

Inférence semi-paramétrique pour des événements récurrents en présence de censures et d'un événement terminal

Olivier Bouaziz¹, Ségolen Geffray² et Olivier Lopez³

¹ MAP5, ² Université de Strasbourg, Irma, ³ Laboratoire de Statistique Théorique et Appliquée

Paris V, 08-10-10

Plan

- 1 Introduction
- 2 Présentation du contexte
- 3 Méthode d'estimation
- 4 Résultats asymptotiques
- 5 Simulations

Le fléau de la dimension

- Soient $X \in \mathbb{R}^d$ et $Y \in \mathbb{R}$.
- Soit $m(x) = \mathbb{E}[Y|X = x]$. On suppose que m possède des dérivées partielles jusqu'à l'ordre β , toutes continues.
- Soit \hat{m} un estimateur de m .

Vitesse de convergence optimale

$$\sup_x \mathbb{E} \left[(\hat{m}(x) - m(x))^2 \right] = O \left(n^{-\frac{2\beta}{2\beta+d}} \right).$$

En pratique : problème d'estimation dès que $d \geq 3$.

Modèles de réduction de la dimension

Modèle de régression linéaire

$$\mathbb{E}[Y|X] = \theta_0' X$$

où $\theta_0 \in \mathbb{R}^d$ est inconnu.

Modèles de réduction de la dimension

Modèle de régression linéaire généralisé

$$\mathbb{E}[Y|X] = g(\theta_0'X)$$

où $\theta_0 \in \mathbb{R}^d$ est inconnu et $g: \mathbb{R} \mapsto \mathbb{R}$ est connu.

Modèles de réduction de la dimension

Modèle à direction révélatrice unique

$$\mathbb{E}[Y|X] = g(\theta_0'X),$$

où $\theta_0 \in \mathbb{R}^d$ et $g : \mathbb{R} \mapsto \mathbb{R}$ sont inconnus.

Modèles de réduction de la dimension

Modèle à direction révélatrice unique (SIM)

$$\mathbb{E}[Y|X] = g(\theta_0'X),$$

où $\theta_0 \in \mathbb{R}^d$ et $g : \mathbb{R} \mapsto \mathbb{R}$ sont inconnus.

On a :

$$\mathbb{E}[Y|\theta_0'X] = \mathbb{E}[\mathbb{E}[Y|X]|\theta_0'X] = g(\theta_0'X).$$

Autre écriture du SIM

$$\mathbb{E}[Y|X] = g(\theta_0'X) = \mathbb{E}[Y|\theta_0'X],$$

où $\theta_0 \in \mathbb{R}^d$ et g sont inconnus.

Plan

- 1 Introduction
- 2 Présentation du contexte**
- 3 Méthode d'estimation
- 4 Résultats asymptotiques
- 5 Simulations

Introduction

- Etude clinique : pour $1 \leq i \leq n$,
 - D_i : durée de vie du patient i (en général censurée à droite).
 - X_i : vecteur de variables explicatives (âge, type de traitement...).
 - $N_i^*(t)$: nombre d'évènements récurrents du patient i survenant dans l'intervalle $[0, t]$, pour $t \in [0, D_i]$.
- Exemples d'évènements récurrents :
 - Crises d'asthme pour des patients asthmatiques,
 - Crises d'épilepsie pour des patients épileptiques,
 - Infections pour des patients atteints du VIH, ...

Observations

- On s'intéresse à $N^*(t)$, $t \geq 0$.

- On observe :
$$\begin{cases} T = D \wedge C \\ \delta = \mathbb{1}_{D \leq C} \\ X \in \mathcal{X} \subset \mathbb{R}^d \\ N(t) = N^*(t \wedge C) \end{cases}$$

Problématique

On veut estimer : $\mu(t|x) := \mathbb{E}[N^*(t)|X = x]$.

Modèles paramétriques et non-paramétriques

- Modèle paramétrique :

$$\mu(t|x) = \mu_0(t, x; \theta_0),$$

où μ_0 est connue et $\theta_0 \in \Theta \subset \mathbb{R}^d$ est inconnu.

- Exemple de modèle paramétrique :

$$\mu(t|x) = t\theta'_0 x,$$

hypothèse satisfaite si N^* est un processus de Poisson d'intensité $\theta'_0 X$.

- Modèle non-paramétrique : on estime directement $\mu(t|x)$ sans hypothèses sur la fonction. Problème : fléau de la dimension dès que $d \geq 3$.

Modèles semi-paramétriques

- Approche intermédiaire : modèle semi-paramétrique de **réduction de la dimension**.

Exemples de modèles semiparamétriques :

- Le « modèle de Cox »

$$\mu(t|x) = \mu_0(t)e^{\theta_0'x},$$

où $\theta_0 \in \Theta \subset \mathbb{R}^d$ et μ_0 sont inconnus.

Modèles semi-paramétriques

- Approche intermédiaire : modèle semi-paramétrique de **réduction de la dimension**.

Exemples de modèles semiparamétriques :

- Le « modèle de Cox »

$$\mu(t|x) = \mu_0(t)e^{\theta'_0 x},$$

où $\theta_0 \in \Theta \subset \mathbb{R}^d$ et μ_0 sont inconnus.

Modèles semi-paramétriques

- Le modèle AFT (Accelerated Failure Time) :

$$\mu(t|x) = \mu_0(t \exp(\theta'_0 x)).$$

- Le modèle à direction révélatrice unique :

Hypothèse S.I.M

$$\mu(t|x) = \mu_{\theta_0}(t, \theta'_0 x),$$

où $\theta_0 \in \Theta \subset \mathbb{R}^d$ et $\mu_{\theta}(t, u) = \mathbb{E}[N^*(t) | \theta'X = u]$ sont inconnus.

Modèles semi-paramétriques

- Le modèle AFT (Accelerated Failure Time) :

$$\mu(t|x) = \mu_0(t \exp(\theta'_0 x)).$$

- Le modèle à direction révélatrice unique :

Hypothèse S.I.M

$$\mu(t|x) = \mu_{\theta_0}(t, \theta'_0 x),$$

où $\theta_0 \in \Theta \subset \mathbb{R}^d$ et $\mu_{\theta}(t, u) = \mathbb{E}[N^*(t) | \theta'X = u]$ sont inconnus.

Quelques hypothèses

On définit $G(t) = \mathbb{P}(C \leq t)$, $H(t) = \mathbb{P}(T \leq t)$ et $\tau_H = \inf\{t : H(t) = 1\}$.

Hypothèses du modèle

- (i) $C \perp\!\!\!\perp (N^*, D)$,
- (ii) $\mathbb{P}(C \leq t | N^*, D, X) = \mathbb{P}(C \leq t | N^*, D)$ pour tout $t \in [0, \tau_H]$,
- (iii) il n'y a pas d'ex-aequo entre décès, censure ou l'apparition d'un évènement récurrent.

Cas particulier où (i) et (ii) sont vraies : $C \perp\!\!\!\perp (N^*, D, X)$.

Plan

- 1 Introduction
- 2 Présentation du contexte
- 3 Méthode d'estimation**
- 4 Résultats asymptotiques
- 5 Simulations

Méthode d'estimation

- On introduit le processus, pour $t \leq \tau_H$:

$$Z(t) := \int_0^t \frac{dN(s)}{1 - G(s-)}.$$

Méthode d'estimation

- On introduit le processus, pour $t \leq \tau_H$:

$$Z(t) := \int_0^t \frac{dN(s)}{1 - G(s-)}.$$

On a :

$$\mathbb{E}[dN(s)|X] = \mathbb{E}[dN^*(s \wedge C)|X]$$

Méthode d'estimation

- On introduit le processus, pour $t \leq \tau_H$:

$$Z(t) := \int_0^t \frac{dN(s)}{1 - G(s-)}.$$

On a :

$$\begin{aligned}\mathbb{E}[dN(s)|X] &= \mathbb{E}[dN^*(s \wedge C)|X] \\ &= \mathbb{E}[dN^*(s)\mathbf{1}_{s \leq C}|X] + \mathbb{E}[dN^*(C)\mathbf{1}_{s > C}|X]\end{aligned}$$

Méthode d'estimation

- On introduit le processus, pour $t \leq \tau_H$:

$$Z(t) := \int_0^t \frac{dN(s)}{1 - G(s-)}.$$

On a :

$$\begin{aligned} \mathbb{E}[dN(s)|X] &= \mathbb{E}[dN^*(s \wedge C)|X] \\ &= \mathbb{E}[dN^*(s)\mathbf{1}_{s \leq C}|X] + \mathbb{E}[dN^*(C)\mathbf{1}_{s > C}|X] \\ &= \mathbb{E}\left[\mathbb{E}[dN^*(s)\mathbf{1}_{s \leq C}|N^*, D, X]|X\right] \end{aligned}$$

Méthode d'estimation

- On introduit le processus, pour $t \leq \tau_H$:

$$Z(t) := \int_0^t \frac{dN(s)}{1 - G(s-)}.$$

On a :

$$\begin{aligned} \mathbb{E}[dN(s)|X] &= \mathbb{E}[dN^*(s \wedge C)|X] \\ &= \mathbb{E}[dN^*(s)\mathbf{1}_{s \leq C}|X] + \mathbb{E}[dN^*(C)\mathbf{1}_{s > C}|X] \\ &= \mathbb{E}\left[\mathbb{E}[dN^*(s)\mathbf{1}_{s \leq C}|N^*, D, X]|X\right] \\ &= \mathbb{E}\left[dN^*(s) \mathbb{E}[\mathbf{1}_{s \leq C}|N^*, D]|X\right] \end{aligned}$$

Méthode d'estimation

- On introduit le processus, pour $t \leq \tau_H$:

$$Z(t) := \int_0^t \frac{dN(s)}{1 - G(s-)}.$$

On a :

$$\begin{aligned} \mathbb{E}[dN(s)|X] &= \mathbb{E}[dN^*(s \wedge C)|X] \\ &= \mathbb{E}[dN^*(s)\mathbf{1}_{s \leq C}|X] + \mathbb{E}[dN^*(C)\mathbf{1}_{s > C}|X] \\ &= \mathbb{E}\left[\mathbb{E}[dN^*(s)\mathbf{1}_{s \leq C}|N^*, D, X] | X\right] \\ &= \mathbb{E}\left[dN^*(s) \mathbb{E}[\mathbf{1}_{s \leq C}|N^*, D] | X\right] \\ &= \mathbb{E}[dN^*(s)|X] (1 - G(s-)). \end{aligned}$$

Méthode d'estimation

Proposition

Sous nos hypothèses :

$$\mathbb{E}[Z(t)|X] = \mathbb{E}[N^*(t)|X] = \mu_{\theta_0}(t, \theta_0' X)$$

- On estime $Z(t)$ par :

$$\hat{Z}(t) := \int_0^t \frac{dN(s)}{1 - \hat{G}(s-)},$$

où \hat{G} est l'estimateur de Kaplan-Meier de G ,

$$\hat{G}(t) = 1 - \prod_{i: T_i \leq t} \left(1 - \frac{1}{\sum_{j=1}^n \mathbb{1}_{T_j \geq T_i}} \right)^{1 - \delta_i}.$$

Méthode d'estimation

$$\begin{aligned}\theta_0 &= \arg \min_{\theta \in \Theta} \mathbb{E} \left[(Z(t) - \mu_\theta(t, \theta' X))^2 \right] \\ &= \arg \min_{\theta \in \Theta} \mathbb{E} [\mu_\theta(t, \theta' X)^2] - 2\mathbb{E} [Z(t)\mu_\theta(t, \theta' X)].\end{aligned}$$

Estimateur de θ_0

$$\hat{\theta} = \arg \min_{\theta \in \Theta} M_{n,w}(\theta, \mu_\theta),$$

$$\begin{aligned}\text{où } M_{n,w}(\theta, \hat{\mu}_\theta) &= n^{-1} \sum_{i=1}^n \int_0^{T^{(n)}} \hat{\mu}_\theta(t, \theta' X_i)^2 dw(t) \\ &\quad - 2n^{-1} \sum_{i=1}^n \int_0^{T^{(n)}} \hat{Z}_i(t) \hat{\mu}_\theta(t, \theta' X_i) dw(t).\end{aligned}$$

Méthode d'estimation

$$\begin{aligned}\theta_0 &= \operatorname{argmin}_{\theta \in \Theta} \int_0^{\tau_H} \mathbb{E} \left[(Z(t) - \mu_\theta(t, \theta'X))^2 \right] dw(t) \\ &= \operatorname{argmin}_{\theta \in \Theta} \int_0^{\tau_H} \mathbb{E} [\mu_\theta(t, \theta'X)^2] dw(t) - 2 \int_0^{\tau_H} \mathbb{E} [Z(t)\mu_\theta(t, \theta'X)] dw(t).\end{aligned}$$

Estimateur de θ_0

$$\hat{\theta} = \operatorname{argmin}_{\theta \in \Theta} M_{n,w}(\theta, \mu_\theta),$$

$$\begin{aligned}\text{où } M_{n,w}(\theta, \hat{\mu}_\theta) &= n^{-1} \sum_{i=1}^n \int_0^{T^{(n)}} \hat{\mu}_\theta(t, \theta'X_i)^2 dw(t) \\ &\quad - 2n^{-1} \sum_{i=1}^n \int_0^{T^{(n)}} \hat{Z}_i(t) \hat{\mu}_\theta(t, \theta'X_i) dw(t).\end{aligned}$$

Méthode d'estimation

$$\begin{aligned}\theta_0 &= \operatorname{argmin}_{\theta \in \Theta} \int_0^{\tau_H} \mathbb{E} \left[(Z(t) - \mu_\theta(t, \theta'X))^2 \right] dw(t) \\ &= \operatorname{argmin}_{\theta \in \Theta} \int_0^{\tau_H} \mathbb{E} [\mu_\theta(t, \theta'X)^2] dw(t) - 2 \int_0^{\tau_H} \mathbb{E} [Z(t)\mu_\theta(t, \theta'X)] dw(t).\end{aligned}$$

Estimateur de θ_0

$$\hat{\theta} = \operatorname{argmin}_{\theta \in \Theta} M_{n,w}(\theta, \mu_\theta),$$

$$\begin{aligned}\text{où } M_{n,w}(\theta, \hat{\mu}_\theta) &= n^{-1} \sum_{i=1}^n \int_0^{T^{(n)}} \hat{\mu}_\theta(t, \theta'X_i)^2 dw(t) \\ &\quad - 2n^{-1} \sum_{i=1}^n \int_0^{T^{(n)}} \hat{Z}_i(t) \hat{\mu}_\theta(t, \theta'X_i) dw(t).\end{aligned}$$

Un estimateur de μ_θ

- Sous nos hypothèses, on a la relation :

$$\mu_\theta(t, u) = \int_0^t \frac{\mathbb{E}[dN(s) | \theta'X = u]}{1 - G(s-)}.$$

Estimateur de μ_θ

$$\hat{\mu}_{\theta, h}(t, u) = \int_0^t \frac{\sum_{i=1}^n K\left(\frac{u - \theta'X_i}{h}\right) dN_i(s)}{\sum_{j=1}^n K\left(\frac{u - \theta'X_j}{h}\right) [1 - \hat{G}(s-)]}.$$

Un estimateur de μ_θ

- Sous nos hypothèses, on a la relation :

$$\mu_\theta(t, u) = \int_0^t \frac{\mathbb{E}[dN(s) | \theta'X = u]}{1 - G(s-)}.$$

Estimateur de μ_θ

$$\hat{\mu}_{\theta, h}(t, u) = \int_0^t \frac{\sum_{i=1}^n K\left(\frac{u - \theta'X_i}{h}\right) dN_i(s)}{\sum_{j=1}^n K\left(\frac{u - \theta'X_j}{h}\right) [1 - \hat{G}(s-)]}.$$

Plan

- 1 Introduction
- 2 Présentation du contexte
- 3 Méthode d'estimation
- 4 Résultats asymptotiques**
- 5 Simulations

Hypothèses sur $\hat{\mu}_\theta$

Hypothèses de convergence

On suppose,

$$\sup_{t \leq T_{(n)}, \theta, x} |\hat{\mu}_\theta(t, \theta'x) - \mu_\theta(t, \theta'x)| = o_P(1),$$

$$\sup_{t \leq T_{(n)}, \theta, x} \|\nabla_\theta \hat{\mu}_\theta(t, x) - \nabla_\theta \mu_\theta(t, x)\| = o_P(1),$$

$$\sup_{t \leq T_{(n)}, \theta, x} \|\nabla_\theta^2 \hat{\mu}_\theta(t, x) - \nabla_\theta^2 \mu_\theta(t, x)\| = o_P(1),$$

$$\begin{aligned} \sup_{t \leq T_{(n)}, x} |\hat{\mu}_{\theta_0}(t, \theta_0'x) - \mu_{\theta_0}(t, \theta_0'x)| \cdot \|\nabla_\theta \hat{\mu}_{\theta_0}(t, x) - \nabla_\theta \mu_{\theta_0}(t, x)\| \\ = o_P(n^{-1/2}). \end{aligned}$$

Résultats principaux

Soient

$$S_n(f, w) = \frac{1}{n} \sum_{i=1}^n \int_0^{\tau_H} Z_i(t) f(X_i, t) dw(t)$$

et

$$\hat{S}_n(f, w) = \frac{1}{n} \sum_{i=1}^n \int_0^{T(n)} \hat{Z}_i(t) f(X_i, t) dw(t).$$

Lemme 1

$$\hat{S}_n(f, w) - S_n(f, w) = \frac{1}{n} \sum_{i=1}^n \int_0^{\tau_H} \eta_t(T_i, X_i, \delta_i) dw(t) + R_n(f, w),$$

où les $\eta_t(T_i, X_i, \delta_i)$ sont i.i.d de moyenne nulle et $\sup_{w, f} \|R_n(f, w)\| = o_P(n^{-1/2})$.

Résultats principaux

Lemme 2

Soit \hat{f} un estimateur de f tel que $\sup_f \|\hat{f} - f\| = o_P(1)$, alors

$$\sup_w \|\hat{S}_n(\hat{f}, w) - S_n(\hat{f}, w)\| = o_P(n^{-1/2}).$$

Théorème

$\sqrt{n}(\hat{\theta}(\cdot) - \theta_0)$ converge vers un processus gaussien, en particulier, pour tout w appartenant à une certaine classe de mesures,

$$\sqrt{n}(\hat{\theta}(w) - \theta_0) \xrightarrow{\mathcal{L}} \mathcal{N}(0, \Sigma_w).$$

Choix adaptatif de w

- On prend un ensemble fini de mesures : \mathcal{W}
- Critère asymptotique :

- Alors $\hat{\theta} = \hat{\theta}(\hat{w})$.
- On a toujours :

$$\sqrt{n}(\hat{\theta}(\hat{w}) - \theta_0) \xrightarrow{\mathcal{L}} \mathcal{N}(0, \Sigma_{w_{\text{opt}}})$$

où $\Sigma_{\hat{w}}$ converge vers $\Sigma_{w_{\text{opt}}}$.

Choix adaptatif de w

- On prend un ensemble fini de mesures : \mathcal{W}
- Critère asymptotique :

- Alors $\hat{\theta} = \hat{\theta}(\hat{w})$.
- On a toujours :

$$\sqrt{n}(\hat{\theta}(\hat{w}) - \theta_0) \xrightarrow{\mathcal{L}} \mathcal{N}(0, \Sigma_{w_{\text{opt}}})$$

où $\Sigma_{\hat{w}}$ converge vers $\Sigma_{w_{\text{opt}}}$.

Choix adaptatif de w

- On prend un ensemble fini de mesures : \mathcal{W}
- Critère asymptotique :

$$\lim_n \mathbb{E} \left[\|\hat{\theta}(w) - \theta_0\|^2 \right]$$

- Alors $\hat{\theta} = \hat{\theta}(\hat{w})$.
- On a toujours :

$$\sqrt{n}(\hat{\theta}(\hat{w}) - \theta_0) \xrightarrow{\mathcal{L}} \mathcal{N}(0, \Sigma_{w_{\text{opt}}})$$

où $\Sigma_{\hat{w}}$ converge vers $\Sigma_{w_{\text{opt}}}$.

Choix adaptatif de w

- On prend un ensemble fini de mesures : \mathcal{W}
- Critère asymptotique :

$$\hat{w} = \operatorname{argmin}_{w \in \mathcal{W}} \lim_n \hat{\mathbb{E}} \left[\|\hat{\theta}(w) - \theta_0\|^2 \right]$$

- Alors $\hat{\theta} = \hat{\theta}(\hat{w})$.
- On a toujours :

$$\sqrt{n}(\hat{\theta}(\hat{w}) - \theta_0) \xrightarrow{\mathcal{L}} \mathcal{N}(0, \Sigma_{w_{\text{opt}}})$$

où $\Sigma_{\hat{w}}$ converge vers $\Sigma_{w_{\text{opt}}}$.

Choix adaptatif de w

- On prend un ensemble fini de mesures : \mathcal{W}
- Critère asymptotique :

$$\hat{w} = \operatorname{argmin}_{w \in \mathcal{W}} \lim_n \hat{\mathbb{E}} \left[\|\hat{\theta}(w) - \theta_0\|^2 \right]$$

- Alors $\hat{\theta} = \hat{\theta}(\hat{w})$.
- On a toujours :

$$\sqrt{n}(\hat{\theta}(\hat{w}) - \theta_0) \xrightarrow{\mathcal{L}} \mathcal{N}(0, \Sigma_{w_{\text{opt}}})$$

où $\Sigma_{\hat{w}}$ converge vers $\Sigma_{w_{\text{opt}}}$.

Choix adaptatif de w

- On prend un ensemble fini de mesures : \mathcal{W}
- Critère asymptotique :

$$\hat{w} = \operatorname{argmin}_{w \in \mathcal{W}} \lim_n \hat{\mathbb{E}} \left[\|\hat{\theta}(w) - \theta_0\|^2 \right]$$

- Alors $\hat{\theta} = \hat{\theta}(\hat{w})$.
- On a toujours :

$$\sqrt{n}(\hat{\theta}(\hat{w}) - \theta_0) \xrightarrow{\mathcal{L}} \mathcal{N}(0, \Sigma_{w_{\text{opt}}})$$

où $\Sigma_{\hat{w}}$ converge vers $\Sigma_{w_{\text{opt}}}$.

Estimation de la partie non-paramétrique

Un développement de Taylor de $\hat{\mu}$ en θ_0 nous donne :

$$\hat{\mu}_{\hat{\theta}}(t, \hat{\theta}'x) = \hat{\mu}_{\theta_0}(t, \theta_0'x) + (\hat{\theta} - \theta_0)' \nabla_{\theta} \hat{\mu}_{\tilde{\theta}}(t, x),$$

pour $\tilde{\theta}$ compris entre θ_0 et $\hat{\theta}$.

Estimation de la partie non-paramétrique

Un développement de Taylor de $\hat{\mu}$ en θ_0 nous donne :

$$\hat{\mu}_{\hat{\theta}}(t, \hat{\theta}'x) = \hat{\mu}_{\theta_0}(t, \theta_0'x) + \underbrace{(\hat{\theta} - \theta_0)'}_{=O_P(n^{-1/2})} \nabla_{\theta} \hat{\mu}_{\tilde{\theta}}(t, x),$$

pour $\tilde{\theta}$ compris entre θ_0 et $\hat{\theta}$.

Estimation de la partie non-paramétrique

Un développement de Taylor de $\hat{\mu}$ en θ_0 nous donne :

$$\hat{\mu}_{\hat{\theta}}(t, \hat{\theta}'x) = \hat{\mu}_{\theta_0}(t, \theta_0'x) + \underbrace{(\hat{\theta} - \theta_0)'}_{=O_P(n^{-1/2})} \nabla_{\theta} \hat{\mu}_{\tilde{\theta}}(t, x),$$

pour $\tilde{\theta}$ compris entre θ_0 et $\hat{\theta}$.

Proposition

Soit Θ^* un voisinage de θ_0 , et soit \mathcal{T} un ensemble sur lequel $\sup_{\theta \in \Theta^*, t \in \mathcal{T}, x \in \mathcal{X}} \|\nabla_{\theta} \mu_{\theta}(t, x)\| < \infty$. Alors,

$$\sup_{t, x, w} |\hat{\mu}_{\hat{\theta}}(t, \hat{\theta}'x) - \hat{\mu}_{\theta_0}(t, \theta_0'x)| = O_P(n^{-1/2}).$$

Plan

- 1 Introduction
- 2 Présentation du contexte
- 3 Méthode d'estimation
- 4 Résultats asymptotiques
- 5 Simulations**

Modèle

Modèle de Poisson

$$\mu(t|x) = t(\theta'_0 x + \text{cste}).$$

- $d = 4$, $n = 100$ et $\theta_0 = (1, 3.2, 2.5, 1.4)$.
- D et C suivent des lois de Weibull, de telle sorte que 30% des observations sont censurées en moyenne.
- En moyenne, on observe 20 évènements récurrents par personne.
- X suit une loi uniforme.

La mesure w et la fenêtre h sont choisis de façon adaptative.

Choix de h et de w

- On considère toutes les mesures w telles que :

$$\int_0^{T(n)} f(t)dw(t) = \sum_{k \in \mathcal{V}} f(k)W(k)$$

où $\mathcal{V} = \{v_1, v_2, \dots, v_{12}\}$ et

$$W(k) = \begin{cases} 1 & \text{pour } k = v_1, \dots, v_8 \\ 0.25, 0.5, 0.75 \text{ ou } 1 & \text{pour } k = v_9, v_{10}, v_{11}, v_{12}. \end{cases}$$

- $h \in \{h_1, \dots, h_{25}\}$

Pour chaque h et chaque w on calcule $\hat{\theta}(w, h)$, puis on en déduit :

$$(\hat{w}, \hat{h}) = \arg \min_{w, h} \lim_n \hat{\mathbb{E}} \left[\|\hat{\theta}(w, h) - \theta_0\|^2 \right].$$

Résultats

100 réplifications d'échantillons de taille 100.

$\tilde{\theta}$: estimateur de θ_0 avec poids W tous égaux à 1.

	Biais	Variance	MSE
$\tilde{\theta}$	$\begin{pmatrix} 0.571 \\ 1.547 \\ 0.221 \end{pmatrix}$	$\begin{pmatrix} 0.06 & 0.017 & -0.022 \\ 0.017 & 0.066 & -0.017 \\ -0.022 & -0.017 & 0.09 \end{pmatrix}$	0.2202
$\hat{\theta}$	$\begin{pmatrix} -0.01082890 \\ -0.03490086 \\ -0.03766846 \end{pmatrix}$	$\begin{pmatrix} 0.025 & -0.002 & -0.006 \\ -0.002 & 0.026 & -0.002 \\ -0.006 & -0.002 & 0.032 \end{pmatrix}$	0.0864

Poids adaptatifs pour $\hat{\theta}$: $W(v_9) = 0.835$, $W(v_{10}) = 0.7025$,
 $W(v_{11}) = 0.5925$, $W(v_{12}) = 0.49$.

Perspectives

- Performance de $\hat{\mu}_{\hat{\theta}}$
- Tester différents estimateurs de $\hat{\mu}_{\theta}$
- Résultats à distance finie
- Étude d'un modèle où l'index de la régression dépend du temps.

Bibliographie

- U. Einmahl, and D. Mason (2005). Uniform in bandwidth consistency of kernel-type function estimators. *Ann. Statist.*, 33(3) : 1380-1403, 2005.
- D. Ghosh, and D. Lin. Nonparametric analysis of recurrent events and death. *Biometrics*, 56 : 554-562, 2000.
- I. Gijbels and N. Veraverbeke. Sánchez Sellero. Almost sure asymptotic representation for a class of functionals of the Kaplan-Meier estimator. *Ann. Statist.*, 19(3) : 1457-1470, 1991.
- A. W. Van der Vaart, and J. A. Wellner. Weak convergence and empirical processes with applications to statistics. *Springer Series in Statistics*. New York : Springer-Verlag., 1996.
- Merci de votre attention !

Bibliographie

- U. Einmahl, and D. Mason (2005). Uniform in bandwidth consistency of kernel-type function estimators. *Ann. Statist.*, 33(3) : 1380-1403, 2005.
- D. Ghosh, and D. Lin. Nonparametric analysis of recurrent events and death. *Biometrics*, 56 : 554-562, 2000.
- I. Gijbels and N. Veraverbeke. Sánchez Sellero. Almost sure asymptotic representation for a class of functionals of the Kaplan-Meier estimator. *Ann. Statist.*, 19(3) : 1457-1470, 1991.
- A. W. Van der Vaart, and J. A. Wellner. Weak convergence and empirical processes with applications to statistics. *Springer Series in Statistics*. New York : Springer-Verlag., 1996.
- **Merci de votre attention !**