

Estimation d'une densité discrète sous contrainte de k -monotonie.

Jade Giguelay sous la direction de Christophe Giraud et Sylvie Huet.


Orsay - 23 juin 2016

Sommaire.

- Densités k -monotones discrètes.
- Estimation sous-contrainte de k -monotonie :
 - ▶ Propriétés.
 - ▶ Algorithme.
- Le choix de k .

Notations.

- $p^* = (p_0, p_1, \dots)$ est une densité dans \mathbb{N} .
- Le maximum du support τ de p est défini par :
$$\tau = \min\{j \in \bar{\mathbb{N}}, \forall k > j, p_k = 0\}.$$
- X_1, \dots, X_n i.i.d de loi p de maximum de support τ (inconnu)
- $\tilde{p}_n : \tilde{p}_n(j) = \frac{1}{n} \sum_{i=1}^n \mathbb{I}_{\{X_i=j\}}$ est l'estimateur empirique.
- $k \geq 2$ est un entier fixé.




La convexité.

Définition

(Le Laplacien) $\Delta^2 p(i) = p_i - 2p_{i+1} + p_{i+2} = (p_{i+2} - p_{i+1}) - (p_{i+1} - p_i)$.

- La loi p est dite **convexe** si pour tout $i \in \mathbb{N}$, $\Delta^2 p(i) \geq 0$.
- Si $\Delta^2 p(i) > 0$ on dit que i est un **noeud** de p .




La convexité 2.

Une fonction convexe est mélange de fonctions triangulaires : si p est une fonction convexe discrète alors :

$$p(i) = \sum_{j=0}^{\infty} \frac{\Delta p(j+1)}{(j+1)(j+2)} T_j(i)$$

. Où T_{τ} est la distribution triangulaire de support $\{0, \dots, \tau\}$:

$$T_{\tau}(i) = \begin{cases} \frac{2(\tau+1-i)}{(\tau+1)(\tau+2)} & \text{si } j \in \{0, \dots, \tau\} \\ 0 & \text{sinon.} \end{cases}$$



Fonction k -monotone.

Une fonction p de $L^1(\mathbb{N})$ est :

- **monotone** (**1-monotone**) si pour tout i , $\Delta^1 p(i) := p_{i+1} - p_i \leq 0$
- **convexe** (**2-monotone**) si pour tout i ,

$$\Delta^2 p(i) := p_i - 2p_{i+1} + p_{i+2} = \Delta^1 p_{i+1} - \Delta^1 p_i \geq 0.$$

→ Pour généraliser on dira que p est :

- **3-monotone** si pour tout i , $\Delta^3 p(i) := \Delta^2 p_{i+1} - \Delta^2 p_i \leq 0$,

⋮

- **k -monotone** si pour tout i , $\Delta^k p(i) := \Delta^{k-1} p_{i+1} - \Delta^{k-1} p_i$ est du signe de $(-1)^k$.


Fonction k -monotone.

Définition

(Le j -ième Laplacien) $\Delta^j p(i) = \sum_{h=0}^j \binom{j}{h} (-1)^{j-h} p(h+i)$.

- La distribution p est k -monotone sur \mathbb{N} si $(-1)^k \Delta^k p(i)$ est positive pour tout i .
- Si $(-1)^k \Delta^k p(i) > 0$ on dit que i est un k -**noeud** de p .
- k -monotone $\Rightarrow j$ -monotone strictement sur son support, $j = 1, \dots, k-1$.

Exemple de fonctions k -monotones.



Ecriture en base de spline.

On définit une famille de splines $(Q_j^k)_{j \in \mathbb{N}^*}$:

$$Q_j^k(i) = C_{j-i+k-1}^{k-1} = \frac{(j-i+k-1) \dots (j-i+1)}{(k-1)!} \mathbb{I}_{j \geq i} \quad (1)$$

(Lefèvre et Loisel (2012)).

Exemple :

- $Q_j^2(i) = (j+1-i)_+$ est la triangulaire T_j .
- $Q_j^3(i) = \frac{1}{2} ((j+1-i)_+^2 + (j+1-i)_+)$.
- $Q_j^4(i) = \frac{1}{6} ((j+1-i)_+^3 - (j+1-i)_+)$.

Ecriture en base de splines.

Une fonction k -monotone s'écrit comme un mélange de Q_j^k :

Theorem

Soit p une densité de masse finie sur \mathbb{N} . p est k -monotone si et seulement si p s'écrit :

$$p(i) = \sum_{j \geq i} (-1)^k \Delta^k p_j Q_j^k(i) = \sum_{j \geq i} \tilde{\pi}_j \frac{Q_j^k(i)}{m_j}, \quad (2)$$

où $m_j = \sum_{i=0}^j Q_j^k(i)$.

De plus, p est une probabilité $\Leftrightarrow \tilde{\pi}$ est une probabilité.

La convexité 3.

Durot et al. (2013) : Estimation de p^* sous-contrainte de convexité par méthode des moindres carrés :

$$\hat{p}_n = \operatorname{argmin}\{\|f - \tilde{p}_n\|_2, f \text{ fonction convexe}\}. \quad (3)$$

- \hat{p}_n est de support fini.
- \hat{p}_n est de masse 1.
- Algorithme exact via Support Reduction Algorithm (Groeneboom et al., (2008))

Estimateur sous contrainte de k -monotonie.

L'estimateur $\hat{p}_{n,k}$ sous contrainte de k -monotonie est défini ainsi :

$$\hat{p}_{n,k} = \operatorname{argmin}\{\|f - \tilde{p}_n\|_2, f \text{ probabilité } k\text{-monotone}\}. \quad (4)$$

- Il existe et il est unique.
- Son support est fini.

Propriétés de \hat{p}_n .

Propriété

Pour toute probabilité f k -monotone $\|f - \hat{p}_{n,k}\|_2 \leq \|f - \tilde{p}_n\|_2$ avec une inégalité stricte si \tilde{p}_n n'est pas k -monotone.

Propriété

Soit p une probabilité discrète quelconque.

Pour tout $r \in [2, +\infty]$ on a $\sqrt{n} \|p_{S_k} - \hat{p}_{n,k}\|_r = O_P(1)$

où $p_{S_k} = \operatorname{argmin}\{\|f - p\|_2, f \in S_k\}$ est le projeté orthogonal de p sur l'ensemble des probabilités k -monotones.

Propriété

Soit p une densité k -monotone de support fini. Soit $r \in \mathbb{N}$ un k -noeud de p . Alors avec probabilité 1 il existe un rang n_0 tel que pour tout $n \geq n_0$, r est un k -noeud de \hat{p}_n .

Remarque sur la masse.

On peut également définir :

$$\hat{p}_{n,k}^* = \operatorname{argmin}\{\|f - \tilde{p}_n\|_2, f \text{ fonction } k\text{-monotone}\}. \quad (5)$$

Lemme

Soit δ_1 la masse de Dirac en 1. Le projeté de δ_1 sur les fonctions 3-monotones est :

$$p = \frac{3}{238} Q_5^3 + \frac{1}{238} Q_6^3,$$

La masse de p est d'environ 1.14.

Un algorithme en deux temps.

Step 1) Adaptation de l'**Algorithme de Réduction de Support**,
Groeneboom et al. (2008).

$L \in \mathbb{N}^*$ est fixé, on calcule l'estimateur \hat{p}_n^L :

$$\hat{p}_n^L = \operatorname{argmin}\{\|\tilde{p}_n - q\|_2, q \in S_{k,L}\},$$

où $S_{k,L} = \{\text{probabilités } f \text{ } k\text{-monotones, } \operatorname{supp}(f) \subset \{0, \dots, L\}\}$.

Step 2) On trouve un **critère d'arrêt** : à partir de quel $L \in \mathbb{N}^*$, $\hat{p}_n = \hat{p}_n^L$?

Caractérisation de \hat{p}_n .

- $\forall l \in \mathbb{N}, \begin{cases} F_f^1(l) = F_f(l) = \sum_{i=0}^l f(i), \\ \forall j \geq 2, F_f^j(l) = \sum_{i=0}^l F_f^{j-1}(l). \end{cases}$
- $\beta(p) = \sum_{i=0}^{\infty} p(i)(p(i) - \tilde{p}_n(i)).$

Theorem

Soit p une probabilité. Soit m_l^k la masse de Q_l^k . Il y a équivalence entre :

- 1 $p = \hat{p}_n.$
- 2 \blacktriangleright Pour tout $l \in \mathbb{N}$ on a l'égalité :

$$F_{\hat{p}_n}^k(l) - F_{\tilde{p}_n}^k(l) \geq m_l^k \beta(\hat{p}_n) \quad (6)$$

- \blacktriangleright il y a égalité si l est un noeud de \hat{p}_n .

Critère d'arrêt.

Résultats :

- On sait calculer un tel L en pratique pour tout $k \geq 3$.
- Pour les cas $k = 3$ et $k = 4$ on a un résultat plus précis :

Propriété

Soit s le maximum entre le support de p et le support de \tilde{p}_n . On a équivalence entre :

- 1 $p = \hat{p}_n$.
- 2
 - 1 $\forall l \leq s + 1, F_{\hat{p}_n}^k(l) - F_{\tilde{p}_n}^k(l) \geq m_l^k \beta(\hat{p}_n)$.
 - 2 Si l est un k -noeud de p il y a égalité dans l'inégalité précédente.
 - 3 $\forall j \in \{1, \dots, k - 1\}, F_p^j(s + 1) \geq F_{\tilde{p}_n}^j(s + 1)$

Bilan et nouveaux objectifs.

A k fixé :

- On a proposé un estimateur de p sous contrainte de k -monotonie.
- Il est de support fini, de masse 1.
- On sait le caractériser et le calculer en pratique.

Objectifs :

- Quantifier la concentration de \hat{p}_k autour de p en fonction de k :

$$\mathbb{P}(\|\hat{p}_k - p^*\|_2^2 \leq \text{BIAIS} + V(k) + f(x)) \geq 1 - e^{-x}.$$

- Choisir k .

Adaptation d'un argument de Chatterjee (2014).

Objectif : $\mathbb{P} (\|\hat{p}_k - p^*\|_2^2 \leq \text{BIAIS} + V(k) + f(x)) \geq 1 - e^{-x}$.

Rappel : $\|\hat{p}_k - p^*\|_2^2 = O_{\mathbb{P}}(\frac{1}{\sqrt{n}})$.

On suppose $p^* \in S_k := \{\text{probabilités } k\text{-monotones}\}$.

$$\|\hat{p}_k - p\|_2^2 = \operatorname{argmax}_t \left[\underbrace{\min_{p \in S_k, \|p - p^*\|_2 \leq 2} \langle \tilde{p} - p^*, p - p^* \rangle}_{M(t)} - \frac{t^2}{2} \right] := \hat{t}$$

$$M(t) = \frac{c_k t}{\sqrt{n}} \Rightarrow \hat{t} = \frac{d_k}{\sqrt{n}}$$

Nouvel Objectif : Trouver un majorant \bar{M} de M de la forme $\bar{M}(t) = \frac{c_k t}{\sqrt{n}}$.

Entropie Métrique.

- (E, d) un espace métrique de fonctions à valeur réelle.
- T un sous-espace de E .
- $\epsilon > 0$.

Un ϵ -**crochet** de borne $(t_1, t_2) \in E^2$ est défini par :

$$[t_1, t_2] = \{t \in T, s_1 \leq t \leq s_2\}$$

Le nombre minimal de ϵ -crochets nécessaires pour recouvrir T est noté $N_{[\cdot]}(\epsilon, T, d)$.

$\log(N_{[\cdot]}(\epsilon, T, d))$ est l'**entropie à crochet** de T .

Lien entre Entropie Métrique et Vitesse de Convergence.

Objectif : Trouver un majorant \bar{M} de M de la forme $\bar{M}(t) = \frac{c_k t}{\sqrt{n}}$.

Theorem

(Massart, p193). Soit $t \in [0, 1]$. On suppose que :

- $\forall h \geq 2, \forall f \in \mathcal{F}_t, \mathbb{E}[|f(X_1)|^h] \leq \frac{h!t^h}{2}$.
- Pour tout $\delta > 0$ on peut construire un crochet de \mathcal{F}_t , $B_\delta = \{(\underline{f}_1 - \bar{f}_1), \dots, (\underline{f}_{N_\delta} - \bar{f}_{N_\delta})\}$ de longueur N_δ tel que pour tout $i \in \llbracket 1, N_\delta \rrbracket$:

$$\forall h \geq 2, \mathbb{E}[|\underline{f}_i(X_1) - \bar{f}_i(X_1)|^h] \leq \frac{h!t^h}{2}.$$

Alors :

$$\mathbb{P} \left(M(t) \leq \frac{27}{\sqrt{n}} \int_0^t \sqrt{H(u) \wedge n} du + \frac{4tH(t)}{n} + \frac{7t\sqrt{2x}}{\sqrt{n}} + \frac{2tx}{n} \right) \geq 1 - e^{-x} \quad (7)$$

Le calcul de l'entropie sur l'espace des fonctions k -monotones et le résultat de concentration associé.

Propriété

Soit $\delta > 0$. On a :

$$H(\delta) := N_{[\cdot]}(\delta, l_2(p^*), \mathcal{F}_t) = \left(\frac{1}{\delta} \log\left(\frac{t^2}{\delta}\right) + o\left(\frac{1}{\delta}\right) \right) \mathbb{I}_{t^2 \geq \delta}.$$

Propriété

Il existe des constantes α_k, β_k telles que pour tout $t \in]0, 1[$, pour tout $x > 0$, pour tout $k \geq 2$:

$$\mathbb{P} \left(M(t) \leq \alpha_k t^2 + \frac{\beta_k t}{\sqrt{n}} + 2t \frac{x+2}{n} \right) \geq 1 - e^{-x} \quad (8)$$

Une différence avec le cas continu.

→ Vitesse paramétrique.

$$\begin{aligned} \mathbb{E} [\|\tilde{p} - p^*\|_2^2] &= \mathbb{E} \left[\sum_{l=0}^{\infty} \left(\frac{1}{n} \sum_{i=1}^n \mathbb{I}_{X_i=l} - p^*(l) \right)^2 \right] \\ &= \frac{1}{n} \mathbb{E} \left[\sum_{l=0}^{\infty} (\mathbb{I}_{X_i=l} - p^*(l))^2 \right] \\ &= \frac{1}{n} p^*(l)(1 - p^*(l)). \end{aligned}$$

Theorem

(Gao et Wellner (2009)). Soit $\epsilon > 0$. Soit $\mathcal{F}_k([0, 1])$ l'ensemble des densités (continues) k -monotones sur $[0, 1]$. Il existe des constantes C, D telle que pour toute densité p^* :

$$\log N_{[\cdot]}(\epsilon, \mathcal{F}_k([0, 1]), \|\cdot\|_{2, p^*}) \leq C \frac{D^{1/k}}{\epsilon^{1/k}}.$$

Perspectives.

- Améliorer la borne supérieure \bar{M} pour une meilleure dépendance en k .
- Trouver une borne inférieure.
- Choisir k via sélection de modèle.
- Application à l'estimation du nombre d'espèces dans une population.

Bibliographie.

Merci !

- Durot, Huet, Koladjo, and Robin, Computational Statistics and Data Analysis, **67**, (2013)
- Groeneboom et al., Scandinavian Journal of Statistics, **35**, (2008)
- Balabdaoui and Wellner, The Annals of Statistics, (2007)
- Lefevre and Loisel, Journal of Applied Probability, **50**, (2013)
- Chatterjee, The Annals of Statistics, **42**, (2014)
- Massart, Concentration Inequalities and Model Selection, Springer, Ecole d'Eté de Probabilités de Saint-Flour (2003).
- Gao and Wellner, On the rate of convergence of the maximum likelihood estimator of a k -monotone density, Springer, (2009).