

Minimiser le risque empirique pour des pertes à queue lourde

Emilien Joly

Université Paris Sud

sous la direction de Gábor Lugosi et de Gilles Stoltz

11 avril 2014

Quelle question ?

Un statisticien (même le vendredi matin) travaille avec un échantillon Z_1, \dots, Z_n i.i.d. dans un espace plus ou moins complexe \mathcal{Z} .

Et on optimise...

Exemples :

- Si $Z_i = (X_i, Y_i)$, on cherche à minimiser $\sum_{i=1}^n |Y_i - aX_i - b|$. Plus particulièrement, on cherche les valeurs de a et de b optimales.
- Moindre carrés : $\min_{a,b} \sum_{i=1}^n (Y_i - aX_i - b)^2$
- Maximum de vraisemblance : $\max_{\theta} \sum_{i=1}^n \log f_{\theta}(Z_i)$

Quelle question ?

Dans tout ces cas, on cherche à minimiser une quantité empirique "s'approchant" d'une espérance. Dans l'idéal, le choix du minimum serait $\operatorname{argmin}_\ell \mathbb{E} [\ell(Z)]$.

- ① Cadre de l'estimation robuste
- ② Estimateur de Catoni
- ③ Résolution sur une classe \mathcal{F}
- ④ Un exemple de perte

Soit Z une variable aléatoire réelle. Z peut être une variable réelle, à valeur dans \mathbb{R}^d ou même dans un espace mesurable quelconque Ω .

- Une fonction de risque est $\ell : \Omega \rightarrow [0, +\infty[$. On l'appelle certaines fois fonction de coût ou fonction de perte.
- Choix de $\ell : \mathcal{F}$ ensemble des candidats.

On se réfère à la perte optimale **théorique** ℓ_{opt} définie par :

$$\ell_{opt} \in \operatorname{argmin}_{\ell \in \mathcal{F}} \mathbb{E}[\ell(Z)]$$

Pour toute fonction de perte ℓ , le risque prend la forme :

$$R(\ell) = \mathbb{E}[\ell(Z)] - \mathbb{E}[\ell_{opt}(Z)]$$

Objectif : Trouver une estimation $\hat{\ell}$ rendant $R(\hat{\ell})$ le plus petit possible.

Le statisticien a accès à (Z_1, \dots, Z_n) un échantillon de la loi de Z .
Un **estimateur de risque empirique** $\hat{\ell}_{erm}$ est défini par :

$$\hat{\ell}_{erm} \in \operatorname{argmin}_{\ell \in \mathcal{F}} \sum_{i=1}^n \ell(Z_i)$$

Le **risque** de cet estimateur dépend fortement du comportement de $\sum_{i=1}^n \ell(Z_i)$.

Deux types d'hypothèses de **concentration** :

- $\operatorname{Var}(\ell(Z)) < \infty \implies \sum_{i=1}^n \ell(Z_i)$ à queue sous-quadratique
- ℓ bornée $\implies \sum_{i=1}^n \ell(Z_i)$ à queue sous-Gaussienne

Peut-on faire mieux? On ne s'autorise que des hypothèses faibles sur la distribution Z .

Une inégalité de concentration a la forme :

$$\mathbb{P}(Z > u) \leq g(u)$$

où g est une fonction décroissant plus ou moins rapidement en u .

La concentration sous-Gaussienne est donnée par

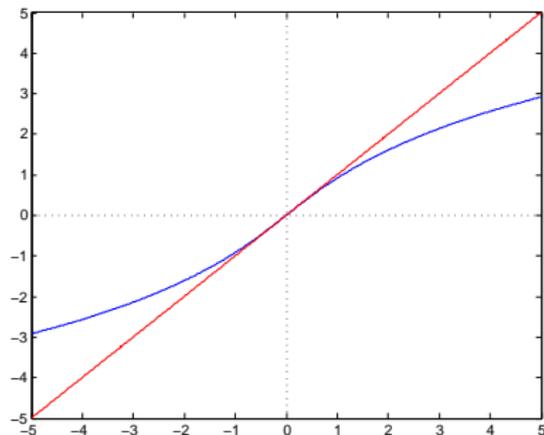
$g(u) = K \exp(-\frac{u^2}{v})$, plus utilisée sous la forme

$$Z \leq \sqrt{c \ln\left(\frac{K}{\varepsilon}\right)} \text{ avec probabilité au moins } 1 - \varepsilon$$

Un estimateur robuste pour les queues lourdes

On définit une fonction ϕ de troncature.

$$\phi(x) = \mathbb{1}_{\{x \geq 0\}} \log\left(1 + x + \frac{x^2}{2}\right) - \mathbb{1}_{\{x < 0\}} \log\left(1 - x + \frac{x^2}{2}\right)$$



Le nouvel estimateur est défini comme l'unique solution $\hat{\mu}_\ell$ de :

$$\sum_{i=1}^n \phi\left(\alpha(\ell(Z_i) - \mu)\right) = 0$$

α est un paramètre à optimiser.

Concentration autour de la moyenne

Pour **chaque** ℓ on obtient une concentration quasi-sous-Gaussienne.

Théorème (Catoni 2011)

Soit $\varepsilon > 0$, $\alpha = \sqrt{\frac{2 \log \varepsilon^{-1}}{vn}}$. On suppose que $n > 2 \log \varepsilon^{-1}$ et que $\text{Var}(\ell(Z)) \leq v$. L'estimateur $\hat{\mu}_\ell$ vérifie avec probabilité plus grande que $1 - 2\varepsilon$,

$$|\mathbb{E}[\ell(Z)] - \hat{\mu}_\ell| \leq \sqrt{\frac{2v \log \varepsilon^{-1}}{n}}$$

Le choix de ε dépend de n .

Par α l'estimateur dépend de la variance v et du niveau de confiance ε . Il faut donc connaître une borne supérieure de la variance *à priori*.

Le cadre non paramétrique demande un contrôle de l'espace \mathcal{F} . On définit l'entropie :

Definition

On munit l'espace \mathcal{F} d'une distance d . On appelle Entropie la quantité :

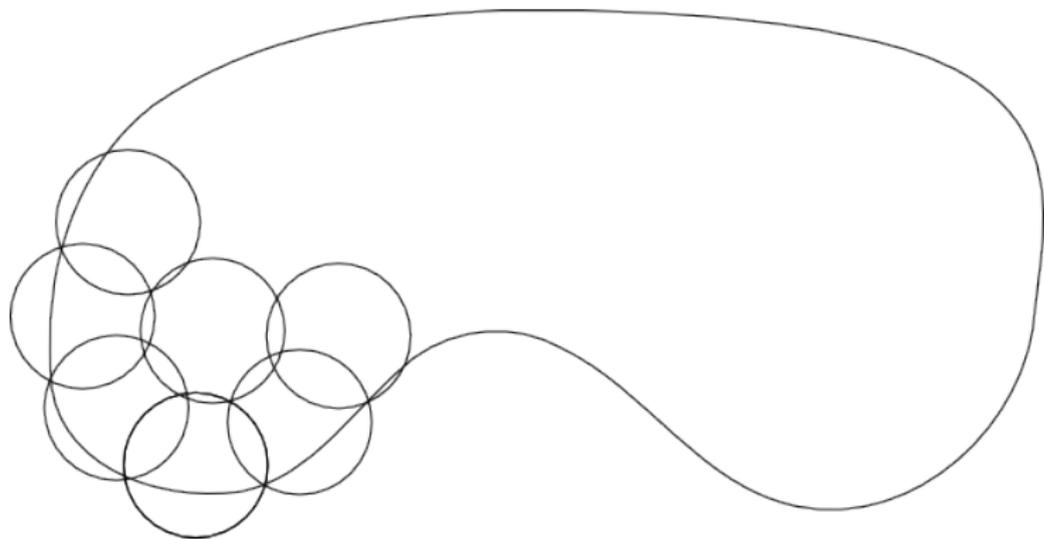
$$\gamma_d = \int_0^{\text{diam}_d \mathcal{F}} \sqrt{\log N(\mathcal{F}, d, \varepsilon)} d\varepsilon$$

où $N(\mathcal{F}, d, \varepsilon)$ est le nombre minimal de boules de rayon ε recouvrant \mathcal{F} .

Cette quantité mesure la complexité de l'espace \mathcal{F} .
On notera γ_2 l'entropie pour la distance L_2 .

Un aperçu du chaining

L'idée du chaining est de contrôler le $\mathbb{E}[\sup_{f \in \mathcal{F}} X_f]$.



Soient X_f des variables aléatoires d'espérance nulle. On suppose que $\mathbb{P}(X_f - X_{f'} > t) \leq \exp(-\frac{t^2}{d(f,f')^2})$

$$\mathbb{E} \left[\sup_{f \in \mathcal{F}} X_f \right] \leq K \gamma_d(\mathcal{F})$$

On récupère aussi une concentration sous-Gaussienne pour $\sup_{f \in \mathcal{F}} X_f$

Résultat principal

De la même façon on peut définir : $\hat{\ell} = \operatorname{argmin} \hat{\mu}_\ell$.

On désigne par δ_2 la norme quadratique sur \mathcal{F} . Le risque de $\hat{\ell}$ est contrôlé par une queue sous-gaussienne :

Theorem

Soit $\varepsilon > 0$. On choisit $\alpha = \sqrt{2 \log \varepsilon^{-1} / (vn)}$. On suppose que pour tout $\ell \in \mathcal{F}$, $\operatorname{Var}(\ell(Z)) < v$. Enfin on suppose que γ_{δ_2} est finie. Alors avec probabilité plus grande que $1 - 6\varepsilon$,

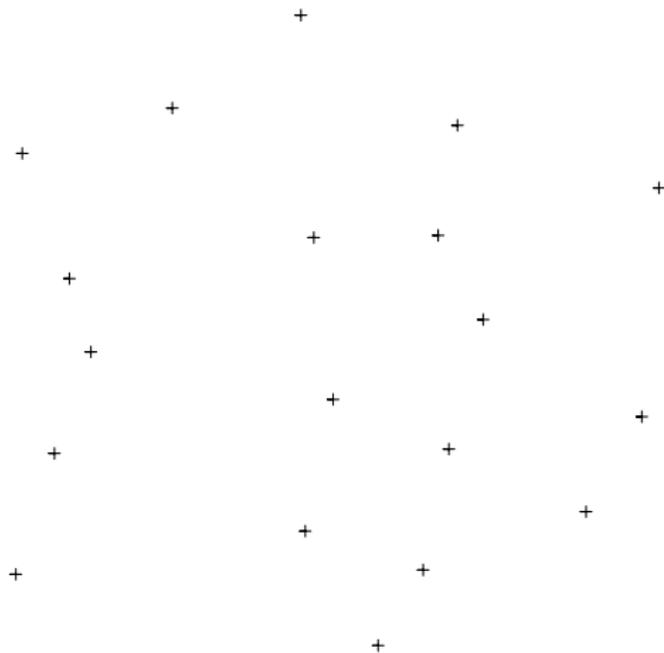
$$\mathbb{E} [\hat{\ell}(Z)] - \mathbb{E} [l_{\text{opt}}(Z)] \leq \square \sqrt{\log \varepsilon^{-1}} \left(\sqrt{\frac{v}{n}} + \sqrt{\frac{\gamma_{\delta_2}^2}{n}} + o\left(\frac{1}{\sqrt{n}}\right) \right)$$

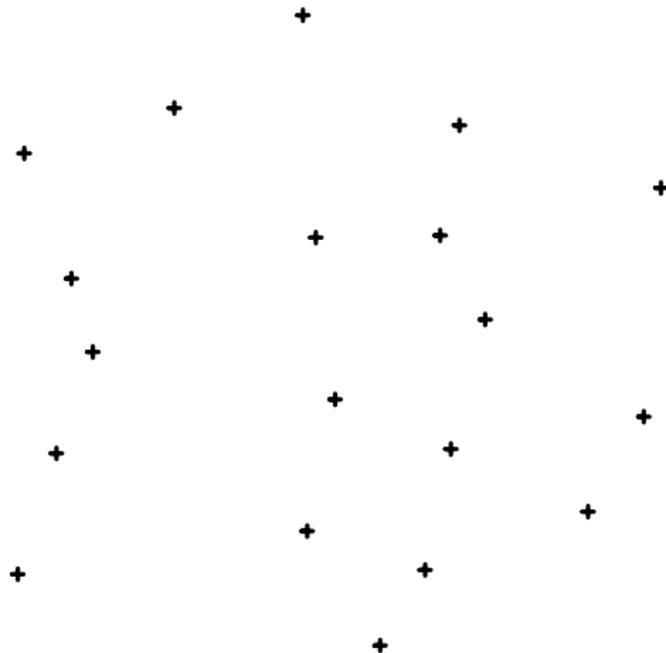
où \square désigne une constante universelle.

Prenons l'exemple d'une classe de fonctions vivant dans un espace de dimension finie d .

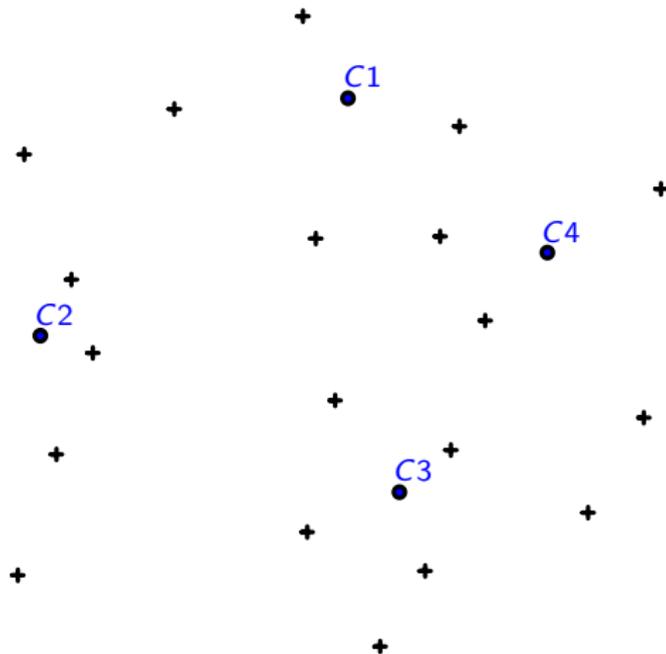
k-means : Soit Z une variable aléatoire de \mathbb{R}^d de variance finie V . A l'aide de k éléments c_i de l'espace \mathbb{R}^d , on veut "décrire" la distribution de Z .

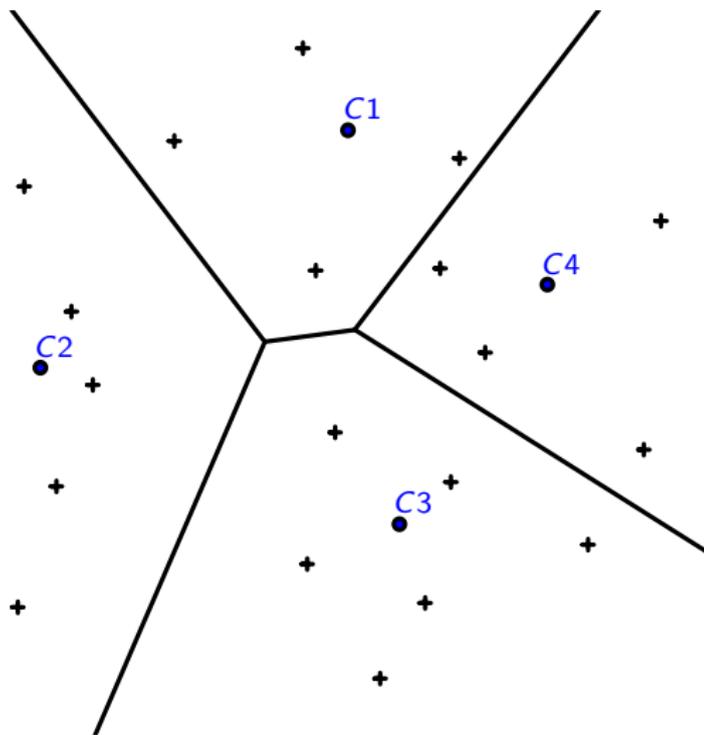
$$\ell(Z) = \min_{1 \leq i \leq k} \|Z - c_i\|$$





k-means





Prenons l'exemple d'une classe de fonctions vivant dans un espace de dimension finie d .

k-means : Soit Z une variable aléatoire de \mathbb{R}^d de variance finie V . A l'aide de k éléments c_i de l'espace \mathbb{R}^d , on veut "décrire" la distribution de Z .

$$\ell(Z) = \min_{1 \leq i \leq k} \|Z - c_i\|$$

Prenons l'exemple d'une classe de fonctions vivant dans un espace de dimension finie d .

k-means : Soit Z une variable aléatoire de \mathbb{R}^d de variance finie V . A l'aide de k éléments c_i de l'espace \mathbb{R}^d , on veut "décrire" la distribution de Z .

$$\ell(Z) = \min_{1 \leq i \leq k} \|Z - c_i\|$$

On peut montrer qu'avec "grande probabilité"
 $(\hat{c}_1, \dots, \hat{c}_k) \in B(0, R)$. R ne dépendant que de la distribution de Z .

Il faut calculer la variance de $\ell(Z)$! Elle est majorée par $2Vk$.

Il faut calculer γ_{δ_2} ! Nous avons donc besoin de recouvrir la boule de rayon R par des boules de rayon ϵ . On a un majorant bien connu :

$$N_{d_2}(B(0, R), \epsilon) \leq \left(\frac{4R}{\epsilon}\right)^d$$

donc $\gamma_{\delta_2} \leq C\sqrt{d}$

La borne est donc de la forme

$$\mathbb{E} \left[\hat{\ell}(Z) \right] - \mathbb{E} [\ell_{opt}(Z)] \leq C \sqrt{\log \frac{1}{\epsilon}} \left(\sqrt{\frac{Vk}{n}} + \sqrt{\frac{d}{n}} \right)$$

- Simplifier le résultat lorsque l'on se trouve en fait dans un cadre paramétrique.
- Qu'est-ce que ça donne lorsque les données sont sparses ?
- Peut-on appliquer cette technique à des estimations robustes alternatives ?

-  S. Boucheron, G. Lugosi, and P. Massart, *Concentration inequalities : A nonasymptotic theory of independence*, Oxford University Press, 2013.
-  P.L. Bartlett and S. Mendelson, *Empirical minimization*, Probability Theory Related Fields **135** (2006), 311–334.
-  O. Catoni, *Challenging the empirical mean and empirical variance : a deviation study*.
-  T. Linder, *Learning-theoretic methods in vector quantization*, Principles of nonparametric learning, Springer-Verlag, 2002.
-  M. Talagrand, *The generic chaining*, Springer, 2005.
-  S. van de Geer, *Empirical processes in M-estimation*, Cambridge University Press, Cambridge, UK, 2000.

Merci !

Des questions ?

