1}{N_i} \sum_{j=1}^{N_i} x_{ij}.$$

$\bar{X}$  est la moyenne générale observée sur l'ensemble des observations de tous les échantillons :

$$\bar{X} = \frac{1}{N} \sum_{i=1}^4 \sum_{j=1}^{N_i} x_{ij} = \frac{1}{N} \sum_{j=1}^4 N_j \bar{x}_j$$

## Exemple

La somme des carrés totale ou dispersion totale, notée  $SCE_t$ , est définie par

$$SCE_t = \sum_{j=1}^4 \sum_{i=1}^{N_j} (x_{ij} - \bar{x})^2 .$$

La somme des carrés résiduelle ou dispersion intra-échantillons, noté  $SCE_r$ , est définie par

$$SCE_r = \sum_{j=1}^4 \sum_{i=1}^{N_j} (x_{ij} - \bar{x}_i)^2 .$$

La somme des carrés factorielle ou dispersion inter-échantillons, noté  $SCE_f$ , est définie par

$$SCE_{fa} = \sum_{j=1}^4 N_j (\bar{x}_j - \bar{x})^2 .$$

## Exemple

$x_{ij}$  est l'observation numéro  $j$  de l'échantillon numéro  $i$ , par exemple

$$\left[ \begin{array}{l} x_{11} = 8.8, x_{14} = 4.5, x_{121} = 7.0, x_{26} = 8.0 \\ x_{210} = 7.7, x_{32} = 6.3, x_{35} = 5.4, x_{45} = 5.0 \end{array} \right]$$

$\bar{X}_i (i = 1, 2, 3, 4)$  est la moyenne de l'échantillon  $E_i$  :

$$\bar{x}_i = \frac{1}{N_i} \sum_{j=1}^{N_i} x_{ij}.$$

$\bar{X}$  est la moyenne générale observée sur l'ensemble des observations de tous les échantillons :

$$\bar{X} = \frac{1}{N} \sum_{i=1}^4 \sum_{j=1}^{N_i} x_{ij} = \frac{1}{N} \sum_{j=1}^4 N_j \bar{x}_j$$

## Exemple

Remarque On peut montrer les formules suivantes, qui sont mieux adaptées pour les calculs

$$SCE_t = \sum_{j=1}^4 \sum_{i=1}^{N_i} (X_{ij})^2 - \frac{X_{\bullet\bullet}^2}{N}$$

$$SCE_{fa} = \sum_{j=1}^4 \frac{X_{ij}^2}{N_i} - \frac{X_{\bullet\bullet}^2}{N}$$

$$SCE_r = \sum_{j=1}^4 \sum_{i=1}^{N_i} (x_{ij})^2 - \sum_{j=1}^4 \frac{X_{i\bullet}^2}{N_i}$$

On rappelle les notations

$$X_{\bullet\bullet} = \sum_{i=1}^4 \sum_{j=1}^{N_i} X_{ij} \text{ et } X_{i\bullet} = \sum_{j=1}^{N_i} X_{ij}$$

La variance interclasse ou carré moyen factoriel, notée  $CM_{fa}$ , est définie par

$$CM_{fa} = \frac{SCE_{fa}}{k - 1} = \frac{SCE_{fa}}{3}.$$

La variance intra-classe ou carré moyen résiduel, notée  $CM_r$ , est définie par

$$CM_T = \frac{SCE_T}{N - k} = \frac{SCE_r}{127}.$$

Equation de l'analyse de la variance On peut montrer l'équation suivante, appelée équation de la variance.

$$SCE_t = SCE_r + SCE_{fa}$$

Variabilité totale = Variabilité résiduelle (intra-échantillons) + variabilité factorielle (inter-échantillons)

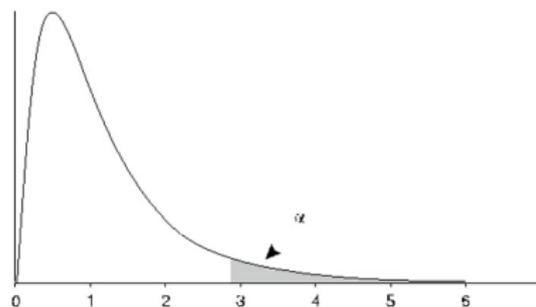
Les étapes du test. 1)- Hypothèse nulle  $H_0 : \mu_1 = \mu_2 = \mu_3 = \mu_4$ ,  
l'hypothèse alternative  $H_1$  : au moins deux moyennes ne sont pas égales.  
ici  $\mu_i (i = 1, 2, 3, 4)$  est le diamètre moyen de la variété  $i$ . 2) Le seuil critique est à calculer sur la loi de Fisher  $F_{3,127}$  de ddl ( $v_1, v_2$ ) où  $v_1 = k - 1 = 3$  et  $v_2 = N - k = 127$ . Ce seuil est le quantile  $F_{3,127,0.95}$  d'ordre  $1 - 0.05 = 0.95$  :

## Exemple

Dans la table de Fisher (table 5), on a pas la valeur exacte de  $F_{3,127,0.95}$ , mais on a  $F_{3,100,0.95} = 2.70$  et  $F_{3,200,0.95} = 2.65$ . On prend la moyenne :

$$\begin{aligned} \mathbf{F}_{3,127,0.95} &= \frac{F_{3,100,0.95} + F_{3,200,0.95}}{2} \\ &= \frac{2.70 + 2.65}{2} = \mathbf{2.675} \end{aligned}$$

# Exemple



**Table de Fisher Snédécour**

$$P(F_{\theta_1, \theta_2} \geq c) = 0.05$$

$\nu_1$	$\nu_2$											
	18	20	22	24	26	28	30	40	50	60	100	200
1	4,41	4,35	4,30	4,26	4,23	4,20	4,17	4,08	4,03	4,00	3,94	3,89
2	3,55	3,49	3,44	3,40	3,37	3,34	3,32	3,23	3,18	3,15	3,09	3,04
3	3,16	3,10	3,05	3,01	2,98	2,95	2,92	2,84	2,79	2,76	2,70	2,65
4	2,93	2,87	2,82	2,78	2,74	2,71	2,69	2,61	2,56	2,53	2,46	2,42
5	2,77	2,71	2,66	2,62	2,59	2,56	2,53	2,45	2,40	2,37	2,31	2,26
6	2,66	2,60	2,55	2,51	2,47	2,45	2,42	2,34	2,29	2,25	2,19	2,14
7	2,58	2,51	2,46	2,42	2,39	2,36	2,33	2,25	2,20	2,17	2,10	2,06
8	2,51	2,45	2,40	2,36	2,32	2,29	2,27	2,18	2,13	2,10	2,03	1,98
9	2,46	2,39	2,34	2,30	2,27	2,24	2,21	2,12	2,07	2,04	1,97	1,93
10	2,41	2,35	2,30	2,25	2,22	2,19	2,16	2,08	2,03	1,99	1,93	1,88

FIGURE –

3)- La statistique de test observée  $T_O$  est donnée par la formule

$$T_O = \frac{CM_{fa}}{CM_r} = \frac{17.53}{2.17} = \mathbf{8.08}$$

4)- Décision. Puisque

$$T_O = \mathbf{8.08} > F_{3,127,0.99} = \mathbf{2.675},$$

on rejette l'hypothèse nulle  $H_0$

et on accepte l'hypothèse alternative  $H_1$  : au moins les diamètres moyens de deux variétés ne sont pas égaux.

Ce test concerne la comparaison des variances  $\sigma_1$  et  $\sigma_2$  de deux populations. La condition nécessaire pour réaliser ce test est la normalité des deux populations. Présentation du test On se propose de comparer les variances  $\sigma_1$  d'une population  $X_1$  et  $\sigma_2$  d'une population  $X_2$  en utilisant les variances,  $S_1^2$  d'un échantillon aléatoire de  $X_1$  et  $S_2^2$  d'un échantillon aléatoire de  $X_2$ . Les deux échantillons de  $X_1$  et  $X_2$  sont indépendants,

de tailles  $n_1$  et  $n_2$  respectivement. Le test qu'on va présenter est valide sous la condition de normalité des lois des deux populations  $X_1$  et  $X_2$ .

Étapes du test. 1. Hypothèse nulle  $H_0 : \sigma_1 = \sigma_2$  contre l'hypothèse alternative  $H_1$  : a.  $\sigma_1 \neq \sigma_2$  (pour un test bilatéral), b.  $\sigma_1 > \sigma_2$  (pour un test unilatéral à droite) ou c.  $\sigma_1 < \sigma_2$  (pour un test unilatéral à gauche).  
2. La statistique de test observée  $T_O$  est égale au rapport des variances des échantillons :

$$T_O = \frac{S_1^2}{S_2^2}$$

3. La région d'acceptation de l'hypothèse nulle. a. Test bilatéral : la région d'acceptation de  $H_0$  est l'intervalle  $[a, b]$ , où  $a = F_{u,v,\frac{\alpha}{2}}$  est le quantile d'ordre  $\frac{\alpha}{2}$  de la loi de Fisher de degrés de liberté  $(u = n_1 - 1, v = n_2 - 1)$   $b = F_{u,v,1-\frac{\alpha}{2}}$  est le quantile d'ordre  $1 - \frac{\alpha}{2}$  de la loi de Fisher de degrés de liberté  $(u = n_1 - 1, v = n_2 - 1)$ .

b. Test unilatéral à droite : la région d'acceptation de  $H_0$  est l'intervalle  $[-\infty, d]$ , où  $d = F_{u,v,1-\alpha}$  est le quantile d'ordre  $1 - \alpha$  de la loi de Fisher de degrés de liberté ( $u = n_1 - 1, v = n_2 - 1$ ) c. Test unilatéral à gauche : la région d'acceptation de  $H_0$  est l'intervalle  $[e, +\infty]$ , où  $e = F_{u,v,\alpha}$  est le quantile d'ordre  $\alpha$  de la loi de Fisher de degrés de liberté ( $u = n_1 - 1, v = n_2 - 1$ ).

Utilisation de la table 5 de la loi de Fisher Les tables de Fisher-Snédecor donne les valeurs des quantiles de la loi de Fisher pour  $1 - \alpha$  ( $\alpha < 0.5$ ).

pour calculer des quantiles d'ordre inférieur à 0.5 on utilise la relation suivante. Le quantile d'ordre  $\alpha$  de la loi de Fisher-Snédecor de  $ddl' = (u, v)$  est égal à l'inverse du quantile d'ordre  $1 - \alpha$  de la loi de Fisher-Snédecor de  $ddl = (v, u)$ .

$$F_{u,v,\alpha} = \frac{1}{F_{v,u,1-\alpha}}.$$

Par exemple

$$\begin{aligned} F_{30,10,0.05} &= \frac{1}{F_{10,30,0.95}} \\ &= \frac{1}{2.16} = 0.46 = \frac{1}{2.16} = 0.46 \end{aligned}$$