

ÉQUATION D'ANALYSE DE LA VARIANCE (I, J)

(08 / 01 / 2020, © Monfort, Dicostat2005, 2005-2020)

L'équation d'analyse de la variance est une équation classique de décomposition d'une **variance d'ensemble** en une somme de variances partielles, notamment pour effectuer un **test d'hypothèses** (cf aussi **analyse de la variance**, **décomposition de la variance**, **modèle d'analyse de la variance**, **modèle d'analyse de la covariance**, **modèle à variance composée**, **modèle linéaire**, **problème linéaire**, **théorème de COCHRAN**).

(i) Dans le cadre du **problème linéaire** général, on considère un **vecteur aléatoire** de carré intégrable y à valeurs dans l'**espace d'observation** \mathbf{R}^N (muni d'une **structure** donnée) et une variété linéaire \mathcal{L} de **rang** K de \mathbf{R}^N . Quelle que soit la **probabilité** $P \in \mathcal{P}$ (**famille** donnée), on suppose que $E_P y = \mu_P \in \mathcal{L}$ et que $V_P y = \Sigma_P$. Soit alors \mathcal{M} une sous-variété de rang L de \mathcal{L} .

On considère un **problème de test** de l'**hypothèse de base**, souvent appelée **hypothèse nulle** (cf **test de l'hypothèse linéaire**) :

$$(1) \quad H_0 : \mu_P \in \mathcal{M}$$

contre l'**alternative générale** :

$$(2) \quad H_a : \mu_P \in \mathcal{L}.$$

Ici, l'hypothèse de base est une **hypothèse emboîtée** dans l'hypothèse alternative (ce qui peut se noter $\mathcal{M} \subset \mathcal{L}$ ou $\mathcal{M} \triangleleft \mathcal{L}$). On peut aussi noter $H(\mathcal{M})$ au lieu de H_0 et $H(\mathcal{L})$ au lieu de H_a . On considère alors la **projection oblique** (ie selon Σ_P) $z(\mathcal{M})$ de y sur \mathcal{M} .

Si $y \sim \mathcal{N}_N(\mu_P, \Sigma_P)$ (**loi normale multidimensionnelle**), on établit que :

(a) lorsque Σ_P est connue, la **statistique (forme quadratique)** :

$$(3) \quad Q_N = (z(\mathcal{L}) - z(\mathcal{M}))' \Sigma_P^{-1} (z(\mathcal{L}) - z(\mathcal{M}))$$

suit, sous H_0 , la loi $\mathcal{X}^2(K-L)$ (**loi du chi-deux à $K - L$ degrés de liberté**) : ie $Q_N \sim_{H_0} \mathcal{X}^2(K-L)$.

Par suite, la **région critique** du test (rejet de H_a) est :

$$(4) \quad w = [Q_N > q_{1-\alpha}],$$

où $q_{1-\alpha}$ est le **quantile** d'ordre $1 - \alpha$ de \mathcal{X}^2 (K-L) ;

(b) lorsque Σ_P n'est que partiellement connue (eg $\Sigma_P = \sigma_P^2 \cdot \Omega_P$, où Ω_P est seule connue), la statistique :

$$(5) \quad F_N = (K - L)^{-1} \cdot (N - K) \cdot \{Q(\mathcal{L}, \mathcal{M}) / Q(\mathbf{R}^N, \mathcal{L})\},$$

dans laquelle :

$$(6) \quad Q(\mathcal{L}, \mathcal{M}) = (z(\mathcal{L}) - z(\mathcal{M}))' \Omega_P^{-1} (z(\mathcal{L}) - z(\mathcal{M})),$$

$$Q(\mathbf{R}^N, \mathcal{L}) = (y - z(\mathcal{L}))' \Omega_P^{-1} (y - z(\mathcal{L})),$$

suit, sous H_0 , une loi \mathcal{F} (K-L, N-K) (**loi de FISHER-SNEDECOR** à K - L et N - K degrés de liberté) : ie $F_N \sim \mathcal{F}$ (K-L, N-K).

La région critique du test (rejet de H_a) est :

$$(7) \quad w = [F_N > q_{1-\alpha}],$$

où $q_{1-\alpha}$ est le quantile d'ordre $1 - \alpha$ de \mathcal{F} (K-L, N-K).

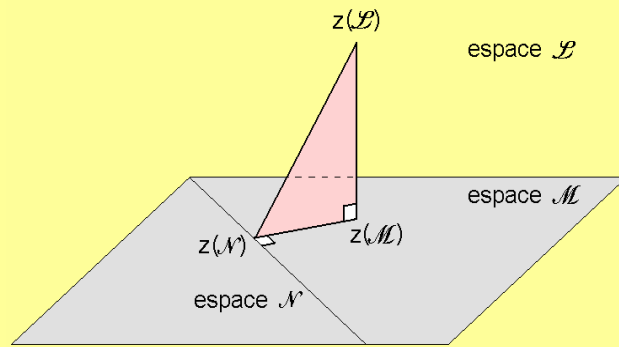
On appelle **tableau d'analyse de la variance** un tableau de la forme suivante (souvent utilisé dans l'étude d'un **plan d'expérience** et des modèles linéaires associés) :

Vecteur aléatoire	Degré de liberté	Variance « corrigée »
$y - z(\mathcal{L})$	N - K	$(N - K)^{-1} Q(\mathbf{R}^N, \mathcal{L})$
$z(\mathcal{L}) - z(\mathcal{M})$	K - L	$(K - L)^{-1} Q(\mathcal{L}, \mathcal{M})$
$y - z(\mathcal{M})$	N - L	$(N - L)^{-1} Q(\mathbf{R}^N, \mathcal{M})$

L'équation d'analyse de la variance associée s'écrit :

$$(8) \quad Q(\mathbf{R}^N, \mathcal{M}) = Q(\mathbf{R}^N, \mathcal{L}) + Q(\mathcal{L}, \mathcal{M}).$$

(ii) Cette démarche s'étend directement au test d'une **suite d'hypothèses emboîtées**. Ainsi, dans le cas où trois hypothèses $H(\mathcal{L})$, $H(\mathcal{M})$ et $H(\mathcal{N})$ sont resp associées à des variétés linéaires \mathcal{L} , \mathcal{M} et \mathcal{N} , de dimensions resp K, L et M et tq $\mathcal{N} \subset \mathcal{M} \subset \mathcal{L}$, on note resp $z(\mathcal{L})$, $z(\mathcal{M})$ et $z(\mathcal{N})$ les projections obliques (ie selon Σ_P) de y sur \mathcal{L} , \mathcal{M} et \mathcal{N} (cf graphique ci-dessous).



L'équation d'analyse de la variance s'écrit alors :

$$(9) \quad Q(\mathbf{R}^N, \mathcal{N}) = Q(\mathbf{R}^N, \mathcal{L}) + Q(\mathcal{L}, \mathcal{M}) + Q(\mathcal{M}, \mathcal{N}),$$

et le tableau d'analyse de la variance correspondant s'écrit :

Vecteur aléatoire	Degré de liberté	Variance « corrigée »
$y - z(\mathcal{L})$	$N - K$	$(N - K)^{-1} Q(\mathbf{R}^N, \mathcal{L})$
$z(\mathcal{L}) - z(\mathcal{M})$	$K - L$	$(K - L)^{-1} Q(\mathcal{L}, \mathcal{M})$
$z(\mathcal{M}) - z(\mathcal{N})$	$L - M$	$(L - M)^{-1} Q(\mathcal{M}, \mathcal{N})$
$y - z(\mathcal{N})$	$N - M$	$(N - M)^{-1} Q(\mathbf{R}^N, \mathcal{N})$