

V Statistiques adaptatives et inegalites exponentelles pour Processus de Poisson

$E(\int \lambda dt) = \int \lambda dt$ (si il faut écrire qd $\lambda = \lambda_t$)
ou $\int \lambda dt = \int \lambda^2 dt$ (si il faut écrire qd $\lambda = \lambda_t$)

1) Probability generating functional (p.g.fl)

Soit h une fonction test, la p.g.fl du processus N pris sur X

h est $E(\prod_{x \in N} h(x))$

2) Pour le Poisson, si $h = \exp(f)$

$E(\prod_{x \in N} h(x)) = E(\exp \int_X f(t) dN_t)$ (*)

Supposons f constante par morceaux $f = \sum_I \alpha_I 1_I$

alors (*) devient par independance du processus de Poisson

$= \prod_I E(\exp \alpha_I \int_I 1_I dN_t)$

$= \prod_I E(\exp[\alpha_I N_I])$

ou si $X \sim \mathcal{P}(\lambda)$ alors $E(e^{tx}) = \sum \frac{\lambda^k}{k!} e^{-\lambda} e^{tk} = e^{(e^\lambda - 1)\lambda}$

donc

$= \prod_I e^{\lambda_I (e^{\alpha_I} - 1)}$

la meme moyenne = $\int \lambda(x) dx$

$= e^{\int_X (e^{f(x)} - 1) \lambda(x) dx}$

De maniere generale,

Thm Soit f bornee mesurable,

$E[e^{\int f dN}] = e^{\int (e^f - 1) \lambda dx}$

ou $E(e^{\int f (dN - \lambda dx)}) = e^{\int (e^f - f - 1) \lambda dx} = e^{\phi(f)}$

3) Inégalité exponentielle (p.ee).

(19)

Théorème

$$P\left(\int f(x) (dN - \mu(dx)) \geq \xi\right) \leq \exp\left(-\frac{\int f^2 d\mu}{\|f\|_\infty^2} h\left(\frac{\xi \|f\|_\infty}{\int f^2 d\mu}\right)\right)$$

avec $h(u) = (1+u) \ln(1+u) - u$.

Preuve On applique le lemme précédent à λf .

Puis $\forall \lambda > 0$

$$\begin{aligned} P\left(\int f dN - d\mu \geq \xi\right) &= P\left(\int \lambda f dN - d\mu \geq \lambda \xi\right) \\ &= P\left(e^{\int \lambda f (dN - d\mu)} \geq e^{\lambda \xi}\right) \leq e^{-\lambda \xi} E\left(e^{\int \lambda f (dN - d\mu)}\right) \\ &\leq e^{-\lambda \xi} + \int \phi(\lambda f) d\mu. \end{aligned}$$

or $\phi(\lambda f(x)) = \sum_{k=2}^{\infty} \frac{(\lambda f(x))^k}{k!} \leq \sum_{k=2}^{\infty} \frac{\lambda^k \|f\|_\infty^{k-2}}{k!} f^2(x)$.

donc si $v = \int f^2 d\mu$ (Remarque c'est la variance de $\int f dN$).

$$P\left(\int f dN - d\mu \geq \xi\right) \leq \exp\left[-\lambda \xi + \frac{v}{\|f\|_\infty^2} \phi(\lambda \|f\|_\infty)\right]$$

on dérive en λ

$$-\xi + \frac{v}{\|f\|_\infty^2} \left[\|f\|_\infty e^{\lambda \|f\|_\infty} - \|f\|_\infty\right] = 0$$

ie $\frac{v}{\|f\|_\infty} (e^{\lambda \|f\|_\infty} - 1) = \xi$

$$e^{\lambda \|f\|_\infty} = 1 + \frac{\xi \|f\|_\infty}{v}$$

$$\lambda = \frac{1}{\|f\|_\infty} \ln\left(1 + \frac{\xi \|f\|_\infty}{v}\right)$$

avec ce λ ,

$$\leq \exp\left[-\frac{\xi}{\|f\|_\infty} \ln\left(1 + \frac{\xi \|f\|_\infty}{v}\right) + \frac{v}{\|f\|_\infty^2} \left[\lambda \xi \|f\|_\infty - \ln\left(1 + \frac{\xi \|f\|_\infty}{v}\right)\right]\right]$$

$$\left[-\frac{v}{\|f\|_\infty^2} \left[\left(1 + \frac{\xi v}{\|f\|_\infty}\right) \ln\left(1 + \frac{\xi \|f\|_\infty}{v}\right) - \frac{\xi \|f\|_\infty}{v}\right]\right]$$

C'est l'équivalent de la Bennett.

mais on a aussi l'équivalent de la Bernstein (version faible ici...) (20)

Preuve rigolote:

$$\begin{aligned} P\left(e^{-\lambda \int f(x) dN - \mu(dx)} \geq \int (e^{-\lambda f} - \lambda f - 1) d\mu \geq e^{-\lambda x}\right) \\ \leq E\left(e^{-\lambda \int f(x) dN - \mu(dx)}\right) e^{-\int e^{-\lambda f} - \lambda f - 1} = e^{-\lambda x} \end{aligned}$$

donc $P\left(\int f(x) dN - \mu(dx) \geq \frac{1}{\lambda} \int (e^{-\lambda f} - \lambda f - 1) d\mu + \frac{x}{\lambda}\right) \leq e^{-x}$
 vrai $\forall \lambda > 0$

$$\begin{aligned} \text{on } \int (e^{-\lambda f} - \lambda f - 1) &\leq \sum_{k=2}^{\infty} \frac{\lambda^k}{k!} \|f\|_{\infty}^{k-2} f(x)^2 \\ &\leq \frac{\lambda^2 f(x)^2}{2(1 - \frac{\lambda \|f\|_{\infty}}{3})} \end{aligned}$$

$\forall \lambda > 0$

donc $P\left(\int f(x) dN - \mu(dx) \geq \frac{\lambda x}{2(1 - \frac{\lambda \|f\|_{\infty}}{3})} + \frac{x}{\lambda}\right) \leq e^{-x}$

on cherche λ tq soit minimal

... le minimum vaut $\sqrt{2x} + \frac{\|f\|_{\infty} x}{3}$

donc $P\left(\int f(x) dN - \mu(dx) \geq \sqrt{2x} + \frac{\|f\|_{\infty} x}{3}\right) \leq e^{-x}$
 (et Bernstein en tid)

4) Lien avec le seuillage

On veut estimer l'intensité $\lambda(x)$ du PP qu'on observe.

On suppose $\lambda(x)$ dans $K^2(\mathbb{R})$.

On se donne une \mathcal{B} bon (typiquement ondelette pour que ça marche bien jusqu'au bout)

donc $\lambda(x) = \sum_k \alpha_k \varphi_k$

On prend un observé typiquement fini de $\Lambda \cdot M$
 et sur M on estime tous les α_k

on $\alpha_k = \int \varphi_k \lambda(x) dx$ estimé sans biais par $\hat{\alpha}_k = \int \varphi_k dN$

donc on peut reconstruire λ par $\hat{\lambda}_M = \sum \hat{\alpha}_k \varphi_k$
 estimé

Mais si M mal choisi c'est une catastrophe

en effet $\int (\hat{\lambda}_M - \lambda)^2 dx = \sum_{k \in \Lambda \setminus M} \alpha_k^2 + \sum_{k \in M} (\hat{\alpha}_k - \alpha_k)^2$

$E(\quad) = \sum_{k \in \Lambda \setminus M} \alpha_k^2 + \sum_{k \in M} \int \varphi_k^2 dx$

Première terme $\sum_{k \in \Lambda \setminus M} \alpha_k^2$ bien \downarrow si Γ grandit
 Deuxième terme $\sum_{k \in M} \int \varphi_k^2 d\mu$ \uparrow si Γ grandit
 Le meilleur $\Gamma = dk / \int \varphi_k^2 d\mu < \alpha_k^2$ ensemble "trade"
Idee On se fixe quand même un Λ_0 grand $\hookrightarrow \sum \min(\alpha_k^2, \int \varphi_k^2)$
 et on ne garde k que si $\hat{\alpha}_k$ est assez grand

Problème : Que veut dire assez grand ?

Si $\alpha_k = 0$ $\mathbb{P}(|\hat{\alpha}_k| \geq \sqrt{2v_k} x + \frac{\|\varphi_k\|_\infty x}{3}) \leq 2e^{-x}$
 où $v_k = \int \varphi_k^2 d\mu = \int \varphi_k^2 f(x) dx$

Donc si $x = \gamma \ln n$
 $\mathbb{P}(\hat{\alpha}_k \geq \frac{\sqrt{2v_k} x}{x} + \frac{\|\varphi_k\|_\infty x}{3}) \leq \frac{2n^{-x}}{e^{-x}}$ } ici garder les x

Mais v_k dépend de f

on $\mathbb{P}(\hat{v}_k - v_k \geq \sqrt{2v_k} x + \frac{\|\varphi_k\|_\infty^2 x}{3}) \leq e^{-x}$

avec $\hat{v}_k = \int \varphi_k^2 dN$

et $v_k = \int \varphi_k^2 d\mu \leq v_k \|\varphi_k\|_\infty^2$

\implies On va garder $\hat{\alpha}_k$ si $|\hat{\alpha}_k| \geq \eta_k$

avec $\eta_k = \sqrt{\frac{2}{f(x)} \hat{v}_k} + \frac{\|\varphi_k\|_\infty}{3}$ Pour $x \geq 0$ et x bien et

Alors on peut mes (sous des hyp sur choix base etc...) (article Rivovard RB)

Thm si $\hat{d} = \sum_{k \in \Lambda_0} \hat{\alpha}_k \mathbb{1}_{|\hat{\alpha}_k| \geq \eta_k} \varphi_k$

Alors $E(\|d - \hat{d}\|^2) \leq \square \left[\sum_{k \notin \Lambda_0} \alpha_k^2 + \sum_{k \in \Lambda_0} \min(\alpha_k^2, v_k \ln n) \right] + \square$

(et c'est la borne asymptotique si négligeable devant l'autre terme si on voit un n échantillon et $n \rightarrow \infty$ et $x = \gamma \ln n$)

5) Sélection de modèles

Principe : on se donne un contraste \rightarrow log vraisemblance
 \rightarrow moindres carrés

Ici on se concentre sur deuxième choix

$$\gamma(f) = -\int 2f \, dN + \int f^2 \, dx$$

Pourquoi est-ce un contraste? $E_{\lambda}(\gamma(f)) = -2 \int f \, d\lambda + \int f^2$
 $= \int (f - 1)^2 - \int 1^2$
 donc minimal quand $f=1$.

quand $f = \sum_{k \in M} \beta_k \varphi_k$ β_k inconnu

alors quand on minimise $\gamma(f)$ pour trouver les meilleurs β_k
 on trouve

$$\gamma(f) = \sum_{k \in M} \left[-2\beta_k \underbrace{\int \varphi_k \, dN}_{\hat{\alpha}_k} + \beta_k^2 \right]$$

C'est donc minimal quand $\beta_k = \hat{\alpha}_k$ et ça vaut $-\sum_{k \in P} \hat{\alpha}_k^2$
 ie $\hat{I}_m = \underset{f \text{ élitum}}{\text{argmin}} \gamma(f)$

Donc pour tout sous ensemble m de Λ on peut faire ça.
 = "modèle"

Comment choisir m ?

ça dépend de la famille de modèles

soit \mathcal{M} une famille de modèle

$$\hat{m} = \underset{m \in \mathcal{M}}{\text{argmin}} \gamma(\hat{I}_m) + \text{pen } m$$

si $\mathcal{M} = \{ \text{tous les sous ensembles possibles de } \Lambda_0 \}$

$$\text{et } \text{pen } m = \sum_{k \in m} \eta_k^2$$

$$\text{alors } -\sum_{k \in m} \hat{\alpha}_k^2 + \sum_{k \in m} \eta_k^2 = \sum_{k \in m} \left[\eta_k^2 - \hat{\alpha}_k^2 \right]$$

donc si on veut minimiser ça par un choix de m

on a intérêt à prendre tous les k / $\hat{\alpha}_k^2 > \eta_k^2$ et pas les autres

ie $\hat{I}_m = \sum_{k \in \Lambda_0} \hat{\alpha}_k \mathbb{1}_{\{\hat{\alpha}_k^2 > \eta_k^2\}} \varphi_k$ c'est l'estimateur par suite
 (trues + grix évidemment)

Mais alors du coup à quoi ça sert ?

Avantages :

- Plus général ! Et m on est pas forcé de tout écrire sur une base \mathcal{L}^2 mais juste avec des sev (par convexes...)
- Inégalité exacte -- possibilité de perdre le log.

Inconvénients

- En général il faut calculer tous les $\hat{I}_m \rightarrow$ très demandeur en calcul.
- Il faut une famille généralement finie de modèles \hat{m} si ça peut grandir avec n .
- hyp au style : borne, support, borne etc ...

lien avec la concentration ?

Voir pour selec modèle et livre Pascal Massart

Concentration Inequality and Model selection

Pour tout u ,

$$\underbrace{- \sum_{k \in \hat{m}} \hat{\alpha}_k^2}_{\sigma(\hat{I}_{\hat{m}})} + \text{pen } \hat{u} \leq \underbrace{- \sum_{k \in m} \hat{\alpha}_k^2}_{\sigma(\hat{I}_m)} + \text{pen } m \leq \dots \leq \sigma(I_m) + \text{pen } m.$$

mais $\sigma(f) = \|f - d\|^2 - \|d\|^2 = 2 \int f [dN - d(x) dx]$.

donc

$$\begin{aligned} \|\hat{I}_{\hat{m}} - d\|^2 &\leq \|I_m - d\|^2 + \text{pen } m - 2 \int I_m (dN - d(x) dx) \\ &\quad + 2 \int \hat{I}_{\hat{m}} (dN - d(x) dx) - \text{pen } \hat{u} \\ &\leq \|I_m - d\|^2 + \text{pen } m - \underbrace{2 \int (I_m - \hat{I}_{\hat{m}}) (dN - d(x) dx)}_{\textcircled{A}} \\ &\quad + \underbrace{2 \int (\hat{I}_{\hat{m}} - I_m) (dN - d(x) dx)}_{\textcircled{B}} - \text{pen } \hat{u}. \end{aligned}$$

\textcircled{A} presque de nos jours nullité

$\textcircled{B} = 2 \sum_{k \in \hat{m}} (\hat{\alpha}_k - \alpha_k) \int \varphi_k dN - d(x) dx = 2 \sum_{k \in \hat{m}} (\hat{\alpha}_k - \alpha_k)^2 = 2 \chi^2(\hat{m}) \dots$

et donc on choisit peu /

$P(2 \chi^2(\hat{m}) \geq \text{pen } m)$ petit ... uniformément en m .

Donc on cherche une inégalité exponentielle pour

$\chi(m) = \sup_{\substack{f \in S_m \\ \|f\|=1}} \int f [dN - d(x) dx]$. [en effet $f = \sum \beta_k \varphi_k \Rightarrow \sum \beta_k (\hat{\alpha}_k - \alpha_k)$ et on maximise]

Théorème: Pour toute famille Ψ_a de fonctions $\|\Psi_a\|_\infty \leq b$

On considère $Z = \sup_{a \in A} \left| \int \Psi_a dN - \mu(da) \right|$

et $v_0 = \sup_{a \in A} \int \Psi_a^2(x) \mu(dx)$.

Alors

$P(Z \geq (1+\epsilon)E(Z) + \sqrt{2Kv_0 x} + K(\epsilon)bx) \leq e^{-x}$

avec $K=6$ et $K(\epsilon) = 1.25 + 32/\epsilon$

Preuve: ID + Talagrand.

La appliqué à $\chi(m)$ on obtient

$P(\chi(m) \geq (1+\epsilon) \sqrt{\sum_{k \in m} v_k} + \sqrt{\frac{2K\|A\|_\infty x}{m}} + K(\epsilon)Bx) \leq e^{-x}$

↑
dépend de la base.

donc on voit que +/- obligatoire que la pénalité utilisée $\|d\|_\infty$ (ou une estimation).

Puis

si plus $m \geq \square$ $\left[\sqrt{\sum_{k \in m} v_k} + \sqrt{2K\hat{M}L_m D_m} \right]^2$
avec \hat{M} estimation de la $\|A\|_\infty$
et $\sum_{m \in \mathcal{D}} e^{-L_m D_m} \leq 1$

alors $E\|\hat{I}_m - I\|^2 \leq \square \left[\inf \|d - L_m\|^2 + \sum_{k \in m} v_k^2 + ML_m D_m \right] + \frac{1}{m}$

si famille pas trop complexe $L_m = 1$
et on n'a plus le ln du maillage.
(En particulier ça ne marche pas pour la famille du maillage)

Ruig: on peut aussi faire des tests adaptés (ie alternative +/- régulière et on ne sait pas sa régularité à l'avance)