

## TEST D'UNIMODALITÉ (C5, I2)

(10 / 06 / 2020, © Monfort, Dicostat2005, 2005-2020)

Un **test d'unimodalité** tire sa finalité de l'intérêt pratique à utiliser une **loi unimodale** (cf aussi **méthode du maximum de vraisemblance** ou **école bayésienne**). En effet :

(a) les **observations** disponibles peuvent, notamment lorsqu'elles sont peu nombreuses, comporter des « trous » (cf **lacune**) tendant à étayer l'hypothèse d'un **mélange de lois** : l'**histogramme** obtenu peut alors comporter des classes « rares » ou vides (cf **loi multimodale**) ;

(b) en outre, une loi unimodale est souvent une **loi symétrique** : il est donc utile de tester si une loi donnée est unimodale, ou si elle appartient à une famille de lois unimodales.

(i) On considère un **modèle produit**  $(\mathcal{X}, \mathcal{B}, \mathcal{P}^X)$  dans lequel  $X = (X_1, \dots, X_N)$  est un **échantillon iid** selon une **loi**  $P^\xi$ , ie  $P^X = (P^\xi)^{\otimes N}$ . Ici,  $P^\xi \in \mathcal{P}^\xi$  est supposée être la « vraie » loi qui génère l'échantillon  $X$ .

Un **test d'unimodalité** a pour objectif de détecter si l'**hypothèse de base** :

$H_0$  :  $P^\xi$  est une **loi unimodale**,

est plus vraisemblable qu'une **hypothèse alternative** donnée, laquelle est, le plus souvent, l'alternative générale :

$H_a$  :  $P^\xi$  n'est pas une loi unimodale (ie  $P^\xi$  est multimodale).

Un test d'unimodalité est donc plus ou moins fondé sur les propriétés connues du **mode** et suppose souvent une hypothèse de **différentiabilité** de la **densité**.

Deux approches sont présentées, dans le cas où  $\mathcal{X} = \mathbf{R}$  et  $\mathcal{B} = \mathcal{B}_{\mathbf{R}}$  (**tribu borélienne**).

(ii) Soit  $F$  la **fonction de répartition** théorique associée à  $P^\xi$  et  $F_N$  la **fr empirique** associée à  $X$ . On note  $\mathcal{F}$  l'ensemble des fonctions  $F$  ( $\mathcal{F}$  est donc associé à l'ensemble  $\mathcal{P}^\xi$  des lois  $P^\xi$ ) et l'on suppose donnée une **distance**  $d$  sur  $\mathcal{F}$ , eg :

$$(1) \quad d(F_1, F_2) = \sup_{x \in \mathcal{X}} |F_1(x) - F_2(x)|, \quad \forall (F_1, F_2) \in \mathcal{F}^2.$$

On considère alors un **test d'unimodalité** tq le suivant :

(2)  $H_0 : F = F_0$  (fonction unimodale en un point  $\alpha \in \mathcal{X}$ ),

$H_a : F \in \mathcal{F} \setminus \{F_0\}$  (fonctions multimodales),

et l'on pose :

(3)  $\delta(F) = \inf_{G \in \mathcal{G}} d(F, G)$ ,

où  $\mathcal{G} = \{G : \mathbf{R} \mapsto [0, 1]\} = \mathcal{F} \setminus \{F_0\}$  désigne l'ensemble des fonctions de répartition multimodales. En effet, si  $F_0$  est unimodale (au point  $\alpha$ ) et si les fonctions  $G$  sont multimodales, le nombre  $\delta(F_0)$  sera généralement plus grand que si les fonctions  $G$  étaient toutes unimodales en  $\alpha$ .

Par suite, la **statistique naturelle** :

(4)  $D_N = \delta(F_N)$

peut servir à fonder un test d'unimodalité. En effet, le **théorème de CANTELLI-GLIVENKO** implique que, sous  $H_0$ ,  $d(F_N, F_0) \rightarrow 0$  lorsque  $N \rightarrow +\infty$  ;

(iii) Le test précédent supposait que les éléments  $G \in \mathcal{G}$  de l'hypothèse alternative  $H_a$  comportaient un nombre indéterminé (mais supérieur à 1) de modes. Or la multiplicité des modes d'une loi vient souvent du fait que cette loi est un **mélange légal** (ou peut être considérée comme tel).

Un autre type de test consiste à supposer, dans le **modèle image** précédent (**modèle produit**), que :

(5)  $P^\xi = \sum_{i \in I} \alpha_i \cdot P_i$ ,

où  $I$  est un ensemble d'indices fini (donné a priori) et où chaque composante  $P_i$  ( $i \in I$ ) du mélange (5) est supposée (sans restreindre la généralité) unimodale.

Dans ce cadre, l'**hypothèse d'unimodalité**  $H_0$  peut alors s'écrire (« absence » de mélange) :

(6)  $H_0 : \exists i \in I : \alpha_i = 1$  et  $\alpha_j = 0$  ( $\forall j \in I \setminus \{i\}$ ).

Son **alternative**  $H_a$  est alors la complémentaire  $H_0^c$  (« existence » d'un mélange).

A une **permutation** près sur l'ensemble  $I$ , le test peut se ramener à un test portant sur les **proportions**  $\alpha_i$  du mélange. Lorsque  $\mathcal{P}^\xi$  est une **famille de lois identifiable**, une **procédure** consiste à estimer, la **suite**  $(\alpha_i)_{i \in I}$  définie par (5) selon  $\tilde{\alpha} = (\tilde{\alpha}_i)_{i \in I}$  (eg à l'aide de la **méthode du maximum de vraisemblance contraint**), puis à tester (6) à l'aide de la loi de  $\tilde{\alpha}$ .