

Les processus d'évolution génétique en filtrage de signaux et en analyse de risques

P. Del Moral

INRIA Centre Bordeaux-Sud Ouest

Séminaire de Stat. et Santé Publique de l'IFR 99, décembre 08

qq-références :

- Feynman-Kac formulae. Genealogical and interacting particle systems, Springer (2004), [+ Réfs](#)
- + Doucet, Jasra. SMC Samplers. *JRSS B* (2006).
- + Kallel, Rowe, Modelling genetic models with IPS, Theoretical Aspects of Evolutionary Computing (2000)

- 1 Les processus d'évolution génétique
- 2 Évolution d'arbres généalogiques
- 3 QQ domaines d'application
- 4 Les intégrales de chemins de Feynman
- 5 Théorie champ moyen

1 Les processus d'évolution génétique

- Dynamique adaptative des populations
- Les processus de mutation et sélection
- QQ exemples

2 Évolution d'arbres généalogiques

3 QQ domaines d'application

4 Les intégrales de chemins de Feynman

5 Théorie champ moyen

Dynamique adaptative des populations (*temps discret*)

- Population d'individus évoluant en interaction selon des mécanismes de mutation/exploration couplées à des processus de naissance et mort et/ou de branchements spatiaux-temporel.
- **Processus stochastique formalisé :** (*taille fixe N pour simplifier*)

⇒ Population = N individus ξ_n^i dans un espace d'état E_n

- Indice-Label de l'individu : $i \in \{1, \dots, N\}$
 - Paramètre temporel : $n \geq 0$ (*temps discret*).
- **Exemples d'espace d'états :**

Gènes (séquences adn, allèles), positions, vitesses, accélérations, permutations, sous-espaces de points, codes génétiques, traits d'individus, age, taille, poids, communautés, nationalité, lignes ancestrales, excursions trajectorielles, ...

2 mécanismes d'adaptation naturelle \Rightarrow Sélection & Mutation

- **Sélection** ($=\text{naissance}/\text{mort}=\text{clonage}=\text{branchements}$) :

$$(\xi_n^1, \dots, \xi_n^N) \in E_n^N \longrightarrow \underbrace{\left(\widehat{\xi}_n^1, \dots, \widehat{\xi}_n^N \right)}_{\text{individus sélectionnés}} \in E_n^N$$

\sim Potentiel d'adaptation G_n : $x_n \in E_n \mapsto G_n(x_n) \in [0, 1]$

- ① Acceptation $\rightsquigarrow \widehat{\xi}_n^i = \xi_n^i$ avec une proba $G_n(\xi_n^i)$
- ② Sinon saut sur le j -ième $\widehat{\xi}_n^i = \xi_n^j$ avec une proba $\frac{G_n(\xi_n^j)}{\sum_{k=1}^N G_n(\xi_n^k)}$

QQ exemples académiques élémentaires:

$$G_n(x_n) = 1_{A_n}(x_n), e^{-\frac{1}{2} (y_n - x_n)^2} \text{ avec } y_n \text{ référence fixée}$$

ou encore en trajectoriel \rightsquigarrow sélection de trajectoires

$$x_n = (x'_0, \dots, x'_n) \rightsquigarrow G_n(x_n) = 1_{(x'_p \neq x'_q, \forall p < q < n)}$$

2 mécanismes d'adaptation naturelle \Rightarrow Sélection & Mutation

- **Mutation** ($=\text{exploration}=\text{proposition}=\text{prédiction}$) :

$$\left(\widehat{\xi}_n^1, \dots, \widehat{\xi}_n^N\right) \in E_n^N \longrightarrow (\xi_{n+1}^1, \dots, \xi_{n+1}^N) \in E_{n+1}^N$$

Indépendamment des uns des autres, chaque individu sélectionné $\widehat{\xi}_n^i$ explore l'espace en mimant les transitions

$$X_n = \widehat{\xi}_n^i \rightsquigarrow X_{n+1} = \xi_{n+1}^i$$

d'une chaîne de Markov $X_n \in E_n \rightsquigarrow X_{n+1} = E_{n+1}$.

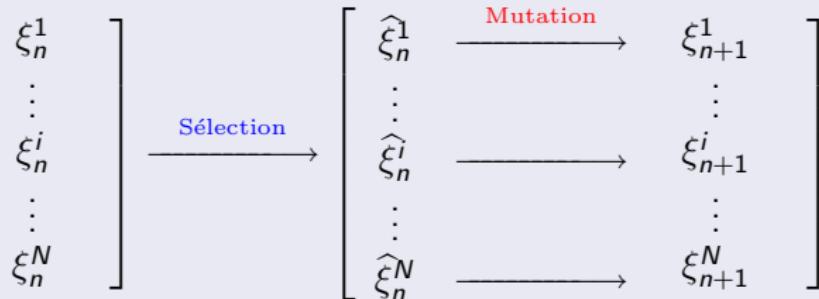
QQ exemples académiques élémentaires:

X_n = marche aléa. sur \mathbb{Z} , processus $X_n = F_n(X_{n-1}, W_n)$ sur \mathbb{R}^d

ou encore en trajectoriel \rightsquigarrow extension locale de trajectoires

$$X_n = (X'_0, \dots, X'_n) \rightsquigarrow X_{n+1} = ((X'_0, \dots, X'_n), X'_{n+1})$$

Algorithme d'évolution génétique



Exemples :

- X_n marche aléatoire sur \mathbb{Z} & $G_n(X_n) = 1_A(X_n)$.
- $X_n = F_n(X_{n-1}, W_n)$ dyn. aléa sur \mathbb{R}^d & $G_n(X_n) = e^{-\frac{1}{2}(Y_n - H_n(X_n))^2}$.
- $X_n = X'_{[T_{n-1}, T_n]}$ excursion inter-niveaux & $G_n(X_n) = 1_{B_n}(X'_{T_n})$.
- $X_n = X'_{[0, n]}$ traject. aléa. sur \mathbb{Z}^2 & $G_n(X_n) = 1_{(X'_p \neq X'_q, \forall p < q \leq n)}$.
- Modèles trajectoriels $\mathbf{X}_n = X_{[0, n]}$ & $\mathbf{G}_n(\mathbf{X}_n) = G_n(X_n)$.

Summary

1 Les processus d'évolution génétique

2 Évolution d'arbres généalogiques

- Processus historiques et lignes ancestrales
- Les 3 types de mesures d'occupation

3 QQ domaines d'application

4 Les intégrales de chemins de Feynman

5 Théorie champ moyen

(Sélection & Mutation) trajectorielle \Leftrightarrow Arbres généalogiques

- **Mutation** = extension locale des trajectoires \sim Proc. trajectoriel

$$X_n = (X'_0, \dots, X'_n) \rightsquigarrow X_{n+1} = ((X'_0, \dots, X'_n), X'_{n+1})$$

- **Sélection**=clonage=sauts des trajectoires \sim Potentiel trajectoriel

$$G_n(X_n) = G_n(X'_0, \dots, X'_n)$$



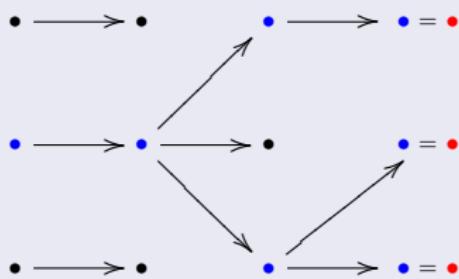
Arbre généalogique

- **Individus trajectoriels** $\rightsquigarrow \xi_n^i := \underbrace{(\xi_{0,n}^i, \xi_{1,n}^i, \dots, \xi_{n,n}^i)}_{=\text{ligne ancestrale}}$

- **Arbre généalogique** = $(\xi_{0,n}^i, \xi_{1,n}^i, \dots, \xi_{n,n}^i)_{1 \leq i \leq N}$

Processus naissance/mort G_n -adaptatif \hookrightarrow 3 types de mesures

($N = 3$)



- **Population courante** $\hookrightarrow \eta_n^N := \frac{1}{N} \sum_{i=1}^N \delta_{\xi_n^i} \leftarrow$ *i-ième individu au temps n*
- **Arbre généalogique** $\hookrightarrow \frac{1}{N} \sum_{i=1}^N \delta_{(\xi_{0,n}^i, \xi_{1,n}^i, \dots, \xi_{n,n}^i)} \leftarrow$ *i-ième ligne ancestrale*
- **Arbre généalogique complet** $\hookrightarrow \frac{1}{N} \sum_{i=1}^N \delta_{(\xi_0^i, \xi_1^i, \dots, \xi_n^i)}$
- \oplus **Potentiels moyens [% de succès ($G_n = 1_A$)]** $\hookrightarrow \frac{1}{N} \sum_{i=1}^N G_n(\xi_n^i)$

Summary

1 Les processus d'évolution génétique

2 Évolution d'arbres généalogiques

3 QQ domaines d'application

- Confinement de processus
- Marches aléatoires répulsives
- Processus de ruine
- Filtrage de signaux

4 Les intégrales de chemins de Feynman

5 Théorie champ moyen

Confinement \Leftrightarrow absorption \rightsquigarrow Quantum & Diffusion Monte Carlo

X_n marche aléatoire sur \mathbb{Z} & $G_n(X_n) = 1_A(X_n)$.



$$\eta_n^N := \frac{1}{N} \sum_{i=1}^N \delta_{\xi_n^i} \simeq_{N \uparrow \infty} \text{Loi}(X_n \mid \forall 0 \leq p < n \quad X_p \in A) := \eta_n$$

et

$$\prod_{0 \leq p < n} \frac{1}{N} \sum_{i=1}^N 1_A(\xi_p^i) \simeq_{N \uparrow \infty} \mathbb{P}(\forall 0 \leq p < n \quad X_p \in A)$$

et

$$\frac{1}{N} \sum_{i=1}^N \delta_{(\xi_{0,n}^i, \xi_{1,n}^i, \dots, \xi_{n,n}^i)} \simeq_{N \uparrow \infty} \text{Loi}((X_0, \dots, X_n) \mid \forall 0 \leq p < n \quad X_p \in A)$$

Remarque : idem avec des mutation-sélection données par

(\widehat{X}_n transition locales $\in A$) & ($\widehat{G}_n(x_n) = \mathbb{P}(X_{n+1} \in A \mid X_n = x_n)$)

Comparaisons & Convergence

- Méthode de Monte Carlo usuelle \sim copies iid X^i de X

$$(1) \quad \frac{1}{N} \sum_{i=1}^N \prod_{0 \leq p < n} 1_A(X_p^i) \quad \simeq_{N \uparrow \infty} \quad \mathbb{P}(\forall 0 \leq p < n \quad X_p \in A)$$

$$(2) \quad \prod_{0 \leq p < n} \frac{1}{N} \sum_{i=1}^N 1_A(\xi_p^i) \quad \simeq_{N \uparrow \infty} \quad \mathbb{P}(\forall 0 \leq p < n \quad X_p \in A)$$

- Est. sans biais de variances : $[P_n = \mathbb{P}(\forall 0 \leq p < n \quad X_p \in A) \simeq e^{-a/n}]$

$$\text{Var}(1) = \frac{1}{N} P_n (1 - P_n) \quad \& \quad \text{Var}(2) \leq c \frac{n}{N} P_n^2$$

de plus (sous qq hyp. de régularité)

$$\sup_{n \geq 0} \mathbb{E} \left(|\eta_n^N(f) - \eta_n(f)|^p \right)^{1/p} \leq c/\sqrt{N}$$

Marches aléatoires répulsives \rightsquigarrow prune-enriched Rosenbluth method

$X_n = X'_{[0,n]}$ traject. aléa. sur \mathbb{Z}^2 & $G_n(X_n) = \mathbb{1}_{(X'_p \neq X'_q, \forall p < q \leq n)}$.



$$\frac{1}{N} \sum_{i=1}^N \delta_{(\xi_{0,n}^i, \xi_{1,n}^i, \dots, \xi_{n,n}^i)} \simeq_{N \uparrow \infty} \text{Loi}((X'_0, \dots, X'_n) \mid \forall p < q < n \quad X'_p \neq X'_q)$$

et

$$\prod_{0 \leq p < n} \frac{1}{N} \sum_{i=1}^N \mathbb{1}_{(\xi_{k,p}^i \neq \xi_{l,p}^i, \forall k < l \leq p)} \simeq_{N \uparrow \infty} \mathbb{P}(\forall p < q < n \quad X'_p \neq X'_q)$$

Remarque : idem avec des mutation-sélection données par

(\widehat{X}'_n transition locales sans intersections)

&

($\widehat{G}_n(x_n) = \mathbb{P}(X'_{n+1} \text{ intersecte le passé} \mid X_n = x_n)$)

Processus de ruine = excursions/branchements sur des niveaux ↓

- $X_n = X'_{[T_{n-1}, T_n]}$ excursion inter-niveaux & $G_n(X_n) = 1_{B_n}(X'_{T_n})$.
- T_n =temps d'atteinte du niveau B_n ou d'un ensemble attractif C

⇓

$$\frac{1}{N} \sum_{i=1}^N \delta_{\text{ligne ancestrale}_n(i)} \simeq_{N \uparrow \infty} \text{Loi(excursions de } X \mid B_n \text{ atteint avant } C)$$

et

$$\prod_{0 \leq p \leq n} (\% \text{ de succès au temps } p) \simeq_{N \uparrow \infty} \mathbb{P}(B_n \text{ atteint avant } C)$$

Filtrage de processus \rightsquigarrow filtres particulaires

$$X_n = F_n(X_{n-1}, W_n) \text{ dyn. aléa sur } \mathbb{R}^d \text{ & } G_n(X_n) = e^{-\frac{1}{2}(Y_n - H_n(X_n))^2}.$$

- Processus d'observations :

$$Y_n = H_n(X_n) + V_n \rightsquigarrow \text{avec } V_n \text{ bruits de mesure } \sim \mathcal{N}(0, 1)$$

- Fonctions de vraisemblance locale :

$$\mathbb{P}(Y_n \in dy \mid X_n = x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}(y - H_n(x))^2} dy$$

\Downarrow

$$\frac{1}{N} \sum_{i=1}^N \delta_{\text{ligne ancestrale}_n(i)} \simeq_{N \uparrow \infty} \text{Loi}((X_0, \dots, X_n) \mid (Y_0, \dots, Y_n))$$

Summary

1 Les processus d'évolution génétique

2 Évolution d'arbres généalogiques

3 QQ domaines d'application

4 Les intégrales de chemins de Feynman

- Lois de processus de Markov pondérés
- Formules de normalisation
- Processus historiques et lignes ancestrales

5 Théorie champ moyen

Mesures de Feynman-Kac (Fonctions test $f : E_n \rightarrow \mathbb{R}$)

- **X-explorations & G_n -selection**

$$\implies \eta_n^N(f) := \frac{1}{N} \sum_{i=1}^N f(\xi_n^i) \xrightarrow{N \uparrow \infty} \eta_n(f) := \frac{\gamma_n(f)}{\gamma_n(1)}$$

avec

$$\gamma_n(f) := \mathbb{E} \left(f_n(\textcolor{red}{X}_n) \prod_{0 \leq p < n} \textcolor{blue}{G}_p(\textcolor{red}{X}_p) \right)$$

- Ex. : Confinement $G_n = 1_A$

$$\gamma_n(1) = \mathbb{P}(\forall 0 \leq p < n \quad X_p \in A) \quad \& \quad \eta_n = \text{Law}(X_n \mid \forall 0 \leq p < n \quad X_p \in A)$$

Ctes de normalisation

Formule produit :

$$\gamma_n(1) := \mathbb{E} \left(\prod_{0 \leq p < n} G_p(X_p) \right) = \prod_{0 \leq p < n} \eta_p(G_p)$$



Estimations non biaisées :

$$\gamma_n^N(1) := \prod_{0 \leq p < n} \eta_p^N(G_p) \xrightarrow{N \uparrow \infty} \gamma_n(1) = \prod_{0 \leq p < n} \eta_p(G_p)$$

Ex. : Confinement $G_n = 1_A$

$$\prod_{0 \leq p < n} (\text{proportion de succès tps } p) \simeq \mathbb{P}(\forall 0 \leq p < n \quad X_p \in A)$$

Processus historique et arbres généalogiques

- Mutation et selection de trajectoires :

$$\rightsquigarrow \boxed{X_n := (X'_0, \dots, X'_n) \in E_n := (E'_0 \times \dots \times E'_n)}$$

- Population courante trajectorielle=Lignes ancestrales :

$$\eta_n^N(f_n) := \frac{1}{N} \sum_{i=1}^N f_n(\xi_{0,n}^i, \xi_{1,n}^i, \dots, \xi_{n,n}^i) \xrightarrow{N \uparrow \infty} \eta_n(f_n) := \frac{\gamma_n(f_n)}{\gamma_n(1)}$$

avec

$$\gamma_n(f_n) := \mathbb{E} \left(f_n(X'_0, \dots, X'_n) \prod_{0 \leq p < n} G_p(X'_0, \dots, X'_p) \right)$$

Ex. : Confinement $G_n = 1_A$

$$\eta_n = \text{Loi}((X'_0, \dots, X'_n) \mid \forall 0 \leq p < n \quad X'_p \in A)$$

Arbres généalogiques complets

- \sim algo. génétique "sans proba. d'acceptation"

$$\frac{1}{N} \sum_{i=1}^N F_n(\xi_0^i, \xi_1^i, \dots, \xi_n^i) \xrightarrow{N \uparrow \infty} (\eta_0 \otimes \dots \otimes \eta_n)(F_n)$$

avec les mesures produits

$$(\eta_0 \otimes \dots \otimes \eta_n)(F_n) = \int_{E_0} \dots \int_{E_n} \eta_0(dx_0) \dots \eta_n(dx_n) F_n(x_0, \dots, x_n)$$

- "Avec proba. d'acceptation" $\rightsquigarrow \neq$ Mesures de McKean :

$$\eta_n = \text{Loi}(\overline{X}_n) \quad \text{avec des transitions Markov} \quad \overline{X}_n \xrightarrow{\eta_n} \overline{X}_{n+1}$$



Algorithme Génétique = Interprétation champ moyen de \overline{X}_n

Algorithme Génétique

[X_n -mutations \oplus G_n -adaptation/selection/branchement]

\Downarrow & \Uparrow

Mesures de Feynman-Kac

[X_n -Markov de référence. \oplus G_n -fonctions de potentiel]

\Updownarrow

!!! Algorithme génétique \neq Métaheuristique (cf. Wikipedia définition) !!!!!

Algorithmes stochastiques "équivalents" :

- Algorithmes génétiques, processus de branchements.
- Méthodes de Monte Carlo séquentielles.
- Algorithmes de "population Monte Carlo", Diffusion Monte Carlo (DMC), Quantum Monte Carlo (QMC), ...
- Botanique des processus d'adaptation $\sim \neq$ domaines d'applications :

Bootstrapping, selection, pruning-enrichment, reconfiguration, cloning, go with the winner, spawning, condensation, grouping, rejuvenations, harmony searches, biomimetics, ...

- 1 Les processus d'évolution génétique
- 2 Évolution d'arbres généalogiques
- 3 QQ domaines d'application
- 4 Les intégrales de chemins de Feynman
- 5 Théorie champ moyen
 - Chaines de Markov non linéaires
 - Interprétations particulières

Flot (non linéaires) de mesures de probabilités

- Flots non linéaires : $[\Phi_n : \text{Proba} \mapsto \text{Proba}]$

$$\eta_n = \Phi_n(\eta_{n-1})$$

- \exists Famille de transitions Markov $K_{n,\eta}$ (pas unique!)

$$\begin{aligned}\eta_n(dy) &= \Phi_n(\eta_{n-1})(dy) \\ &= (\eta_{n-1} K_{n,\eta_{n-1}})(dy) := \int \eta_{n-1}(dx) K_{n,\eta_{n-1}}(x, dy)\end{aligned}$$

Ex. : Mesures de Feynman-Kac

$$\eta_n \xrightarrow{\text{Correction}} \widehat{\eta}_n = \Psi_{G_n}(\eta_n) \xrightarrow{\text{Prédiction}} \eta_{n+1} = \widehat{\eta}_n M_{n+1}$$

Transf. de Boltzmann-Gibbs : $G_n(x)$ =vraisemblance/qualité du site x

$$\Psi_{G_n}(\eta_n)(dx) := \frac{1}{\eta_n(G_n)} G_n(x) \eta_n(dx) = \eta_n S_{n,\eta_n}(dx)$$

avec le transport

$$S_{n,\eta_n}(x, dy) := G_n(x) \delta_x(dy) + (1 - G_n(x)) \Psi_n(\eta_n)(dy)$$

⇓

$$\eta_{n+1} = \eta_n S_{n,\eta_n} M_{n+1}$$

Chaines de Markov \overline{X}_n non linéaires t.q. $\eta_n = \text{Loi}(\overline{X}_n)$

- **Transitions locales :**

$$\mathbb{P}(\overline{X}_n \in dx_n \mid \overline{X}_{n-1}) = K_{n,\eta_{n-1}}(\overline{X}_{n-1}, dx_n)$$

- **Mesure de McKean (processus canonique) :**

$$\mathbb{P}_n(d(x_0, \dots, x_n)) = \eta_0(dx_0) K_{1,\eta_0}(x_0, dx_1) \dots K_{n,\eta_{n-1}}(x_{n-1}, dx_n)$$

Interprétation particulière de type champ moyen

- Chaine Markov $\xi_n = (\xi_n^1, \dots, \xi_n^N) \in E_n^N$ t.q.

$$\eta_n^N := \frac{1}{N} \sum_{1 \leq i \leq N} \delta_{\xi_n^i} \simeq_{N \uparrow \infty} \eta_n$$

- Transitions locales "approchées" ($\forall 1 \leq i \leq N$)

$$\xi_{n-1}^i \rightsquigarrow \xi_n^i \sim K_{n,\eta_{n-1}^N}(\xi_{n-1}^i, dx_n)$$

Modèle champ moyen temps discret

Figure schématique : $\xi_n \in E_n^N \rightsquigarrow \xi_{n+1} \in E_{n+1}^N$

$$\begin{array}{ccc} \xi_n^1 & \xrightarrow{K_{n+1,\eta_n^N}} & \xi_{n+1}^1 \\ \vdots & & \vdots \\ \xi_n^i & \xrightarrow{\quad} & \xi_{n+1}^i \\ \vdots & & \vdots \\ \xi_n^N & \xrightarrow{\quad} & \xi_{n+1}^N \end{array}$$

Idée intuitive :

$$\begin{aligned} \eta_n^N &\simeq_{N \uparrow \infty} \eta_n \implies K_{n+1,\eta_n^N} \simeq_{N \uparrow \infty} K_{n+1,\eta_n} \\ &\implies \xi_n^i \text{ copies i.i.d. de } \bar{X}_n \end{aligned}$$

& les mesures de McKean trajectorielles :

$$\frac{1}{N} \sum_{i=1}^N \delta_{(\xi_0^i, \xi_1^i, \dots, \xi_n^i)} \longrightarrow_{N \uparrow \infty} \eta_0 \times K_{1,\eta_0} \times \dots \times K_{n,\eta_{n-1}}$$

QQ Avantages

- Modèle de champ moyen = linéarisation / perturbation stoch. :

$$\eta_n^N = \eta_{n-1}^N K_{n,\eta_{n-1}^N} + \frac{1}{\sqrt{N}} W_n^N$$

avec $W_n^N \simeq W_n$ Champs gaussiens centrés et \perp .

- $\eta_n = \eta_{n-1} K_{n,\eta_{n-1}}$ stable \Rightarrow non propagation des erreurs locales
 \implies control uniforme des erreurs globales / temps
- "Pas besoin" d'étudier la cv à l'équilibre de modèles MCMC.
- Grille/Maillage stochastique adaptatif.
- Non linéarité du syst. \rightsquigarrow interactions bénéfiques.
- Algo. naturel et facile à simuler, etc.

Theorie "asymptotique" TCL,PGD, PDM,...(n,N). QQ exemples :

- Mesure McKean particulière

$$\frac{1}{N} \sum_{i=1}^N \delta_{(\xi_0^i, \dots, \xi_n^i)} \simeq_N \text{Loi}(\bar{X}_0, \dots, \bar{X}_n) \quad \text{et} \quad \eta_n^N = \frac{1}{N} \sum_{i=1}^N \delta_{\xi_n^i} \simeq_N \eta_n$$

- Proc. empiriques : $\sup_{n \geq 0} \sup_{N \geq 1} \sqrt{N} \mathbb{E}(\|\eta_n^N - \eta_n\|_{\mathcal{F}_n}^p) < \infty$
- Inégalités de concentration uniformes :

$$\sup_{n \geq 0} \mathbb{P}(|\eta_n^N(f_n) - \eta_n(f_n)| > \epsilon) \leq c \exp(-(N\epsilon^2)/(2\sigma^2))$$

- Propagations du chaos : $\mathbb{P}_{n,q}^N := \text{Loi}(\xi_n^1, \dots, \xi_n^q)$

$$\mathbb{P}_{n,q}^N \simeq \eta_n^{\otimes q} + \frac{1}{N} \partial^1 \mathbb{P}_{n,q} + \dots + \frac{1}{N^k} \partial^k \mathbb{P}_{n,q} + \frac{1}{N^{k+1}} \partial^{k+1} \mathbb{P}_{n,q}^N$$

avec $\sup_{N \geq 1} \|\partial^{k+1} \mathbb{P}_{n,q}^N\|_{\text{tv}} < \infty$ et $\sup_{n \geq 0} \|\partial^1 \mathbb{P}_{n,q}\|_{\text{tv}} \leq c q^2$.