

STATISTIQUE DE BALAYAGE (C5, I2)

(07 / 10 / 2019, © Monfort, Dicostat2005, 2005-2019)

La **statistique de balayage** est une **statistique** permettant de tester si un échantillon comporte des **observations groupées** (**accumulation** autour de certaines valeurs). Dans ce cas, la loi qui les génère peut être une **loi multimodale** (cf **mélange de lois**, **test d'unimodalité**).

(i) Soit $\xi \sim \mathcal{U}(0, 1)$ une va uniforme (cf **loi uniforme continue**) et $X = (X_1, \dots, X_N)$ un **échantillon iid** comme ξ . On pose, $\forall h \in [0, 1]$:

$$(1) \quad C_N(x, h) = \sum_{n=1}^N \mathbf{1}_{[I_n(x, h)]} = F_N(x+h) - F_N(x),$$

où $I_n(x, h) = [X_n \in]x, x+h]] = \{\omega \in \Omega : X_n(\omega) \in]x, x+h]]\}$ et F_N est la **fonction de répartition empirique** associée à X . Autrement dit, $C_N(x, h)$ est le nombre d'observations X_n appartenant à l'intervalle $]x, x+h]$.

(ii) On appelle alors **statistique de balayage** la statistique (ou **fonction aléatoire**) $C_N : [0, 1] \mapsto \mathbb{N}_N$ définie par :

$$(2) \quad C_N(h) = \sup_{x \in [0, 1-h]} C_N(x, h), \quad \forall h \in [0, 1].$$

(iii) Cette statistique, de type fonctionnel, permet notamment de tester l'**hypothèse de base** (hypothèse d' « uniformité ») :

$$(3) \quad H_0 : \xi \sim \mathcal{U}(0, 1)$$

contre l'**alternative de groupement** H_a tq eg :

$$(4) \quad H_a : \xi \sim \mathcal{G}(a, b),$$

où $\mathcal{G}(a, b)$ est une loi dont la densité pr à λ_1 est de la forme :

$$(5) \quad g(x) = \begin{cases} \{1 + (b-1)h\}^{-1}, & \forall x \in]0, a], \\ \{1 + (b-1)h\}^{-1} \cdot b, & \forall x \in]a, a+h], \\ \{1 + (b-1)h\}^{-1}, & \forall x \in]a+h, 1], \end{cases}$$

où a et b sont connus et h inconnu.

(iv) C_N s'associe naturellement au **test du rapport des vraisemblances** de l'hypothèse (3) contre l'hypothèse (4). Ce test, fondé sur la loi de C_N lorsque H_0 est supposée vraie, admet pour **région critique** :

$$(6) \quad w = [C_N \geq q_{1-\alpha}]$$

où $q_{1-\alpha}$ est le **quantile** d'ordre $1 - \alpha$ de la loi précédente. Il existe plusieurs approximations de (6) (formules complexes).

(v) L'approche précédente peut s'étendre aux cas où (a) ξ n'est plus uniforme (cf **uniformisation**) et où (b) ξ est à valeurs dans un ensemble plus général \mathcal{X} .