

## TEST DES SCORES NORMAUX (C7, F6, I2)

(05 / 10 / 2019, © Monfort, Dicostat2005, 2005-2019)

Ce **test de rang** est fondé sur une **statistique linéaire de rang** et son objet est la vérification de l'hypothèse d'**homogénéité** des **lois** dans le cadre du problème à deux échantillons (cf **problème à plusieurs échantillons**, **test de FISHER-YATES**).

(i) Soit  $U = (U_1, \dots, U_N) \sim \mathcal{N}_{N(0, I_N)}$  un **vecteur aléatoire** normal,  $U^{(\cdot)}$  la **statistique d'ordre** associée à  $U$  et  $R$  sa **statistique de rang**.

On appelle **statistique des scores normaux** la **statistique** suivante :

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

dans laquelle la suite  $(a_N(n))_{n=1, \dots, N}$  est la suite des **scores normaux**  $a_N(n) = E U^{(n)}$  (pour tout  $n = 1, \dots, N$ ) et  $n(i)$  (resp  $N(i)$ ) désigne l'indice  $n_i$  (resp la taille  $N_i$  de l'échantillon n°  $i$ ), avec  $i = 1, 2$ .

Cette suite vérifie la propriété suivante :

$$(2) \quad a_N(N - n) = -a_N(n), \quad \forall n = 1, \dots, N.$$

(ii) Sous l'hypothèse  $H_0$  d'**homogénéité** (stricte) des deux populations dont sont extraits les échantillons  $X^1$  et  $X^2$  (ie égalité des **fonctions de répartition**  $F_1$  et  $F_2$  qui les génère respectivement) on montre que :

$$(3) \quad \begin{aligned} E_0 S_N &= 0, \\ V_0 S_N &= \{\sigma_0(S_N)\}^2 = N^{-1} (N-1)^{-1} N_1 \cdot N_2 \cdot \sum_{n=1}^N \{a_N(n)\}^2, \end{aligned}$$

où  $N = N_1 + N_2$  et  $\sigma_0(S_N)$  désigne l'**écart-type** de  $S_N$ .

La table « statistique » de la loi de  $S_N$  est définie pour de « petits » échantillons (ie  $\max(N_1, N_2) \ll +\infty$ ), ce qui permet de définir des **régions critiques** à distance finie, associées à tout seuil  $\alpha \in ]0, 1[$ .

Si la taille des échantillons est « grande » (ie  $N_1 \gg 0$  et  $N_2 \gg 0$ ), on utilise la **propriété asymptotique** suivante (**convergence légale**) :

$$(4) \quad \mathcal{L}(U_N) \xrightarrow{\min(N(1), N(2)) \rightarrow \infty} \mathcal{N}(0, 1) \quad (\text{loi normale réduite}),$$

où  $U_N$  désigne la statistique centrée réduite  $(S_N - E_0 S_N) / \sigma_0(S_N)$ .

On peut donc alors définir des régions critiques (asymptotiques) à partir de la loi normale et le test ainsi mis en oeuvre est appelé **test des scores normaux**.

Ce test est souvent utilisé contre des **alternatives d'échelle**.