

## STATISTIQUE LINÉAIRE DE RANG (F6, G1, I2)

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

(i) Soit  $(\mathcal{X}, \mathcal{B}, \mathcal{P}^X)$  un **modèle statistique** dans lequel  $(\mathcal{X}, \mathcal{B}) = (\mathbf{R}^N, \mathcal{B}(\mathbf{R}^N))$  et soit  $R = (R_1, \dots, R_N) = r(X)$  la **statistique de rang** associée à  $X$ .

On appelle aussi, plus généralement, **statistique de rang** une **statistique** (application mesurable) qui dépend de  $R$ , ie une application  $s : \sigma_N \mapsto \mathbf{R}$  définissant la statistique  $S = s(R)$ , où  $\sigma_N$  représente le groupe des **permutations** de  $N_N^* = \{1, \dots, N\}$ .

(ii) On définit alors une statistique linéaire de rang selon l'un des deux procédés suivants.

(a) soit  $c = (c_1, \dots, c_N)' \in \mathbf{R}^N$  un vecteur donné et  $(a_n)_{n \in N^*}$  une **suite finie**, ou **score**, sur  $\mathbf{R}$  (ie  $a_N : \{1, \dots, N\} \mapsto \mathbf{R}$ ).

On appelle **statistique linéaire de rang** une statistique  $S = s(R)$  tq :

$$(1) \quad S = s(R) = \sum_{n=1}^N c_n a_N(R_n).$$

Sous l'hypothèse  $H_0$  de l'**échantillon aléatoire**, les premiers **moments algébriques** de  $S$  sont :

$$(2) \quad \begin{aligned} E_0 S &= N \cdot \bar{c} \cdot \bar{a}, \\ V_0 S &= (N-1)^{-1} \cdot \{\sum_{n=1}^N (c_n - \bar{c})^2\} \cdot \{\sum_{n=1}^N (a_N(n) - \bar{a})^2\}, \end{aligned}$$

avec  $\bar{c} = N^{-1} \sum_{n=1}^N c_n$  (moyenne des  $c_n$ ) et  $\bar{a} = N^{-1} \sum_{n=1}^N a_N(n)$  (moyenne des scores).

Si  $\phi : ]0, 1[ \mapsto \mathbf{R}$  est une fonction  $\lambda_1$ -intégrable (**fonction score**), on établit, sous certaines conditions, la **convergence en loi** :

$$(3)_a \quad \mathcal{L}\{(S - E_0 S) / \sigma_0\} \rightarrow_{N \rightarrow +\infty} \mathcal{N}_1(0, 1),$$

avec :

$$(3)_b \quad \sigma_0^2 = \{\sum_{n=1}^N (c_n - \bar{c})^2\} \cdot \left\{ \int_{[0, 1]} (\phi(u) - \bar{\phi}) du \right\}, \quad \text{où } \bar{\phi} = \int_{[0, 1]} \phi(u) du ;$$

(b) soit  $a_N(n)_{n=1, \dots, N}$  une suite de **scores** et :

$$(4) \quad R_N^+ = \sum_{\alpha=1}^N H(|X_n| - |X_\alpha|), \quad \forall n \in \{1, \dots, N\},$$

où  $H$  désigne la **fonction de HEAVYSIDE**.

On appelle **statistique linéaire de rang** la statistique :

$$(5) \quad S = s(R) \text{ ou } s \circ r(X) = \sum_{n=1}^N a_N(R_n^+) \cdot H(X_n).$$

Si  $X$  est un **échantillon iid** selon la loi  $P^\xi$  et si la **densité de probabilité**  $f$  de  $P^\xi$  pr à  $\lambda_1$  est symétrique pr à  $\alpha \in E$ , ie :

$$(6) \quad f(x - \alpha) = f(x + \alpha), \quad \forall x \in \mathbf{R},$$

alors, sous l'hypothèse  $H_0 : \alpha = 0$ , les premiers **moments algébriques** s'écrivent :

$$(7) \quad \begin{aligned} E_0 S &= (1/2) \cdot \sum_{\alpha=1}^N a_N(n), \\ V_0 S &= (1/4) \cdot \sum_{\alpha=1}^N \{a_N(n)\}^2 = \sigma_0^2. \end{aligned}$$

Par suite, sous des conditions générales portant sur les scores, on établit la **convergence en loi** suivante :

$$(8) \quad \mathcal{L}((S - E_0 S) / \sigma_0) \rightarrow_{N \rightarrow +\infty} \mathcal{N}_1(0, 1),$$

ce qui permet d'effectuer un test de **centralité** relatif à  $\alpha$ .