

Apprentissage statistique à l'ère du *Big Data* :
stabilité et efficacité d'approximations de certains
algorithmes

Florian Maire

Lundi 8 janvier 2018

Programme de cette présentation

Quelques informations sur mon parcours

Statistique computationnelle : modélisation et apprentissage

Apprentissage statistique en présence d'un grand nombre de données : stabilité et efficacité d'approximations de certains algorithmes.

Quelques Illustrations

Plan

Quelques informations sur mon parcours

Statistique computationnelle : modélisation et apprentissage

Apprentissage statistique en présence d'un grand nombre de données : stabilité et efficacité d'approximations de certains algorithmes.

Quelques Illustrations

Quelques dates

- ▶ 2005–2007, Classes prépa, Lycée Lavoisier, Paris
- ▶ 2007–2010, École d'ingénieur, Telecom Sudparis, Evry



- ▶ 2011–2014, Doctorat, Université Paris VI, Telecom Sudparis et ONERA



- ▶ 2014–2017, Post-doctorat, University College Dublin, Irlande



**THESE DE DOCTORAT TELECOM SUDPARIS et
UNIVERSITE PIERRE ET MARIE CURIE**

Spécialité : Probabilités et Statistiques

**Ecole doctorale : Informatique, Télécommunications et
Electronique de Paris**

Présentée par

Florian MAIRE

**Pour obtenir le grade de
DOCTEUR DE TELECOM SUDPARIS**

**DETECTION ET CLASSIFICATION DE CIBLES
MULTISPECTRALES DANS L'INFRAROUGE**

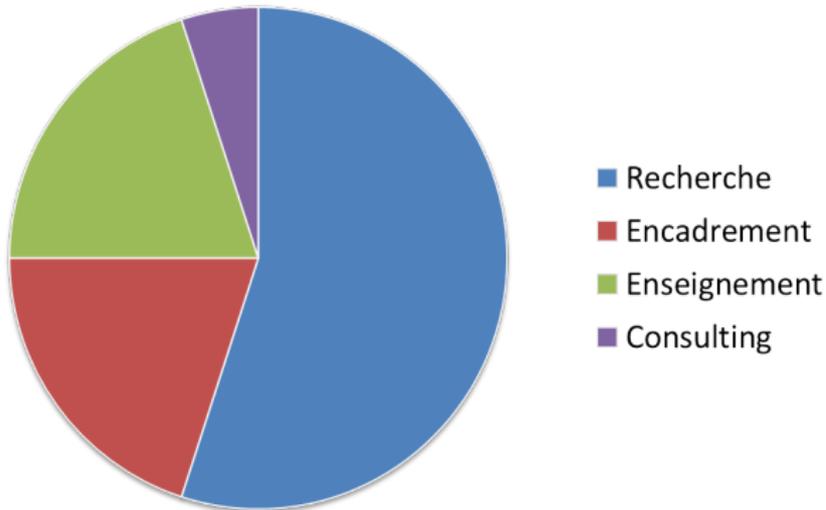
dirigée par Randal DOUC, Professeur à Telecom SudParis,
co-dirigée par Eric MOULINES, Professeur à Telecom ParisTech,
encadrée par Sidonie LEFEBVRE, Ingénieur de Recherche à l'ONERA.

soutenue le : 14 Février 2014

devant le jury composé de :

M ^{me} Stéphanie ALLASSONNIÈRE	Ecole Polytechnique	examinateur
M. Jacques BLANC-TALON	DGA	examinateur
M. Randal DOUC	Telecom SudParis	directeur
M ^{me} Sidonie LEFEBVRE	ONERA	encadrant
M. Jean-Michel MARIN	Université de Montpellier 2	rapporteur
M. Eric MOULINES	Telecom ParisTech	co-directeur
M. Christian ROBERT	Université Paris-Dauphine	examinateur
M. Olivier WINTENBERGER	Université Paris 6	examinateur

Post-doctorat



- ▶ Recherche : Apprentissage en statistique Bayésienne (groupe de Prof. Nial Friel)
- ▶ Encadrement : PhD de Lampros Bourannis (avec N. Friel), 2 thèses de Masters et 3 étudiants de Masters
- ▶ Enseignement : Probability Theory, Time Series, Monte Carlo methods

Plan

Quelques informations sur mon parcours

Statistique computationnelle : modélisation et apprentissage

Apprentissage statistique en présence d'un grand nombre de données : stabilité et efficacité d'approximations de certains algorithmes.

Quelques Illustrations

Notations

Les **données** $\{Y_n, n \in \mathbb{N}\}$ sont des observations d'un phénomène aléatoires \mathcal{Y} d'intérêt

$$\mathcal{Y} \rightsquigarrow Y_1, Y_2, \dots$$

Exemples : signal, image, graphe

- ▶ les données sont généralement dans un espace euclidien de dimension d

$$Y_1 \in \mathcal{Y} \subseteq \mathbb{R}^d.$$

- ▶ Un **modèle** est une distribution de probabilité f sur l'espace mesurable $(\mathcal{Y}, \mathcal{Y})$
- ▶ $f \in \mathcal{F}$ où \mathcal{F} est une famille de distributions de proba. sur $(\mathcal{Y}, \mathcal{Y})$

Apprentissage : trouver un "bon" modèle f^* appartenant à la famille \mathcal{F}

ayant observé $Y = Y_1, Y_2, \dots, Y_N$

$$\Pr(Y \in A) \approx f^*(A) \quad \forall A \in \mathcal{Y}$$

Statistique paramétrique

Hypothèse : \mathcal{F} est une famille de distributions paramétrisée par un vecteur θ

$$\theta \in \Theta \subseteq \mathbb{R}^p \quad (p < \infty)$$

$$\Rightarrow \forall f \in \mathcal{F}, \exists \theta \in \Theta, f \equiv f(\theta)$$

\Rightarrow Passage à un problème en dimension fini

Apprentissage : trouver un "bon" vecteur $\theta^* \in \Theta$ de sorte à ce qu'ayant observé

$$Y = Y_1, Y_2, \dots, Y_N$$

$$\Rightarrow \Pr(Y \in A) \approx f(A | \theta^*), \quad A \in \mathcal{Y}$$

Exemple 1 : Regression logistique

Application : Détecter la présence d'une maladie chez un patient

- ▶ Les données sont des réponses booléennes $Y_1 \in \{0, 1\}$
patient 1 est malade ou sain
- ▶ Variables explicatives (covariates) $X_1 = (X_{1,1}, \dots, X_{1,r})$
patient 1 a des données auxiliaires : age, sexe, indice de santé,...

Le modèle s'écrit

$$f(Y_1 | X_1, \theta) = \left\{ \frac{1}{1 + \exp(-\theta^T X_1)} \right\}^{Y_1} \left\{ 1 - \frac{1}{1 + \exp(-\theta^T X_1)} \right\}^{1 - Y_1} .$$

Apprentissage : consiste à estimer le paramètre $\theta \in \Theta$
sachant $\{(Y_1, X_1), \dots, (Y_n, X_n)\}$

Exemple 2 : Modèle à templates déformables

Application : Classifier un chiffre manuscrit

- ▶ l'image d'un chiffre \mathcal{Y}_n est modélisée par une collection de fonctions **déterministes** (les **templates**) $\mathcal{T}^{(0)}, \dots, \mathcal{T}^{(9)}$:

$$\mathcal{T}^{(i)} : \mathbb{R}^2 \rightarrow \mathbb{R}$$

- ▶ ces templates sont observés à travers un processus aléatoire
 - (i) de déformation du plan $D_n : \mathbb{R}^2 \rightarrow \mathbb{R}^2$,
 - (ii) et un sous bruit additif $\mathcal{W}_n : \mathbb{R}^2 \rightarrow \mathbb{R}$
- ▶ Modèle:

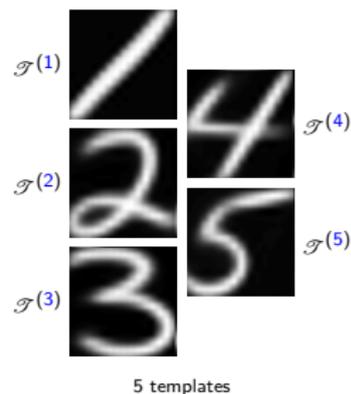
$$\forall u \in \mathbb{R}^2, \quad \mathcal{Y}_n(u) = \mathcal{T}^{(i)} \circ D_n(u) + \mathcal{W}_n(u).$$

- ▶ Les données sont des fonctions $\{\mathcal{Y}_n : \mathbb{R}^2 \rightarrow \mathbb{R}, n \leq N\}$ discrétisées :

$$\{\mathcal{Y}_n, n \leq N\} \xrightarrow[\text{sur une grille de pixels}]{\text{discretisation}} \{Y_n, n \leq N\}$$



Exemple 2 : Modèle à templates déformables



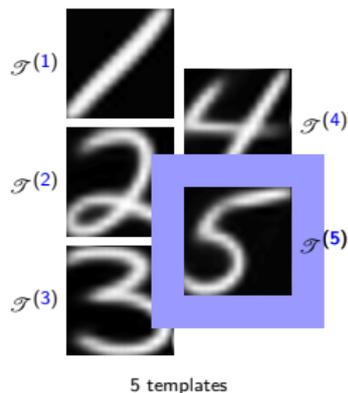
En paramétrisant

- ▶ la famille de templates \mathcal{T} par $\theta \in \Theta$
- ▶ le champ de déformation D_n par $\beta_n \in \mathbb{B}$

et en discrétisant \mathcal{Y}_n sur une grille, le modèle peut se réécrire comme :

$$Y_n = \Phi_{\beta_n} \theta_{i_n} + \zeta_n, \quad \zeta_n \sim \mathcal{N}(0, \Sigma).$$

Exemple 2 : Modèle à templates déformables



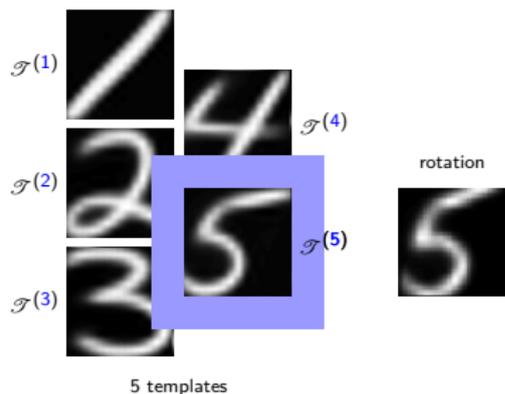
En paramétrisant

- ▶ la famille de templates \mathcal{T} par $\theta \in \Theta$
- ▶ le champ de déformation D_n par $\beta_n \in \mathbb{B}$

et en discrétisant \mathcal{Y}_n sur une grille, le modèle peut se réécrire comme :

$$Y_n = \Phi_{\beta_n} \theta_{i_n} + \zeta_n, \quad \zeta_n \sim \mathcal{N}(0, \Sigma).$$

Exemple 2 : Modèle à templates déformables



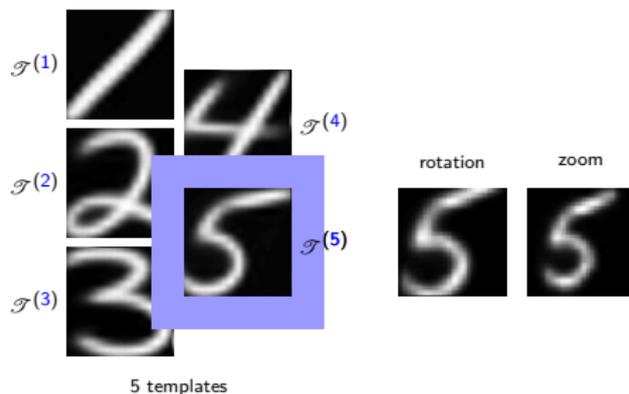
En paramétrisant

- ▶ la famille de templates \mathcal{T} par $\theta \in \Theta$
- ▶ le champ de déformation D_n par $\beta_n \in \mathbb{B}$

et en discrétisant \mathcal{Y}_n sur une grille, le modèle peut se réécrire comme :

$$Y_n = \Phi_{\beta_n} \theta_{i_n} + \zeta_n, \quad \zeta_n \sim \mathcal{N}(0, \Sigma).$$

Exemple 2 : Modèle à templates déformables



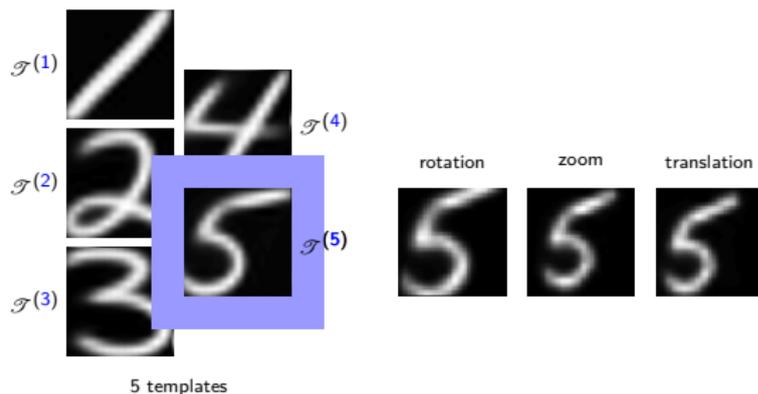
En paramétrisant

- ▶ la famille de templates \mathcal{T} par $\theta \in \Theta$
- ▶ le champ de déformation D_n par $\beta_n \in \mathbb{B}$

et en discrétisant \mathcal{Y}_n sur une grille, le modèle peut se réécrire comme :

$$Y_n = \Phi_{\beta_n} \theta_{i_n} + \zeta_n, \quad \zeta_n \sim \mathcal{N}(0, \Sigma).$$

Exemple 2 : Modèle à templates déformables



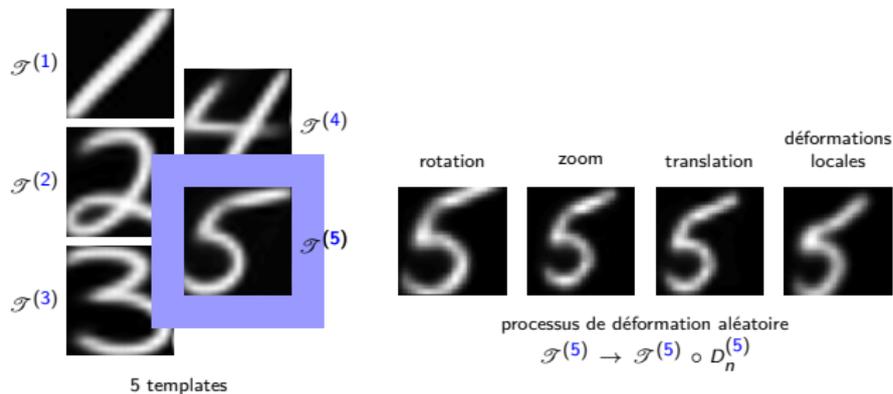
En paramétrisant

- ▶ la famille de templates \mathcal{T} par $\theta \in \Theta$
- ▶ le champ de déformation D_n par $\beta_n \in \mathbb{B}$

et en discrétisant \mathcal{Y}_n sur une grille, le modèle peut se réécrire comme :

$$Y_n = \Phi_{\beta_n} \theta_{i_n} + \zeta_n, \quad \zeta_n \sim \mathcal{N}(0, \Sigma).$$

Exemple 2 : Modèle à templates déformables



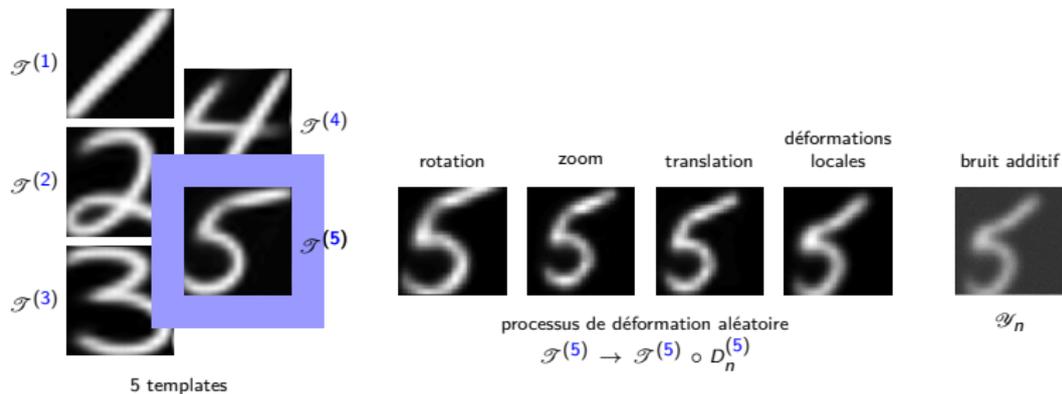
En paramétrisant

- ▶ la famille de templates \mathcal{T} par $\theta \in \Theta$
- ▶ le champ de déformation D_n par $\beta_n \in \mathbb{B}$

et en discrétisant \mathcal{Y}_n sur une grille, le modèle peut se réécrire comme :

$$Y_n = \Phi_{\beta_n} \theta_{i_n} + \zeta_n, \quad \zeta_n \sim \mathcal{N}(0, \Sigma).$$

Exemple 2 : Modèle à templates déformables



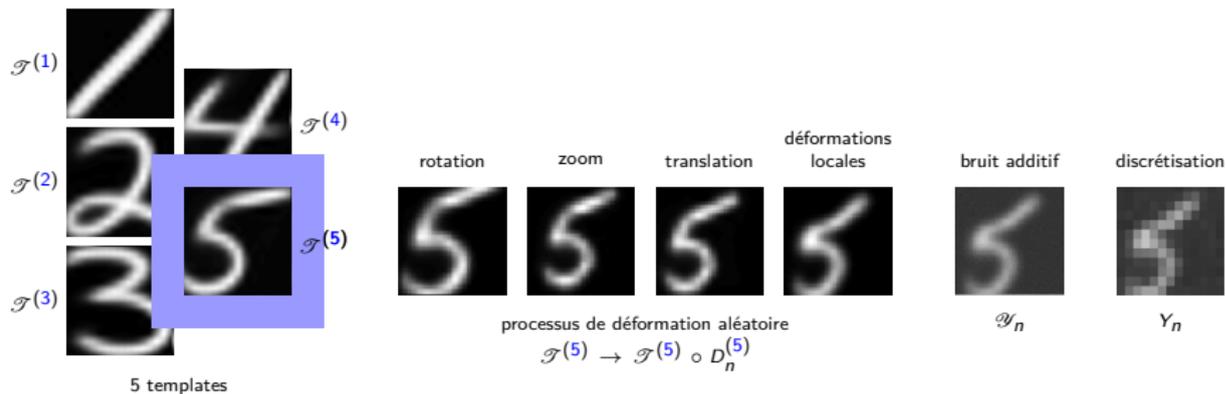
En paramétrisant

- ▶ la famille de templates \mathcal{T} par $\theta \in \Theta$
- ▶ le champ de déformation D_n par $\beta_n \in \mathbb{B}$

et en discrétisant \mathcal{Y}_n sur une grille, le modèle peut se réécrire comme :

$$Y_n = \Phi_{\beta_n} \theta_{i_n} + \zeta_n, \quad \zeta_n \sim \mathcal{N}(0, \Sigma).$$

Exemple 2 : Modèle à templates déformables



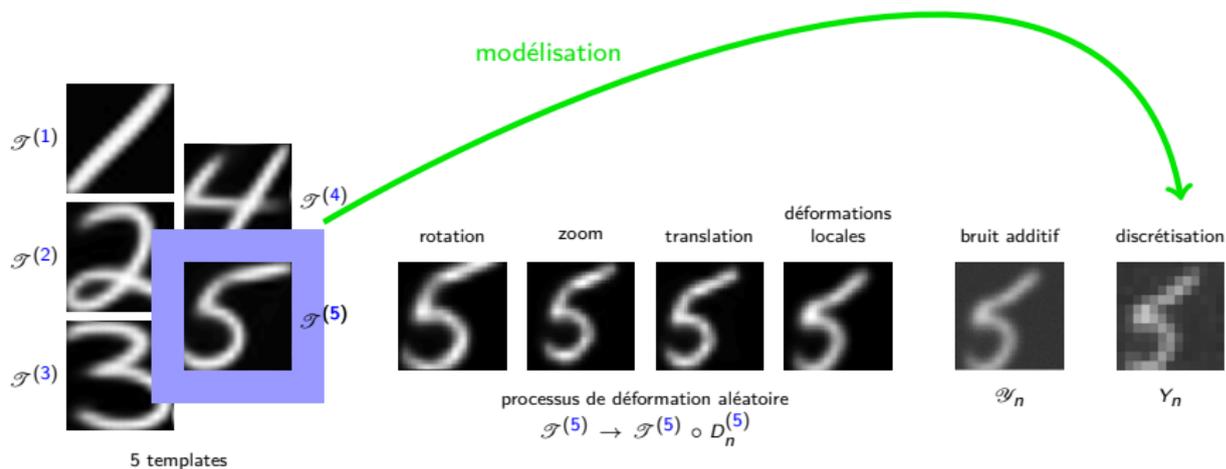
En paramétrisant

- ▶ la famille de templates \mathcal{T} par $\theta \in \Theta$
- ▶ le champ de déformation D_n par $\beta_n \in \mathbb{B}$

et en discrétisant \mathcal{Y}_n sur une grille, le modèle peut se réécrire comme :

$$Y_n = \Phi_{\beta_n} \theta_{i_n} + \zeta_n, \quad \zeta_n \sim \mathcal{N}(0, \Sigma).$$

Exemple 2 : Modèle à templates déformables



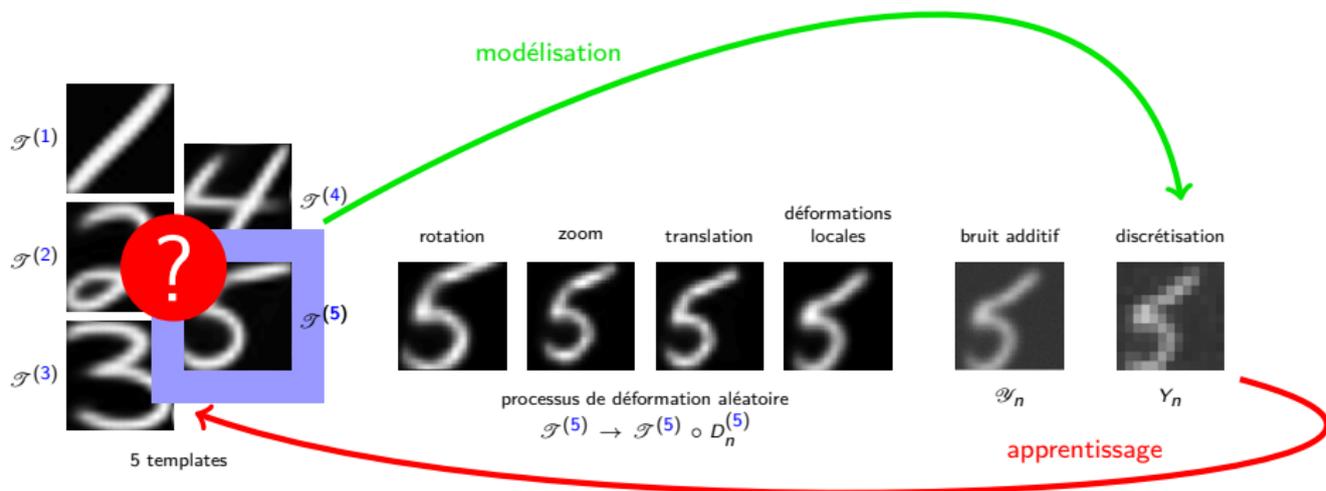
En paramétrisant

- ▶ la famille de templates \mathcal{T} par $\theta \in \Theta$
- ▶ le champ de déformation D_n par $\beta_n \in \mathbb{B}$

et en discrétisant \mathcal{Y}_n sur une grille, le modèle peut se réécrire comme :

$$Y_n = \Phi_{\beta_n \theta_{i_n}} + \zeta_n, \quad \zeta_n \sim \mathcal{N}(0, \Sigma).$$

Exemple 2 : Modèle à templates déformables



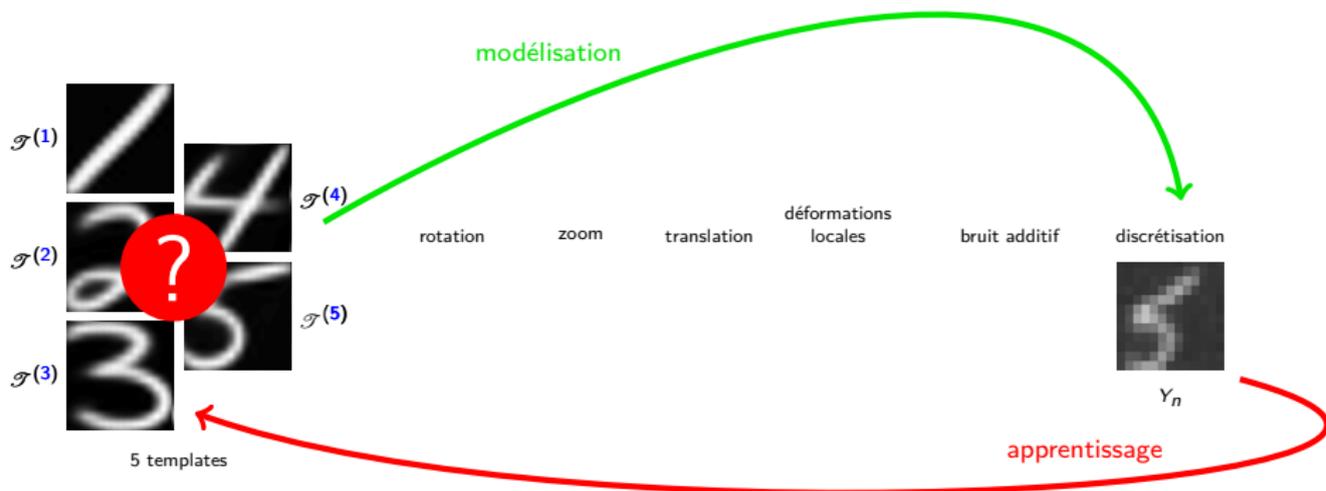
En paramétrisant

- ▶ la famille de templates \mathcal{T} par $\theta \in \Theta$
- ▶ le champ de déformation D_n par $\beta_n \in \mathbb{B}$

et en discrétisant \mathcal{Y}_n sur une grille, le modèle peut se réécrire comme :

$$Y_n = \Phi_{\beta_n} \theta_{i_n} + \zeta_n, \quad \zeta_n \sim \mathcal{N}(0, \Sigma).$$

Exemple 2 : Modèle à templates déformables



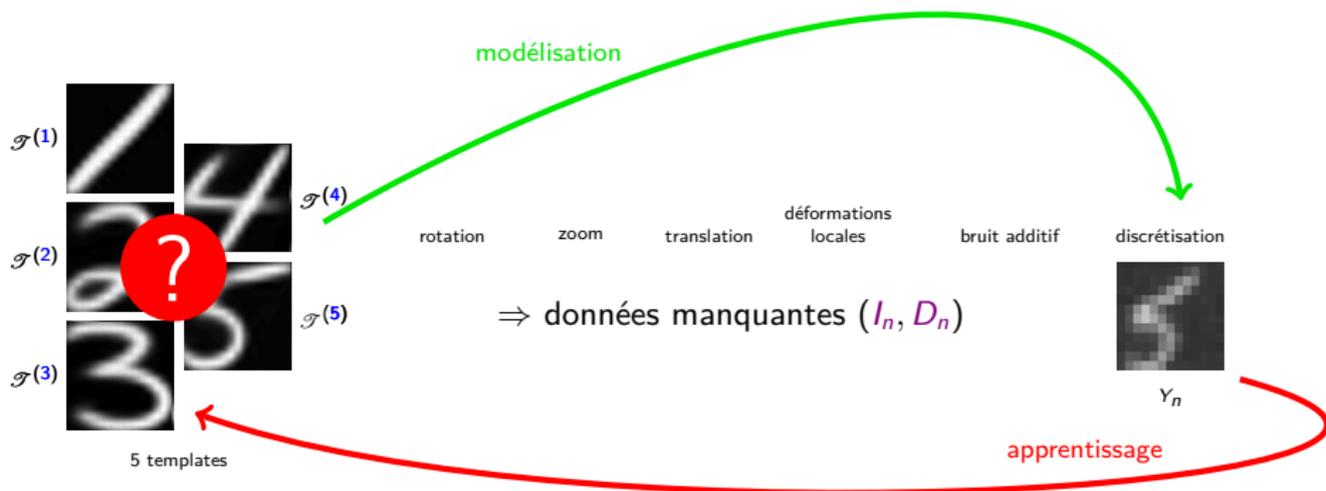
En paramétrisant

- ▶ la famille de templates \mathcal{T} par $\theta \in \Theta$
- ▶ le champ de déformation D_n par $\beta_n \in \mathbb{B}$

et en discrétisant \mathcal{Y}_n sur une grille, le modèle peut se réécrire comme :

$$Y_n = \Phi_{\beta_n} \theta_{i_n} + \zeta_n, \quad \zeta_n \sim \mathcal{N}(0, \Sigma).$$

Exemple 2 : Modèle à templates déformables



En paramétrisant

- ▶ la famille de templates \mathcal{T} par $\theta \in \Theta$
- ▶ le champ de déformation D_n par $\beta_n \in \mathbb{B}$

et en discrétisant \mathcal{Y}_n sur une grille, le modèle peut se réécrire comme :

$$Y_n = \Phi_{\beta_n} \theta_{i_n} + \zeta_n, \quad \zeta_n \sim \mathcal{N}(0, \Sigma).$$

Apprentissage paramétrique

Deux écoles

	fréquentiste	Bayésienne
modèle	$f(\cdot \theta), \theta \in \Theta$	$f(\cdot \theta), \theta \in \Theta$
source d'information	données $Y = Y_1, Y_2, \dots$	données $Y = Y_1, Y_2, \dots$ + une distribution <i>a priori</i> $\theta \sim p$
apprentissage	trouver l'ensemble Θ^* $\arg \min_{\theta \in \Theta} d(Y, f(\cdot \theta))$ pour une distance d	trouver la distribution π $\pi(\theta Y) \propto f(Y \theta)p(\theta)$
nature du problème	optimisation	échantillonnage
objectif	$\Pr(\theta \in A Y)$ intervalle de confiance	$\Pr(\theta \in A) = \pi(A Y)$ intervalle de crédibilité
exemple	Maximum de vraisemblance	méthodes de Monte Carlo

Exemple 1 (régression logistique) : apprentissage Bayésien

- ▶ $N = 10^7$ données $Y = (Y_1, \dots, Y_N)$
- ▶ covariates $X = (X_1, \dots, X_N)$
- ▶ loi a priori $p(\theta) = \text{Laplace}(\theta; 1) \propto \exp\{-\|\theta\|_1\}$
- ▶ loi a posteriori

$$\pi(\theta | Y, X) \propto \prod_{n=1}^N \left\{ \frac{1}{1 + \exp(-\theta^T X_n)} \right\}^{Y_n} \left\{ 1 - \frac{1}{1 + \exp(-\theta^T X_n)} \right\}^{1-Y_n} e^{-\|\theta\|_1}$$

- ▶ π n'est pas une distribution standard \Rightarrow l'échantillonnage de π n'est pas simple

Apprentissage Bayésien : les méthodes de Monte Carlo par chaîne de Markov (MCMC) offrent une possibilité simple et universelle d'échantillonner π

Méthode MCMC

Principe : construire une chaîne de Markov qui admette π comme distribution limite

Un exemple de MCMC : l'algorithme de Metropolis-Hastings construit une chaîne de Markov $\{\theta_k, k \in \mathbb{N}\}$

Initialisation $\theta_0 \sim p$ et à chaque itération $k = 1, 2, \dots$, faire

- (i) $\theta' \sim Q(\theta_{k-1}, \cdot)$
- (ii) définir $\theta_k = \theta'$ avec proba.:

$$\begin{aligned}\alpha(\theta_{k-1}, \theta') &:= 1 \wedge \frac{\pi(\theta' | Y) Q(\theta_{k-1}, \theta')}{\pi(\theta_{k-1} | Y) Q(\theta_{k-1}, \theta')} \\ &= 1 \wedge \frac{f(Y_1, \dots, Y_N | \theta')}{f(Y_1, \dots, Y_N | \theta_{k-1})} \frac{p(\theta') Q(\theta_{k-1}, \theta')}{p(\theta_{k-1}) Q(\theta_{k-1}, \theta')}\end{aligned}$$

et $\theta_k = \theta_{k-1}$ avec proba. $1 - \alpha(\theta_{k-1}, \theta')$.

Problème : la complexité de MH est en $\mathcal{O}(N)$ par itération

Exemple 2 (modèle déformable) : apprentissage fréquentiste

- ▶ $N = 10,000$ images Y_1, Y_2, \dots, Y_N et $Y = \mathcal{M}_{15}\{(0,1)\}$
- ▶ pour chaque image Y_n , la classe I_n et le champ de déformation β_n sont inconnues
- ▶ le bruit additif est supposé Gaussien de sorte que

$$f(Y_1, \dots, Y_N, I_n = i, \beta_n = d | \theta) = \mathcal{N}(\Phi_{\beta_n} \theta_{i_n}, \sigma \text{Id}_{15})$$

- ▶ on pose une loi a priori sur les données manquantes $(I_n, \beta_n) \sim g$
- ▶ la fonction à maximiser sur Θ est

$$\theta \mapsto f(Y_1, \dots, Y_N | \theta) = \sum_i \int_d f(Y_1, \dots, Y_N, I_n = i, D_n = d | \theta) dg(i, d).$$

Apprentissage fréquentiste : l'algorithme Expectation-Maximization (EM) est une façon standard de trouver le maximum de f **en présence de données manquantes**

Algorithme EM

Principe : construire une séquence de paramètres $\{\theta_k, k \in \mathbb{N}\}$ qui converge vers un maximum de f

Initialisation avec $\theta_0 \in \Theta$ et à chaque itération $k = 1, 2, \dots$:

- (i) calculer l'espérance conditionnelle sous la loi des données manquantes sachant θ_{k-1}

$$S_k(\theta) = \mathbb{E} \{ \log f(Y_1, \dots, Y_N, X_1, \dots, X_N | \theta) | \theta_{k-1} \}$$
$$\stackrel{iid}{=} \sum_{n=1}^N \mathbb{E} \{ \log f(Y_n, X_n | \theta) | \theta_{k-1} \}$$

- (ii) définir θ_k comme un maximiseur de $\theta \mapsto S_k(\theta)$

Problème : la complexité de EM est en $\mathcal{O}(N)$ par itération

Plan

Quelques informations sur mon parcours

Statistique computationnelle : modélisation et apprentissage

Apprentissage statistique en présence d'un grand nombre de données : stabilité et efficacité d'approximations de certains algorithmes.

Quelques Illustrations

Approximations d'algorithmes

Thème de recherche actif : conception d'algorithmes qui

- 1– "imitent" les algorithmes d'apprentissage traditionnels
- 2– ont une complexité plus faible que $\mathcal{O}(N)$
- 3– héritent (dans une certaine mesure) des garanties théoriques de ces algorithmes

Nous présentons deux algorithmes qui approximent MH et EM

- ▶ description des algorithmes
- ▶ garanties théoriques
- ▶ outils mathématiques pour justifier l'intuition de ces algorithmes

Approximation de MH (avec N. Friel, UCD et P. Alquier, ENSAE)

Simuler une chaîne de Markov $\{\tilde{\theta}_k, k \in \mathbb{N}\}$ en utilisant un sous-ensemble des données $Y_U \subset Y$ de taille $n \ll N$ ($U \subset \{1, \dots, N\}$) pour accepter/rejeter un nouvel état de la chaîne

$$\alpha(\theta, \theta') = 1 \wedge \frac{f(Y | \theta')}{f(Y | \theta)} \times \frac{p(\theta')Q(\theta', \theta)}{p(\theta)Q(\theta, \theta')}$$

$\xrightarrow{\text{remplacé par}} \hat{\alpha}(\tilde{\theta}, \theta' | U) = 1 \wedge \frac{f(Y_U | \theta')^{N/n}}{f(Y_U | \tilde{\theta})^{N/n}} \times \frac{p(\theta')Q(\theta', \tilde{\theta})}{p(\tilde{\theta})Q(\tilde{\theta}, \theta')}$

A chaque itération, le sous-ensemble Y_U est tiré suivant une loi

$$\nu_{n,\epsilon}(U) \propto \exp\{-\epsilon \|S(Y) - (N/n)S(Y_U)\|\}, \quad \epsilon > 0.$$

Pour un sous-ensemble $Y_U \subseteq Y$, $S(Y_U)$ est un vecteur de statistique résumé de Y_U .

Cette méthode approximant MH est appelée **ISS-MCMC**, acronyme pour *Informed Sub-Sampling MCMC*
Complexité : $\mathcal{O}(n)$

Convergence de MH

On définit le niveau de convergence d'une chaîne de Markov par

$$D_k(\theta_0) := \|\Pr(\theta_k \in \cdot \mid \theta_0) - \pi\| .$$

MH produit une chaîne de Markov ergodique *i.e*

$$\forall \theta_0 \in \Theta, \quad \lim_{k \rightarrow \infty} D_k(\theta_0) = 0 \quad \text{p-s.}$$

et possiblement la convergence se fait géométriquement,

▶ simplement

$$\forall \theta_0 \in \Theta, \quad D_k(\theta_0) \leq C(\theta_0)\rho^k .$$

▶ uniformément

$$\sup_{\theta_0 \in \Theta} D_k(\theta_0) \leq C\rho^k .$$

Héritage des propriétés de MH

Il n'y a aucune raison pour que ISS-MCMC soit ergodique :

$$\Pr(\tilde{\theta}_k \in A) \not\rightarrow_{k \rightarrow \infty} \pi(A)$$

Hypothèse

Il existe un vecteur de statistiques suffisantes S pour f telle que

$$f(Y | \theta) = \psi(\theta) \exp\{\phi(\theta)^T S(Y)\}$$

Proposition

1. *Nous avons*

$$\text{KL}(\pi(\cdot | Y), \pi(\cdot | Y_U)) \leq B(Y_U)$$

et $B(Y_U)$ est minimisé pour le(s) sous-ensemble(s) Y_U qui minimise(nt) $\|S(Y) - S(Y_U)\|$.

2. *Asymptotiquement quand $N \rightarrow \infty$, nous avons*

$$\text{KL}(\pi(\cdot | Y), \pi(\cdot | Y_U))$$

est minimisé pour le(s) sous-ensemble(s) Y_U qui minimise(nt) $\|S(Y) - S(Y_U)\|$.

Héritage des propriétés de MH pour ISS-MCMC

En l'absence de statistiques suffisantes, nous travaillons sous l'hypothèse suivante

Hypothèse

Il existe un vecteur de statistique résumé S et $\gamma > 0$ tels que

$$\forall \theta \in \Theta \quad \left\| \frac{N}{n} \log f(Y_U | \theta) - \log f(Y | \theta) \right\| \leq \gamma \left\| S(Y) - \frac{N}{n} S(Y_U) \right\|$$

Proposition

- ▶ Si MH converge simplement géométriquement alors ISS-MCMC converge de la même façon vers une approximation de π
- ▶ Si MH converge uniformément géométriquement alors ISS-MCMC converge de la même façon vers une approximation de π quantifiée par

$$\begin{aligned} & \|\pi - \tilde{\pi}_k\| \\ & \leq \kappa \sup_{\theta \in \Theta} \mathbb{E} \left\{ \frac{f(Y | \theta)}{f(Y_U | \theta)^{N/n}} \right\} \sup_{U \in \mathcal{U}_n} \mathbb{E} \left\{ \left| \frac{p(\tilde{\theta}) Q(\tilde{\theta}, \theta)}{p(\theta) Q(\theta, \tilde{\theta})} \left| \frac{f(Y_U | \theta)^{N/n}}{f(Y | \theta)} - \frac{f(Y_U | \tilde{\theta})^{N/n}}{f(Y | \tilde{\theta})} \right| \right| \right\} \end{aligned}$$

Approximation de EM (avec É. Moulines, École Polytechnique)

Hypothèse

Il existe un vecteur de statistique suffisante S i.e une fonction Φ telle que

$$f(Y, X | \theta) = \Phi(\theta, S(Y, X)).$$

Dans notre méthode, les observations Y_1, Y_2, \dots sont traitées une par une

Initialisation à $\tilde{\theta}_0 \in \Theta$, la séquence $\{\tilde{\theta}_k, k \in \mathbb{N}\}$ est définie par

1. approximation étape E : mise à jour des statistiques suffisantes

$$s_k = s_{k-1} + \varrho_k (S(Y_k, X_k) - s_{k-1}), \quad X_k \sim \pi(\cdot | Y_k, \tilde{\theta}_{k-1}),$$

avec $\varrho_k = \varrho_0 k^{-\alpha}$, $\alpha \in (0, 1)$

2. approximation étape M : mise à jour du paramètre

$$\tilde{\theta}_{k+1} = \bar{\theta}(s_{k+1}) := \arg \max_{\theta \in \Theta} \Phi(\theta, s_{k+1}).$$

Cette méthode approximant EM est appelée **MCoEM**, pour *Monte Carlo online EM*

Complexité : $\mathcal{O}(1)$

Héritage des propriétés théoriques de l'EM

Dans sa forme traditionnelle, la séquence de l'EM converge pour tout $\theta_0 \in \Theta$ vers

$$\Theta^* := \{\theta \in \Theta, \nabla_{\theta'} f(Y | \theta')|_{\theta} = 0\}$$

Proposition

Sous certaines hypothèses techniques (sur la topologie de Θ), la séquence $\{\tilde{\theta}_k, k \in \mathbb{N}\}$ produite par MCoEM converge vers

$$\Theta^\dagger := \{\theta \in \Theta, \nabla_{\theta'} \text{KL}(\pi^*, f(\cdot | \theta'))|_{\theta'=\theta} = 0\}.$$

presque-sûrement quand $k \rightarrow \infty$. π^ est le processus génératif des données qui peut ne pas appartenir à \mathcal{F} .*

Héritage des propriétés théoriques de l'EM

Monotonicité

- ▶ À chaque itération EM vérifie $f(Y | \theta_{k+1}) \geq f(Y | \theta_k)$
- ▶ À chaque itération MCoEM vérifie

$$\text{KL}(\pi^*, f(\cdot | \tilde{\theta}_{k+1})) \leq \text{KL}(\pi^*, f(\cdot | \tilde{\theta}_k)) + o(\|\tilde{\theta}_{k+1} - \tilde{\theta}_k\|), \quad \text{p-s}$$

Taux de convergence

- ▶ Conditionnellement à (θ_0, Y) , EM est déterministe mais la convergence se fait en $1/\sqrt{n}$
- ▶ Conditionnellement à $(\tilde{\theta}_0, Y)$, MCoEM est stochastique et la convergence se fait en $1/\sqrt{\varrho_n} \propto 1/\sqrt{n^{-\alpha}}$, $\alpha \in (0, 1)$.
- ▶ On peut de plus prouver la normalité asymptotique pour MCoEM:

$$\varrho_n^{-1/2}(\tilde{\theta}_n - \theta^*) \Rightarrow \mathcal{N}(0, \Sigma),$$

où Σ est la matrice de variance covariance d'un problème de Lyapunov défini dépendant de $\text{Var}\{S(Y, X) | Y, \theta\}$.

Outils mathématiques pour établir des résultats en présence d'approximations (1/2)

Pour une chaîne de Markov, on utilise la théorie de perturbation des opérateurs linéaires:

- ▶ caractérisation de la chaîne par l'opérateur de transition

$$K(\theta, A) := \Pr(\theta_{n+1} \in A \mid \theta_n = \theta)$$

- ▶ la loi de probabilité de la chaîne est simplement l'itération de K

Comment une approximation locale se propage-t-elle asymptotiquement?

Exemple de résultat:

Proposition (Mitrophanov (AAP, 2005))

Soit une chaîne $\{\tilde{\theta}_n, n \in \mathbb{N}\}$ ayant pour transition \tilde{K} . Si K est uniformément ergodique alors pour n suffisamment grand, nous avons :

$$\| \Pr\{\theta_n \in \cdot\} - \Pr\{\tilde{\theta}_n \in \cdot\} \| \leq \kappa_n \|K - \tilde{K}\|$$

$\Rightarrow \tilde{K}$ joue le rôle d'une version bruitée de l'opérateur de référence (le noyau de transition de MH dans notre cas)

Outils mathématiques pour établir des résultats en présence d'approximations (2/2)

L'EM peut également être réécrit en terme d'opérateur

$$\theta_{n+1} = K(\theta_n), \quad K(\theta) = \bar{\theta}(\mathbb{E}\{S(Y, X) | \theta\})$$

K est un opérateur non linéaire

⇒ les points stationnaires de l'EM sont dans $\ker h$, $h := K - \text{Id}$

Approximation stochastique (Robbins et Monro, 1951) : trouver les zéros d'une fonction h ne pouvant être évaluée que de façon bruitée $\hat{h}(\theta) \approx h(\theta)$

Sous certaines hypothèses sur l'approximation \hat{h} , la séquence $\{\tilde{\theta}_n, n \in \mathbb{N}\}$

$$\tilde{\theta}_{n+1} = \tilde{\theta}_n + \varrho_n \hat{h}(\tilde{\theta}_n),$$

où $\varrho_n \searrow 0$, $\sum_n \varrho_n = \infty$, $\sum_n \varrho_n^2 < \infty$ alors :

$$\tilde{\theta}_n \rightarrow \{\theta \in \Theta, h(\theta) = 0\} \text{ p-s.}$$

MCoEM : $h \xrightarrow{\text{remplacé par}} \hat{h} = \bar{\theta}(S(Y_n, X_n)) - \text{Id}, \quad (Y_n, X_n) \sim \delta_{y_n} \otimes \pi(\cdot | \tilde{\theta}_n, Y_n)$

Plan

Quelques informations sur mon parcours

Statistique computationnelle : modélisation et apprentissage

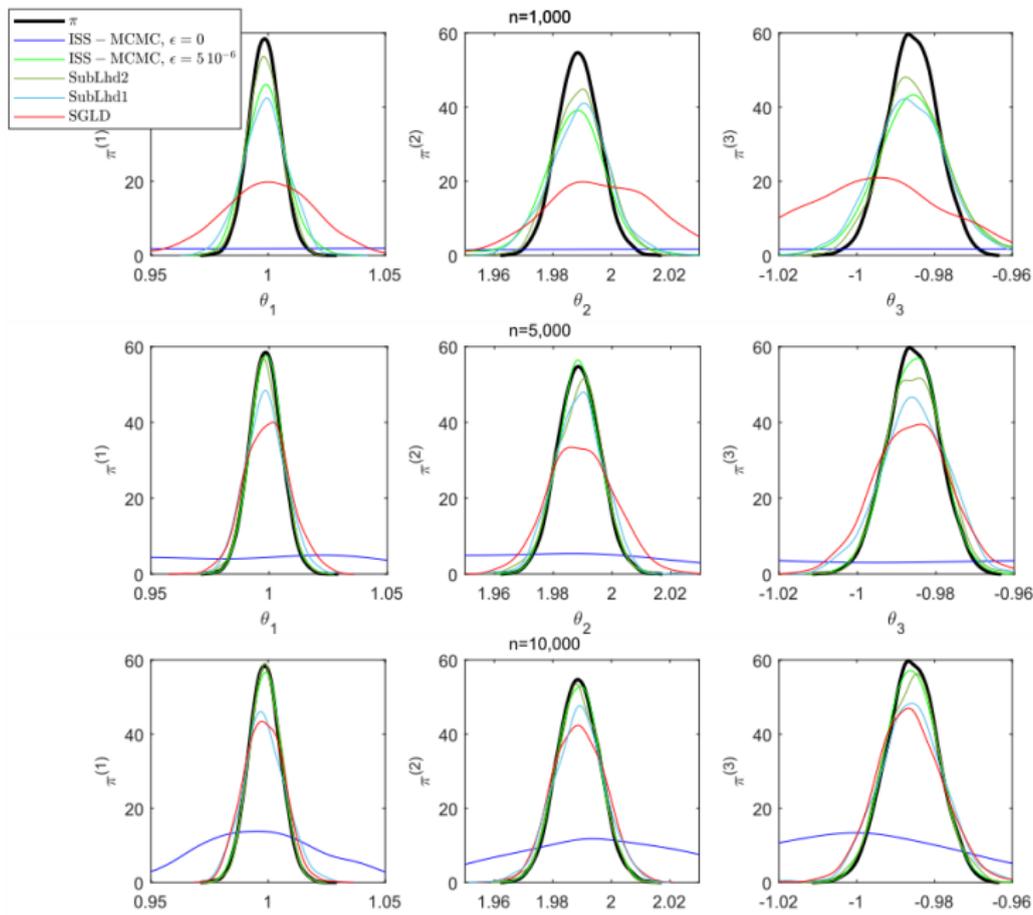
Apprentissage statistique en présence d'un grand nombre de données : stabilité et efficacité d'approximations de certains algorithmes.

Quelques Illustrations

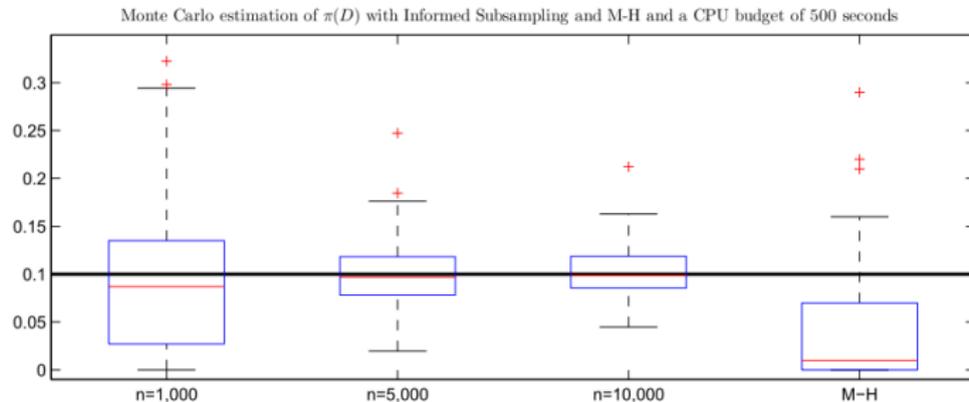
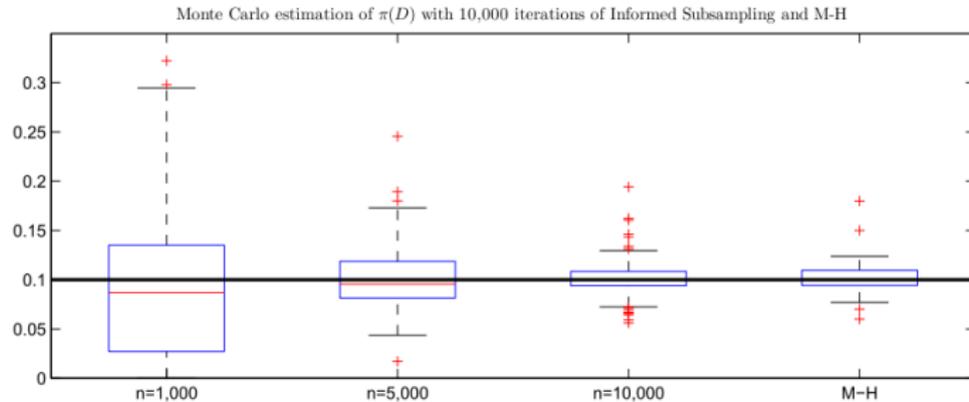
Régression logistique (1/3)

algorithm	time/iter.(s)	iter. completed	RMSE	$\text{var}\{\widehat{\pi(D)}\}$
M-H	10	50	0.1417	0.004
ISS-MCMC, $n = 1,000$	0.05	10,000	0.1016	0.0104
ISS-MCMC, $n = 5,000$	0.08	6,250	0.0351	0.0012
ISS-MCMC, $n = 10,000$	0.13	3,840	0.0267	0.0007
SGLD, $n = 1,000$	0.08	6,000	0.1370	0.0157
SGLD, $n = 5,000$	0.11	5,250	0.0996	0.0100
SGLD, $n = 10,000$	0.12	4,500	0.0326	0.0011

Régression logistique (2/3)



Régression logistique (3/3)



Modèle déformable

- Performance computationnelle

	MCoEM	EM (N=50)	EM (N=300)
temps CPU / itération (sec.)	20	225	1,570

- Performance en classification de chiffre manuscrit

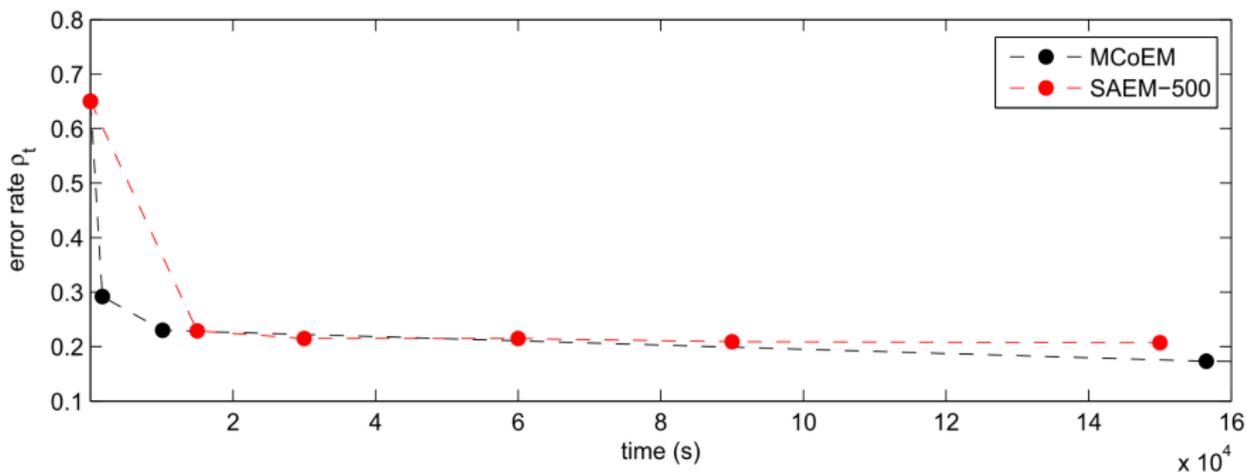


Figure: Erreur de classification en fonction du temps CPU

Discussion

- ▶ Il est crucial d'établir des **approximations scalables** d'algorithmes bien connus afin d'exploiter au mieux les progrès des systèmes de mesure et de stockage
- ▶ Nous avons proposé de telles approximations pour **Metropolis-Hastings** et **Expectation-Maximization**
- ▶ Trouver des garanties théoriques pour ce genre de méthode représente un enjeu de taille, allant au delà de la communauté statistique
- ▶ Les résultats énoncés ici reposent sur **des hypothèses pas toujours réalistes** (existence de statistiques suffisantes ou "bonnes" statistiques résumées, convergence uniforme, Θ compact...)
- ▶ D'autres outils théoriques ont été ou pourraient être utilisés comme le **couplage** de processus stochastiques ou la **théorie spectrale** des opérateurs