

Analyse de la variance

ABDELOUAHAB A

Position du problème :

Comparaison de deux moyennes

→ test de l'écart réduit

Comparaison de plusieurs moyennes ?

Solution :

Comparaison deux à deux :

Inconvénients : méthode longue

Vue d'ensemble floue

Analyse de la variance : bon reflet de dispersion autour de la moyenne.

Test approprié : test de Fisher-Snedecor (analyse de la variance)

Principe de solution :

Il repose sur la **décomposition de la variation de la variable X**

1) La variation totale (D totale) de la variable X est mesurée par la dispersion de toutes les valeurs (N valeurs) autour de la moyenne générale

Cette variation dépend de deux sources de variations :

2) La variation entre les classes (variation inter-groupe)
(D inter) Chaque classe est caractérisée par sa moyenne ($\bar{x}_1, \dots, \bar{x}_k$) qui s'écarte plus ou moins de la moyenne générale (\bar{x}).
Effet du facteur étudié : variable indépendante

3) La variation à l'intérieur de chaque classe (intra-groupe, résiduelle) (D intra)

4) La relation entre les variations

$$D_{\text{totale}} = D_{\text{inter}} + D_{\text{intra}}$$

Principe du test:

On teste le rapport de deux variances

variance **inter-groupes** (variance factorielle V_f)

variance **intra-groupes** (variance résiduelle V_r)

H_0 teste donc l'hypothèse de l'homogénéité des k moyennes.

On dit aussi que le facteur (à partir duquel on a construit les k groupes) n'a pas d'influence sur la variable X

Le rapport suit une loi F de Fisher -Snedecor

1-variance factorielle V_f

$$V_f = D_{\text{inter}} / (k-1)$$

K : nombre d'échantillons

D_{inter} Dispersion inter-groupes : analyse la variabilité **entre les groupes**

$$D_{\text{inter}} = n_1(\bar{X}_1 - \bar{X})^2 + n_2(\bar{X}_2 - \bar{X})^2 + n_3(\bar{X}_3 - \bar{X})^2 + \dots + n_k(\bar{X}_k - \bar{X})^2$$

$$\text{formule pratique } D_{\text{inter}} = n_1(\bar{X}_1)^2 + n_2(\bar{X}_2)^2 + \dots + N(\bar{X})^2$$

\bar{X}_i = les moyennes respectives des K échantillons

\bar{X} = moyenne générale = $\sum \bar{X}_i / (n_1 + n_2 + n_3 + \dots + n_k)$

$N = n_1 + n_2 + n_3 + \dots + n_k$

2- variance résiduelle V_r :

$$V_r = D_{\text{intra}} / (N-k)$$

N = somme des tailles de tous les échantillons :

$$N = n_1 + n_2 + n_3 + \dots + n_k$$

D_{intra} : Dispersion intra-groupes : analyse la variabilité **à l'intérieur des groupes**

$$D_{\text{intra}} = \sum (X_{i1} - \bar{X}_1)^2 + \sum (X_{i2} - \bar{X}_2)^2 + \sum (X_{i3} - \bar{X}_3)^2 + \dots + \sum (X_{ik} - \bar{X}_k)^2$$

Formule pratique :

$$D_{\text{intra}} = \sum X_{ij}^2 - (n_1 \bar{X}_1^2 + n_2 \bar{X}_2^2 + \dots + n_k \bar{X}_k^2)$$

$$\sum x_{ij}^2 = \sum x_{i1}^2 + \sum x_{i2}^2 + \sum x_{i3}^2 + \dots + \sum x_{ik}^2$$

3- la table de Fisher, donne directement F
(valeur critique) selon le risque α choisi

↓
l'intersection de
 $ddl=K-1$ $ddl=N-K$

Procédure

- 1) Détermination du risque α
- 2) Formulation des hypothèses H_0 et H_1
- 3) Calcul de la dispersion inter -groupe
- 4) Calcul de la dispersion intra -groupe
- 5) Calcul de la variance factorielle V_f
- 6) Calcul de la variance résiduelle V_r
- 7) Conclusion : comparaison du rapport V_f/V_r avec F de la table:

Si $V_f/V_r \geq F$ la différence est significative au risque α
→ H_0 est rejetée
Effet de la variable indépendante sur la variable dépendante.
La variation totale du comportement est principalement expliquée par la variable indépendante.

Si $V_f/V_r < F$ la différence n'est significative au risque α
→ H_0 est retenue
Pas d'effet de la variable indépendante sur la variable dépendante.

Conditions d'utilisation

- 1- L'indépendance des échantillons.
- 2- L'homogénéité des variances (c'est-à-dire égalité des variances). Il convient alors de réaliser un test d'homogénéité :
- test de **Bartlett** si les effectifs des échantillons sont différents ;
- test de **Cochran** si les effectifs sont égaux.
- 3- Normalité de la distribution des mesures
Le non-respect de ces conditions peut entraîner des résultats erronés soit en acceptant à tort H_0 soit en rejetant à tort H_0 .
Lorsque les variances sont hétérogènes, l'analyse de variance n'est pas utilisable et on recourt à un test de **Kruskal-Wallis**

Exemple :

5 milieux de culture de BCG

10 tubes par milieu de culture

on observe le nombre de colonies par tubes

question : ces milieux sont ils équivalents?

Milieu de culture	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	3	9	11	6	
Moyenne	9.5	13.0	9.7	10.5	7.0

1) $\alpha = 5\%$

2) H_0 : les milieux sont équivalents

3) $D_{\text{inter}} = n_1(\bar{x}_1)^2 + n_2(\bar{x}_2)^2 + \dots - N(\bar{x})^2 = 10(9.5)^2 + 10(13)^2 + \dots - 50(9.94)^2 = 185.7$

4) $D_{\text{intra}} = \sum x_i^2 - (n_1\bar{x}_1^2 + n_2\bar{x}_2^2 + \dots + n_k\bar{x}_k^2) = 5083 - (10 \cdot 9.5^2 + 10 \cdot 13^2 + \dots + 10 \cdot 7^2) = 225.1$

5) $V_f = 185.7/5 - 1 = 46.4$

6) $V_r = 225.1/50 - 5 = 5$

7) conclusion : $V_f/V_r = 46.4/5 = 9.3$

F de la table = 2.5 (ddl1=4 et ddl2=45)

le rapport est supérieur à F critique

H_0 est rejetée.

Comparaison de deux variances

ABDELOUAHAB A

Intérêt :

1) comparer deux moyennes dans le cas des petits échantillons, le test de Student n'est valide qu'au conditions suivantes:

- la variable étudiée doit être normale
 - les variance des deux populations ne doivent pas être significativement différentes
- 2) comparer la précision de deux méthodes

Principe:

Comparaison du rapport $F = S^2_A / S^2_B$ (S^2_A est supérieure à S^2_B) et F de la table de Fisher.

F critique: intersection de $ddl = n_A - 1$ et $ddl = n_B - 1$

Exemple:

	A	B
	37	38
	36	39
	37	38
	38	37
	37	36
		39
		39
		38
		37
Moyenne	37	38
Variance	0.5	1.11

F calculé = $1.11 / 0.5 = 2.22$

F table = **6.04** (intersection de 9-1 et 5-1)

$F_c < F_t$ pas de différence significative entre les deux variances

Procédure:

Les étapes à suivre sont:

- 1) Détermination du risque α
- 2) construction de l'hypothèse nulle
- 3) Calcul de la variance testée $F = S^2_A / S^2_B$
- 4) Détermination de la valeur critique F de la table de Fischer, en fonction du risque α et les degrés de liberté $V1 = n1 - 1$ et $V2 = n2 - 1$
- 5) Conclusion :

$F_c \geq F_t$ la différence est significative au risque α et H_0 est rejetée

$F_c < F_t$ la différence n'est pas significative au risque α et H_0 est retenue

Exemple 2 :

Trois méthodes pédagogiques sont utilisées sur trois groupes d'adultes de même niveau initial. Après l'enseignement les performances sont les suivantes :

Enseignement	Effectif	Total	Moyenne
livresque	18	198	11
audiovisuel	20	240	12
ordinateur	22	308	14

Sachant que $\sum x^2 = 9967$, peut-on apporter la preuve d'une différence d'efficacité entre ces trois méthodes à $p = 0,01$?

Source de variation	Somme des carrés des écarts	Nombre de ddl	Carrés Moyens (variances)	F
entre les groupes (Inter)	94.73	$3 - 1 = 2$	47.36	4.52
à l'intérieur des groupes (intra)	597.00	$60 - 3 = 57$	10.47	
Total	691.73	59		

Lecture du F de Snédécour : $k - 1 = 2$ et $N - k = 57$

pour $p = 0,01$ $F_{lu} = 5,18$ $F_{calculé} < F_{lu}$

donc Acceptation de H_0

La preuve d'une différence ne peut être apportée (à $p = 0,01$).

L'étude de la distribution du taux de cholestérol dans deux groupes de sujets adultes adonné les résultats en g/l:

	Taille	variance
Echantillon1	50	0.90
Echantillon2	62	0.79

Tester l'égalité des deux variances:

$F_{calculé} = 1.15$

$F_{de\ la\ table} = 1.60(5\%, 49, 61)$