



## *Remerciements*

Au début et avant tout, je rends grâce à dieu **ALLAH** tout puissant qui m'a aidé à terminer ce travail. Merci pour me guider et être toujours avec moi.

Je souhait d'abord exprimer ma profonde gratitude à Monsieur le **Dr. Fethi-Madani** pour son soutien constant tout au long de la préparation de ce travail. Je remercie pour son appui scientifique, qui m'a été indispensable et aussi pour ses encouragements aux initiatives personnelles, ses orientations, ses conseils et sa disponibilité.

Je tiens à remercier sincèrement les membres du jury qui me font le grand honneur d'évaluer ce travail.

Et remercies à ma mère, mon père, mes frères, mes soeurs, mes amies pour le soutien qu'ils m'ont apporté tout au long de la préparation de ce projet de fin d'étude.

## *Dédicaces*

A tous ceux qui me sont chers

# Table des matières

<b>Introduction</b>	<b>5</b>
<b>1 Quelques résultats asymptotiques pour des modèles conditionnels en dimension infinie</b>	<b>8</b>
1.1 L'entropie de Kolomogorov . . . . .	8
1.1.1 Définition . . . . .	8
1.2 Présentation des modèles . . . . .	9
1.2.1 Hypothèses . . . . .	9
1.3 Estimation de la fonction de régression . . . . .	10
1.3.0.1 Corollaire . . . . .	15
1.4 Estimation de la fonction de répartition conditionnelle . . . . .	19
1.5 Estimation de la densité conditionnelle . . . . .	22
<b>2 Les résultats asymptotique de la fonction de hasard conditionnelle</b>	<b>28</b>
2.1 Le contexte bibliographique . . . . .	28
2.1.1 Sur la fonction de hasard conditionnel pour variable explicative fonctionnelle . . . . .	29
2.2 La construction de l'estimateur pour des données complètes . . . . .	30
2.3 Présentation de l'estimateur dans le cas censuré . . . . .	32
2.4 Résultats asymptotiques . . . . .	34
2.4.1 La convergence presque complète . . . . .	34
2.4.2 Cas d'échantillon i.i.d . . . . .	34
2.4.3 Cas d'échantillon dépendant . . . . .	35
2.5 Résultats asymptotique de l'estimateur pour des donnés incomplètes . . . . .	36
2.5.1 Le cas indépendant . . . . .	36
2.5.2 Le cas dépendant . . . . .	37
2.6 Preuves des lemmes . . . . .	38
<b>Conclusion</b>	<b>47</b>
<b>Bibliographie</b>	<b>47</b>

# Introduction

Depuis de plus 50 ans, la statistique mathématique découvre le problème de l'estimateur, de la fonction de densité de probabilité de variable aléatoire continue d'un échantillon aléatoire. En (1956) Rosenblatt a été introduit pour la première fois l'estimateur du noyau pour l'estimateur de la densité et par Nadaraya (1964) et Waston (1964) pour l'estimateur de la régression. L'estimateur linéaire locale introduit par Stone (1977) est entré par le travail de Fan (1992,1993). En (1995) Andrews donna un ensemble complet des résultats concernant la cohérence uniforme du noyau d'estimateurs mais ne sont pas clairs. Masry (1996) calcule la vitesse pour une convergence uniforme presque sûre mais limite au cas de régression borne et place des conditions trop restrictives sur les fonctions de régression. En (2003) Fan et Yao on également donnent un ensemble de résultats mais ils sont restrictifs dans leur application.

La convergence uniforme pour les moyennes des noyaux a été introduit pour un certains des documents Peligrad (1991), Newey(1994), Andrews(1995), Liescher(1996), Masry(1996), Bosq(1998), Fan et Yao(2003), et Ango NZe et Doukhan(2004). La vitesse uniforme que nous avons obtenue pour la fonction d'estimateur est optimal dans le sens de Stone (1982). Dans le temps discret, plusieurs auteurs, dont Bienens(1983), Andrews(1995), Liescher(1996), Masry(1996), Bosq(1998), Fan et Yao(2003), Harsen(2008), Kristensen(2009), Kong, Linton et Xia(2010) et Gao, Kanaya, Li et Tjøsthein(2015) ont étudié la convergence uniforme des estimateurs basés sur le noyau. Kutoyants(1999) et Vanzanten(2000) considèrent l'estimation de la densité pour les processus de diffusion et présentent la convergence uniforme de l'estimateur de densité à base de noyau. Krinsenten(2008) considèrent les vitesses de convergence des estimateurs non paramétrique par rapport à la norme intégrale  $L_2$ .

L'estimation de la fonction de répartition conditionnelle dans un cadre fonctionnel a été introduite par Ferraty et al(2006). Ils ont construit un estimateur à double noyau pour la fonction de répartition conditionnelle et ils ont précisé la vitesse de convergence presque complète de cet estimateur lorsque les observations sont indépendantes et identiquement distribuées. Le cas des observation  $\alpha$ -mélangeantes

a été étudié par Ferraty et al(2005), et plusieurs auteurs ont traité l'estimation de la fonction de répartition conditionnelle comme une étude préliminaire de l'estimation des quantiles conditionnels, Ezzahrioui et Ould-saïd(2005, 2006) qui étudié la normalité asymptotique de cet estimateurs dans les deux cas (*i.i.detamlangeant*). Une autre méthode d'estimation pour les quantiles conditionnels a été proposée par Laksaci et al(2009).

La littérature sur l'estimation de la fonction de hasard conditionnelles est relativement restreinte en statistique fonctionnelle. L'article de Ferraty et al(2008), dans cette publication des auteurs les auteurs on établis la convergence presque complète d'un estimateur à noyau de la fonction de hasard conditionnelle, lorsque les observations sont indépendantes et identiquement distribuées. Ezzahrioui(2007) a étudié la normalité asymptotique. Le cas  $\alpha$ -mélangeant a été traité par Quintela-Del-Rio(2010). Ce dernier a établi la convergence presque complète et la normalité asymptotique de l'estimateur proposé par Ferraty et al(2008).

L'estimation de la fonction de densité conditionnelle, en statistique fonctionnelle, a été introduite par Ferraty et al(2006). Ces autres ont obtenu la convergence presque complète dans le cas *i.i.d.* Ferraty el al(2005) ont établi la convergence presque complète d'un estimateur à noyau du mode conditionnel défini par la variable aléatoire maximisant la densité conditionnelle. Ezzahrioui et Ould-Saïd(2010) on étudiée la normalité asymptotique de l'estimateur a noyau dans les données dépendantes. Madani et al (2012) ont établila convergence uniforme et prèsque complète de l'estimateur linéaire local de la densité conditionnelle pour des données fonctionnelles.

Les premiers résultats en statistique non paramétrique fonctionnelle ont été élaborés par Ferraty et vieu(2006) et ils concernent l'estimation de la fonction de régression à variable explicative de dimension fractale. Ils ont établi la convergence presque complète d'un estimateur à noyau de ce modèle non paramétrique dans la théorie des probabilités de petites boules, Ferraty et vieu(2004) ont généralisé ces derniere résultats au cas  $\alpha$ -mélangeant et ils ont exploité l'importance de la modélisation non paramétrique des données fonctionnelles. Dans le cadre d'observations fonctionnelles  $\alpha$ -mélangeantes, Masry(2005) a montré la normalité asymptotique de l'estimateur de Ferraty et vieu(2004) pour la fonction de régression. La convergence en moyenne quadratique a été étudiée par Ferraty et al(2007). Plus précisément, ils ont explicite le terme asymptotique exacte de l'erreur quadratique. Les résultats sur l'uniforme intégrabilité ont été établis par Delsol(2007, 2009) et Delsol et al(2011). D'autres travaux se sont intéressés à l'estimation de la fonction de régression en utilisant différentes approches : la méthode des K plus proche voisins par Burba et al(2008), les techniques robustes par Azzidine et al(2008), Attouch et al(2009) et

Granbes et al(2008), l'estimation par la methode simplifiée de polynôme locaux par Barrientos-Marin et al(2010). Koo et Linton(2012) considèrent une sorte de modèle à disparaitre semi paramétrique variable dans la temps et présentent les résultat de convergence uniformes pour tous estimateurs semi paramétriques.

Dans cet mémoire, nous nous intéressons à la convergence uniforme de l'estimateur non paramétrique de la fonction de hazard conditionnel pour variable explicative fonctionnelle et une variable réponse réelle. On présente aussi quelques résultats sur la convergence uniforme presque complète d'estimateurs non paramétriques pour certains modèles conditionnels.

Dans le premier chapitre, nous nous intéresson à l'estimateurs par la méthode a noyau pour la fonction de régression conditionnelle et la fonction de répartition conditionnelle, la densité conditionnelle et nous étudions la convergence uniforme presque complète de ces estimateurs en précisant leurs vitesses.

Dans le second chapitre, on présenté quelques résultats asymptotiques de la fonction de hasard conditionnelle pour les deux cas , le premier cas est celui des données complètes et le deuxième est pour des données incomplètes.

# Chapitre 1

## Quelques résultats asymptotiques pour des modèles conditionnels en dimension infinie

### 1.1 L'entropie de Kolomogorov

#### 1.1.1 Définition

Soit  $S$  un sous-ensemble de l'espace métrique  $\mathcal{F}$ , et soit  $\epsilon > 0$ , un ensemble fini de points  $X_1, X_2, \dots, X_N$  dans  $\mathcal{F}$  est appelé un  $\epsilon$ -net pour  $S$  si  $S \subset \bigcup_{k=1}^N B(x_k, \epsilon)$ . La quantité  $\psi_S(\epsilon) = \log(N\epsilon(S))$  où  $N\epsilon(S)$  est le nombre minimal de boules ouvertes en  $\mathcal{F}$  de rayon  $\epsilon$  qui est nécessaire pour couvrir  $S$ , s'appelle l'entropies de Kolmogorov de  $S$ .

Ce concept a été introduit par Kolmogorov au milieu des années 1950 (voir Kolmogorov et Tikhomirov 1959) et il représente sa mesure de la complexité d'un ensemble dans le sens où une l'entropie élevée signifie que beaucoup d'information est nécessaires pour écrire un élément avec une précision  $\epsilon$ . Par conséquent le choix de la structure topologique (autrement dit, le choix de la semi métrique), et jouons un rôle professionnel quand on regarde les résultats asymptotiques uniformes sur certains sous-éléments  $S_{\mathcal{F}}$  de  $\mathcal{F}$ . Plus précisément, nous avons, par la suite, ce semi métrique peut également augmenter la concentration de la mesure de probabilité de la variable fonctionnelle  $X$  pour minimiser  $\epsilon$  l'entropie de sous ensemble  $S_{\mathcal{F}}$ . Ferraty et al, (2006) nous avons souligné le phénomène de concentration de la mesure de probabilité de la variable fonctionnelle en calculant les probabilités de petite boule dans diverses normes situation. Enfin s'intéresser à ces deux (probabilités d'entropie

et de petite boule) ou à l'utilisation de  $\epsilon$  l'entropie de Kolmogorov dans les problèmes de réduction de la dimensionnalité pour se réfères à Kulbs et Li (1993) ou Odoros et Yannis(1997).

## 1.2 Présentation des modèles

Soit  $(X, Y)$  un couple des variables aléatoires à valeurs dans  $\mathcal{F} \times \mathbb{R}$ , où  $\mathcal{F}$  est un espace semi-métrique. On note  $d$  est un semi-métrique de  $\mathcal{F}$  la complexité de l'espace fonctionnelle n'écésite un ensemble d'hypothèses, dans la suite on présente qu'elle que hypothèses qui se figurs dans la plupart des ces résultats qu'on un présenter par la suite.

### 1.2.1 Hypothèses

**(H1)**  $\forall x \in S_{\mathcal{F}}, 0 < C\phi(h) \leq P(X \in B(x, h)) \leq C'\phi(h) < \infty$ .

**(H2)** Il existe  $b > 0$  tel que

$$\forall x_1, x_2 \in S_{\mathcal{F}}, |m_{\varphi}(x_1) - m_{\varphi}(x_2)| \leq Cd^b(x_1, x_2).$$

**(H3)**  $\forall m \geq 2, \mathcal{F}(|\varphi(Y)|^m / X = x) \leq \delta_m(x) < C < \infty$  avec  $\delta_m(\cdot)$  continue sur  $S_{\mathcal{F}}$ .

**(H4)**  $K$  est un noyau borné et Lipchitz sur son support  $[0, 1]$ , et si  $K(1)=0$ , le noyau  $K$  doit remplir la condition supplémentaire  $-\infty < C < K'(t) < C' < 0$ .

**(H5)** Les fonction  $\phi$  et  $\psi_{S_{\mathcal{F}}}$  sont tel que

**(H5<sub>a</sub>)**  $\exists C > 0, \exists \eta_0 > 0, \forall \eta < \eta_0, \phi'(\eta) < C$  et si  $K(1) = 0$ , les fonction  $\phi(\cdot)$  doit remplir la condition supplémentaire

$$\exists C > 0, \exists \eta_0 > 0, \forall 0 < \eta < \eta_0, \int_0^{\eta} \phi(u)du > C_{\eta}\phi(\eta).$$

**(H5<sub>b</sub>)** Pour  $n$  assez grande

$$(\log n)^2/n\phi(h_K) < \psi_{S_{\mathcal{F}}} < (\log n/n) < n\phi(h_K)/\log n.$$

**(H6)**  $\epsilon$ - L'entropie de kolmogorov de  $S_{\mathcal{F}}$  satisfait

$$\sum_{i=1}^{\infty} \exp \left\{ (1 - \beta)\psi_{S_{\mathcal{F}}} \left( \frac{\log n}{n} \right) \right\} < \infty$$

pour certains  $\beta > 1$ .

Les conditions (H1)-(H2) sont très standard dans le cadre non paramétrique. En ce qui concerne (H5a), la limite de la dérivée de  $\phi$  autour du zéro permet de considérer  $\phi$  comme une fonction Lipschitzienne.

En outre, d'un point de vue théorique, il faut séparer le cas où  $K(\cdot)$  est un noyau continu (c'est-à-dire  $K(1)=0$ ) et le cas où  $K(\cdot)$  n'est pas continu (qui contient, par exemple, le noyau uniforme). Le cas où  $K(1)=0$  est plus délicat et on doit introduire une hypothèse supplémentaire agissant sur le comportement  $\phi$  d'environ zéro. L'hypothèse (H5b) traite de considérations topologiques par l'entropie de  $S_{\mathcal{F}}$ . Pour un rayon pas trop grand, on exige que  $\psi_{S_{\mathcal{F}}}(\log n/n)$  n'ait pas trop petit et pas trop grand. Par ailleurs (5b) implique que  $\psi_{S_{\mathcal{F}}}(\log n/n)(n\phi(h_k))$  tend vers 0 lorsque  $n$  tend vers  $+\infty$ . L'hypothèse (H6) s'agit sur l'entropie de Kolomogorov de  $S_{\mathcal{F}}$ . Cependant, si l'on considère le même cas particulier que précédemment, il est facile de voir que (H6) est vérifié que  $\beta > 2$ .

### 1.3 Estimation de la fonction de régression

Estimation de la fonction de régression dans cette section, nous considérons le problème de l'estimation de régression généralisée définie comme comme suit

$$m_{\varphi}(x) = \mathbb{E}[\varphi(Y) \mid X = x],$$

où  $\varphi$  une fonction mesurable connue (voir Ferraty et Vieu (2006)). Notons que cette fonction peut regrouper plusieurs modèles non paramétriques tels la régression classique pour  $\varphi = Id$  (Ferraty et Vieu(2002)).

Soit  $(X_i, Y_i)_{i=1, \dots, n}$  des couples ayant la même loi que  $(X, Y)$ . On considère un estimateur pour la fonction de régression classique, noté  $\hat{m}_{\varphi}$  défini par :

$$\hat{m}_{\varphi}(x) = \frac{\sum_{i=1}^n K(h_K^{-1}d(x, X_i))\varphi(Y_i)}{\sum_{i=1}^n K(h_K^{-1}d(x, X_i))}, \quad \forall x \in \mathcal{F}.$$

où  $K$  est un noyau et  $h_K$  est une suite réels positifs.

**Théorème 1.1.** *Sous hypothèses (H1)-(H6) nous avons*

$$\sup_{x \in S_{\mathcal{F}}} |\widehat{m}_{\varphi}(x) - m_{\varphi}(x)| = o(h_k^b) + o\left(\sqrt{\frac{\psi_{S_{\mathcal{F}}}\left(\frac{\log n}{n}\right)}{n\phi(h_k)}}\right) \quad p.c.$$

**Preuve** Nous désignerons, pour tout  $i=1\dots N$ , par

$$K_i(x) = K(h_K^{-1}d(x, X_i))$$

et

$$H_i(x) = H(h_H^{-1}(y, Y_i)).$$

Tout d'abord, selon (H1) et (H4) il est clair que si  $K(1) > C > 0$ ,

$$\forall x \in S_{\mathcal{F}}, \exists 0 < C < C' < \infty, C\phi(h_K) < \mathbb{E}[K(1)(x)] < C'\phi(h_K). \quad (1.1)$$

On définit  $\epsilon = \frac{\log n}{n}$ .

La preuve du théorème 1.1 est basée sur la décomposition suivante :

$$\begin{aligned} \widehat{m}_{\varphi}(x) - m_{\varphi}(x) &= \frac{1}{\widehat{f}(x)}[\widehat{g}_{\varphi}(x) - \mathbb{E}(\widehat{g}_{\varphi}(x))] + \frac{1}{\widehat{f}(x)}[\mathbb{E}(\widehat{g}_{\varphi}(x)) - m_{\varphi}(x)] \\ &\quad + [1 - \widehat{f}(x)] \frac{m_{\varphi}(x)}{\widehat{f}(x)} \end{aligned} \quad (1.2)$$

où

$$\widehat{f}(x) = \frac{1}{n\mathbb{E}[K(h_K^{-1}d(x, X_1))]} \sum_{i=1}^n K(h_K^{-1}d(x, X_i))$$

et

$$\widehat{g}_{\varphi}(x) = \frac{1}{n\mathbb{E}[K(h_K^{-1}d(x, X_1))]} \sum_{i=1}^n K(h_K^{-1}d(x, X_i))\varphi(Y_i).$$

Par conséquent, le théorème 1 est l'effet des résultats suivants

### Lemme 1.1.1

Sous hypothèses (H1), (H2), (H6), nous avons

$$\sup_{x \in S_{\mathcal{F}}} |\hat{f}(x) - 1| = o\left(\sqrt{\frac{\psi_{S_{\mathcal{F}}}\left(\frac{\log n}{n}\right)}{n\phi(h_K)}}\right), \quad p.c$$

**Preuve** Soit  $X_1, \dots, X_{N_{\epsilon}(S_{\mathcal{F}})}$  et pour tous  $x \in S_{\mathcal{F}}$ , un ensemble

$$K(x) = \arg \min_{K \in \{1, 2, \dots, N_{\epsilon}(S_{\mathcal{F}})\}} d(x, x_k),$$

on considère là de composition suivante

$$\begin{aligned} \sup_{x \in S_{\mathcal{F}}} |\hat{f}(x) - \mathbb{E}(\hat{f}(x))| &\leq \underbrace{\sup_{x \in S_{\mathcal{F}}} |\hat{f}(x) - \hat{f}(x_{K(x)})|}_{t_1} + \underbrace{\sup_{x \in S_{\mathcal{F}}} |\hat{f}(x_{K(x)}) - \mathbb{E}(\hat{f}(x_{K(x)}))|}_{t_2} \\ &\quad + \underbrace{\sup_{x \in S_{\mathcal{F}}} |\mathbb{E}(\hat{f}(x_{K(x)})) - \mathbb{E}(\hat{f}(x))|}_{t_3}. \end{aligned}$$

Laisser-nous étudiez  $t_1$ . En utilisant 2.1 et la limite de  $K$ , on peut écrire

$$\begin{aligned} t_1 &\leq \sup_{x \in S_{\mathcal{F}}} \frac{1}{n} \sum_{i=1}^n \left| \frac{1}{\mathbb{E}[K_1(x)]} K_i(x) - \frac{1}{\mathbb{E}[K_1(x_{k(x)})]} K_i(x_{k(x)}) \right| \\ &\leq \frac{C}{\phi(h_K)} \sup_{x \in S_{\mathcal{F}}} \frac{1}{n} \sum_{i=1}^n |K_i(x) - K_i(x_{k(x)})| \mathbb{1}_{B(x, h_K) \cup B(x_{k(x)}, h_K)}(X_i). \end{aligned}$$

Considérons d'abord le cas  $K(1)=0$ , parceque  $K$  est Lipschitz sûr  $[0, 1]$  dans ce cas, il vient

$$t_1 \leq \sup_{x \in S_{\mathcal{F}}} \frac{C}{n} \sum_{i=1}^n Z_i \quad \text{avec} \quad Z_i = \frac{\epsilon}{h_K \phi(h_K)} \mathbb{1}_{B(x, h_K) \cup B(x_{k(x)}, h_K)}(X_i),$$

uniformément sur  $x$ ,

$$Z_1 = o\left(\frac{\epsilon}{h_K \phi(h_K)}\right), \mathbb{E}(Z_1) = o\left(\frac{\epsilon}{h_K}\right) \text{ et } \text{var}(Z_1) = o\left(\frac{\epsilon^2}{h_K^2 \phi(h_K)}\right),$$

une inégalité standard pour les sommes de variables aléatoires bornées (voir, Ferraty et vieu, (2006)) permet d'obtenir

$$t_1 = o\left(\frac{\epsilon}{h_K}\right) + o\left(\frac{\epsilon}{h_K} \sqrt{\frac{\log n}{n\phi(h_K)}}\right).$$

Et il suffit de combiner (H5a) et (H5b) pour obtenir

$$t_1 = o\left(\sqrt{\frac{\psi_{S_{\mathcal{F}}}(\epsilon)}{n\phi(h_K)}}\right).$$

Maintenant, soit  $K(1) > C > 0$  : dans cette situation,  $K$  est Lipschitz sûr  $[0, 1]$ . On doit décomposer  $t_1$  en trois termes comme suit

$$t_1 \leq C \sup_{x \in S_{\mathcal{F}}} (F_1 + F_2 + F_3).$$

Avec

$$\begin{aligned} F_1 &= \frac{1}{n\phi(h_K)} \sum_{i=1}^n |K_i(x) - K_i(x_{K(x)})| \mathbb{1}_{B(x, h_K) \cap B(x_{K(x)}, h_K)}(X_i) \\ F_2 &= \frac{1}{n\phi(h_K)} \sum_{i=1}^n K_i(x) \mathbb{1}_{B(x, h_K) \cap \overline{B(x_{K(x)}, h_K)}}(X_i) \\ F_3 &= \frac{1}{n\phi(h_K)} \sum_{i=1}^n K_i(x_{K(x)}) \mathbb{1}_{\overline{B(x, h_K)} \cap B(x_{K(x)}, h_K)}(X_i) \end{aligned}$$

On peut suivre les mêmes étapes (c'est-à-dire cas  $K(1)=0$ ) pour étudier  $F_1$  et on obtient le même résultat.

$$F_1 = o\left(\sqrt{\frac{\psi_{S_{\mathcal{F}}}(\epsilon)}{n\phi(h_K)}}\right), \quad p.c$$

suivant les mêmes idées pour étudier  $F_2$  on peut écrire

$$F_2 \leq \frac{C}{n} \sum_{i=1}^n W_i \quad \text{avec} \quad W_i = \frac{1}{\phi(h_K)} \mathbb{1}_{B(x, h_K) \cap \overline{B(x_{K(x)}, h_K)}}(X_i).$$

Et en utilisant l'hypothèse (H5a) et la même inégalité pour des sommes de variables aléatoires bornées, on a

$$F_2 = o\left(\frac{\epsilon}{\phi(h_K)}\right) + o\left(\sqrt{\frac{\epsilon \log n}{n\phi(h_K)^2}}\right), \quad p.c$$

de même, on peut déclarer la convergence pour  $F_3$  : Pour terminer l'étude de  $F_1$ , il suffit de mettre ensemble résultats intermédiaires et à utiliser l'hypothèse (H5b)

pour

$$F_1 \left( \sqrt{\frac{\psi_{S_{\mathcal{F}}}(\epsilon)}{n\phi(h_K)}} \right), \quad p.c$$

– Or, concerne  $F_2$ , nous avons, pour tout  $\eta > 0$

$$\begin{aligned} & \mathbb{P} \left( t_2 > \eta \sqrt{\frac{\psi_{S_{\mathcal{F}}}(\epsilon)}{n\phi(h_K)}} \right) \\ &= \mathbb{P} \left( \max_{K \in \{1, \dots, N\epsilon(S_{\mathcal{F}})\}} | \hat{f}(x_{K(x)}) - \mathbb{E}(\hat{f}(x_{K(x)})) | > \eta \sqrt{\frac{\psi_{S_{\mathcal{F}}}(\epsilon)}{n\phi(h_K)}} \right) \\ &\leq N\epsilon(S_{\mathcal{F}}) \max_{K \in \{1, \dots, N\epsilon(S_{\mathcal{F}})\}} \mathbb{P} \left( | \hat{f}(x_K) - \mathbb{E}(\hat{f}(x_K)) | > \eta \sqrt{\frac{\psi_{S_{\mathcal{F}}}(\epsilon)}{n\phi(h_K)}} \right). \end{aligned}$$

Soit

$$\Delta_{K_i} = \frac{1}{\mathbb{E}[K_1(x_K)]} (K_i(x_k) - \mathbb{E}[K_i(x_k)]).$$

Nous montrons, sous l'hypothèse (H1) et (H4), que  $\forall K = 1, \dots, N\epsilon(S_{\mathcal{F}})$ ,  $\forall i = 1, \dots, n$

$$\Delta_{K_i} = o(\phi(h_K)^{-1})$$

et aussi

$$\text{var}(\Delta_{K_i}) = o(\phi(h_K)^{-1}).$$

Ainsi, on peut appliquer l'égalité de Bernstein en (voir, Ferraty et vieux, 2006) qui donne directement

$$\begin{aligned} \mathbb{P} \left( | \hat{f}(x_K) - \mathbb{E}[\hat{f}(x_K)] | > \eta \sqrt{\frac{\psi_{S_{\mathcal{F}}}(\epsilon)}{n\phi(h_K)}} \right) &= \mathbb{P} \left( \frac{1}{n} \left| \sum_{i=1}^n \Delta_{K_i} \right| > \eta \sqrt{\frac{\psi_{S_{\mathcal{F}}}(\epsilon)}{n\phi(h_K)}} \right) \\ &\leq 2 \exp(-Cn^2\psi_{S_{\mathcal{F}}}(\epsilon)). \end{aligned}$$

Ainsi, en utilisant le  $\psi_{S_{\mathcal{F}}}(\epsilon) = \log N\epsilon(S_{\mathcal{F}})$  et en choisissant une telle  $C\eta^2 = \beta_1$ , nous avons

$$N\epsilon(S_{\mathcal{F}}) \max_{K \in \{1, \dots, N\epsilon(S_{\mathcal{F}})\}} \mathbb{P} \left( \left| \hat{f}(x_K) - \mathbb{E}[\hat{f}(x_K)] \right| > \eta \sqrt{\frac{\psi_{S_{\mathcal{F}}}(\epsilon)}{n\phi(h_K)}} \right) \leq C' N\epsilon(S_{\mathcal{F}})^{1-\beta}.$$

Car  $\sum_{n=1}^{\infty} N\epsilon(S_{\mathcal{F}})^{1-\beta} < \infty$ , nous obtenons

$$t_2 = o \left( \sqrt{\frac{\psi_{S_{\mathcal{F}}}(\epsilon)}{n\phi(h_K)}} \right), \quad p.c$$

– Pour  $t_3$ , il est clair que  $t_3 \leq \mathbb{E}(\sup_{x \in S_{\mathcal{F}}} | \hat{f}(x) - \hat{f}(x_{K(x)}) |)$  et en suivant une preuve similaire à celle utilisée pour étudier

$$t_3 = o \left( \sqrt{\frac{\psi_{S_{\mathcal{F}}}(\epsilon)}{n\phi(h_K)}} \right).$$

### 1.3.0.1 Corollaire

Sous hypothèses (H1), (H4) et (H6), nous avons

$$\sum_{n=1}^{\infty} \mathbb{P} \left( \inf_{x \in S_{\mathcal{F}}} \hat{f}(x) < \frac{1}{2} \right) < \infty.$$

**Preuve** il est facile de voir que

$$\begin{aligned} \inf_{x \in S_{\mathcal{F}}} | \hat{f}(x) | &\leq \frac{1}{2} \Rightarrow \exists x \in S_{\mathcal{F}} \quad \text{telque} \\ 1 - \hat{f}(x) &\geq \frac{1}{2} \Rightarrow \sup_{x \in S_{\mathcal{F}}} | 1 - \hat{f}(x) | \geq \frac{1}{2}. \end{aligned}$$

On déduit de lemme 1.1.1 que

$$\mathbb{P} \left( \inf_{x \in S_{\mathcal{F}}} | \hat{f}(x) | \leq \frac{1}{2} \right) \leq \mathbb{P} \left( \sup_{x \in S_{\mathcal{F}}} | 1 - \hat{f}(x) | \geq \frac{1}{2} \right)$$

conséquence

$$\mathbb{P} \left( \sum_{n=1}^{\infty} \inf_{x \in S_{\mathcal{F}}} | \hat{f}(x) | \leq \frac{1}{2} \right) < \infty.$$

## Lemme 1.1.2

Sous hypothèses (H1), (H2), et (H4), (H6), nous avons

$$\sup_{x \in S_{\mathcal{F}}} | \mathbb{E} \widehat{g}_{\varphi}(x) - m_{\varphi}(x) | = o(h_K^b).$$

**Preuve** ona

$$\begin{aligned} | \mathbb{E}[\widehat{g}_{\varphi}(x)] - m_{\varphi}(x) | &= \left| \frac{1}{n \mathbb{E}[K_i(x)]} \mathbb{E} \left[ \sum_{i=1}^n K_i(x) \varphi(Y_i) \right] - m_{\varphi}(x) \right| \\ &\leq \left| \frac{1}{\mathbb{E}[K_i(x)]} \mathbb{E} [K_1(x) \varphi(Y_1)] - m_{\varphi}(x) \right| \\ &\leq \frac{1}{n \mathbb{E}[K_i(x)]} [ \mathbb{E}[K_1(x) | m_{\varphi}(X_1) - m_{\varphi}(x) ] ]. \end{aligned}$$

Par conséquent, nous obtenons

$$\forall x \in S_{\mathcal{F}}, \quad | \mathbb{E}(\widehat{g}_{\varphi}(x)) - m_{\varphi}(x) | \leq \frac{1}{\mathbb{E}[K_1(x)]} [ \mathbb{E}K_1(x) | m_{\varphi}(X_1) - m_{\varphi}(x) ] ].$$

Ainsi, avec les hypothèses (H1), (H2), nous avons

$$\begin{aligned} \forall x \in S_{\mathcal{F}}, \quad | \mathbb{E}(\widehat{g}_{\varphi}(x)) - m_{\varphi}(x) | &\leq C \frac{1}{\mathbb{E}[K_1(x)]} [ \mathbb{E}K_1(x) \mathbf{1}_{B(x, h_K)}(X_1) d^b(X_1, x) ] \\ &\leq C h_K^b, \end{aligned}$$

cette dernière inégalité donne la preuve, puisque C ne dépend pas de x.

### Lemme 1.1.3

Sous hypothèses (H1) et (H6), nous avons

$$\sup_{x \in S_{\mathcal{F}}} | \widehat{g}_{\varphi}(x) - \mathbb{E} \widehat{g}_{\varphi}(x) | = o \left( \sqrt{\frac{\psi_{S_{\mathcal{F}}} \left( \frac{\log n}{n} \right)}{n \phi(h_K)}} \right), \quad p.c$$

**Preuve** cette preuve suit les mêmes étapes que la preuve du lemme 1.1.1, pour cela, nous gardons ces notations et nous utilisons la décomposition suivante :

$$\sup_{x \in S_{\mathcal{F}}} | \widehat{g}_{\varphi}(x) - \mathbb{E} \widehat{g}_{\varphi}(x) | \leq \underbrace{\sup_{x \in S_{\mathcal{F}}} | \widehat{g}_{\varphi}(x) - \widehat{g}_{\varphi}(x_{K(x)}) |}_{g_1} + \underbrace{\sup_{x \in S_{\mathcal{F}}} | \widehat{g}_{\varphi}(x_{K(x)}) - \mathbb{E} \widehat{g}_{\varphi}(x_{K(x)}) |}_{g_2}$$

$$+ \underbrace{\sup_{x \in S_{\mathcal{F}}} | \mathbb{E} \widehat{g}_{\varphi}(x_{K(x)}) - \mathbb{E} \widehat{g}_{\varphi}(x) |}_{g_3}$$

À condition (H1) permet de s'exprimer directement, pour  $g_1, g_3$

$$\begin{aligned} g_1 &= \sup_{x \in S_{\mathcal{F}}} \left| \sum_{i=1}^n \frac{1}{n \mathbb{E}[K_1(x)]} K_i(x) \varphi(Y_i) - \frac{1}{n \mathbb{E}[K_1(x_{K(x)})]} K_i(x_{K(x)}) \varphi(Y_i) \right| \\ &\leq \sup_{x \in S_{\mathcal{F}}} \frac{1}{n \phi(h_K)} \sum_{i=1}^n | \varphi(Y_i) | | K_i(x) - K_i(x_{K(x)}) | \mathbb{1}_{B(x, h_K) \cup B(x_{K(x)}, h_K)}. \end{aligned}$$

Maintenant, pour  $t_1$ , on considère  $K(1) = 0$  (c'est-à-dire Lipschitz sûr  $[0, 1]$ ) et on obtient

$$g_1 \leq \frac{C}{n} \sum_{i=1}^n Z_i,$$

avec

$$Z_i = \frac{\epsilon \varphi(Y_i)}{h_K \phi(h_K)} \sup_{x \in S_{\mathcal{F}}} \mathbb{1}_{B(x, h_K) \cup B(x_{K(x)}, h_K)}.$$

La principale différence avec l'étude de  $t_1$  est l'on utilise ici l'inégalité exponentielle pour les variables non bornées

$$\mathbb{E} [ | \varphi^m(Y) | ] = \mathbb{E} [ \mathbb{E} [ | \varphi(Y) |^m / X ] ]$$

$$= \int \delta_m(x) dP_x < C < \infty.$$

Ce qui implique que

$$\mathbb{E}(|Z_1|^m) \leq \frac{C\epsilon^m}{h_K^m \phi(h_K)^{m-1}}.$$

donc, en utilisant (corollaire A.8 de Ferraty et Vieu(2006)[3]), avec  $a^2 = \frac{\epsilon}{h_K \phi(h_K)}$  on obtient  $g_1 = o\left(\sqrt{\epsilon \log n / n h_K \phi(h_K)}\right)$ , maintenant l'hypothèse (H5<sub>b</sub>) permet d'obtenir

$$g_1 = o\left(\sqrt{\frac{\psi_{S_{\mathcal{F}}}(\epsilon)}{n\phi(h_K)}}\right), \quad p.c \quad (1.3)$$

Si on considère le cas  $K(1) > C > 0$ , on doit diviser  $g_1$  en trois termes pour  $t_1$  et en utilisant les arguments des équation similaires, on peut ou même taux la convergence presque complète. les étapes similaires permettent d' écrire

$$g_3 = o\left(\sqrt{\frac{\psi_{S_{\mathcal{F}}}(\epsilon)}{n\phi(h_K)}}\right) \quad (1.4)$$

Pour  $g_2$ , de même que pour la preuve de lemme 1.1.1, on a,  $\forall \eta > 0$

$$\begin{aligned} \mathbb{P}\left(g_2 > \eta \sqrt{\frac{\psi_{S_{\mathcal{F}}}(\epsilon)}{n\phi(h_K)}}\right) &= \mathbb{P}\left(\max_{K \in \{1, \dots, N\epsilon(S_{\mathcal{F}})\}} |\hat{g}_{\varphi}(x_K) - \mathbb{E}\hat{g}_{\varphi}(x_K)| > \eta \sqrt{\frac{\psi_{S_{\mathcal{F}}}(\epsilon)}{n\phi(h_K)}}\right) \\ &\leq N\epsilon(S_{\mathcal{F}}) \max_{K \in \{1, \dots, N\epsilon(S_{\mathcal{F}})\}} \mathbb{P}\left(|\hat{g}_{\varphi}(x_K) - \mathbb{E}\hat{g}_{\varphi}(x_K)| > \eta \sqrt{\frac{\psi_{S_{\mathcal{F}}}(\epsilon)}{n\phi(h_K)}}\right). \end{aligned}$$

Le reste de la preuve est basé sur l'inégalité exponentielle. En effet

$$\Gamma_{ki} = \frac{1}{\mathbb{E}[K_1(x_k)]} [K_i(x_k)\varphi(Y_i) - \mathbb{E}[Y_i(x_k)\varphi(Y_i)]].$$

Les mêmes arguments que ceux invoqués pour preuve le lemme (6.3)(a Ferraty et Vieu (2006, p=65)[3]), peuvent être utilisés pour montrer que  $\mathbb{E}|\Gamma_{ki}|^m = o(\phi(h_K)^{-m+1})$  qui donne en appliquant l'inégalité exponentielle, pour tout  $\eta > 0$

$$\mathbb{P}\left(|\hat{g}_{\varphi}(x_K) - \mathbb{E}\hat{g}_{\varphi}(x_K)| > \eta \sqrt{\frac{\psi_{S_{\mathcal{F}}}(\epsilon)}{n\phi(h_K)}}\right) \leq 2N\epsilon(S_{\mathcal{F}})^{-C\eta^2}.$$

Par conséquent, par un choix approprié  $\eta > 0$ , nous avons

$$N\epsilon(S_{\mathcal{F}}) \max_{K \in \{1, \dots, N\epsilon(S_{\mathcal{F}})\}} \mathbb{P} \left( \left| \widehat{g}_{\varphi}(x_K) - \mathbb{E} \widehat{g}_{\varphi}(x_K) \right| > \eta \sqrt{\frac{\log N\epsilon(S_{\mathcal{F}})}{n\phi(h_K)}} \right) < C' N\epsilon(S_{\mathcal{F}})^{1-\beta}.$$

Comme  $\sum_{n=1}^{\infty} N\epsilon(S_{\mathcal{F}}) < \infty$ , on obtient que

$$g_2 = o \left( \sqrt{\frac{\psi_{S_{\mathcal{F}}}(\epsilon)}{n\phi(h_K)}} \right), \quad p.c \quad (1.5)$$

## 1.4 Estimation de la fonction de répartition conditionnelle

Dans cette section, nous supposons que la version régulière de la probabilité conditionnelle de  $Y$  donner  $X$  existe et nous étudions la convergence uniforme presque complète d'un estimateur du noyau de la fonction de répartition conditionnelle, notée  $f^x$  : Une de façon simple pour estimer la fonction  $F^x$  est de traiter cette fonction comme cas particulier de  $m_{\varphi}$  avec  $\varphi(t) = \mathbf{1}_{[-\infty, y]}(t)$  (pour  $y \in \mathbb{R}$ ). Nous estimons ainsi  $F^x$  par

$$\widehat{F}^x(y) = \sum_{i=1}^n W_{ni}(x) \mathbf{1}_{[Y_i \leq y]}, \quad \forall y \in \mathbb{R}, \forall x \in \mathcal{F}$$

où

$$W_{ni}(x) = \frac{K(h_k^{-1}d(x, X_i))}{\sum_{i=1}^n K(h_k^{-1}d(x, X_i))}.$$

L'estimation de la fonction de répartition conditionnelle a été étudiée, dans le cas réel, par plusieurs auteurs (voir Roussas 1969, samanta 1989). Dans le cas fonctionnel Ferraty et al.(2006) établi la convergence de l'estimateur des noyaux a double de la fonction de répartition conditionnelle.

Pour obtenir la cohérence uniforme , nous fixons un sous-ensemble compact  $S_{\mathbb{R}}$  de  $\mathbb{R}$  et nous considérons les hypothèses ,

**(H7)**  $\forall (y_1, y_2) \in S_{\mathbb{R}} \times S_{\mathbb{R}}, \forall (x_1, x_2) \in S_{\mathcal{F}} \times S_{\mathcal{F}}$

$$| F^{x_1}(y_1) - F^{x_2}(y_2) | \leq C(d(x_1, x_2)^{b_1} + | y_1 - y_2 |^{b_2}).$$

(H8)  $\epsilon$ -L'entropie de kolmogorov de  $S_{\mathcal{F}}$  satisfait

$$\sum_{i=1}^{\infty} n^{\frac{1}{2b_2}} \exp \left\{ (1 - \beta) \psi_{S_{\mathcal{F}}} \left( \frac{\log n}{n} \right) \right\} < \infty$$

pour certains  $\beta > 1$ .

**Théorème 1.2.** *Sous hypothèses (H1), (H4), (H5), (H7) et (H8) nous avons*

$$\sup_{x \in S_{\mathcal{F}}} \sup_{y \in S_{\mathcal{F}}} | \hat{F}^x(y) - F^x(y) | = o(h_k^b) + o \left( \sqrt{\frac{\psi_{S_{\mathcal{F}}} \left( \frac{\log n}{n} \right)}{n\phi(h_k)}} \right), \quad p.c \quad (1.6)$$

**Preuve** On considère la décomposition suivante

$$\begin{aligned} \hat{F}^x(y) - F^x(y) &= \frac{1}{\hat{f}(x)} \left[ (\hat{F}_N^x(y) - \mathbb{E}\hat{F}_N^x(y)) - (\hat{F}(y) - \mathbb{E}\hat{F}_N^x(y)) \right] \\ &\quad + \frac{F^x(y)}{\hat{f}(x)} [\mathbb{E}\hat{f}(x) - \hat{f}(x)]. \end{aligned} \quad (1.7)$$

Où

$$\hat{F}_N^x(y) = \frac{1}{n\mathbb{E}[K(h_K^{-1}d(x, X_1))]} \sum_{i=1}^n K(h_K^{-1}d(x, X_1)) \mathbf{1}_{\{Y_i \leq y\}}.$$

Ensuite, on peut déduire le théorème 2 des résultats suivants

### Lemme 1.2.1

Sous hypothèses (H4) et (H7), on a

$$\sup_{x \in S_{\mathcal{F}}} \sup_{y \in S_{\mathbb{R}}} | F^x(y) - \hat{F}_N^x(y) | = o(h_k^{b_1}).$$

**Preuve** il est clair que l'hypothèse (H4), implique  $\forall (x, y) \in S_{\mathcal{F}} \times S_{\mathbb{R}}$ ,

$$\mathbb{E}[\hat{F}_n^x(y)] - F^x(y) = \frac{1}{\mathbb{E}[K_1(x)]} \mathbb{E}[(K_1(x) \mathbf{1}_{B(x, h_k)}(X_1))(F^{X_1}(y) - F^x(y))]. \quad (1.8)$$

La condition de Lipschitz permet d'écrire

$$\forall (x, y) \in S_{\mathcal{F}} \times S_{\mathbb{R}}, \quad \mathbb{1}_{B(x, h_k)}(X_1) \mid F^{X_1}(y) - F^x(y) \mid \leq Ch_k^{b_1},$$

puis

$$\forall (x, y) \in S_{\mathcal{F}} \times S_{\mathbb{R}}, \quad \mid \mathbb{E}[\hat{F}_n^x(y)] - F^x(y) \mid < Ch_k^{b_1}.$$

## Lemme 1.2.2

Sous les hypothèses (H1), (H4), (H5), et (H7), (H8), nous avons

$$\sup_{x \in S_{\mathcal{F}}} \sup_{y \in S_{\mathbb{R}}} \mid \hat{F}_N^x(y) - \mathbb{E}\hat{F}_N^x(y) \mid = o\left(\sqrt{\frac{\psi_{S_{\mathcal{F}}}\left(\frac{\log n}{n}\right)}{n\phi(h_K)}}\right), \quad p.c$$

**Preuve :** Nous gardons notation de lemme (1.1.1) et utilisons la compacité de  $S_{\mathbb{R}}$ , on peut écrire , pour certains  $t_1, t_2, \dots, t_{Z_n} \in S_{\mathbb{R}}$ ,

$$S_{\mathbb{R}} \in \bigcup_{j=1}^{Z_n} (t_j - l_n, t_j + l_n),$$

avec  $l_n = n^{-\frac{1}{2b_2}}$  et  $Z_n \leq n^{\frac{1}{2b_2}}$ . Prendre

$$j(y) = \arg \min_{j \in \{1, 2, \dots, Z_n\}} \mid y - t_j \mid.$$

Ainsi, nous avons la décomposition suivante

$$\begin{aligned} \sup_{x \in S_{\mathcal{F}}} \sup_{y \in S_{\mathbb{R}}} \mid \hat{F}_N^x(y) - \mathbb{E}[\hat{F}_N^x(y)] \mid &\leq \underbrace{\sup_{x \in S_{\mathcal{F}}} \sup_{y \in S_{\mathbb{R}}} \mid \hat{F}_N^x(y) - \mathbb{E}[\hat{F}_N^{x_{K(x)}}(y)] \mid}_{A_1} \\ &+ \underbrace{\sup_{x \in S_{\mathcal{F}}} \sup_{y \in S_{\mathbb{R}}} \mid \hat{F}_N^{x_{K(x)}}(y) - \mathbb{E}\hat{F}_N^{x_{K(x)}}(y) \mid}_{A_2} + \underbrace{\sup_{x \in S_{\mathcal{F}}} \sup_{y \in S_{\mathbb{R}}} \mid \mathbb{E}\hat{F}_N^{x_{K(x)}}(y) - \mathbb{E}\hat{F}_N^x(y) \mid}_{A_3}. \end{aligned}$$

Concernant  $(A_1)$  et  $(A_3)$ , en suivant les mêmes lignes que pour des termes  $(t_1)$  et  $(t_2)$ , il vient

$$A_1 = o\left(\sqrt{\frac{\psi_{S_{\mathcal{F}}}(\epsilon)}{n\phi(h_k)}}\right), \quad p.c \quad \text{et} \quad A_2 = o\left(\sqrt{\frac{\psi_{S_{\mathcal{F}}}(\epsilon)}{n\phi(h_k)}}\right), \quad p.c \quad (1.9)$$

Concernant  $(A_2)$  monotonie des fonctions  $\mathbb{E}[\hat{F}_N^x(\cdot)]$  et  $\hat{F}_N^x(\cdot)$  permet d'écrire, pour tout  $j \leq z_n$  et pour tout  $x \in S_{\mathcal{F}}$ ,

$$\begin{aligned} \mathbb{E}\hat{F}_N^{x_k(x)}(t_j - l_n) &\leq \sup_{y \in (t_j - l_n, t_j - n)} \mathbb{E}\hat{F}_N^{x_k(x)}(y) \leq \mathbb{E}\hat{F}_N^{x_k(x)}(t_j + l_n), \\ \hat{F}_N^{x_k(x)}(t_j - l_n) &\leq \sup_{y \in (t_j - l_n, t_j - l_n)} \hat{F}_N^{x_k(x)}(y) \leq \hat{F}_N^{x_k(x)}(t_j + l_n) \end{aligned} \quad (1.10)$$

en suit, nous utilisons la condition de Hölder plus ancienne sur  $F^x$  et nous montrons que, pour tout  $y_1, y_2 \in S_{\mathbb{R}}$  et pour tout  $x \in S_{\mathcal{F}}$ ,

$$\begin{aligned} |\mathbb{E}\hat{F}_N^x(y_1) - \mathbb{E}\hat{F}_N^x(y_2)| &= \left| \frac{1}{\mathbb{E}[K_1(x)]} \mathbb{E}[K_1(x)F^{X_1}(y_1)] - \frac{1}{\mathbb{E}[K_1(x)]} \mathbb{E}[K_1(x)F^{X_1}(y_2)] \right| \\ &\leq C |y_1 - y_2|^{b_2}. \end{aligned}$$

En suit, nous passons par (1.9) et l'inégalité précédente et parce que

$$A_2 \leq A_4 + o\left(\sqrt{\frac{\psi_{S_{\mathcal{F}}}(\epsilon)}{n\phi(h_K)}}\right)$$

$$\text{où } A_4 = \max_{K \in \{1, \dots, N\epsilon(S_{\mathcal{F}})\}} \max_{1 \leq j \leq z_n} \max_{s_j = t_j - i_n, t_j + i_n} |\hat{F}_N^{x_k(x)}(s_j) - \mathbb{E}\hat{F}_N^{x_k(x)}(s_j)|.$$

Ainsi, il reste à étudier  $A_4$ . En utilisant des arguments similaires à ceux invoqués pour l'étude de  $A_2$  et comme hypothèse (H8), on a  $A_4 = o(\sqrt{\psi_{S_{\mathcal{F}}}(\epsilon)/n\phi(h_K)})$ , ce qui implique que

$$\sup_{x \in S_{\mathcal{F}}} \sup_{y \in S_{\mathbb{R}}} |\hat{F}_N^{x_k(x)}(s_j(y)) - \mathbb{E}\hat{F}_N^{x_k(x)}(s_j(y))| = o\left(\sqrt{\frac{\psi_{S_{\mathbb{R}}}(\epsilon)}{n\phi(h_K)}}\right), \quad p.c.$$

## 1.5 Estimation de la densité conditionnelle

Dans cette section, les résultats similaires seront utilisés pour l'estimateur du noyau de la densité conditionnelle de  $Y$  donner  $X$ . Nous supposons que la probabilité conditionnelle de  $Y$  donner  $X$  est absolument continue par rapport à la mesure

de Lebesgue sur  $\mathbb{R}$  et nous noterons par  $f^x$  la densité conditionnelle de  $Y$  donner  $X=x$ . Nous définissons l'estimateur à noyau  $\hat{f}^x$  de  $f^x$  comme suit

$$\hat{f}^x(y) = \frac{h_H^{-1} \sum_{i=1}^n K(h_K^{-1}d(x, X_i))H(h_H^{-1}(y - Y_i))}{\sum_{i=1}^n K((h_K^{-1}d(x, X_i))}, \forall y \in \mathbb{R}, \forall x \in \mathcal{F} \quad (1.11)$$

où  $H$  est un noyau  $h_H$  est une suite de réels positifs. Estimation était déjà introduite dans le cas particulier où  $X$  est la variable aléatoire par Rosenblatt(1969) et par Youdjé(1996) parmi d'autres auteurs.

Afin d'établir la convergence uniforme et presque complète de cet estimateur, nous considérons les hypothèses suivantes :

**(H9)**  $\forall (y_1, y_2) \in S_{\mathbb{R}} \times S_{\mathbb{R}}, \forall (x_1, x_2) \in S_{\mathcal{F}} \times S_{\mathcal{F}}$ ,

$$|f^{x_1}(y_1) - f^{x_2}(y_2)| \leq (d^{b_1}(x_1, x_2) + |y_1 - y_2|^{b_2}).$$

**(H10)** Pour certains  $\gamma \in (0, 1)$ ,  $\lim_{n \rightarrow \infty} n^\gamma h_H = \infty$  et pour  $n$  suffisamment grand

$$\frac{(\log n)^2}{n^{1-\gamma}\phi(h_K)} < \psi_{S_{\mathcal{F}}} \left( \frac{\log n}{n} \right) < \frac{n^{1-\gamma}\phi(h_K)}{\log n}.$$

**(H11)** L'entropie de Kolomogrov de  $S_{\mathcal{F}}$  satisfait

$$\sum_{n=1}^{\infty} n^{3\gamma+1/2} \exp \left\{ (1-\beta)\psi_{S_{\mathcal{F}}} \left( \frac{\log n}{n} \right) \right\} < \infty$$

pour certains  $\beta > 1$ .

**(H12)**  $H$  est une fonction continue Lipschitzienne bornée, telle que  $\int |t|^{b_2} H(t)dt$  et  $\int H^2(t)dt < \infty$ .

**Théorème 1.3.** *Sous hypothèse (H1), (H4), (H5a), (H7), (H9), (H10), (H11), nous avons*

$$\sup_{x \in S_{\mathcal{F}}} \sup_{y \in S_{\mathcal{F}}} |\hat{f}^x(y) - f^x(y)| = o(h_K^{b_1}) + o(h_H^{b_2}) + o \left( \sqrt{\frac{\psi_{S_{\mathcal{F}}} \left( \frac{\log n}{n} \right)}{n^{1-\gamma}\phi(h_K)}} \right).$$

**Preuve** la preuve est basé sur la décomposition suivante :

$$\begin{aligned} \hat{f}^x(y) - f^x(y) &= \frac{1}{\hat{f}^x(y)} [(\hat{f}_N^x(y) - \mathbb{E}\hat{f}_N^x(y)) - (f^x(y) - \mathbb{E}\hat{f}_N^x(y))] \\ &\quad + \frac{f^x(y)}{\hat{f}^x(x)} [\mathbb{E}\hat{f}^x(x) - \hat{f}^x(x)] \end{aligned} \quad (1.12)$$

où

$$\hat{f}_N^x(y) = \frac{1}{nh_K \mathbb{E}[K(h_K^{-1}d(x, X_i))]} \sum_{i=1}^n K(h_K^{-1}d(x, X_i))H(h_H^{-1}(y - y_i)).$$

Le théorème 1.3 peut être déduit des résultats suivants,

### Lemme 1.3.1

Sous hypothèses (H4), (H7) et (H9), nous avons

$$\sup_{x \in S_{\mathcal{F}}} \sup_{y \in S_{\mathbb{R}}} |f^x(y) - \mathbb{E}\hat{f}_N^x(y)| = o(h_K^{b_1}) + o(h_H^{b_2}).$$

**Preuve** ona

$$\begin{aligned} \mathbb{E}\hat{f}_N^x(y) - f^x(y) &= \frac{1}{nh_H \mathbb{E}K_1(x)} \left( \mathbb{E} \left[ \sum_{i=1}^n K_i(x)H_i(y) \right] - f^x(y) \right) \\ &= \frac{1}{\mathbb{E}K_1(x)} \mathbb{E} \left( K_1(x) [h_H^{-1} \mathbb{E}(H_1(y)/X_1) - f^x(y)] \right). \end{aligned}$$

En outre, par changement de variable

$$h_H^{-1} \mathbb{E}(H_1(y)/X_1) = \frac{1}{h_H} \int_{\mathbb{R}} H \left( \frac{y-z}{h_H} \right) f^{X_1}(z) dz = \int_{\mathbb{R}} H(t) f^{X_1}(y - h_H t) dt,$$

nous arrivons

$$|h_H^{-1} \mathbb{E}(H_1(y)/X_1) - f^x(y)| \leq \int_{\mathbb{R}} H(t) |f^{X_1}(y - h_H t) - f^x(y)| dt.$$

Enfin, l'utilisation d'hypothèse (H9) implique que

$$|h_H^{-1} \mathbb{E}(H_1(y)/X_1) - f^x(y)| \leq C \int_{\mathbb{R}} H(t) (h_K^{b_1} + |t|^{b_2} h_H^{b_2}) dt.$$

Cette inégalité est uniforme sur  $(x, y)$  dans  $S_{\mathcal{F}} \times S_{\mathbb{R}}$ .

### Lemme 1.3.2

Sous les hypothèses du théorème 1.3, nous avons

$$\sup_{x \in S_{\mathcal{F}}} \sup_{y \in S_{\mathbb{R}}} | \hat{f}_n^x(y) - \mathbb{E} \hat{f}_N^x(y) | = o \left( \sqrt{\frac{\psi_{S_{\mathcal{F}}} \left( \frac{\log n}{n} \right)}{n^{1-\gamma} \phi(h_K)}} \right), \quad p.c$$

**Preuve** la compacité de  $S_{\mathbb{R}}$  parmi d'écrire cela

$$S_{\mathbb{R}} \subset \bigcup_{j=1}^{Z_n} (t_j - l_n, t_j + l_n).$$

Avec  $l_n = n^{-(3/2)\gamma-1/2}$  et  $Z_n \leq Cn^{(3/2)\gamma+1/2}$ . Nous avons la décomposition suivante :

$$\begin{aligned} & | \hat{f}_N^x(y) - \mathbb{E} \hat{f}_N^x(y) | \leq \underbrace{\sup_{x \in S_{\mathcal{F}}} \sup_{y \in S_{\mathbb{R}}} | \hat{f}_N^x(y) - \hat{f}_N^{x_{k(x)}}(y) |}_{T} \\ & + \underbrace{\sup_{x \in S_{\mathcal{F}}} \sup_{y \in S_{\mathbb{R}}} | \hat{f}_N^{x_{k(x)}}(y) - \hat{f}_N^{x_{k(x)}}(t_j(y)) |}_{T_1} + \underbrace{\sup_{x \in S_{\mathcal{F}}} \sup_{y \in S_{\mathbb{R}}} | \hat{f}_N^{x_{k(x)}}(t_j(y)) - \mathbb{E} \hat{f}_N^{x_{k(x)}}(t_j(y)) |}_{T_2} \\ & \underbrace{\sup_{x \in S_{\mathcal{F}}} \sup_{y \in S_{\mathbb{R}}} | \mathbb{E} \hat{f}_N^{x_{k(x)}}(t_j(y)) - \mathbb{E} \hat{f}_N^{x_{k(x)}}(y) |}_{T_3} + \underbrace{\sup_{x \in S_{\mathcal{F}}} \sup_{y \in S_{\mathbb{R}}} | \mathbb{E} \hat{f}_N^{x_{k(x)}}(y) - \mathbb{E} \hat{f}_N^x(y) |}_{T_4}. \end{aligned}$$

De même que l'étude du terme  $g_1$  et en remplaçant (H5b) par (H10), il vient

$$T = o \left( \sqrt{\frac{\psi_{S_{\mathcal{F}}}(\epsilon)}{n^{1-\gamma} \phi(h_K)}} \right), \quad \text{et} \quad T_4 = o \left( \sqrt{\frac{\psi_{S_{\mathcal{F}}}(\epsilon)}{n^{1-\gamma} \phi(h_K)}} \right), p.c \quad (1.13)$$

En ce qui concerne le terme  $T_1$ , ont utilisant l'état de Lipschitz sur le noyau H, on peut écrire

$$\begin{aligned} | \hat{f}_N^{x_{k(x)}}(y) - \hat{f}_N^{x_{k(x)}}(t_j(y)) | & \leq C \frac{1}{n_{h_H} \phi(h_K)} \sum_{i=1}^n K_i(x_{k(x)}) | H_i(y) - H_i(t_j(y)) | \\ & \leq \frac{C}{n} \sum_{i=1}^n Z_i, \end{aligned}$$

où  $Z_i = l_n K_i(x_{k(x)}) / h_H^2 \phi(h_K)$ . Encore une fois, une norme exponentielle en matière d'égalité pour les variables bornées nous permet d'écrire

$$\hat{f}_N^{x_{k(x)}}(y) - \hat{f}_N^{x_{k(x)}}(t_j(y)) = o \left( \frac{l_n}{h_H^2} \right) + o \left( \frac{l_n}{h_H^2} \sqrt{\frac{\log n}{n \phi(h_K)}} \right).$$

Maintenant, le fait que  $\lim_{n \rightarrow +\infty} n^\gamma h_H = \infty$  et  $l_n = n^{(-3/2)\gamma - 1/2}$  implique que

$$T_1 = o\left(\sqrt{\frac{\psi_{S_{\mathcal{F}}}(\epsilon)}{n^{1-\gamma}\phi(h_K)}}\right) \quad \text{et} \quad T_3 = o\left(\sqrt{\frac{\psi_{S_{\mathcal{F}}}(\epsilon)}{n^{1-\gamma}\phi(h_K)}}\right), p.c. \quad (1.14)$$

En utilisant les arguments de lemme 1.4.1, nous pouvons montrer à tout  $\eta > 0$

$$\begin{aligned} & \mathbb{P}\left(T_2 > \eta \sqrt{\frac{\psi_{S_{\mathcal{F}}}(\epsilon)}{nh_H\phi(h_K)}}\right) \\ &= \mathbb{P}\left(\max_{j \in \{1, 2, \dots, Z_n\}} \max_{K \in \{1, 2, \dots, N\epsilon(S_{\mathcal{F}})\}} |\hat{f}_N^{x_K}(t_j) - \mathbb{E}\hat{f}_N^{x_K}(t_j)| > \eta \sqrt{\frac{\psi_{S_{\mathcal{F}}}(\epsilon)}{nh_H\phi(h_K)}}\right) \\ &\leq Z_n N\epsilon(S_{\mathcal{F}}) \max_{j \in \{1, 2, \dots, Z_n\}} \max_{K \in \{1, 2, \dots, N\epsilon(S_{\mathcal{F}})\}} \mathbb{P}\left(|\hat{f}_N^{x_K}(t_j) - \mathbb{E}\hat{f}_N^{x_K}(t_j)| > \eta \sqrt{\frac{\psi_{S_{\mathcal{F}}}(\epsilon)}{nh_H\phi(h_K)}}\right). \end{aligned}$$

Soit

$$\Delta_i = \frac{1}{h_H\phi(h_K)} [K_i(x_k)H_i(t_j) - \mathbb{E}(K_i(x_k)H_i(t_j))].$$

Et ont appliqué l'inégalité exponentielle de Bernstein (voir Ferraty et vieu, (2006)[3]). Pour cela, nous avons calculé l'asymptotique comportement de  $|\Delta_i|$  et  $\mathbb{E}(\Delta_i^2)$ . Tout d'abord, il résulte du fait que les noyaux  $K$  et  $H$  ne sont liés que  $\mathbb{E}|\Delta_i| \leq C(h_H\phi(h_K))^{-1}$ . Deuxièmes, l'utilisation des mêmes arguments de lemme (3.1) nous permet d'obtenir

$$\lim_{n \rightarrow \infty} \frac{1}{h_H} \mathbb{E}[H_1^2(y)/X_1] = f^{x_1} \int_{\mathbb{R}} H^2(t) dt,$$

ce qui implique que

$$\mathbb{E}|\Delta_i|^2 \leq \frac{C}{h_H\phi(h_K)}.$$

Ce qui implique que, ainsi, nous sommes maintenant en mesure d'appliquer l'exponentielle de Bernstein et nous obtenons

$$\forall j \leq Z_n, \quad \mathbb{P}\left(|\hat{f}_N^{x_k(x)}(t_j) - \mathbb{E}\hat{f}_N^{x_k(x)}(t_j)| > \eta \sqrt{\frac{\psi_{S_{\mathcal{F}}}(\epsilon)}{nh_H\phi(h_K)}}\right) \leq \exp(-C\eta^2\psi_{S_{\mathcal{F}}}(\epsilon)).$$

Par conséquent, puisque  $Z_n = o(l_n^{-1}) = o(n^{(3/2)\eta + 1/2})$ , en choisissant  $C\eta^2 = \beta$  on a

$$\begin{aligned}
Z_n N\epsilon(S_{\mathcal{F}}) \max_{j \in \{1, 2, \dots, Z_n\}} \max_{k \in \{1, 2, \dots, N\epsilon(S_{\mathcal{F}})\}} \mathbb{P} \left( \left| \hat{f}_N^{x_k(x)}(t_j) - \mathbb{E} \hat{f}_N^{x_k(x)}(t_j) \right| > \eta \sqrt{\frac{\psi_{S_{\mathcal{F}}}(\epsilon)}{nh_H \phi(h_K)}} \right) \\
\leq C' Z_n N\epsilon(S_{\mathcal{F}})^{1-C\eta^2}.
\end{aligned}$$

En utilisant le fait que  $\lim_{n \rightarrow \infty} n^\gamma h_H = \infty$  et l'hypothèse (H7), on obtient

$$T_2 = o \left( \sqrt{\frac{\psi_{S_{\mathcal{F}}}(\epsilon)}{n^{1-\gamma} \phi(h_K)}} \right), \quad p.c$$

## Chapitre 2

# Les résultats asymptotique de la fonction de hasard conditionnelle

### 2.1 Le contexte bibliographique

Si  $X$  est une variable aléatoire associée à une durée de vie (c-à-d, une variable aléatoire à valeurs dans  $\mathbb{R}^+$ ), le taux de hasard de  $X$  (parfois appelé aussi fonction de hasard, taux de défaillance ou taux de survie) est défini au point  $x$  comme étant la probabilité instantanée que cette durée de vie se termine à l'instant  $x$ . Précisément, on a

$$h(x) = \lim_{\Delta_x \rightarrow 0} \frac{P(X \leq x + \Delta_x \mid X \geq x)}{\Delta_x}, \quad x > 0. \quad (2.1)$$

Lorsque la variable  $X$  possède une densité  $f$  par rapport à la mesure de Lebesgue il est aisé de voir que ce taux de hasard peut être écrit

$$h(x) = \frac{f(x)}{S(x)}, \quad (2.2)$$

pour tout  $x$  tel que  $F(x) < 1$ , où  $F$  désigne la fonction de répartition de  $X$  et  $S=1-F$  la fonction de survie de  $X$ .

Dans de nombreuses situations pratiques, on peut disposer d'une variable explicative  $Z$  et la question devient celle de l'estimation du taux de hazard conditionnel défini pour  $x > 0$  par

$$h^Z(x) = \lim_{\Delta_x \rightarrow 0} \frac{P(X \leq x + \Delta_x \mid X > x, Z)}{\Delta_x}, \quad (2.3)$$

qui s'écrit lui aussi naturellement à partir de la densité conditionnelle  $f^Z(\cdot)$  et de la fonction de répartition conditionnelle  $F^Z(\cdot)$  de  $X$  sachant  $Z$ , sous la forme

$$h^Z(x) = \frac{f^Z(x)}{S^Z(x)}, \quad (2.4)$$

dès que  $Z(x) < 1$ . L'étude des fonction  $h$  et  $h^Z$  est d'un intérêt évident dans de nombreux domaines scientifiques (biologie, médecine, fiabilité,.....), et de nombreux auteurs se sont intéressés à la construction d'estimateurs non-paramétriques de  $h$ . Une des techniques les plus courantes pour construire des estimateurs de  $h$  (resp de  $h^Z$ ) est basée sur le résultat 2.3 (resp le résultat 2.5) et consiste à étudier un quotient entre un estimateur de  $f$  (resp de  $f^Z$ ) et un estimateur de  $S$  (resp de  $S^Z$ ). L'article de Petit et al fait une présentation générale de ce techniques d'estimation. Les méthodes non paramétriques basées sur les idées de noyau de convolution, qui sont connues pour leurs bon comportement dans les problèmes d'estimation de densité (conditionnelle ou non), sont ainsi abondamment utilisées en estimation non-paramétrique de fonction de hasard. Un large éventail de la littérature dans ce domaine est fourni par les revues bibliographiques de Singpurwalla et Wong[24], Hassani et al[17], Izenman[18], Gefeller et Michels [16] et Pascu et Vaduva[21].

### 2.1.1 Sur la fonction de hasard conditionnel pour variable explicative fonctionnelle

Les progrès des procédés de recueil de données ont pour conséquence immédiate d'offrir la possibilité aux statisticiens de disposer de plus en plus souvent d'observations de variables fonctionnelles. Les ouvrages de Ramsay et Silverman(2005)[23] et Ferraty et vieu(2006)[3] proposent un large éventail de méthodes statistiques, paramétriques ou non paramétrique, récemment développées pour traiter divers problèmes d'estimation dans lesquels interviennent des variables aléatoires fonctionnelles (c'est à dire à valeurs dans espace de dimension infinie). Jusqu'à présent de tels développements statistiques pour variables fonctionnelles n'existent pas dans le contexte de l'estimation d'une fonction de hasard, et ce malgré le potentiel évident en matière d'applications.

L'objectif de cette section a étudié un modèle de hasard conditionnel dans lequel la variable explicative  $Z$  n'est pas nécessairement réelle ou multidimensionnelle mais seulement supposée être à valeurs dans un espace abstrait  $\mathcal{F}$  muni d'une semi-métrique  $d$ . Comme dans tout problème d'estimation non-paramétrique, la dimension de l'espace  $\mathcal{F}$  joue un rôle important dans les propriétés de concentration de la variable  $X$ . Ainsi, lorsque cette dimension n'est pas nécessairement finie. les

fonctions de probabilité de petites boules définies par

$$\phi_z(h) = P(Z \in B(z, h)) = P(Z \in \{z' \in \mathcal{F}, d(z, z') < h\}),$$

interviennent de manière directe dans le comportement asymptotique de tout estimateurs non-paramétrique fonctionnel (voir Ferraty et vieu (2006)[3])

Dorénavant,  $z$  désigne un élément fixé de l'espace fonctionnel  $\mathcal{F}$ ,  $N_z$  désigne un voisinage fixé de  $z$  et  $\mathcal{S}$  est un compact fixé de  $\mathbb{R}^+$ . Nous serons amenés à faire l'hypothèse ci-dessous concernant la fonction de concentration  $\phi_z$  :

$$(A1) \quad \forall h > 0, \phi_z(h) > 0.$$

Le modèle non-paramétrique sur la fonction  $h^Z$  à estimer sera déterminé par des conditions de régularité portant sur la loi conditionnelle de  $X$  sachant  $Z$ .

Ces conditions sont les suivantes :

$$(A2) \quad \exists A_z < \infty, \exists b_1, b_2 > 0 \quad \forall (x_1, x_2) \in \mathcal{S}^2, \forall (z_1, z_2) \in N_z^2 :$$

$$\begin{aligned} |F^{z_1}(x_1) - F^{z_2}(x_2)| &\leq A_z(d(z_1, z_2)^{b_1} + |x_1 - x_2|^{b_2}), \\ |f^{z_1}(x_1) - f^{z_2}(x_2)| &\leq A_z(d(z_1, z_2)^{b_1} + |x_1 - x_2|^{b_2}); \end{aligned}$$

$$(A3) \quad \exists \nu < \infty, \forall (x, z') \in \mathcal{S} \times N_z, f^{z'}(x) \leq \nu;$$

$$(A4) \quad \exists \beta > 0, \forall (x, z') \in \mathcal{S} \times N_z, F^{z'}(x) \leq 1 - \beta.$$

## 2.2 La construction de l'estimateur pour des données complètes

Soit  $(X_i, Z_i)_{1 \leq i \leq n}$  des variables aléatoires suivant chacune la même loi qu'un couple  $(X, Z)$  où  $X$  est à valeurs dans  $\mathbb{R}$  et  $Z$  à valeurs dans l'espace semi-métrique  $(\mathcal{F}, d(\cdot, \cdot))$ . Dans ce paragraphe, nous nous plaçons dans le cas le plus simple pour lequel toutes les variables  $X_i$  et  $Z_i$  ont été observées.

Les recherche récentes en statistique non-paramétrique pour variables fonctionnelles, telles que présentées dans Ferraty et vieu(2006)[3], font apparaître que les techniques basées sur les noyaux de convolution sont facilement transposables au cadre de variables fonctionnelles. Par ailleurs ces techniques à noyau possèdent

de bonnes propriétés dans les problèmes d'estimation de fonction de hasard pour variables de dimension finie. Pour plus de détails en se servant principalement au livre de Singpurwalla et Wong (1983)[24] qui est un des papiers en la matière et celui de Estéver pour les résultats les plus récents dans ce domaine.

Il est tout naturel d'essayer de construire un estimateur de la fonction  $h^Z$  en s'inspirant de ces idées. Pour estimer la fonction de répartition conditionnelle de la densité conditionnelle en présence de variable  $Z$  fonctionnelle, Ferraty et al (2006), ont proposé les estimateurs à noyau fonctionnels suivants :

$$\hat{F}^z(x) = \frac{\sum_{i=1}^n K(h_K^{-1}d(z, Z_i))H(h_H^{-1}(x - X_i))}{\sum_{i=1}^n K(h_K^{-1}d(z, Z_i))} \quad (2.5)$$

et

$$\hat{f}^z(x) = \frac{\sum_{i=1}^n K(h_K^{-1}d(z, Z_i))H'(h_H^{-1}(x - X_i))}{h_H \sum_{i=1}^n K(h_K^{-1}d(z, Z_i))}, \quad (2.6)$$

où  $K$  est un noyau,  $H$  une fonction de répartition et  $h_K = h_{K,n}$  (resp.  $h_H = h_{H,n}$ ) est une suite de nombre réels positifs. Le bon comportement de ces estimateurs, à la fois du point de vue asymptotique et sur le plan appliqué, est mis en évidence dans Ferraty et vieu (2006) .

L'estimateurs à noyau da la fonction da hasard conditionnelle fonctionnelle  $h^z$  peut donc se construire de la manière suivante :

$$\hat{h}^z(x) = \frac{\hat{f}^z(x)}{1 - \hat{F}^z(x)}. \quad (2.7)$$

Les hypothèses dont nous aurons ultérieurement concernant les paramètres de cet estimateurs, c'est à dire concernant  $K, H, h_H$  et  $h_K$ , sont peu restrictives. En effet, d'une part elles ne sont pas propres au problèmes d'estimation de  $h^Z$ , et d'autre part elles correspondent aux hypothèses faites habituellement dans la cadre de variables non fonctionnelles. Plus précisément, nous introduirons les condition suivantes qui garantissent le bon comportement des estimateurs  $\hat{F}^z$  et  $\hat{f}^z$  (voir Ferraty et vieu (2006)) :

**(A5)** Le noyau cummulatif  $H$  est dérivable et tel que

- i)  $\exists A < \infty, \forall (x_1, x_2) \in \mathbb{R}^2, |H'(x_1) - H'(x_2)| \leq |x_1 - x_2|$ ;
- ii)  $H'$  est de support compact  $[-1, 1]$  et  $H'(t) > 0, \forall t \in [-1, 1]$ .

(A6) Le noyau fonctionnel  $K$  vérifie les conditions

- i)  $K$  est à support compact  $(0, 1)$ ;
- ii)  $\exists A_1, A_2, \forall t \in (0, 1), 0 < A_1 < K(t) < A_2 < \infty$ .

(A7) La largeur de fenêtre  $h_K$  vérifie les conditions

$$\lim_{n \rightarrow \infty} h_K = 0$$

et

$$\lim_{n \rightarrow \infty} \frac{\log n}{nh_H \phi_x(h_K)} = 0.$$

(A8) La largeur de fenêtre  $h_H$  vérifie les condition

$$\lim_{n \rightarrow \infty} h_H = 0$$

et

$$\exists a > 0, \lim_{n \rightarrow \infty} n^a h_H = \infty.$$

Sous ces conditions très générales, nous établirons la convergence de l'estimateur à noyau  $\hat{h}^z$  de la fonction de hasard conditionnelle fonctionnelle  $h^z$  lorsque les couples de variables  $(X_i, Y_i)_{i=1, \dots, n}$  sont indépendants et ces résultats seront généralisés en s'affranchissant de la condition d'indépendance.

On présente dans ce paragraphe notre estimateur dans la présence des données incomplètes (censuré).

## 2.3 Présentation de l'estimateur dans le cas censuré

Dans la pratique, lors d'applications médicales en particulier, on peut trouver en présence de variables censurées. Ce problème est habituellement modélisé en considérant une variable positive  $C$  dite de censure, et les variables aléatoires observées ne sont pas les couples  $(X_i, Z_i)$  mais seulement les  $(T_i, \Delta_i, Z_i)$  où  $T_i = \min(X_i, C_i)$  et  $\Delta_i = \mathbb{1}_{X_i \leq C_i}$ . Dans la suite nous utiliserons les notations  $F_1^Z, f_1^Z$  pour désigner la fonction de répartition et la densité conditionnelles de  $C$  sachant  $Z$ , et nous utiliserons la notation  $S_1^Z = 1 - F_1^Z$ . De tels modèles à censure ont été abondamment étudiés dans la littérature pour des variables aléatoires réelles ou multi-dimensionnelles. et dans des cadres non-paramétriques les techniques à noyau sont particulièrement utilisées (voir Tanner et Wong (1983)[24], Padgett (1988)[25], Lecourte et Ould-Said

et Van (1988)[19] Keilegom et Veraverbeke (2001)[27], pour un échantillon nécessairement non-exhaustif de la littérature dans ce domaine).

L'objectif de ce paragraphe est d'adapter ces idées au cadre de variable explicative  $Z$  fonctionnelle, et de construire un estimateur de type noyau de la fonction de hasard conditionnelle  $h^Z$  adapté aux échantillons censurés. Si l'on introduit les notations  $L^Z = 1 - S_1^Z$  et  $\varphi^Z = f^Z S_1^Z$ , on peut reformuler l'expression 2.5 comme

$$h^Z(t) = \frac{\varphi^Z(t)}{1 - L^Z(t)}, \quad \forall t, L^Z(t) < 1. \quad (2.8)$$

On peut alors définir des estimateurs des fonction  $\varphi^Z$  et  $L^Z$  en posant

$$\hat{L}^Z(t) = \frac{\sum_{i=1}^n K(h_K^{-1}d(z, Z_i))H(h_H^{-1}(t - T_i))}{\sum_{i=1}^n K(h_K^{-1}d(z, Z_i))} \quad (2.9)$$

et

$$\hat{\varphi}^Z(t) = \hat{F}^z(x) = \frac{\sum_{i=1}^n K(h_K^{-1}d(z, Z_i))\Delta_i H'(h_H^{-1}(t - T_i))}{h_H \sum_{i=1}^n K(h_K^{-1}d(z, Z_i))}. \quad (2.10)$$

Finalement l'estimateur de la fonction de hasard est donné par

$$\tilde{h}^Z(t) = \frac{\hat{\varphi}^Z(t)}{1 - \hat{L}^Z(t)}. \quad (2.11)$$

Outre les hypothèses introduites dans la section (1.2), nous aurons besoin de conditions supplémentaires. Ces hypothèses, qui sont identiques à celles que l'on retrouve dans la littérature classique pour variables non-fonctionnelles, sont les suivantes :

(A9) conditionnellement à  $Z$ , les variables  $X$  et  $C$  sont indépendantes ;

(A10)  $\exists A_z < \infty, \exists b_1, b_2 > 0, \forall (t_1, t_2) \in \mathcal{S}^2, \forall (z_1, z_2) \in N_z^2 :$

$$\begin{aligned} |L^{z_1}(t_1) - L^{z_2}(t_2)| &\leq A_z(d(z_1, z_2)^{b_1} + |t_1 - t_2|^{b_2}) \\ |\varphi^{z_1}(t_1) - \varphi^{z_2}(t_2)| &\leq A_z(d(z_1, z_2)^{b_1} + |t_1 - t_2|^{b_2}); \end{aligned}$$

(A11)  $\exists \mu < \infty, \varphi^{z'}(t) < \mu, \forall (t, z') \in \mathbb{R}_+ \times N_z,$

(A12)  $\exists \mu > 0, L^{z'}(t) < 1 - \eta, \forall (t, z') \in \mathbb{R}_+ \times N_z$ .

Sous ces conditions très générales, nous établirons les vitesses de convergence de l'estimateurs à noyau  $\tilde{h}^z$  de la fonction de hasard conditionnelle fonctionnelle  $h^z$  lorsque les couples de variables  $(X_i, Z_i)_{i=1, \dots, n}$  sont indépendants. Dans le paragraphe (1.5.2) résultats seront généralisés en s'affranchissant de la condition d'indépendance.

## 2.4 Résultats asymptotiques

### 2.4.1 La convergence presque complète

L'objectif de ce paragraphe est d'établir la convergence presque complète de l'estimateurs à noyau  $\hat{h}^Z$  de la fonction de hasard conditionnelle fonctionnelle  $h^Z$  lorsque l'échantillon observé n'est pas censuré, Les résultats présentés sont accompagnés par la donnée des vitesses de convergence. Comme nous allons le voir, ces résultat seront relativement faciles à obtenir en ce sens qu'ils vont découler quasi-directement de résultats déjà connus en estimation non-paramétrique de densité ou fonction de répartition conditionnelle fonctionnelles. Les preuves seront succinctes et renverront abondamment à la littérature existante, mais elle seront présentées de sorte à préparer le terrain pour l'obtention des résultats plus délicats dans le cadre d'échantillons censurés (voir section 4).

### 2.4.2 Cas d'échantillon i.i.d

Nous commençons par l'étude d'échantillons statistiques vérifiant une hypothèses classique d'indépendance, à savoir,

(A13a) Les couples  $(X_i, Z_i)$  sont i.i.d.

**Théorème 2.1.** *Sous les hypothèses (A1)-(A8) et (A13a) on a*

$$\sup_{x \in \mathcal{S}_{\mathbb{R}}} |\hat{h}^z(x) - h^z(x)| = o(h_K^{b_1}) + o(h_H^{b_2}) + o\left(\sqrt{\frac{\log n}{nh_H \phi_z(h_K)}}\right), \quad p.c. \quad (2.12)$$

**Preuve** La preuve est basée sur la décomposition

$$\hat{h}^z(x) - h^z(x) = \frac{1}{(1 - \hat{F}^z(x))(1 - F^z(x))}.$$

$$\{(\hat{f}^z(x) - f^z(x)) + f^z(x)(\hat{F}^z(x) - F^z(x)) - F^z(x)(\hat{f}^z(x) - f^z(x))\}.$$

Valable pour tout  $x \in \mathcal{S}_{\mathbb{R}}$ , ce qui, pour une constante  $C < \infty$ , amène

$$\sup_{x \in \mathcal{S}_{\mathbb{R}}} |\hat{h}^z(x) - h^z(x)| \leq C \frac{\left\{ \sup_{x \in \mathcal{S}_{\mathbb{R}}} | \hat{f}^z(x) - f^z(x) | + | \hat{F}^z(x) - F^z(x) | \right\}}{\inf_{x \in \mathcal{S}_{\mathbb{R}}} | 1 - \hat{F}^z(x) |}. \quad (2.13)$$

Ainsi de manière classique (voir par exemple la condition (A6ii) de Ferraty et Vieu (2006)[3]) le résultat annoncé découle directement des propriétés

$$\sup_{x \in \mathcal{S}_{\mathbb{R}}} | F^z(x) - \hat{F}^z(x) | = o(h_K^{b_1}) + o(h_H^{b_2}) + o\left(\sqrt{\frac{\log n}{n\phi_z(h_K)}}\right), \quad p.c. \quad (2.14)$$

et

$$\sup_{x \in \mathcal{S}_{\mathbb{R}}} | f^z(x) - \hat{f}^z(x) | = o(h_K^{b_1}) + o(h_H^{b_2}) + o\left(\sqrt{\frac{\log n}{nh_H\phi_z(h_K)}}\right), \quad p.c. \quad (2.15)$$

Les résultats 2.14 et 2.15 sont des résultats connus (voir Ferraty et Vieu (2006)).

### 2.4.3 Cas d'échantillon dépendant

Dans de nombreux domaines d'application, comme en particulier en économétrie (voir par exemple les problèmes traités par Engle et Russel (1988)[13] ou Nielson et Linton (1995)[20]) ou en sismologie (voir par exemple les données étudiées dans Estévez-Pérez et al (2002)[15]), l'hypothèse d'indépendance entre les variables observées n'est pas réaliste. Pour pouvoir étendre les résultats obtenus ci-dessus, il est nécessaire d'introduire une structure probabiliste qui permette de contrôler la dépendance entre les variables constituant l'échantillon statistique. Une manière naturel de faire consiste à introduire une condition d'indépendance asymptotique. Nous ferons ici l'hypothèse de mélange

(A13b) La suite  $(X_i, Z_i)_{i \in N}$  est  $\alpha$ -mélangeate et ses coefficients de mélange

$\alpha(n)$  sont tels que  $\exists a, c \in \mathbb{R}_+^* : \forall n \in N, \alpha(n) \leq cn^{-a}$ . Afin de contrôler les lois jointes, nous aurons aussi besoin d'introduire les condition ci-dessous.

(A13c) La densité jointe de  $(Y_i, Y_j)$  sachant  $(Z_i, Z_j)$  existe et est bornée, et

$$\exists \epsilon_1 \in ]0, 1], 0 < \sup_{i \neq j} P((Z_i, Z_j) \in B(z, h) \times B(z, h)) = o(\phi_z(h))^{1+\epsilon_1}.$$

L'hypothèse

$$(A13d) \exists \epsilon_2 \in ]0, 1[, a > \frac{1+\epsilon_1}{\epsilon_2 \epsilon_1} \text{ et } h_H \phi_z(h_K) = o(n^{-\epsilon_2})$$

permet de maîtriser les liens existant entre les paramètres de lissage  $h_H, h_K$  et les coefficients de mélange  $\alpha(n)$ . Il faut noter que ces hypothèses sont classiques dans les problèmes d'estimation non-paramétrique avec variables dépendantes, fonctionnelles ou non (voir Ferraty et Vieu (2006)) on a le résultat suivant.

**Théorème 2.2.** *Sous les hypothèses (A1)-(A8) et (A13b) – (A13d) on a*

$$\sup_{x \in \mathcal{S}_{\mathbb{R}}} |\hat{h}^z(x) - h^z(x)| = o(h_K^{b_1}) + o(h_H^{b_2}) + o\left(\sqrt{\frac{\log n}{nh_H \psi_z(h_K)}}\right), \quad p.c. \quad (2.16)$$

**Preuve** Les propriétés 2.14 et 2.15 restent vraies sous les hypothèses de la mélange puisque ce sont des cas particuliers (voir Ferraty et Vieu (2006)). Le résultat 2.16 est donc obtenu directement à partir de la décomposition 2.13 et des résultat 2.14 et 2.15.

## 2.5 Résultats asymptotique de l'estimateur pour des données incomplètes

L'objectif maintenant est de reprendre ces propriétés asymptotiques dans le cadre plus général d'un échantillon censuré tel que décrit dans le paragraphe (1.3). Nous allons commencer dans le paragraphe (1.5.1) par traiter cas d'échantillon i.i.d, puis nous étendrons nos résultats à des données issues d'un processus mélangeant. De toute évidence, l'obtention de ces résultats nécessitera des développements techniques plus sophistiqués que ceux présentés dans le cadre non censuré.

### 2.5.1 Le cas indépendant

Nous commençons par l'étude d'échantillons statistique vérifiant une hypothèse classique d'indépendance, à savoir,

$$(A14a) \text{ Les triplets } (X_i, C_i, Z_i) \text{ sont i.i.d.}$$

**Théorème 2.3.** *Sous les hypothèses (A1)-(A11) et (A14a), on a*

$$\sup_{t \in \mathcal{S}_{\mathbb{R}}} |\hat{h}^z(t) - h^z(t)| = o(h_K^{b_1}) + o(h_H^{b_2}) + o\left(\sqrt{\frac{\log n}{nh_H \phi_z(h_K)}}\right), \quad p.c. \quad (2.17)$$

**Preuve** Le résultat est basé sur la décomposition ci-dessous, dans laquelle  $C$  est une constante réelle strictement positive :

$$\sup_{t \in \mathcal{S}_{\mathbb{R}}} |\hat{h}^z(x) - h^z(x)| \leq C \frac{\left\{ \sup_{x \in \mathcal{S}_{\mathbb{R}}} |\hat{\varphi}^z(x) - \varphi^z(x)| + |\hat{L}^z(x) - L^z(x)| \right\}}{\inf_{t \in \mathcal{S}_{\mathbb{R}}} |1 - \hat{L}^z(x)|}, \quad (2.18)$$

qui s'obtient à partir de 2.5 et 2.9 en procédant comme pour établir 2.13. Puisque  $\hat{L}^z$  n'est autre que l'estimateur à noyau de la fonction de répartition conditionnelle de  $T$  sachant  $Z$ , on obtient directement (voir Ferraty et Vieu (2006)) que

$$\sup_{t \in \mathcal{S}_{\mathbb{R}}} |\hat{L}^z(t) - L^z(t)| = o(h_K^{b_1}) + o(h_H^{b_2}) + o\left(\sqrt{\frac{\log n}{n\phi_z(h_K)}}\right), \quad p.c. \quad (2.19)$$

Les propriétés de l'estimateur  $\hat{\varphi}^Z$  sont données dans le Lemme (2.3.1) ci-dessous. Finalement, le résultat recherché est obtenu directement à partir de 2.18, 2.19 et 2.20

## Lemme 2.3.1

Sous les condition du théorème (3), on a

$$\sup_{x \in \mathcal{S}_{\mathbb{R}}} |\hat{\varphi}^z(t) - \varphi^z(t)| = o(h_K^{b_1}) + o(h_H^{b_2}) + o\left(\sqrt{\frac{\log n}{nh_H \phi_z(h_K)}}\right), \quad p.c. \quad (2.20)$$

## 2.5.2 Le cas dépendant

Ces résultats s'étendent aux cas d'échantillons censurés non nécessairement indépendants en introduisant des conditions similaires à celles présentées dans le paragraphe(1.4.3). Ces conditions sont les suivantes :

**(A14b)** la suite  $(X_i, C_i, Z_i)_{i \in \mathbb{N}}$  est  $\alpha$ -mélangeante et de coefficients de mélange  $\alpha(n)$  tels que  $\exists a, c \in \mathbb{R}_+^* : n \in \mathbb{N} \alpha(n) \leq cn^{-a}$ ;

(A14c) la densité jointe de  $(Y_i, Y_j)$  sachant  $(Z_i, Z_j)$  existe et est bornée, et

$$\exists \epsilon_1 \in ]0, 1[, 0 < \sup_{i \neq j} \mathbb{P}((Z_i, Z_j) \in B(z, h) \times B(z, h)) = o(\phi_z(h))^{1+\epsilon_1}.$$

(A14d)  $\exists \epsilon_2 \in ]0, 1[, a > \frac{1+\epsilon_1}{\epsilon_2 \epsilon_1}$  et  $h_H \phi_z(h_K) = o(n^{-\epsilon_2})$ .

**Théorème 2.4.** *Sous les hypothèses (A1)-(A12) et (A14b) – (A14d) on a*

$$\sup_{t \in \mathcal{S}_{\mathbb{R}}} |\hat{h}^z(t) - h^z(t)| = o(h_K^{b_1}) + o(h_H^{b_2}) + o\left(\sqrt{\frac{\log n}{nh_H \phi_z(h_K)}}\right), \quad p.c. \quad (2.21)$$

**Preuve** Puisque le résultat 2.19 reste valable sous condition d' $\alpha$ -mélange (voir Ferraty et Vieu), le résultat du Théorème (3) s'obtient directement à partir de la décomposition 2.18 et du Lemme (4.1).

## Lemme 2.4.1

Sous les conditions du théorème (2.4), on a

$$\sup_{t \in \mathcal{S}_{\mathbb{R}}} |\hat{\varphi}^z(t) - \varphi^z(t)| = o(h_K^{b_1}) + o(h_H^{b_2}) + o\left(\sqrt{\frac{\log n}{nh_H \phi_z(h_K)}}\right), \quad p.c. \quad (2.22)$$

## 2.6 Preuves des lemmes

Dans ce qui suit  $C$  et  $c$  désigneront des constantes réelles strictement positives génériques. Par ailleurs, on introduit les notations suivantes :

$$K_i(z) = K(h_K^{-1}d(z, Z_i)), \quad H_i(z) = H'(h_K^{-1}(t, T_i)),$$

$$\hat{\varphi}_N^z(t) = \frac{1}{nh_H \mathbb{E}[K_1(z)]} \sum_{i=1}^n K_i(z) H_i(t) \Delta_i, \quad \hat{\varphi}_D(z) = \frac{1}{n \mathbb{E}[K_1(z)]} \sum_{i=1}^n K_i(z),$$

$$V_i = \frac{1}{\mathbb{E}[K_1(z)]} K_i(z), \quad W_i = \frac{1}{h_H \mathbb{E}[K_1(z)]} K_i(z) H_i(t) \Delta_i,$$

$$s_n^2 = \sum_{i_1=1}^n \sum_{i_2=1}^n \text{cov}(V_{i_1}, V_{i_2}), \quad S_n^2 = \sum_{i_1=1}^n \sum_{i_2=1}^n \text{cov}(W_{i_1}, W_{i_2}).$$

**Preuve de lemme 2.3.1** En utilisant la décomposition suivant :

$$\hat{\varphi}^z(t) - \varphi^z(t) = \frac{(\hat{\varphi}_N^z(t) - \varphi_N^z(t))\varphi_D(z) - (\hat{\varphi}_D(z) - \varphi_N(z))\varphi_N^z(t)}{\hat{\varphi}_D(z)\varphi_D(z)}, \quad (2.23)$$

et en vertu de la proposition (A6ii) de Ferraty et Vieu (2006), le résultat du Lemme (2.3.1) découlera directement des trois propriétés suivantes :

$$|\hat{\varphi}_D(z) - 1| = o\left(\sqrt{\frac{\log n}{nh_H\phi(z)(h_K)}}\right), \quad p.c. \quad (2.24)$$

$$\sup_{t \in \mathcal{S}} |\mathbb{E}\hat{\varphi}_N^z(t) - \varphi^z(t)| = o(h_K^{b_1}) + o(h_H^{b_2}) \quad (2.25)$$

et

$$\frac{1}{\hat{\varphi}_D} \sup_{t \in \mathcal{S}} |\hat{\varphi}_N^z(t) - \mathbb{E}\hat{\varphi}_N^z(t)| = o\left(\sqrt{\frac{\log n}{nh_H\phi(z)(h_K)}}\right), \quad p.c. \quad (2.26)$$

– Preuve de 2.24. Il suffit de remarque que l'on peut écrire

$$\hat{\varphi}_D(z) = \frac{1}{n} \sum_{i=1}^n V_i,$$

avec

$$|V_i| = o\left(\frac{1}{\phi_z(h)}\right), \quad (2.27)$$

et

$$\mathbb{E}(V_i^2) = o\left(\frac{1}{\phi_z(h)}\right). \quad (2.28)$$

En appliquant une inégalité exponentielle pour variables bornées et en tenant compte des résultats 2.27 et 2.29, on arrive a

$$\mathbb{P} \left[ \left| \hat{\varphi}_D(z) - \mathbb{E}\hat{\varphi}_D(z) \right| > \epsilon \sqrt{\frac{\log n}{n\phi_{(z)}(h_K)}} \right] = o(n^{-C\epsilon^2}).$$

Il suffit maintenant de choisir  $\epsilon$  suffisamment grand pour obtenir le résultat 2.24.

– Preuve de 2.25. Pour tout  $x \in \mathcal{S}$  on a

$$\mathbb{E}\hat{\varphi}_N^Z(t) = \frac{1}{h_H \mathbb{E}K_1(z)} \mathbb{E}(K_i(z)H_1\Delta_1) \quad (2.29)$$

$$\begin{aligned} &= \frac{1}{h_H \mathbb{E}K_1(z)} \mathbb{E}(K_1(z)\mathbb{E}(H_1(t)\mathbf{1}_{X_1 \leq C_1} \setminus Z_1)) \\ &= \frac{1}{h_H \mathbb{E}K_1(z)} \mathbb{E}(K_1(z)\mathbb{E}(H_1(t)S_1^{Z_1} \setminus Z_1)). \end{aligned}$$

La dernière égalité découlant de l'indépendance conditionnelle entre  $C_1$  et  $X_1$  introduite dans (A9). Par ailleurs nous avons

$$\mathbb{E}(H_1(t)S_1^z(X_1) \setminus Z_1) = \int H' \left( \frac{t-u}{h_H} \right) S_1^{Z_1}(u) f^{Z_1}(u) du \quad (2.30)$$

$$h_H \int H'(v)\varphi^{Z_1}(t-vh_H)dv = h_H(\varphi^z + o(h_H^{b_2} + h_H^{b_1})).$$

La dernière égalité découlant de la propriété de Lipschitz de la fonction  $\varphi^z$  introduite dans (A10) et du fait que  $H'$  est une densité de probabilité. Il faut noter, toujours à cause de la condition (A10), que les  $o(\cdot)$  intervenant dans le résultat 2.30 sont uniformes pour  $t \in \mathcal{S}$ . Ainsi, le résultat 2.25 est une conséquence immédiate de ?? et 2.30

– Preuve de 2.26. La compacité de l'ensemble  $\mathcal{S}$  permet de la recouvrir par un intervalles disjoints de sorte que

$$\mathcal{S} \subset \bigsqcup_{k=1}^{u_n} [\tau_k - l_n, \tau_k + l_n[$$

où  $\tau_1, \dots, \tau_{u_n}$  sont des points de  $\mathcal{S}$  et où  $l_n$  et  $u_n$  sont choisi tels que

$$\exists C > 0, \exists c > 0, l_n = Cu_n^{-1} = n^{-c}. \quad (2.31)$$

Pour chaque  $t \in \mathcal{S}$  on note  $\tau_t$  l'unique  $\tau_k$  tel que  $t \in [\tau_k - l_n, \tau_k + l_n[$ . Finalement, 2.26 découlera directement des résultats suivants :

$$\frac{1}{\hat{\varphi}_D(z)} \sup_{t \in \mathcal{S}} |\hat{\varphi}_D^z(t) - \hat{\varphi}_D^z(\tau_x)| = o\left(\sqrt{\frac{\log n}{nh_H \phi(z)(h_K)}}\right). \quad (2.32)$$

$$\frac{1}{\hat{\varphi}_D(z)} \sup_{t \in \mathcal{S}} |\mathbb{E}\hat{\varphi}_D^z(t) - \mathbb{E}\hat{\varphi}_D^z(\tau_x)| = o\left(\sqrt{\frac{\log n}{nh_H \phi(z)(h_K)}}\right), \quad p.c., \quad (2.33)$$

et

$$\frac{1}{\hat{\varphi}_D(z)} \sup_{t \in \mathcal{S}} |\hat{\varphi}_D^z(\tau_x) - \mathbb{E}\hat{\varphi}_D^z(\tau_x)| = o\left(\sqrt{\frac{\log n}{nh_H \phi(z)(h_K)}}\right). \quad (2.34)$$

- Preuve de 2.32. A cause de la condition (A5i), il existe une constante finie  $C$  telle que pour tout  $t \in \mathcal{S}_{\mathbb{R}}$  on a

$$\begin{aligned} |\hat{\varphi}_D^z(t) - \hat{\varphi}_D^z(\tau_x)| &= \frac{1}{nh_H \mathbb{E}K_1(z)} \sum_{i=1}^n \Delta_i K_i(z) (H_i(t) - H_i(\tau_x)) \\ &\leq \frac{C}{nh_H \mathbb{E}K_1(z)} \sum_{i=1}^n K_i(z) \frac{|x - \tau_x|}{h_H} \leq C \hat{\varphi}_D(z) l_n h_H^{-2}. \end{aligned} \quad (2.35)$$

En utilisant 2.31 et en choisissant  $c$  assez grand, on obtient directement 2.32.

- Preuve de 2.33. Ce résultat s'obtient directement à partir de 2.24 et 2.35 en utilisant la proposition (A6ii) de Ferraty et Vieu (2006)
- Preuve de 2.34. L'obtention de 2.34 est basée sur l'utilisation d'une inégalité exponentielle. Plus précisément, il suffit de remarquer que l'on peut écrire

$$\hat{\varphi}_D^z(t) = \frac{1}{n} \sum_{i=1}^n W_i,$$

avec

$$|W_i| = o\left(\frac{1}{h_H \phi_z(h)}\right), \quad (2.36)$$

et

$$\begin{aligned}
\mathbb{E}W_i^2 &= \frac{1}{h_H^2(\mathbb{E}K_1(x))^2} \mathbb{E}K_i^2(z)H_i^2(t)\Delta_i^2 & (2.37) \\
&\leq C \frac{1}{h_H^2(\mathbb{E}K_1(z))^2} \mathbb{E}(K_i^2(z)\mathbb{E}(H_i^2(t)\setminus Z_i)) \\
&\leq C \frac{1}{h_H\phi_z(h)^2} \mathbb{E} \left( K_i^2(z) \int \frac{1}{h_H} H' \left( \frac{x-u}{h_H} \right)^2 f^{Z_i}(u) du \right) \\
&= o \left( \frac{1}{h_H\phi_z(h)} \right).
\end{aligned}$$

En utilisant la condition 2.31 on arrive à

$$\begin{aligned}
&\mathbb{P} \left[ \sup_{x \in \mathcal{S}} |\hat{\varphi}_D^z(\tau_t) - \mathbb{E}\hat{\varphi}_D^z(\tau_t)| > \epsilon \sqrt{\frac{\log n}{nh_H\phi_z(h_K)}} \right] & (2.38) \\
&\leq n^\epsilon \max_{j=1, \dots, u_n} \mathbb{P} \left[ |\hat{\varphi}_D^z(\tau_j) - \mathbb{E}\hat{\varphi}_D^z(\tau_j)| > \epsilon \sqrt{\frac{\log n}{nh_H\phi_z(h_K)}} \right].
\end{aligned}$$

Par ailleurs, en appliquant une inégalité exponentielle pour variables bornées et en tenant compte des résultats 2.36 et 2.37, on arrive à

$$\mathbb{P} \left[ |\hat{\varphi}_D^z(\tau_j) - \mathbb{E}\hat{\varphi}_D^z(\tau_j)| > \epsilon \sqrt{\frac{\log n}{nh_H\phi_z(h_K)}} \right] = o(n^{-C\epsilon^2}). \quad (2.39)$$

Il suffit maintenant de choisir  $\epsilon$  suffisamment grand pour obtenir directement le résultat recherché à partir de 2.38 et de 2.39.

- Les résultats 2.32, 2.33 et 2.34 suffisent pour conclure la preuve du résultat 2.26.

Finalement, le lemme (3.1) découle directement des résultats 2.24, 2.25 et 2.26 et de la décomposition 2.23.

**Preuve de lemme 2.4.1** La preuve suit le même cheminement que la précédente, mais avec des difficultés supplémentaires liées à la non indépendance des variables constituant l'échantillon. Comme précédemment, au vu de la décomposition 2.23, il suffira de prouver que les résultats 2.24, 2.25 et 2.26 restent valables.

- Preuve de 2.24. La principale étape de la démonstration consiste à obtenir une évaluation de la somme des covariances  $s_n^2$ . Pour  $i_1 \neq i_2$ , d'après la condition (A14<sub>c</sub>) on a

$$| \mathbb{E}V_{i_1}V_{i_2} | \leq \frac{C}{(\mathbb{E}K_1(z))^2} \phi_z(h_K)^{1+\epsilon_1} = o(\phi_z(h_K)^{-1+\epsilon_1}),$$

et, par suite,

$$| cov(V_{i_1}V_{i_2}) | \leq \frac{C}{(\mathbb{E}K_1(z))^2} \phi_z(h_K)^{1+\epsilon_1} = o(\max\{\phi_z(h_K)^{1+\epsilon_1}, 1\}). \quad (2.40)$$

D'un autre côté, en utilisant une inégalité de covariace pour processus mélangeant, on peut écrire

$$cov(V_{i_1}, V_{i_2}) \leq C\phi_z(h_K)^{-2}\alpha(|i_1 - i_2|). \quad (2.41)$$

Finalement, pour toute suite  $v_n$  positive on peut écrire

$$s_n^2 = \sum_{i=1}^n var(V_i) + \sum_{0 < |i_1 - i_2| \leq v_n} cov(V_{i_1}, V_{i_2}) + \sum_{|i_1 - i_2| > v_n} cov(V_{i_1}, V_{i_2}), \quad (2.42)$$

et en utilisant respectivement 2.29, 2.40 et 2.41 pour traiter chacun des trois termes de 2.42 on arrive à

$$s_n^2 = o\left(\frac{n}{\phi_z(h_K)}\right) + o(nv_n \max\{\phi_z(h_K)^{-1+\epsilon_1}, 1\}) \\ + o\left(\phi_z(h_K)^{-2} \sum_{|i_1 - i_2| > v_n} \alpha(|i_1 - i_2|)\right).$$

Il suffit maintenant de choisir  $v_n = \phi_z(h_K)^{-\epsilon_1}$  pour arriver à

$$s_n^2 = o\left(\frac{n}{\phi_z(h_K)}\right) + o(\phi_z(h_K)^{-2}n(n - v_n)\alpha(v_n)) \quad (2.43)$$

$$o\left(\frac{n}{\phi_z(h_K)}\right) + o(\phi_z(h_K)^{-2}n^2\phi_z(h_K)^{a\epsilon_1}) = o\left(\frac{n}{\phi_z(h_K)}\right),$$

le dernière égalité découlant directement de la condition (A14<sub>d</sub>).

En utilisant les bornes données par 2.27 et 2.29, et en appliquant une inégalité exponentielle pour variables bornées mélangeantes, on arrive à

$$\hat{\phi}_D(z) - \mathbb{E}\hat{\phi}_D(z) = o(n^{-1}\sqrt{\log ns_n^2}), \quad p.c. \quad (2.44)$$

Le résultat 2.24 découle directement de 2.43 et 2.44.

- Preuve de 2.25. Pour traiter ce terme déterministe, les calculs effectués lors de la preuve du lemme (3.1) n'utilisaient pas l'indépendance des variables. Le résultat 2.25 rest donc variable sous condition de mélange.
- Preuve de 2.26. En reprenant la démarche et les notations introduites lors de la preuve (3.1), il suffit de vérifier que les résultat 2.32, 2.33 et 2.34 restent vrais.
- Preuve de 2.32 et 2.33. Les calculs effectués de la preuve du lemme (3.1) n'utilisaient pas l'indépendance des variables. Ainsi, le résultat 2.35 reste vrai sous-condition de dépendance. Par conséquent 2.32 et 2.33 sont obtenus directement à partir de 2.24 et 2.35
- Preuve de (1.34). La principale étape de la démonstration consiste à obtenir une évaluation de la somme des covariances  $S_n^2$ . En reprenant la même démarche que celle utilisée pour prouver (1.24), pour  $i_1 \neq i_2$  on a

$$|\mathbb{E}W_{i_1}W_{i_2}| \leq \frac{C}{h_H^2(\mathbb{E}K_1(z))^2}\phi_z(h_K)^{1+\epsilon_1} = o(h_H^{-2}\phi_z(h_K)^{-1+\epsilon_1})$$

et, par suite,

$$\begin{aligned} |cov(W_{i_1}, W_{i_2})| &\leq \frac{C}{h_H^{-2}(\mathbb{E}K_1(z))^2} \phi_z(h_K)^{1+\varepsilon_1} \\ &= o(h_H^{-2}(\max\{\phi_z(h_K)^{-1+\varepsilon_1}, 1\})). \end{aligned} \quad (2.45)$$

D'un autre côté, en utilisant une inégalité de covariance pour processus mélangeant on a

$$cov(W_{i_1}, W_{i_2}) \leq Ch_H^{-2} \phi_z(h_K)^{-2} \alpha(|i_1 - i_2|). \quad (2.46)$$

Finalement, pour toute suite  $v_n$  positive on peut écrire

$$s_n^2 = \sum_{i=1}^n var(W_i) + \sum_{0 < |i_1 - i_2| \leq v_n} cov(W_{i_1}, W_{i_2}) + \sum_{|i_1 - i_2| > v_n} cov(W_{i_1}, W_{i_2}),$$

et en utilisant respectivement 2.29, 2.45 et 2.46 on arrive à

$$\begin{aligned} s_n^2 &= o\left(\frac{n}{h_H \phi_z(h_K)}\right) + o(nv_n h_H^{-2} \max\{\phi_z(h_K)^{-1+\varepsilon_1}, 1\}) \\ &\quad + o\left(h_H^{-2} \phi_z(h_K)^{-2} \sum_{|i_1 - i_2| > v_n} \alpha(|i_1 - i_2|)\right). \end{aligned}$$

Il suffit maintenant de choisir  $v_n = \phi_z(h_K)^{-\varepsilon_1}$  et d'utiliser la condition (A14<sub>d</sub>) pour arriver à

$$S_n^2 = o\left(\frac{n}{h_H \phi_z(h_K)}\right). \quad (2.47)$$

En utilisant les bornes données par (1.36) et (1.37), et en appliquant une inégalité exponentielle pour variables bornées mélangeantes, on arrive à

$$\hat{\varphi}_D^z(\tau_j) - \mathbb{E}\hat{\varphi}_D^z(\tau_j) = o(n^{-1} \sqrt{\log n S_n^2}), \quad p.c. \quad (2.48)$$

Le résultat 2.34 découle directement de 2.38, 2.47 et 2.48.

- Ainsi, il suffi d'utiliser 2.32, 2.33 et 2.34 pour terminer la preuve de 2.26.

Finalement, le lemme (2.4.1) découle directement des résultat 2.24, 2.25 et 2.26 et la décomposition 2.23.

# Conclusion

Le but de mon travail est la présentation d'une étude théorique qui porte sur plusieurs modèles non-paramétrique. Plus précisément ; on est arrivèr à confirmer que l'estimateur de non- paramétrique de la fonction de hazard conditionnelle. Est consistant ces vitesses de convergence sont similaire pour les deux contexte. Le premier est celui des données complètes et le deuxième est pour les données incomplètes. les vitesses de convergence restent similaires dans le cas des variables indépendantes et identiquement distribuées (iid) est le cas du mélange fort ( $\alpha$ -mélange).

# Bibliographie

- [1] Deheuvels, P., Mason, D. (2004). General asymptotic confidence bands based on kernel type function estimators. *Statistical inference stochastic processes*, **7**, 225-277.
- [2] Ferraty, F., Goia, A., Vieu, P. (2002) *Function nonparametric model for time series*, A Fractal approach for dimension reduction test, **11**, 317-344.
- [3] Ferraty, F., Laksaci, A., Vieu, P. (2006). Estimating some characteristics of the conditional distribution in nonparametric functional model. *statistics inference for stochastic processes*, **9**, 47-76.
- [4] Ferraty, F., Vieu, P. *Nonparametric functional data analysis theory and practice*. Springer Series in statistics. Springer, New York, 2006.
- [5] Kolmogorov, A. N., Tikhomirov, V.M. (1959).  $\epsilon$ -entropy and  $\epsilon$ -capacity. *Uspekhi Mat. Nauk* **14** 3-86. *Engl transl. Amer. Math. Soc. Transl. Ser.*, **2**, 277-364 (1961)
- [6] Kuelbs, J., Li, W. (1993). Metric entropy and the small ball problem for gaussian measures. *J. Funct. Anal.*, **116** 133-157.
- [7] Madani, F. et al (2012). *convergence uniforme et presque complète de l'estimateur linéaire local de la densité conditionnelle pour des données fonctionnelles*
- [8] Rosenblatt, M. (1969). Conditional probability density and regression estimators. *In multivariate analysis*, In, Ed. P.R. Krishnaiah. Academic press, New York and London.
- [9] Rosenblatt, M. (1956) Remarks on some non-parametric estimates of a density function, *Annals of mathematical statistics*, **27**, 832-837.
- [10] Roussas, G. G. (1968). On some properties of nonparametric estimates of probability density functions. *Bull-Soc math. Greece (N.S)* **9**, 29-43.
- [11] Samanta, M. (1989). Nonparametric estimation of conditional quantiles, *Stat, Probab. Lett.*, **7**, 407-412.
- [12] Stone, G.J. (1977) : Consistent nonparametric regression, *Annal of statistic*, **5** 595-645.

- [13] Theodoros, N.,Yannis G.Y. (1997). Rates of convergence of estimate, Kolmogorov entropy and the dimensionality reduction principale in regression. *The Amals of statistics*, **25**, No.6, 2493-2511.
- [14] Youndjé, E.,(1996). Propriétés de convergence de l'estimateur à noyau de la densité conditionnelle. *Rev, Roumaine math. Pures appl*, **41**, 531-566.
- [15] R.F. Engle and J.Russel, *Autoregressive conditional duration : A new model irregularly spaced transaction data*. *Econometrica* **66** (1988), 1127-1162.
- [16] G. Estévez, *On convergence rates for quadratic errors in kernel hazard estimation*. *Statist .Probab. Lett.***57** (2002), 231-241.
- [17] G. Estévez-Pérez, A. Quintela-del-Rio and P. Vieu, *convergence rate for cross-validatory bandwidth in kernel hazard estimation from dependent samples*. *J. Statist. Plann. Inference* **104** (2002), 1-30.
- [18] O. Gefeller and P. Michels, *A review on smoothing methods for the estimation of the hazard rate based on kernel functions*. In : Y. Dodge and J.Whittaker (Eds.), *computational statistics*, pp. 459-464. Physica-Verlag,1992.
- [19] S.Hassani,P. Sarda et P. Vieu, *Approche non-paramétrique en théorie de la fiabilité : revue bibliographique*. *Rev.Statist. Appl.* **35**(1986), 4, 27-41
- [20] A. Izenman, *developments in nonparametric density estimation*. *J. Amer. Statist. Assoc* **86** (1991), 205-224.
- [21] J-P. Lecourte and E. Ould-Said, *Hazard rate estimation for strong mixing and censored processes*. *J.Nonparametr.Statist.* **5**(1995),83-89.
- [22] J.P. Nielson and O. Linton,*Kernel estimation in a nonparametric marker dependent hazard model*. *Ann. Statist.***23** (1995), 1735-1748.
- [23] M. Pascu and I. Vaduva, *nonparametric estimation of the hazard rate a survey*. *Rev Roumaine Math. Pures Appl.***48** (2003), 173-191.
- [24] P.N. Patil, M.T.Wells and J.S.Marón, *Some heuristics of kernel based estimators of ratio functions*. *J. Nonparametre. Statist.* **4**(1994), 203-209.
- [25] J. Ramsay and B. Silverman, *Functional Dta Analysis*, 2nd Ed. Springer Series in statistics. Springer, New York, 2005.
- [26] N.Singpurwalla and M.Y. Wong, *Estimation of the failure rate - a survey of non-parametric models. part I : Non-Bayesian methods*. *Comm. Statist. Theory Methods* **12** (1983), 559-588.
- [27] W.J.Padgett, *Nonparametric estimation of density and hazard rate functions when samples are censoder*. In P.R. Krishnaiah and C.R. Rao(Eds.), *Handbook of Statistics*, **7**.pp. 313-331. Elsevies Science Publishers, 1988.
- [28] M.Tanner and W.H.Wong, *The estimation of the hazard function from randomly censored data by the kernel methods*. *Ann .Statist.***11** (1983), 989-993 .

- 
- [29] I. Van Keilegom and N. Veraverbeke, *Hazard rate estimation in nonparametric regression with censored data*. Ann.Inst.Statist. Math.**53** (2001), 730-745.
- [30] Nadaraya, E. A.(1964) : On estimatings regression, *Theory of prabability and it application* , **9**,141-142.
- [31] Watson, G.S. (1964) : Smooth regression analysis, *Sankaya Series, A*, **26**, 359-372.