

TEST DE LA MÉDIANE (F3, I2)

(24 / 09 / 2020, © Monfort, Dicostat2005, 2005-2020)

Le **test de la médiane** est un **test d'homogénéité** fondé sur une **statistique linéaire de rang** de la forme :

$$(1) \quad S_N = \sum_{n=1}^N c_n \cdot a_N(R_n).$$

(i) Ce test s'associe notamment au problème à deux **échantillons** (cf **problème à plusieurs échantillons, score**). Dans ce cadre, on pose, dans (1) :

$$(2) \quad c_n = 1, \quad n = 1, \dots, N,$$

et :

$$(3) \quad a_N(n) = \begin{cases} 0 & \text{ssi } n \leq (N+1)/2, \\ 1 & \text{ssi } n > (N+1)/2, \end{cases}$$

et l'on définit alors la **statistique de la médiane** suivante :

$$(4) \quad S_N = \sum_{n=1}^{N(1)} a_N(R_n),$$

dans laquelle $N = N_1 + N_2$ est la taille de l'échantillon d'ensemble (empilé) X , N_1 la taille du premier échantillon (aussi noté $N(1)$), et R_n le rang de la n -ième coordonnée de X (cf **statistique de rang**).

La statistique de la médiane (4) s'interprète donc comme le nombre d'observations du premier échantillon X , situées à droite de la **médiane** d'ensemble.

(ii) Sous l'hypothèse H_0 d'**homogénéité** (stricte) des deux échantillons (ie $P^{\xi(2)} = P^{\xi(1)}$), en notant $\xi(i)$ pour désigner ξ_i , ses deux premiers **moments** sont donnés par :

$$(5) \quad E_0 S_N = \begin{cases} N_2 / 2 & \text{ssi } N \in 2 \mathbf{N}^*, \\ N_2 (N - 1) / (2 N) & \text{ssi } N \in 2 \mathbf{N} + 1, \end{cases}$$

et :

$$(6) \quad V_0 S_N = \begin{cases} (N_1 N_2) / \{4 (N - 1)\} & \text{ssi } N \in 2 \mathbf{N}^*, \\ (N_1 N_2) (N + 1) / (4 N^2) & \text{ssi } N \in 2 \mathbf{N}^*, \end{cases}$$

et S_N suit la **loi hypergéométrique** :

$$(7) \quad S_N \sim^{H_0} \mathcal{H} \{N, N_2, 1/2\} \quad \text{ssi } N \in 2\mathbf{N}^*,$$

$$\mathcal{H} \{N, N_2, (N-1)/(2N)\} \quad \text{ssi } N \in 2\mathbf{N} + 1.$$

Les tests qui en résultent sont ainsi appelés **tests de la médiane**.

(iii) De tels tests sont adaptés aux **distributions** à « **queue épaisse** » (eg la première des **lois de LAPLACE** ou la **loi de CAUCHY**).

(iv) Plus généralement, dans le cadre du problème à $k \geq 2$ échantillons, on considère l'échantillon d'ensemble (échantillon « empilé ») X , on définit T_i comme le nombre d'observations de X situées à droite de la médiane de X , et l'on pose :

$$(8) \quad S_{N(1) \dots N(k)} = 4 \cdot \left\{ \sum_{i=1}^k N_i^{-1} (T_{N(i)})^2 \right\} - N,$$

où $N(i)$ dénote, par commodité, la taille N_i de l'échantillon n° i .

Lorsque la taille des échantillons est grande (ie lorsque $N^* = \min_{i=1}^k N_i \gg 0$), le **test de la médiane** utilise la **propriété asymptotique** suivante, valable sous certaines conditions :

$$(9) \quad \mathcal{L}(S_{N(1) \dots N(k)}) \rightarrow_{N^* \rightarrow +\infty} \mathcal{X}_{k-1}^2 \text{ (loi du chi-deux à } k \text{ degrés de liberté)}.$$

Ceci permet de tester l'hypothèse d'homogénéité stricte :

$$(10) \quad H_0 : F_1 = \dots = F_k$$

contre une alternative tq (**alternative de position**) :

$$(11) \quad H_1 : F_i(x_{i,n(i)}) = F(x_{i,n(i)} - \mu_i),$$

avec $\mu = (\mu_1, \dots, \mu_k) = 0$ (cf **test de KRUSKAL-WALLIS**) et où $i, n(i)$ dénote, par commodité, l'indice double (i, n_i) ($i = 1, \dots, k$).