

Groupe de travail du 24/01: introduction aux systèmes de particules en interaction

Introduction

$$(X_1(t), \dots, X_N(t)) \in (\mathbb{R}^d)^N \quad N \text{ grand}$$

Dynamique = ODE ou SDE couplées.

Idee : représenter le système par une
mesure sur \mathbb{R}^d :

$$\hat{\mu}_t^N = \frac{1}{N} \sum_{i=1}^N \delta(x - X_i(t)) = \text{mesure empirique.}$$

On espère que $\hat{\mu}_t^N$ a une limite pour
 $N \rightarrow \infty$, par exemple $f(x, t) dx$.

A quoi ça sert ?

① Modélisation (physique, bio, économie...)
On cherche une équation pour $f(x, t)$
(une EDP) et on l'étudie.

② Méthode numérique : on a une
EDP non linéaire ; on cherche un système
de particules, dont la mesure empirique
est proche d'une solution de l'EDP.
→ facile à programmer.

Réseaux de neurones = différent.

$f: \Omega \subset \mathbb{R}^d \longrightarrow \mathbb{R}$: on cherche à
approximer f .

$$f^{(n)}(\Theta, x) = \frac{1}{n} \sum_{i=1}^n c_i \cdot \sigma(w_i \cdot x + b_i)$$

$$\Theta_i = (c_i, w_i, b_i)$$

On cherche à optimiser les θ_i , en utilisant les données.

Apprentissage (stochastic gradient dynamics)

→ dynamique sur les θ_i

→ système de particules en interaction.

I Convergence de la mesure empirique.

(0) A un instant donné

$\hat{\mu}^N$ = mesure aléatoire, donc la loi de $\hat{\mu}^N$ est un objet un peu compliqué...

Lemme: $\hat{\mu}^N \xrightarrow{\mathcal{L}} \mu$ μ = mesure déterministe

$$\Leftrightarrow \forall \varphi \in \mathcal{C}_b(\mathbb{R}^d) \quad \mathbb{E}_{\mu^{(N)}} \left[\left| \int \varphi d\hat{\mu}^N - \int \varphi d\mu \right| \right] \xrightarrow[N \rightarrow \infty]{} 0$$

mesure empirique construite à partir de la mesure à N particules $\mu^{(N)}$.

Ex: $\mu^{(N)} = \mu^{\otimes N}$ (les X_i sont i.i.d.)

$$\int \varphi d\mu_N = \frac{1}{N} \sum \varphi(x_i)$$

$$E \left[\left| \frac{1}{N} \sum \varphi(x_i) - \int \varphi d\mu \right| \right] \xrightarrow{N \rightarrow \infty} 0$$

Def: Soit $(\mu^{(N)})_{N \in \mathbb{N}}$ une suite de mesures sur $(\mathbb{R}^d)^N$.

$(\mu^{(N)})$ est μ -chaotique si $\forall k \in \mathbb{N}$
 $\forall \varphi_1, \dots, \varphi_k \in \mathcal{C}_c(\mathbb{R}^d)$

$$\int \varphi_1(x_1) \dots \varphi_k(x_k) d\mu^{(N)}(x) \xrightarrow{N \rightarrow \infty} \left(\int \varphi_1 d\mu \right) \dots \left(\int \varphi_k d\mu \right)$$

ie: la loi $\mu^{(N)}$ "ressemble à une loi produit".

Théo: Soit $(\mu^{(N)})_{N \in \mathbb{N}}$ une suite de mesures sur $(\mathbb{R}^d)^N$ symétriques. Alors il y a équivalence entre:

i) $(\mu^{(n)})$ μ -chaotique

ii) $\forall \varphi_1, \varphi_2 \in \mathcal{C}_b(\mathbb{R}^d)$
$$\int_{(\mathbb{R}^d)^N} \varphi_1(x_1) \varphi_2(x_2) d\mu^{(n)}(x) \xrightarrow{N \rightarrow \infty} \left(\int_{\mathbb{R}^d} \varphi_1 d\mu \right) \left(\int_{\mathbb{R}^d} \varphi_2 d\mu \right)$$

iii) $\hat{\mu}^N \xrightarrow{\mathcal{L}} \mu$.

→ montrer que $\hat{\mu}^N$ a un comportement déterministe quand $N \rightarrow \infty$, c'est la même chose que montrer la chaotique de $\mu^{(n)}$.

→ importance de la "propagation du chaos".

Preuve :

ii) \Rightarrow iii) $\varphi \in \mathcal{C}_b$.

$$\begin{aligned} \left[\int \varphi d\hat{\mu}_N - \int \varphi d\mu \right]^2 &= \frac{1}{N^2} \sum_i \varphi(x_i)^2 + \frac{1}{N^2} \sum_{i \neq j} \varphi(x_i) \varphi(x_j) \\ &+ \left(\int \varphi d\mu \right)^2 - 2 \left(\int \varphi d\mu \right) \left[\frac{1}{N} \sum_i \varphi(x_i) \right] \end{aligned}$$

On prend l'espérance :

$$\mathbb{E} \left(\left(\frac{1}{N} \mathbb{E}(\varphi(x_1)^2) + \frac{N-1}{N} \mathbb{E}(\varphi(x_1)\varphi(x_2)) \right) + \left(\int \varphi d\mu \right)^2 - 2 \left(\int \varphi d\mu \right) \mathbb{E}(\varphi(x_1)) \right)$$

Par l'hypothèse ii) $\mathbb{E}(\varphi(x_1)) \rightarrow \int \varphi d\mu$
 et $\mathbb{E}(\varphi(x_1)\varphi(x_2)) \rightarrow \left(\int \varphi d\mu \right)^2$

$$\text{Donc } \mathbb{E} \left(\left| \int \varphi d\hat{\mu}^N - \int \varphi d\mu \right| \right) \xrightarrow{N \rightarrow \infty} 0$$

(Cauchy-Schwarz).

(ici) \rightarrow (i) On fait le cas $k=2$.

$$\int_{(\mathbb{R}^d)^N} \varphi_1(x_1) \varphi_2(x_2) d\mu^{(N)} - \int \varphi_1 d\mu \int \varphi_2 d\mu =$$

$$\int_{(\mathbb{R}^d)^N} \varphi_1(x_1) \varphi_2(x_2) d\mu^{(N)} - \int_{(\mathbb{R}^d)^N} \left(\int \varphi_1 d\hat{\mu}^N \right) \left(\int \varphi_2 d\hat{\mu}^N \right) d\mu^{(N)}$$

①

$$+ \int_{(\mathbb{R}^d)^N} \left(\int \varphi_1 d\tilde{\mu}_N \right) \left(\int \varphi_2 d\tilde{\mu}_N \right) d\mu^{(N)} - \left(\int \varphi_1 d\mu \right) \left(\int \varphi_2 d\mu \right)$$

②

② $\rightarrow 0$ par (iii) avec la fonction $\phi: \gamma \rightarrow \frac{\int \varphi_1 dV}{\int \varphi_2 dV}$
on a $E \phi(\tilde{\mu}^N) \rightarrow E \phi(\mu)$

$$\begin{aligned} \textcircled{1} &= \dots + \int_{(\mathbb{R}^d)^N} \frac{1}{N^2} \sum_{i,j} \varphi_1(x_i) \varphi_2(x_j) d\mu^{(N)}(x) \\ &= \dots + \frac{1}{N} \int_{(\mathbb{R}^d)^N} \varphi_1(x_1) \varphi_2(x_1) d\mu^{(N)}(x) \\ &\quad + \frac{N-1}{N} \int_{(\mathbb{R}^d)^N} \varphi_1(x_1) \varphi_2(x_2) d\mu^{(N)}(x) \end{aligned}$$

On a utilisé la symétrie.

2°) Evolution temporelle.

a) Déterministe, sans interaction

$$\begin{cases} \dot{X}_i = K(X_i) \\ X_i(t=0) \sim \mu_0 \text{ (iid)} \end{cases}$$

$$T_t: \mathbb{R}^d \longrightarrow \mathbb{R}^d = \text{flot associé}$$

$$\text{loi de } X_i(t) \equiv \mu(t) = \underbrace{T_t \# \mu_0}$$

mesure μ_0 transportée
par le flot.

Alors : * Pour toute fonction test φ

$$\int \varphi d\mu_t = \int \varphi \circ T_t d\mu_0$$

$$* \mu_t \text{ solution de } \partial_t \mu_t + \nabla \cdot (K \cdot \mu_t) = 0$$

équation de
transport.

$$* \hat{\mu}_t^N \text{ proche de } \mu_t \text{ pour } N \text{ grand (LGN)}$$

b) Déterministe, avec interaction

NB: premier cas important pour les réseaux de neurones.

$$\begin{cases} \dot{X}_i = \frac{1}{N} \sum_j K(X_j, X_i) \\ X_i(t=0) \sim \mu_0 \end{cases} \quad (1)$$

Idée: Si $\hat{\mu}_t^N$ proche de μ_t , alors

$$\frac{1}{N} \sum_j K(X_j, X_i) = \int_{\mathbb{R}^d} K(x, X_i) d\hat{\mu}_t^N(x)$$

proche de $\int_{\mathbb{R}^d} K(x, X_i) d\mu_t(x) = \bar{K}[\mu_t](X_i)$

$$\dot{y} = \bar{K}[\mu_t](y) \rightarrow \text{flot } T_t[\mu]: \mathbb{R}^d \rightarrow \mathbb{R}^d$$

On cherche que μ_t solution de:

$$\partial_t \mu_t + \nabla \cdot (\bar{K}[\mu_t] \mu_t) = 0 \quad (2)$$

Remarque: $\hat{\mu}_t^N$ construite à partir de (1) est solution de (2).

Donc la question de savoir si $\hat{\mu}_t^N$ est proche de μ_t est une question sur la stabilité des solutions de (2).

Théo: $L_M > 0$ fixé. $\sup_{0 \leq t \leq L_M} W_1(\hat{\mu}_t^N, \mu_t) \xrightarrow{N \rightarrow \infty} 0$.
 $W_1(\hat{\mu}_0^N, \mu_0) \xrightarrow{N \rightarrow \infty} 0$

W_1 = distance de Wasserstein d'ordre 1.

$$W_1(\mu, \nu) = \sup_{\text{Lip}(f) \leq 1} \left| \int f d(\mu - \nu) \right|$$

$$= \inf_{\substack{(X, Y) \in \mathcal{P} \\ X \sim \mu \\ Y \sim \nu}} \mathbb{E} |X - Y|$$

⚠ Vitesse de convergence pas donnée ici

⚠ Pas d'uniformité en temps. On y reviendra.

Preuve: Soient μ_t, ν_t 2 solutions de ②
avec CI μ_0, ν_0 .

$$\text{Alors } [W_1(\mu_t, \nu_t) \leq e^{2L_K t} W_1(\mu_0, \nu_0)]$$

$y \mapsto K(y, x)$ L_K -lipschitzienne, $\forall x$.

→ pas uniforme en temps; la convergence
se dégrade rapidement en temps grand.

$$W_1(\mu_t, \nu_t) \leq W_1(T_t[\mu] \# \mu_0, T_t[\mu] \# \nu_0) \quad \textcircled{a} \\ + W_1(T_t[\mu] \# \nu_0, T_t[\nu] \# \nu_0) \quad \textcircled{b}$$

$$\textcircled{a}: \leq \left| \int \varphi \circ T_t[\mu] d(\mu_0 - \nu_0) \right| \quad \forall \varphi, \text{Lip}(\varphi) \leq 1 \\ \leq \text{Lip}(T_t[\mu]) W_1(\mu_0, \nu_0) \\ \leq e^{L_K t} W_1(\mu_0, \nu_0)$$

$$\textcircled{b} \leq \left| \int (\varphi \circ T_t[\mu] - \varphi \circ T_t[\nu]) d\nu_0 \right| \leq \underbrace{\int |T_t[\mu] - T_t[\nu]| d\nu_0}_{= \lambda(t)}$$

$$\begin{aligned} \frac{d\lambda}{dt} &\leq \int |\bar{k}[\mu_t] \circ \bar{\tau}_t[\mu] - \bar{k}[v_t] \circ \bar{\tau}_t[v]| dv_0 \\ &\leq \int |\bar{k}[\mu_t] \circ \bar{\tau}_t[\mu] - \bar{k}[\mu_t] \circ \bar{\tau}_t[v]| dv_0 \quad b_1 \\ &\quad + \int |\bar{k}[\mu_t] \circ \bar{\tau}_t[v] - \bar{k}[v_t] \circ \bar{\tau}_t[v]| dv_0 \quad b_2 \end{aligned}$$

$$b_1 \leq \text{Lip}(\bar{k}[\mu_t]) \lambda(t) \leq L_K \lambda(t)$$

$$\begin{aligned} b_2 &= \int |\bar{k}[\mu_t] - \bar{k}[v_t]| dv_t \\ &= \int \left| \int k(y, x) d\mu_t(y) - \int k(y, x) dv_t(y) \right| dv_t(x) \\ &\leq L_K \int W_1(\mu_t, v_t) dv_t(x) = L_K W_1(\mu_t, v_t) \end{aligned}$$

$$\text{Denc } \frac{d\lambda}{dt} \leq L_K \lambda + L_K W_1(\mu_t, v_t)$$

$$(\text{Gronwall}) \quad \lambda(t) \leq L_K e^{L_K t} \int_0^t W_1(\mu_s, v_s) e^{-L_K s} ds$$

$$\Rightarrow W_1(\mu_t, v_t) \leq e^{L_K t} W_1(\mu_0, v_0) + L_K e^{L_K t} \int_0^t W_1(\mu_s, v_s) e^{-L_K s} ds$$

$$(\text{Gronwall}) \quad W_1(\mu_t, v_t) \leq W_1(\mu_0, v_0) e^{2Ct}$$

c) Evolution aléatoire, sans interaction

$$dX_i = K(X_i^t) dt + \sqrt{2} dB_i^t$$

$$\text{loi de } X_i^t = f(x, t) dx$$

$$\partial_t f = \nabla \cdot (-K(x) f(x) + \nabla f(x))$$

d) Evolution aléatoire, avec interaction

$$dX_i^t = \frac{1}{N} \sum_j K(X_j^t, X_i^t) dt + \sqrt{2} dB_i^t$$

$$\text{Limite attendue: } \partial_t f = \nabla \cdot (-\bar{K}[f] f + \nabla f) \quad \textcircled{1}$$

$$\text{avec } \bar{K}[f] = \int K(x, y) f(y) dy$$

Problème: $\hat{\mu}_t^N$ n'est plus solution de $\textcircled{1}$.

Idee: Introduire les particules \bar{X}_i

$$d\bar{X}_i = \bar{K}[f_t](\bar{X}_i^t) dt + \sqrt{2} dB_i^t$$

le même que pour les X_i

densité \bar{f}

$$\text{Alors } \partial_t \bar{f} = \nabla \cdot (-\bar{K}[f_t] \bar{f} + \nabla \bar{f})$$

Donc $\bar{f} = f$! (unicité de la solution de l'EDP).

Remarque : les \bar{X}_i sont indépendants

$$\begin{aligned} \frac{d(X_i - \bar{X}_i)}{dt} &= \frac{1}{N} \sum_j K(X_j, X_i) - \bar{K}[f_t](X_i) \\ &= \frac{1}{N} \sum_j [K(X_j, X_i) - K(\bar{X}_j, \bar{X}_i)] \quad \left. \vphantom{\sum_j} \right\} \text{contrôle par } |X - \bar{X}| \\ &\quad + \underbrace{\frac{1}{N} \sum_j [K(\bar{X}_j, \bar{X}_i) - \bar{K}[f_t](X_i)]}_{\text{petit par LGN}} \\ &\quad \text{puis Gronwall} \end{aligned}$$

\Rightarrow à nouveau en contrôle pour tout horizon temporel fini, mais pas pour $t \rightarrow \infty \dots$

II Structure de flot gradient

Outil important pour aborder le comportement au temps grand.

Dimension finie : $\dot{x} = -\nabla U(x)$ $U: \mathbb{R}^d \rightarrow \mathbb{R}$

$$\text{alors } \frac{dU(x_t)}{dt} = -|\nabla U(x_t)|^2 \leq 0$$
$$= 0 \text{ seulement si } \nabla U|_{x_t} = 0$$

→ très utile pour la convergence en temps grand; le "paysage" de U contient toute la dynamique.

Remarque : discrétisation en temps

$$x(t+\Delta t) = \arg \min_y \left(\frac{1}{2\Delta t} \|y - x_t\|^2 + U(y) \right)$$

2 ingrédients : fonctionnelle U et métrique, ici norme euclidienne.

Pour des mesures : distance de Wasserstein W_2

$$W_2^2(\mu, \nu) = \inf_{\substack{X \sim \mu \\ Y \sim \nu}} \mathbb{E}(|X - Y|^2)$$

$$\mu_{t+\Delta t} = \arg\min_{\mu} \left(\frac{1}{2\Delta t} W_2^2(\mu_t, \mu) + U(\mu) \right)$$

$$\underline{\text{Ex}} : U(\mu) = \int V d\mu + \frac{1}{2} \int W(x, y) d\mu(x) d\mu(y)$$

Alors μ_t satisfait l'équation :

$$\partial_t \mu_t = \nabla \cdot \left(\mu_t \nabla \frac{\delta U}{\delta \mu} \right)$$

← équation de transport

$$\frac{\delta U}{\delta \mu} = V + \int W(x, y) d\mu(y)$$

Nuage de points :

$$\begin{array}{cccc} x_1 & x_2 & y_1 & y_2 \\ x & x & x & x \\ x_3 & x_4 & y_3 & y_4 \end{array}$$

$$W_2^2(\hat{\mu}_t^N, \hat{\mu}_g^N) = \frac{1}{N} \sum_i (y_i - x_i)^2 \quad (\text{couplage trivial, OK si } \Delta t \text{ petit})$$

$$U(\hat{\mu}_g^N) = \frac{1}{N} \sum_i V(y_i) + \frac{1}{2N^2} \sum_{i,j} W(y_i, y_j)$$

argmin

$$\rightarrow \forall i \quad \frac{y_i - x_i}{\Delta t} = -\nabla V(y_i) - \frac{1}{N} \sum_j \nabla_i W(y_i, y_j)$$

\uparrow
hyp W symétrique.

$$\Rightarrow y_i = x_i - \Delta t \left[\nabla V(y_i) + \frac{1}{N} \sum_j \nabla_i W(y_i, y_j) \right]$$

$$\dot{X}_i = -\nabla V(X_i) - \frac{1}{N} \sum_j \nabla W(X_i, X_j)$$

$$= -\nabla_i U^N(X_1, \dots, X_N)$$

$$U^N(X_1, \dots, X_N) = \frac{1}{N} \sum_i U(X_i) + \frac{1}{2N^2} \sum_{i,j} W(X_i, X_j)$$

Remarque: si $U(\mu) = \int f \ln f dx$ et $\mu = f dx$

flot gradient: $\partial_t f = +\nabla \cdot (f \nabla \ln f) = \Delta f$
diffusion!