

PROBLÈME À PLUSIEURS ÉCHANTILLONS (I2)

(05 / 05 / 2020, © Monfort, Dicostat2005, 2005-2020)

Il arrive souvent que le **statisticien** possède plusieurs **échantillons** relatifs à un **phénomène** donné, ou à des phénomènes comparables. Un problème usuel consiste alors à comparer ces échantillons (cf aussi **comparaison multiple**) : ce problème revient donc à définir divers **tests d'hypothèses** les concernant dans leur ensemble. Généralement, ces tests sont fondés sur des **statistique de test** déduites des échantillons (eg **estimateurs** divers).

(i) Soit $(\Omega, \mathcal{F}, \mathcal{P})$ un **modèle statistique**, $(\mathcal{X}, \mathcal{B})$ un **espace mesurable** (eg un **espace d'observation**) et $\xi_i : \Omega \mapsto \mathcal{X}$ ($i \in N_k^*$) une **suite** (finie) de **va** (indépendantes entre elles) dont les **lp** resp $P^{\xi(i)}$ admettent les **densités** $f_i = dP^{\xi(i)} / d\mu$ pr à une **mesure positive** μ donnée et les **fonctions de répartition** $F_i, \forall i \in N_k^*$.

Soit $X^i = (X_{i1}^1, \dots, X_{iN(i)}^i)$ un N_i -**échantillon iid** généré par la **variable parente** $\xi_i, \forall i \in N_k^*$ (en désignant $\xi(i)$ par ξ_i et $n(i)$ par n_i).

On peut disposer l'ensemble X de ces va selon le **tableau statistique** (non « équilibré ») :

$$(1) \quad \begin{array}{l} X_{11}, \dots, X_{1,N(1)} \\ \dots\dots\dots \\ X_{i1}, \dots, X_{i,N(i)} \\ \dots\dots\dots \\ X_{k1}, \dots, X_{k,N(k)}, \end{array}$$

dans lequel on suppose que $k \geq 2$ et $N_i \geq 1, \forall i \in N_k^*$. On pose enfin $\sum_{i=1}^k N_i = N$ (nombre total d'**observations**).

La **vraisemblance** associée à l'échantillon partiel X^i , s'écrit (échantillon iid) :

$$(2) \quad p_i(x_i) = \prod_{n(i)=1}^{N(i)} f_i(x_{i,n(i)}), \forall x_i \in \mathbf{R}^{N(i)}$$

(où les $N(i)$ désignent les N_i).

Celle du N -échantillon d'ensemble X s'écrit (**indépendance** des X^i entre eux) :

$$(3) \quad p(x) = \prod_{i=1}^k p_i(x_i) = \prod_{i=1}^k \prod_{n(i)=1}^{N(i)} f_i(x_{i,n(i)}), \quad \forall x \in \mathbf{R}^N.$$

(ii) On appelle **problème à plusieurs échantillons**, ou **problème à k échantillons**, un **problème de test** dont l'**hypothèse de base** est, le plus souvent, la suivante :

$$(4) \quad H_0 : P^{\xi(1)} = \dots = P^{\xi(k)} = P^{\xi(0)} \quad (\text{identité entre elles des lois des } \xi_i),$$

ou encore, en termes de fonctions de répartition (resp de densités) :

$$(5) \quad H_0 : F_i = F_0 \quad (\text{resp } f_i = f_0), \quad \forall i \in N_k^*.$$

On appelle souvent H_0 l'**hypothèse de l'échantillon aléatoire**.

D'autres hypothèses de base sont aussi concevables (cf eg **test de BARTLETT**).

L'alternative peut être :

(a) une **alternative de position**, où l'on suppose l'existence d'une fr F fixe tq :

$$(6) \quad F_i(x_{i,n(i)}) = F(x_{i,n(i)} - \alpha_i), \quad \forall i \in N_k^*,$$

où $\alpha_i \in \mathbf{R}$ est, $\forall i \in N_k^*$, un **paramètre de position** ;

(b) une **alternative d'échelle**, où l'on suppose l'existence d'une fr F fixe tq :

$$(7) \quad F_i(x_{i,n(i)}) = F(x_{i,n(i)} / \beta_i), \quad \forall i \in N_k^*,$$

où $\beta_i \in \mathbf{R}_+^*$ est, $\forall i \in N_k^*$, un **paramètre d'échelle** ;

(c) une **alternative d'échelle et de position**, dans laquelle on suppose l'existence d'une fr F fixe tq :

$$(8) \quad F_i(x_{i,n(i)}) = F\{(x_{i,n(i)} - \alpha_i) / \beta_i\}, \quad \forall i \in N_k^*,$$

où $(\alpha_i, \beta_i) \in \mathbf{R} \times \mathbf{R}_+^*$ est, $\forall i \in N_k^*$, un **paramètre d'échelle et de position** ;

(d) une **alternative ordonnée** ;

(e) ou encore une **alternative en parapluie**.

(iii) Divers tests permettent de résoudre le problème à k échantillons : **test de KRUSKAL-WALLIS** (des **rangs**), **test de MOOD** (de la **médiane**) (cf **méthode de BROWN-MOOD**), **test de J.C. KIEFER** (analogue, pour k échantillons, du **test de KOLMOGOROV-SMIRNOV**), etc.

(iv) En pratique, le cas où $k = 2$ est fréquent : **problème à deux échantillons**.

L'exemple-type est le **test de comparaison** entre :

(a) un **échantillon expérimental**, dont les **unités expérimentales** sont soumises à des **traitements** : **facteurs expérimentaux**, **stimuli**, etc ;

(b) un **échantillon témoin**, dont les unités ne sont pas soumises aux stimuli, ou sont soumises à d'autres traitements, ou encore à un traitement « fictif » (placebo).

Le but est de vérifier si les traitements exercent des « effets » différents de ceux observés sans traitements.