

CHAPITRE 3: ANALYSE DE LA VARIANCE

1) Analyse de la variance à un facteur $AV(1)$:

L' $AV(1)$ est une technique statistique qui sert à tester l'influence d'un ou de plusieurs facteurs qualitative sur une variable quantitative. Notons A le facteur et A_1, \dots, A_p ses p modalités ou niveaux. Soient Y la variable étudiée et y_1, \dots, y_n ses observations. Pour chaque niveau A_j du facteur est associé n_j mesures de Y : $y_{1j}, \dots, y_{n_j j}$.

y_{ij} : $i^{\text{ème}}$ obs du $j^{\text{ème}}$ niveau
 n_j : taille de l'échantillon y_{*j}
 \bar{y}_j : moyenne de la classe j
 n : taille de l'échantillon y
 \bar{y} : moyenne totale

A_1	...	A_j	...	A_p
y_{11}	...	y_{1j}	...	y_{1p}
:	:	:	:	:
$y_{n_1 1}$...	$y_{n_j j}$...	$y_{n_p p}$
\bar{y}_1	...	\bar{y}_j	...	\bar{y}_p

On a

$$n = \sum_{j=1}^p n_j, \quad \bar{y}_j = \frac{1}{n_j} \sum_{i=1}^{n_j} y_{ij}, \quad \bar{y} = \frac{1}{n} \sum_{j=1}^p n_j \bar{y}_j = \frac{1}{n} \sum_{j=1}^p \sum_{i=1}^{n_j} y_{ij}.$$

1.1) Modèle d' $AV(1)$:

Soit $\mu = \frac{1}{n} \sum_{j=1}^p n_j \mu_j$, ($\mu_j = E[Y_j]$: moyenne théorique). En terme d'observations, on a le modèle:

$$\underbrace{y_{ij} - \bar{y}}_{\text{écart total}} = \underbrace{(y_{ij} - \bar{y}_j)}_{\text{écart résiduel}} + \underbrace{(\bar{y}_j - \bar{y})}_{\text{écart factoriel}} \quad (1)$$

et théoriquement, on a

$$y_{ij} - \mu = (y_{ij} - \mu_j) + (\mu_j - \mu).$$

Posons $\mu - \mu_j = \alpha_j$ et $y_{ij} - \mu_j = \varepsilon_{ij}$. Nous obtenons le modèle d' $AV(1)$:

$$\underbrace{y_{ij}}_{\text{modèle}} = \underbrace{\mu}_{\text{moyenne générale}} + \underbrace{\alpha_j}_{\text{effet principale}} + \underbrace{\varepsilon_{ij}}_{\text{effet résiduel}}, \quad (2)$$

$\varepsilon \sim \mathcal{N}(0, \sigma^2)$. Il est clair que $\bar{\alpha} = 0$.

1.2) Equation d' $AV(1)$:

Le modèle observé (1), permet d'obtenir l'équation d' $AV(1)$:

$$\sum_{j=1}^p \sum_{i=1}^{n_j} (y_{ij} - \bar{y})^2 = \sum_{j=1}^p \sum_{i=1}^{n_j} (y_{ij} - \bar{y}_j)^2 + \sum_{j=1}^p \sum_{i=1}^{n_j} (\bar{y}_j - \bar{y})^2$$

$$\underbrace{\sum_{j=1}^p \sum_{i=1}^{n_j} y_{ij}^2 - n\bar{y}^2}_{SCT} = \underbrace{\sum_{j=1}^p \sum_{i=1}^{n_j} (y_{ij} - \bar{y}_j)^2}_{SCR} + \underbrace{\sum_{j=1}^p n_j \bar{y}_j^2 - n\bar{y}^2}_{SCA}.$$

Tableau d' $AV(1)$

Variation	ddl	SC	MC	F
Factorielle	$p - 1$	SCA	MCA	F
Résiduelle	$n - p$	SCR	MCR	
Total	$n - 1$	SCT		

1.3) Test d'égalité des moyennes:

Si le facteur A n'a pas d'influence sur Y . Alors, l'hypothèse à tester est

$$H_0 : \mu_1 = \mu_2 = \dots = \mu_p \iff \alpha_1 = \alpha_2 = \dots = \alpha_p = 0.$$

Sous l'hypothèse de normalité des ε , on a

$$MCA = \frac{SCA}{p-1} \sim \chi_{p-1}^2, \quad MCR = \frac{SCR}{n-p} \sim \chi_{n-p}^2 \quad \text{et} \quad \mathbf{F} = \frac{MCA}{MCR} \sim \mathcal{F}(p-1, n-p).$$

Nous acceptons l'hypothèse H_0 d'égalité des moyennes si $F \leq f_{1-\alpha}(p-1, n-p)$. Le rejet de H_0 implique qu'au moins deux moyennes sont différentes ($\exists \mu_k, \mu_j | \mu_k \neq \mu_j$). Dans ce cas nous utilisons le test de Benfarouni basé sur les comparaisons deux à deux des couples (μ_k, μ_j) :

$$\begin{cases} H_0 : \mu_k - \mu_j = 0 \\ H_1 : \mu_k - \mu_j \neq 0 \end{cases}, k \neq j$$

On a donc, $m = \mathfrak{C}_p^2$ tests de Student à faire. On accepte $H_0 (\mu_k = \mu_j)$ si $|T| < t_{1-\frac{\alpha}{2m}}(n-p)$, où

$$T = \frac{\bar{y}_k - \bar{y}_j}{\sqrt{\left(\frac{1}{n_k} + \frac{1}{n_j}\right) MCR}}$$

t_* est le fractile d'ordre * du Student à $n-p$ degré de liberté.

1.4) Exemple d'AV (1) : En veut étudier l'influence de trois types d'essence A_1, A_2, A_3 sur les distances parcourés en (km). Le type d'essence influe sur les distances ? Localiser les différences si oui:

A_1	240	250	243	255	
A_2	253	265	264	270	276
A_3	233	240	247		

Solution: le tableau d'AV (1) est donné par

Variation	ddl	SC	MC	F
Factorielle	2	1550	775	21.46
Résiduelle	9	325	36.11	
Total	11	1875		

$$\bar{y}_1 = 247, \quad \bar{y}_2 = 265.6, \quad \bar{y}_3 = 240.$$

Au niveau 95% de confiance, $F = 21.46 > f_{0.95}(2, 9) = 19.4$. Alors il y a une influence (non égalité des moyennes : H_0 rejeté). Il y'a $m = \mathfrak{C}_3^2 = 3$ tests de comparaison $(\mu_1 \text{ vs } \mu_2)$, $(\mu_1 \text{ vs } \mu_3)$, $(\mu_2 \text{ vs } \mu_3)$:

1^{er} cas, $(\mu_1 \text{ vs } \mu_2)$: on a

$$T_1 = \frac{\bar{y}_1 - \bar{y}_2}{\sqrt{\left(\frac{1}{n_1} + \frac{1}{n_2}\right) MCR}} = \frac{247 - 265.6}{\sqrt{\left(\frac{1}{4} + \frac{1}{5}\right) 58.36}} = -3.53$$

avec, $t_{1-\frac{0.05}{6}}(9) = 2.28 < |T| \implies H_0$ rejeté ($\mu_1 \neq \mu_2$) à 95%. (de même pour les autres cas, on a ($\mu_1 = \mu_3$) et ($\mu_2 \neq \mu_3$)). On dit dans ce cas que les type A_1 et A_3 ont le même effet qu'est différent de celui de A_2 .

2) Analyse de la variance à deux facteur AV (2) :

Dans ce cas les données sont regroupées selon deux catégories ou facteurs: A, B . Notons A_1, \dots, A_p les p niveaux du facteur A et B_1, \dots, B_q les q niveaux du facteur B , de telle sorte que chaque case contient r mesures de la variable d'intérêt $Y (y_{**1}, \dots, y_{**r})$:

	A_1	...	A_i	...	A_p
B_1	y_{111}, \dots, y_{11r}	...	y_{i11}, \dots, y_{i1r}	...	y_{p11}, \dots, y_{p1r}
:	:	:	:	:	:
B_j	y_{1j1}, \dots, y_{1jr}	...	y_{ij1}, \dots, y_{ijr}	...	y_{pj1}, \dots, y_{pjr}
:	:	...	:	...	:
B_q	y_{1q1}, \dots, y_{1qr}	...	y_{iq1}, \dots, y_{iqr}	...	y_{pq1}, \dots, y_{pqr}

2.1) Modèle d'AV (2) :

$$y_{ijk} = \underbrace{\mu}_{\text{moyenne générale}} + \underbrace{\alpha_i}_{\text{effet de } A} + \underbrace{\beta_j}_{\text{effet de } B} + \underbrace{\gamma_{ij}}_{\text{effet d'interaction}} + \underbrace{\varepsilon_{ijk}}_{\text{effet résiduel}},$$

$$\begin{cases} \alpha_i = \mu_{i*} - \mu & \text{effet de } A \text{ au niveau } i = 1, \dots, p \\ \beta_j = \mu_{*j} - \mu & \text{effet de } B \text{ au niveau } j = 1, \dots, q \\ \gamma_{ij} = \mu_{ij} - \mu_{i*} - \mu_{*j} + \mu & \text{effet d'interaction entre } A \text{ et } B \\ \varepsilon_{ijk} = y_{ijk} - \mu_{ij} & \text{erreur } (k = 1, \dots, r). \end{cases}$$

Les hypothèses d'intérêt dans l'AV (2) sont:

$$\begin{cases} 1) & H_0 : \mu_{ij} = \mu_{\ell m}, & H_1 : \exists! (i, j, \ell, m) \mid \mu_{ij} \neq \mu_{\ell m} \\ 2) & H_0 : \alpha_i = 0, & H_1 : \alpha_i \neq 0, \quad i = 1, \dots, p \\ 3) & H_0 : \beta_j = 0, & H_1 : \beta_j \neq 0, \quad j = 1, \dots, q \\ 4) & H_0 : \gamma_{ij} = 0, & H_1 : \gamma_{ij} \neq 0, \quad i = 1, \dots, p, \quad j = 1, \dots, q \end{cases}$$

2.2) Equation d'AV (2) :

Notons

$$\begin{aligned} \overline{y_{i**}} &= \frac{1}{qr} \sum_{j=1}^q \sum_{k=1}^r y_{ijk} && \text{moyenne de la colonne } i \\ \overline{y_{*j*}} &= \frac{1}{pr} \sum_{i=1}^p \sum_{k=1}^r y_{ijk} && \text{moyenne de la ligne } j \\ \overline{y_{ij*}} &= \frac{1}{r} \sum_{k=1}^r y_{ijk} && \text{moyenne de la case } (i, j) \\ \bar{y} = \overline{y_{***}} &= \frac{1}{pqr} \sum_{i=1}^p \sum_{j=1}^q \sum_{k=1}^r y_{ijk} && \text{moyenne total } (n = pqr). \end{aligned}$$

L'équation d'analyse de la variance dans ce cas s'écrit

$$\sum_{i=1}^p \sum_{j=1}^q \sum_{k=1}^r (y_{ijk} - \bar{y})^2 = \sum_{i=1}^p \sum_{j=1}^q \sum_{k=1}^r (y_{ijk} - \overline{y_{ij*}})^2 + qr \sum_{i=1}^p (\overline{y_{i**}} - \bar{y})^2 + pr \sum_{j=1}^q (\overline{y_{*j*}} - \bar{y})^2 + r \sum_{i=1}^p \sum_{j=1}^q (\overline{y_{ij*}} - \overline{y_{i**}} - \overline{y_{*j*}} + \bar{y})^2$$

en d'autre terme:

$$\begin{aligned} \underbrace{\sum_{i=1}^p \sum_{j=1}^q \sum_{k=1}^r y_{ijk}^2 - n\bar{y}^2}_{SCT} &= \underbrace{\sum_{i=1}^p \sum_{j=1}^q \sum_{k=1}^r (y_{ijk} - \overline{y_{ij*}})^2}_{SCR} + \underbrace{qr \sum_{i=1}^p \overline{y_{i**}}^2 - n\bar{y}^2}_{SCA} \\ &\quad + \underbrace{pr \sum_{j=1}^q \overline{y_{*j*}}^2 - n\bar{y}^2}_{SCB} + \underbrace{r \sum_{i=1}^p \sum_{j=1}^q (\overline{y_{ij*}} - \overline{y_{i**}} - \overline{y_{*j*}} + \bar{y})^2}_{SCAB} \end{aligned}$$

L'AV (2) permet de tester l'absence ou l'existence des effets de A et/ou de B ou d'interaction entre A et B . Les résultats d'AV (2) sont résumés dans le tableau suivant:

Tableau d'AV (2)

Variation	ddl	SC	MC	F
Fac. A	$p - 1$	SCA	MCA	\mathbf{F}_A
Fac. B	$q - 1$	SCB	MCB	\mathbf{F}_B
Fac. A, B	$(p - 1)(q - 1)$	$SCAB$	$MCAB$	\mathbf{F}_{AB}
Résiduelle	$pq(r - 1)$	SCR	MCR	
Total	$n - 1 = pqr - 1$	SCT		

$$\begin{cases} F_A > f_{1-\alpha}(p-1, pq(r-1)) & \Rightarrow H_1 : \text{effet de } A \\ F_B > f_{1-\alpha}(q-1, pq(r-1)) & \Rightarrow H_1 : \text{effet de } B \\ F_{AB} > f_{1-\alpha}((p-1)(q-1), pq(r-1)) & \Rightarrow H_1 : \text{effet d'interaction.} \end{cases}$$

2.3) Modèle d'AV (2) sans répétitions:

Supposons dans ce cas que chaque case contient une seule observation ($r = 1$). On dit aussi qu'une seule mesure de la vraie Y pour chaque couple (A_i, B_j) :

	A_1	...	A_i	...	A_p
B_1	y_{11}	...	y_{i1}	...	y_{p1}
:	:	:	:	:	:
B_j	y_{1j}	...	y_{ij}	...	y_{pj}
:	:	...	:	...	:
B_q	y_{1q}	...	y_{iq}	...	y_{pq}

Variation	ddl	SC	MC	F
Fac. A	$p - 1$	SCA	MCA	F_A
Fac. B	$q - 1$	SCB	MCB	F_B
Résiduelle	$(p - 1)(q - 1)$	SCR	MCR	
Total	$pq - 1$	SCT		

Le modèle d'AV (2) est

$$y_{ij} = \underbrace{\mu}_{\text{moyenne générale}} + \underbrace{\alpha_i}_{\text{effet de } A} + \underbrace{\beta_j}_{\text{effet de } B} + \underbrace{\varepsilon_{ij}}_{\text{effet résiduel}} .$$

et l'équation d'AV (2) est

$$\underbrace{\sum_{i=1}^p \sum_{j=1}^q (y_{ijk} - \bar{y})^2}_{SCT} = \underbrace{\sum_{i=1}^p \sum_{j=1}^q (y_{ij} - \bar{y}_{i.})^2}_{SCR} + \underbrace{q \sum_{i=1}^p (\bar{y}_{i.} - n\bar{y})^2}_{SCA} + \underbrace{p \sum_{j=1}^q (\bar{y}_{.j} - n\bar{y})^2}_{SCB} .$$

2.4) Exemple: considérons les résultats d'AV (2) :

Variation	ddl	SC	MC	F
Fac. A	2	105	52.5	17.5
Fac. B	4	225	112.5	37.5
Fac. A, B	8	130	65	21.67
Résiduelle	30	90	3	
Total	44	550		

$p = 3$
 $q = 5$
 $r = 3$
 $n = 45$

au niveau 95% de confiance, nous avons:

$$\begin{cases} F_A = 17.5 < f_{0.05}(2, 30) = 19.5 & \Rightarrow H_0 : \text{absence d'effet de } A \\ F_B = 37.5 > f_{0.05}(4, 30) = 5.75 & \Rightarrow H_1 : \text{effet de } B \\ F_{AB} = 21.67 > f_{0.05}(8, 30) = 3.08 & \Rightarrow H_1 : \text{effet d'interaction.} \end{cases}$$

2.5) Exercice: La quantité d'oxygène consommé par deux espèces de patelle : *Acmaea Scabra* et *Acmaea Digitalis* a été analysée pour différentes conditions halines : pourcentages d'eau; les résultats suivants ont été obtenues:

%	A. Scabra	A. Digitalis
100%	7.16, 6.78, 13.6, 8.93, 8.26	6.14, 3.86, 10.4, 5.49, 6.14
75%	5.2, 5.2, 7.18, 6.37, 13.2	4.47, 9.9, 5.75, 11.8, 4.95
50%	11.11, 9.74, 18.8, 9.74, 10.5	9.63, 6.38, 13.4, 14.5, 14.5

Analyser les résultats obtenus au cours de cette expérience au niveaux : $\alpha = 90\%$, 95% , 99% .