

Estimation séquentielle de quantiles conditionnels dans les codes stochastiques

T. Labopin-Richard F. Gamboa A. Garivier

Institut de mathématiques de Toulouse

29 Septembre 2015

Plan

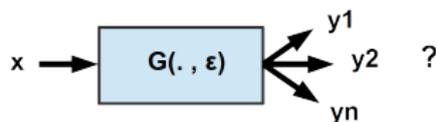
- 1 Position du problème
 - Code stochastique et estimation de quantile
 - Premières idées
 - Vers une autre stratégie
- 2 Algorithme stochastique et théorie des k -plus proches voisins
 - Présentation de l'algorithme
 - Résultats
- 3 Simulations numériques
 - Dimension 1
 - Dimension supérieure
 - Supports non compacts

- 1 Position du problème
 - Code stochastique et estimation de quantile
 - Premières idées
 - Vers une autre stratégie
- 2 Algorithmes stochastiques et théorie des k -plus proches voisins
 - Présentation de l'algorithme
 - Résultats
- 3 Simulations numériques
 - Dimension 1
 - Dimension supérieure
 - Supports non compacts

Qu'est-ce qu'un code stochastique ?

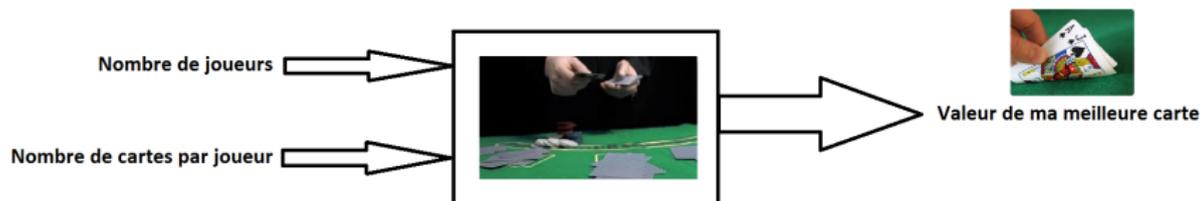


Numerical code : $Y=G(X)$
 $G(x)$ is a real number

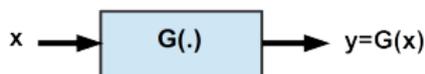


Stochastic code : $Y=G(X, \epsilon)$
 $G(x, \epsilon)$ is a random variable

Un exemple simple



Qu'est-ce qu'un code stochastique ?



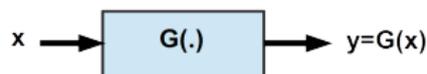
Numerical code : $Y=G(X)$
 $G(x)$ is a real number



Stochastic code : $Y=G(X, \epsilon)$
 $G(x, \epsilon)$ is a random variable

Notations : $X \in \mathbb{R}^d$ vecteur des entrées. α fixé le niveau du quantile à estimer.

Qu'est-ce qu'un code stochastique ?



Numerical code : $Y=G(X)$
 $G(x)$ is a real number



Stochastic code : $Y=G(X, \epsilon)$
 $G(x, \epsilon)$ is a random variable

Notations : $X \in \mathbb{R}^d$ vecteur des entrées. α fixé le niveau du quantile à estimer.

But : Estimer le **quantile** de la loi $\mathcal{L}(G(X, \epsilon)|X = x)$ en utilisant le moins possible d'appels au code.

- 1 Position du problème
 - Code stochastique et estimation de quantile
 - Premières idées
 - Vers une autre stratégie
- 2 Algorithme stochastique et théorie des k -plus proches voisins
 - Présentation de l'algorithme
 - Résultats
- 3 Simulations numériques
 - Dimension 1
 - Dimension supérieure
 - Supports non compacts

Pour estimer un quantile d'une loi Z , on peut...

- 1) Construire un échantillon (Z_1, \dots, Z_n) de la loi Z .
- 2) Utiliser un estimateur du quantile, par exemple :
 - a) Le quantile empirique $Z_{(\lfloor n\alpha \rfloor + 1)}$.
 - b) L'algorithme stochastique suivant :

$$\begin{cases} \theta_0 \in \mathbb{R} \\ \theta_{n+1} = \theta_n - \frac{1}{n^\gamma} (\mathbf{1}_{Z_{n+1} \leq \theta_n} - \alpha). \end{cases}$$

Application à notre problème

On veut estimer le quantile de la loi $\mathcal{L}(G(X, \epsilon) | X = x)$, on pourrait donc :

- 1) Fournir plusieurs fois l'entrée x au code stochastique, pour construire un échantillon de notre loi.
- 2) Utiliser un des deux estimateurs précédents.

Problème

On veut estimer le quantile conditionnel pour **plusieurs entrées x à la fois**.

Chaque appel au code coûte **cher**, on ne peut pas se permettre de construire un échantillon de la loi conditionnelle pour chacun de ces x .

- 1 Position du problème
 - Code stochastique et estimation de quantile
 - Premières idées
 - Vers une autre stratégie
- 2 Algorithmes stochastiques et théorie des k -plus proches voisins
 - Présentation de l'algorithme
 - Résultats
- 3 Simulations numériques
 - Dimension 1
 - Dimension supérieure
 - Supports non compacts

Stratégie adoptée

- 1) On fixe un budget N .
- 2) On tire un échantillon d'entrées (X_1, \dots, X_N) .
- 3) On observe les réponses correspondantes (Y_1, \dots, Y_N) .
- 4) On applique un algorithme qui permettra, pour tout x et n'utilisant que le passé, de calculer un estimateur du quantile conditionnel.

- 1 Position du problème
 - Code stochastique et estimation de quantile
 - Premières idées
 - Vers une autre stratégie
- 2 Algorithme stochastique et théorie des k -plus proches voisins
 - Présentation de l'algorithme
 - Résultats
- 3 Simulations numériques
 - Dimension 1
 - Dimension supérieure
 - Supports non compacts

Un algorithme solution

Notre algorithme

$$\begin{cases} \theta_0(x) \in \mathbb{R} \\ \theta_{n+1}(x) = \theta_n(x) - \frac{1}{n^\gamma} \left(\mathbf{1}_{Y_{n+1} \leq \theta_n(x)} - \alpha \right) \mathbf{1}_{X_{n+1} \in kNN_n(x)} \end{cases}$$

où $k_n = \lfloor n^\beta \rfloor$.

Un algorithme solution

Notre algorithme

$$\begin{cases} \theta_0(x) \in \mathbb{R} \\ \theta_{n+1}(x) = \theta_n(x) - \frac{1}{n^\gamma} \left(\mathbf{1}_{Y_{n+1} \leq \theta_n(x)} - \alpha \right) \mathbf{1}_{X_{n+1} \in kNN_n(x)} \end{cases}$$

où $k_n = \lfloor n^\beta \rfloor$.

- Quels sont les **paramètres optimaux** γ et β ?
- Sous quelles hypothèses l'algorithme est-il **convergent** ?
- Peut-on montrer des **résultats non-asymptotiques** ?

- 1 Position du problème
 - Code stochastique et estimation de quantile
 - Premières idées
 - Vers une autre stratégie
- 2 Algorithme stochastique et théorie des k -plus proches voisins
 - Présentation de l'algorithme
 - Résultats
- 3 Simulations numériques
 - Dimension 1
 - Dimension supérieure
 - Supports non compacts

Hypothèse de continuité

On introduit les notations suivantes :

- 1) $B_n(x)$ est le plus petit segment contenant les k plus proches voisins de x .
- 2) $F_{Y^{B_n(x)}}$ est la fonction de répartition de la loi $\mathcal{L}(Y|X \in B_n(x))$.
- 3) F_{Y^x} est la fonction de répartition de la loi de $\mathcal{L}(Y|X = x)$.

Hypothèse de continuité

On introduit les notations suivantes :

- 1) $B_n(x)$ est le plus petit segment contenant les k plus proches voisins de x .
- 2) $F_{Y^{B_n(x)}}$ est la fonction de répartition de la loi $\mathcal{L}(Y|X \in B_n(x))$.
- 3) F_{Y^x} est la fonction de répartition de la loi de $\mathcal{L}(Y|X = x)$.

Hypothèse A1 Il existe une constante de Lipschitz M telle que $\forall n, \forall x \in \text{Supp}(X), \forall t \in \mathbb{R}$:

$$|F_{Y^{B_n(x)}}(t) - F_{Y^x}(t)| \leq M \max_{a \in B_n(x)} \|x - a\| = M \|X - x\|_{(k_n, n)}$$

Hypothèses techniques

Hypothèse A2 La loi des entrées est à densité et cette fonction de densité est minorée sur son support par une constante $C_{inputs} > 0$.

\Rightarrow Permet de gérer des quantités comme $\mathbb{E}(\|X - x\|_{(k_n, n)})$ ou $\mathbb{P}(X \in kNN_n(x))$.

Hypothèses techniques

Hypothèse A2 La loi des entrées est à densité et cette fonction de densité est minorée sur son support par une constante $C_{inputs} > 0$.

\Rightarrow Permet de gérer des quantités comme $\mathbb{E}(\|X - x\|_{(k_n, n)})$ ou $\mathbb{P}(X \in kNN_n(x))$.

Hypothèse A3 La fonction code g est à valeurs dans le compact $[a, b]$.

$\Rightarrow \forall x, \theta_n(x)$ est bornée uniformément en ω . On appelle R la borne uniforme de $(\theta_n - \theta^*)^2$.

Hypothèses techniques

Hypothèse A2 La loi des entrées est à densité et cette fonction de densité est minorée sur son support par une constante $C_{inputs} > 0$.

\Rightarrow Permet de gérer des quantités comme $\mathbb{E}(\|X - x\|_{(k_n, n)})$ ou $\mathbb{P}(X \in kNN_n(x))$.

Hypothèse A3 La fonction code g est à valeurs dans le compact $[a, b]$.

$\Rightarrow \forall x, \theta_n(x)$ est bornée uniformément en ω . On appelle R la borne uniforme de $(\theta_n - \theta^*)^2$.

Hypothèse A4 Pour tout x , la loi $g(X, \epsilon) | X = x$ est à densité minorée par une constante $D(x) > 0$.

\Rightarrow Il existe une constante $D_{code}(x)$ telle que :

$$\forall \theta_n(x), [F_{Y^x}(\theta_n(x)) - F_{Y^x}(\theta^*(x))] [\theta_n(x) - \theta^*(x)] \geq D_{code}(x) [\theta_n(x) - \theta^*(x)]^2.$$

Résultats théoriques

Théorème : convergence presque-sûre

Soit x une entrée fixée. Sous les hypothèses **A1** and **A2**,
l'algorithme en x est convergent presque sûrement si et seulement
si $\frac{1}{2} < \gamma < \beta < 1$.

Esquisse de preuve

- 1) On décompose H en un terme de martingale et un reste, en posant :

$$h_n(\theta_n) = \mathbb{E}(H(\theta_n, X_{n+1}, Y_{n+1}) | \mathcal{F}_n) \text{ and } \xi_{n+1} = H(\theta_n, X_{n+1}, Y_{n+1}) - h_n(\theta_n).$$

On a

$$T_n = \theta_n(x) + \sum_{j=1}^n \gamma_j h_{j-1}(\theta_{j-1}(x))$$

martingale bornée dans L^2 donc qui converge presque-sûrement.

- 2) On montre la convergence presque-sûre de $(\theta_n(x))_n$.
- $(\theta_n(x))$ ne diverge pas vers $+\infty$ ou $-\infty$.
 - $(\theta_n(x))$ converge p.s vers une limite finie.
- 3) La limite est $\theta^*(x)$ le quantile conditionnel que nous voulons estimer.

Théorème : vitesse de convergence

Soit x une entrée fixée. Sous les hypothèses **A1**, **A2**, **A3** et **A4**, pour tout $0 < \gamma < 1$, $0 < \beta < 1$ and $1 > \epsilon > 1 - \beta$, et pour $n \geq 2^{\frac{1}{\epsilon - (1 - \beta)}} := N_0$,

$$\mathbb{E} \left[(\theta_n(x) - \theta^*(x))^2 \right] \leq R \exp \left(-\frac{3n^{1-\epsilon}}{8} \right) + a_0(x) \exp \left(-2D_{code}(x) \sum_{k=1}^n \frac{1}{k^{\gamma+\epsilon}} \right) + \sum_{k=1}^n \exp \left(-2D_{code}(x) \sum_{i=k}^n \frac{1}{i^{\gamma+\epsilon}} \right) \beta_k$$

avec

$$\beta_n = R \exp \left(-\frac{3n^{1-\epsilon}}{8} \right) + 2\sqrt{RMD}(d) \gamma_{n+1} \left(\frac{k_n}{n+1} \right)^{\frac{1}{d}+1} + \gamma_{n+1}^2 \frac{k_n}{n+1},$$

$$D(d) = \sqrt[d]{2} \left(1 + \frac{8}{3d} + \frac{1}{\sqrt[d]{C_{input} H(d)}} \right) \text{ et } H(d) = \frac{\pi^{\frac{5}{2}}}{\Gamma(\frac{d}{2}+1)}.$$

Théorème : paramètres optimaux

Sous les mêmes hypothèses, le risque quadratique décroît plus rapidement lorsque les paramètres sont $\gamma = \frac{1}{1+d}$ and $\beta = \gamma + \eta$ où $\eta > 0$ est le plus petit possible. Avec ces paramètres, nous obtenons, pour $n \geq \max(N_0, N_1)$

$$\mathbb{E} \left[(\theta_n(x) - \theta^*(x))^2 \right] \leq \frac{C_1}{n^{\frac{1}{1+d} - \eta'}}$$

où les constantes sont connues explicitement.

Esquisse de preuve

- L'idée de la preuve est d'établir une inégalité du genre

$$a_{n+1}(x) \leq a_n(x)(1 - \alpha_n) + \beta_n$$

- On commence donc pas développer le carré de $a_{n+1}(x)$:

$$\begin{aligned} (\theta_{n+1}(x) - \theta^*(x))^2 &= (\theta_n(x) - \theta^*(x))^2 + \gamma_{n+1}^2 \left[(1 - 2\alpha) \mathbf{1}_{Y_{n+1} \leq \theta_n(x)} + \alpha^2 \right] \mathbf{1}_{X_{n+1} \in kNN_n(x)} \\ &\quad - 2\gamma_{n+1}(\theta_n(x) - \theta^*(x)) \left(\mathbf{1}_{Y_{n+1} \leq \theta_n(x)} - \alpha \right) \mathbf{1}_{X_{n+1} \in kNN_n(x)} \end{aligned}$$

- On prend l'espérance conditionnelle et on utilise la formule de Bayes

$$\begin{aligned} \mathbb{E}_n \left((\theta_{n+1}(x) - \theta^*(x))^2 \right) &\leq \mathbb{E}_n \left((\theta_n(x) - \theta^*(x))^2 \right) + \gamma_{n+1}^2 P_n \\ &\quad - 2\gamma_{n+1} (\theta_n(x) - \theta^*(x)) P_n \left[F_{Y^{B_n(x)}}(\theta_n(x)) - F_{Y^x}(\theta^*(x)) \right] \end{aligned}$$

Esquisse de preuve

- $F_{Y^{B_n(x)}}(\theta_n(x)) - F_{Y^x}(\theta_n(x))$, erreur **type variance**.

Par **A1**,

$$|F_{Y^{B_n(x)}}(\theta_n(x)) - F_{Y^x}(\theta_n(x))| \leq M \sup\{\|y - x\|, y \in B_n(x)\} = M\|X - x\|_{(k_n, n)}$$

et par **A3**, $|\theta_n(x) - \theta^*(x)| \leq \sqrt{R}$ donc

$$\begin{aligned} & -2\gamma_{n+1}(\theta_n(x) - \theta^*(x))P_n \left[F_{Y^{B_n(x)}}(\theta_n(x)) - F_{Y^x}(\theta_n(x)) \right] \\ & \leq 2\gamma_{n+1}\sqrt{R}MP_n\|X - x\|_{(k_n, n)} \end{aligned}$$

- $F_{Y^x}(\theta_n(x)) - F_{Y^x}(\theta^*)$, erreur **type biais**.

Par **A4** nous avons

$$(\theta_n - \theta^*) [F_{Y^x}(\theta_n(x)) - F_{Y^x}(\theta^*(x))] \geq D_{code}(x) [\theta_n(x) - \theta^*(x)]^2.$$

donc

$$\begin{aligned} & -2\gamma_{n+1}(\theta_n(x) - \theta^*(x))P_n [F_{Y^x}(\theta^*(x)) - F_{Y^x}(\theta^*(x))] \\ & \leq -2\gamma_{n+1}D_{code}(x)(\theta_n(x) - \theta^*(x))^2P_n \end{aligned}$$

Esquisse de preuve

- Finalement,

$$\mathbb{E}_n \left(\theta_{n+1}(x) - \theta^*(x) \right)^2 \leq (\theta_n(x) - \theta^*(x))^2 - 2\gamma_{n+1} D_{\text{code}}(x) (\theta_n(x) - \theta^*(x))^2 P_n \\ + \gamma_{n+1}^2 P_n + 2\gamma_{n+1} M \sqrt{R} \|X - x\|_{(k_n, n)} P_n.$$

- On prend l'espérance

$$a_{n+1}(x) \leq a_n(x) - 2\gamma_{n+1} D_{\text{code}}(x) \mathbb{E} \left[(\theta_n(x) - \theta^*(x))^2 P_n \right] \\ + \gamma_{n+1}^2 \mathbb{E}(P_n) + 2\gamma_{n+1} M \sqrt{R} \mathbb{E}(\|X - x\|_{(k_n, n)} P_n).$$

Esquisse de preuve

- $\mathbb{E}(P_n) = \frac{k_n}{n+1}$ car

$$P_n = \mathbb{P}(\|X-x\| \leq \|X-x\|_{(k_n,n)}) = F_{\|X-x\|}(\|X-x\|_{(k_n,n)}) \sim \beta(k_n, n-k_n+1)$$

- $\mathbb{E}(\|X-x\|_{(k_n,n)} P_n) \leq D(d) \left(\frac{k_n}{n+1}\right)^{1+\frac{1}{d}}$ car

- 1) $\mathbb{E}(\|X-x\|_{(k_n,n)} P_n) = \frac{k_n}{n+1} \mathbb{E}(\|X-x\|_{(k_n+1,n+1)})$.

- 2) Inégalités type Bernstein dans

$$\mathbb{E}(\|X-x\|_{(k_n+1,n+1)}) \leq \int_0^A \mathbb{P}(\mathcal{B}(n+1, q_u) < k_n+1) du$$

Esquisse de preuve

- $\mathbb{E}(P_n(\theta_n(x) - \theta^*(x))^2) = ?$

Solution : On va utiliser une borne sur cette espérance. Pour cela, on doit considérer $b_n(x) = \mathbb{E}((\theta_n(x) - \theta^*(x))^2 \mathbf{1}_{P_n > \epsilon_n})$ avec $\epsilon_n = \frac{1}{n^\epsilon}$.

On peut faire les mêmes raisonnements sur cette quantité pour trouver :

$$b_{n+1}(x) \leq b_n(x)(1 - \alpha_n) + \beta_n$$

Pour se ramener au même type d'inégalité sur $a_n(x)$, on gère le terme $\overline{b_n(x)} := \mathbb{E}((\theta_n(x) - \theta^*(x))^2 \mathbf{1}_{P_n \leq \epsilon_n})$ avec des inégalités de concentration.

- 1 Position du problème
 - Code stochastique et estimation de quantile
 - Premières idées
 - Vers une autre stratégie
- 2 Algorithme stochastique et théorie des k -plus proches voisins
 - Présentation de l'algorithme
 - Résultats
- 3 Simulations numériques
 - Dimension 1
 - Dimension supérieure
 - Supports non compacts

Modèle en dimension 1-Convergence presque-sûre

Nous avons testé deux modèles pour $X \sim \mathcal{U}([-1, 1])$,
 $\epsilon \sim \mathcal{U}([-0.5, 0.5])$ et $x = 0$:

$$g(X, \epsilon) = X^2 + \epsilon \text{ et } g(X, \epsilon) = |X| + \epsilon$$

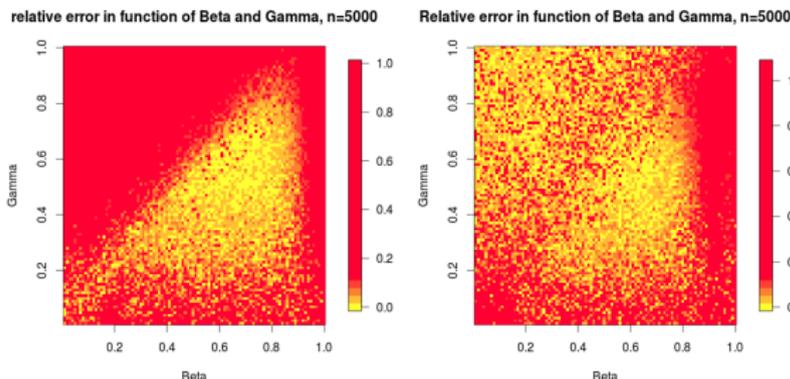


FIGURE – Convergence presque-sûre en fonction de β et γ .

Etude du risque quadratique

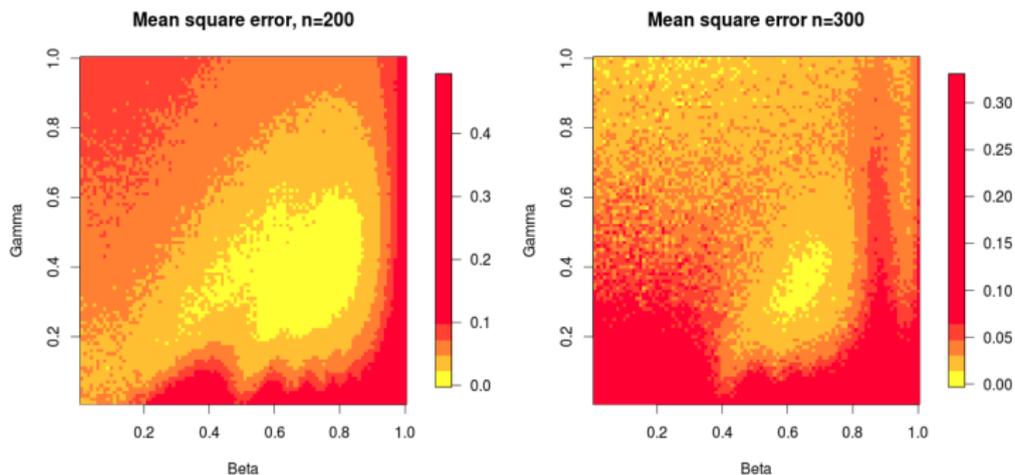


FIGURE – Convergence du risque quadratique en fonction de β et γ .

- 1 Position du problème
 - Code stochastique et estimation de quantile
 - Premières idées
 - Vers une autre stratégie
- 2 Algorithme stochastique et théorie des k -plus proches voisins
 - Présentation de l'algorithme
 - Résultats
- 3 Simulations numériques
 - Dimension 1
 - Dimension supérieure
 - Supports non compacts

Dimensions 2 et 3

Nous avons testé les modèles $g(X, \epsilon) = \|X\|^2 + \epsilon$ for $X \sim \mathcal{U}([-1, 1]^d)$, $\epsilon \sim \mathcal{U}([-0.5, 0.5])$ et $x = 0_{\mathbb{R}^d}$.

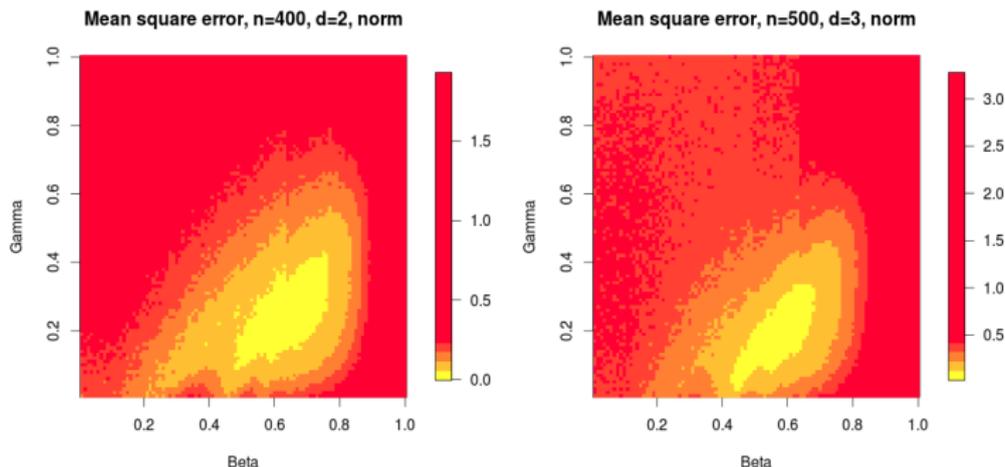


FIGURE – Convergence du risque quadratique en fonction de β and γ .

- 1 Position du problème
 - Code stochastique et estimation de quantile
 - Premières idées
 - Vers une autre stratégie
- 2 Algorithme stochastique et théorie des k -plus proches voisins
 - Présentation de l'algorithme
 - Résultats
- 3 Simulations numériques
 - Dimension 1
 - Dimension supérieure
 - Supports non compacts

Lorsque les supports ne sont pas compacts

Pour le modèle $g(X, \epsilon) = X^2 + \epsilon$ avec $X \sim \mathcal{E}(1)$ et $\epsilon \sim \mathcal{N}(0, 1)$, nous avons :

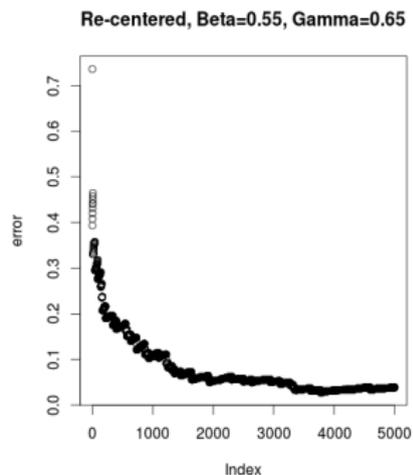
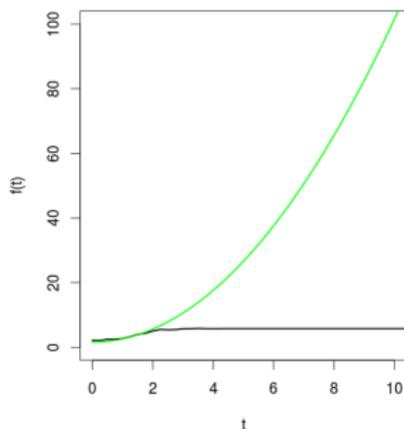


FIGURE – Vers des supports non-compacts

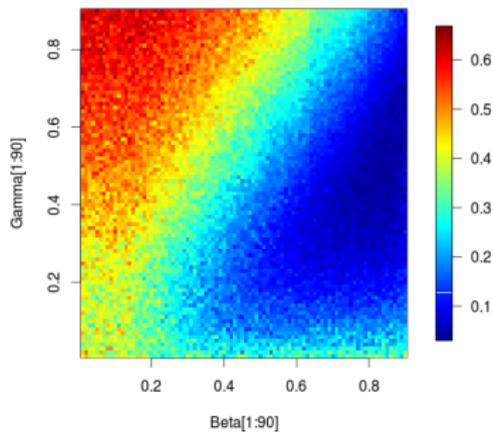


FIGURE – Vers des supports non-compacts

Conclusion et perspectives

Conclusion :

- Nous avons présenté un algorithme pour estimer le quantile conditionnel de la sortie d'un code stochastique.
- Nous avons mis en avant les paramètres optimaux de cet algorithme, pour qu'il ait la meilleure vitesse de convergence.
- Les simulations numériques montrent que notre algorithme est un outil puissant pour répondre au problème.

Perspectives :

- Que se passe-t-il en sortant des hypothèses de support compact ?
- Trouver une manière intelligente de choisir l'échantillon de départ.
- Appliquer cet algorithme à des vrais jeux de données.

Merci pour votre attention.