

## STATISTIQUE DE Hoeffding (G, H, I)

(12 / 11 / 2019, © Monfort, Dicostat2005, 2005-2019)

(i) Soit  $(\mathcal{X}, \mathcal{B}, \mathcal{P}^X)$  un **modèle image** d'un modèle de base par un **N-échantillon**  $X$ , avec  $\mathcal{X} = \mathcal{X}_0^N$ , et  $(\mathcal{U}, \mathcal{E})$  un **espace mesurable** auxiliaire doté d'une **structure de groupe mesurable**.

On appelle **statistique de W. Hoeffding**, ou **U-statistique**, associée au modèle précédent une **statistique**  $U_N$  définie par une **application mesurable**  $u_N : \mathcal{X} \mapsto \mathcal{U}$  de la forme suivante (**moyenne** calculée sur  $N_0$  coordonnées de  $X$ ) :

$$(1) \quad U_N = u_N(X) = (C_N^{N(0)})^{-1} \sum_{A(0)} \phi(X_{\alpha(1)}, \dots, X_{\alpha(N(0))}),$$

où  $X = (X_1, \dots, X_N)$ , l'entier  $N_0$  (aussi noté  $N(0)$ ) est généralement donné et tq  $1 \leq N_0 \leq N$ ,  $C_N^{N(0)}$  est nombre de **combinaisons** de  $N$  objets pris  $N_0$  à  $N_0$ ,  $A(0) = \{(\alpha_1, \dots, \alpha_{N(0)}) : 1 \leq \alpha_1 \leq \dots \leq \alpha_{N(0)} \leq N\}$  et  $\phi : \mathcal{X}_0^{N(0)} \mapsto \mathcal{U}$  est une **application** symétrique. On a noté  $\alpha(n)$  pour désigner  $\alpha_n$  ( $n = 1, \dots, N(0)$ ).

L'entier  $N_0$  est appelé **degré** de  $\phi$  et l'application  $\phi$  est appelée **noyau** de  $U_N$ .

En pratique, on a généralement  $(\mathcal{U}, \mathcal{E}) = (\mathbf{R}, \mathcal{B}_{\mathbf{R}})$ .

(ii) Sous des **conditions de régularité** générales, dont :

(a) les  $X_n$  sont à valeurs dans  $\mathcal{X}_0 = \mathbf{R}$  et forment une **suite iid** ;

(b)  $(\mathcal{U}, \mathcal{E}) = (\mathbf{R}, \mathcal{B}_{\mathbf{R}})$ ,

on montre que  $U_N$  est asymptotiquement gaussienne (cf **normalité asymptotique**).

Si  $U_N$  est de carré intégrable et si l'on pose  $E \phi(X_1, \dots, X_{N_0}) = \alpha$ , alors  $E U_N = \alpha$  et :

$$(4) \quad V U_N = (N_0^2 / N) \cdot \beta + O(N^{-2}) \quad (\text{grand zéro}),$$

où  $\beta = V \phi_1(X_1)$ , en notant  $\phi_n(x_1, \dots, x_n) = E \phi(x_1, \dots, x_n, X_{n+1}, \dots, X_{N(0)})$ ,  $\forall n \in \{1, \dots, N_0\}$  et  $\forall (x_1, \dots, x_n) \in \mathbf{R}^n$ .

(ii) Les **U-statistiques de W. Hoeffding** interviennent dans divers contextes, eg :

(a) soit  $\phi$  le **noyau** (supposé symétrique) d'une **fonctionnelle** linéaire  $h : \mathcal{F}^X \mapsto \mathbf{R}$  et  $N_0$  le **degré** de  $h$ . La **va** réelle  $U_N$  définie par l'**application mesurable**  $u_N$  selon (1), où l'entier  $N_0 \leq N$  est généralement donné et où les  $X_n$  ( $n = 1, \dots, N$ ) sont indépendantes, est une U-statistique. Cette statistique est un **estimateur sans biais** de la valeur de la fonctionnelle  $h$  au point  $F \in \mathcal{F}^X$  :

$$(2) \quad E U_N = h(F), \quad \forall F \in \mathcal{F}^X \text{ et } \forall N \geq N_0 .$$

Elle possède une **variance** minimale dans la classe des **estimateurs sans biais** de  $h(F)$ . Enfin, sous des hypothèses générales de régularité, la loi asymptotique de  $U_N$  est gaussienne ;

(b) dans le cadre du problème à deux échantillons  $X = (X_1, \dots, X_M)$  et  $Y = (Y_1, \dots, Y_N)$  (cf **problème à plusieurs échantillons**), on utilise souvent (cf **test de WILCOXON, test de MANN-WHITNEY**) une statistique de la forme :

$$(3) \quad U_{MN} = \sum_{m=1}^M \sum_{n=1}^N \mathbf{1}_{A(m,n)} ,$$

où  $A(m,n) = [X^{(m)} \geq Y^{(n)}] = \{\omega \in \Omega : X^{(m)}(\omega) \geq Y^{(n)}(\omega)\}$  et où  $X^{(\cdot)} = (X^{(1)}, \dots, X^{(M)})$  et  $Y^{(\cdot)} = (Y^{(1)}, \dots, Y^{(N)})$  sont les **statistiques d'ordre** (ou échantillons ordonnés) resp associées à  $X$  et  $Y$ .

$U_{MN}$  est une U-statistique de Hoeffding qui indique le nombre de fois où une coordonnée de  $X$  dépasse une coordonnée de  $Y$ . Elle peut être utilisée pour un **test de décentrement** (cf **test de déplacement**).