

# Optimisation de champ moyen régularisé par l'information de Fisher

Julien CLAISSE <sup>1</sup> Giovanni CONFORTI <sup>2</sup> Zhenjie REN <sup>1</sup> Songbo WANG <sup>2</sup>

<sup>1</sup>CEREMADE, Université Paris-Dauphine

<sup>2</sup>CMAP, École Polytechnique

01/06/2022

- 1 Le problème
- 2 Condition du premier ordre
- 3 La dynamique
- 4 HJB CM
- 5 Décroissance d'énergie
- 6 Convergence
- 7 Descente de gradient

- 1 Le problème
- 2 Condition du premier ordre
- 3 La dynamique
- 4 HJB CM
- 5 Décroissance d'énergie
- 6 Convergence
- 7 Descente de gradient

## Motivations

On s'intéresse aux réseaux de neurones.

Cas : une seule couche cachée.

$i = 1, \dots, n$  – neurones.

$\varphi : \mathbb{R} \rightarrow \mathbb{R}$  – fonctions d'activation, e.g.  $\varphi(x) = x_+$  (ReLU).

Perte quadratique.

Problème : minimiser

$$F(n, a, b, c) = \mathbf{E} \left[ \left| f(Z) - \frac{1}{n} \sum_{i=1}^n c_k \varphi(a_k Z + b_k) \right|^2 \right].$$

Quand  $n \rightarrow \infty$ ,

$$F \rightarrow \mathbf{E} \left[ |f(Z) - \mathbb{E}_m [C \varphi(AZ + B)]|^2 \right]$$

où  $(A, B, C) \sim m$ .

Remarques :  $F$  est convexe en  $m$ . Ce n'est plus vrai pour réseaux profonds ( $\#$  couche  $\geq 2$ ).

# Champ-moyen

On considère une fonction “champ-moyen” générale :

$$F : \mathcal{P}(\mathbb{R}^d) \rightarrow \mathbb{R}.$$

On suppose souvent que  $F$  est continue par rapport à la distance de Wasserstein.

# Régularisation entropique

On fixe une mesure de base.  $H(m)$  est l'entropique relative.

On considère

$$\inf_m F(m) + \frac{\sigma^2}{2} H(m).$$

[Hu, Ren, Šiška, Szpruch, 2019] : la descente de gradient (par apport à Wasserstein) donne la loi marginale de Langevin de champ moyen

$$dX_t = -DF(m_t, X_t) dt + \sigma dW_t, m_t \sim X_t.$$

$m_t$  converge vers l'unique minimiseur de  $F(m) + \frac{\sigma^2}{2} H(m)$ .

# Régularisation de Fisher

L'information de Fisher :

$$I(m) = \int |\nabla \log m|^2 m dx = 4 \int |\nabla \sqrt{m}|^2 dx.$$

On considère

$$\inf_m F(m) + \frac{\sigma^2}{4} I(m) = \inf_m F^\sigma(m).$$

L'espace de probas dont l'information de Fisher est fini :

$$\mathcal{P}_H = \left\{ m \in \mathcal{P}(\mathbb{R}^d) : \sqrt{m} \in H^1 \right\}.$$

On suppose toujours que  $F$  est convexe dans la suite.

- 1 Le problème
- 2 Condition du premier ordre
- 3 La dynamique
- 4 HJB CM
- 5 Décroissance d'énergie
- 6 Convergence
- 7 Descente de gradient



# Différentiabilité d'une fonction CM

## Définition

On dit que  $F: \mathcal{P}(\mathbb{R}^d) \rightarrow \mathbb{R}$  est  $C^1$  s'il existe une continue  $\frac{\delta F}{\delta m}: \mathcal{P}(\mathbb{R}^d) \times \mathbb{R}^d \rightarrow \mathbb{R}$  t.q. pour tout  $m_0, m_1 \in \mathcal{P}$

$$F(m_1) - F(m_0) = \int_0^1 \int \frac{\delta F}{\delta m}(m_t, x) d(m_1 - m_0)(x) dt$$

où  $m_t = (1 - t)m_0 + tm_1, t \in (0, 1)$ .

Remarques :

- 1  $\frac{\delta F}{\delta m}$  est définie à cste près.
- 2 ( $F$  est convexe). Si  $m$  minimise  $F$ , alors  $\frac{\delta F}{\delta m}(m, \cdot)$  est cste.

# Calculs différentiels de l'information de Fisher

Rappel :

$$I(m) = \int \frac{|\nabla m|^2}{m}.$$

On calcule formellement:

$$\begin{aligned} \delta I(m) &= \int \frac{2\nabla m \cdot \nabla \delta m}{m} - \frac{|\nabla m|^2}{m^2} \delta m \\ &= \int \left( -2\nabla \cdot \left( \frac{\nabla m}{m} \right) - \frac{|\nabla m|^2}{m^2} \right) \delta m. \end{aligned}$$

Donc

$$\frac{\delta F^\sigma}{\delta m} = \frac{\delta F}{\delta m} - \frac{\sigma^2}{2} \nabla \cdot \left( \frac{\nabla m}{m} \right) - \frac{\sigma^2}{4} \frac{|\nabla m|^2}{m^2}.$$

# Pour tout rendre rigoureux...

## Théorème

Si  $m \in \mathcal{P}_H$  est t.q.  $m \in L^\infty$ ,  $m^{-1} \in L^\infty_{loc}$ , et

$$\frac{\delta F^\sigma}{\delta m}(m, \cdot) = \frac{\delta F}{\delta m}(m, \cdot) - \frac{\sigma^2}{2} \nabla \cdot \left( \frac{\nabla m}{m} \right) - \frac{\sigma^2}{4} \frac{|\nabla m|^2}{m^2} = \text{cste}$$

au sens de distribution, alors  $m$  est l'unique minimiseur de  $F^\sigma$ .

## Théorème

Si  $m, m' \in \mathcal{P}_H \cap L^\infty$  et que  $m^{-1} \in L^\infty_{loc}$ . (Une certaine croissance de  $m, m'$ .) Alors

$$F^\sigma(m') - F^\sigma(m) \geq \int \frac{\delta F^\sigma}{\delta m}(m, x) (m' - m) dx.$$

- 1 Le problème
- 2 Condition du premier ordre
- 3 La dynamique**
- 4 HJB CM
- 5 Décroissance d'énergie
- 6 Convergence
- 7 Descente de gradient

# Observations

Notons  $\psi = \sqrt{m}$ . La condition du premier ordre est équivalente à

$$cste = \frac{\delta F}{\delta m} - \sigma^2 \nabla \cdot \left( \frac{\nabla \psi}{\psi} \right) - \sigma^2 \frac{|\nabla \psi|^2}{\psi^2} = \frac{\delta F}{\delta m} - \sigma^2 \frac{\Delta \psi}{\psi}$$

$$\Leftrightarrow cste \cdot \psi = \frac{\delta F}{\delta m} \psi - \sigma^2 \Delta \psi.$$

$\psi$  est une fonction propre de l'opérateur de Schrödinger CM

$$\sigma^2 \Delta - \frac{\delta F}{\delta m} (m, \cdot).$$

# Observations

Notons  $u = -\log m$ . La condition du premier ordre est équivalente à

$$cste = \frac{\delta F}{\delta m} + \frac{\sigma^2}{2} \Delta u - \frac{\sigma^2}{4} |\nabla u|^2.$$

C'est une équation HJB CM associée à un problème de contrôle ergodique.

# Définition de la dynamique

On définit la dynamique :

$$\partial_t m_t = - \frac{\delta F^\sigma}{\delta m} (m_t, \cdot) m_t$$

où  $\frac{\delta F}{\delta m}$  est choisie t.q.  $\int \frac{\delta F^\sigma}{\delta m} (m, x) dm = 0$ .

“Sanity check”:  $\partial_t \langle \mathbf{1}, m_t \rangle = 0$ . Conservation de masse.

Formellement  $F^\sigma$  est décroissante :

$$\frac{dF^\sigma (m_t)}{dt} = - \int \left| \frac{\delta F^\sigma}{\delta m} (m_t, \cdot) \right|^2 dm_t$$

On peut espérer que  $m_t \rightarrow$  minimiseur.

# Formulations équivalentes

La dynamique en  $\psi$  :

$$\partial_t \psi_t = \frac{\sigma^2}{2} \Delta \psi_t - \frac{1}{2} \frac{\delta F}{\delta m} (m_t, \cdot) \psi_t$$

– Schrödinger dynamique CM

La dynamique en  $u$ :

$$\partial_t u = \frac{\sigma^2}{2} \Delta u - \frac{\sigma^2}{4} |\nabla u|^2 + \frac{\delta F}{\delta m} (m_t, \cdot)$$

– HJB dynamique CM



- 1 Le problème
- 2 Condition du premier ordre
- 3 La dynamique
- 4 HJB CM**
- 5 Décroissance d'énergie
- 6 Convergence
- 7 Descente de gradient

# Hypothèses

$F$  est continue par apport à  $\mathcal{W}_1$  et convexe.

$F \in C^1$  et sa dérivée  $\frac{\delta F}{\delta m}$  peut se décomposer

$$\frac{\delta F}{\delta m}(m, x) = g(x) + G(m, x)$$

où

- 1  $\kappa \text{id} \leq \nabla^2 g \leq C \text{id}$ ;
- 2  $G$  est uniformément Lipschitzienne en  $x$  :  $\sup_m \|\nabla G(m, \cdot)\|_\infty \leq L_G$ .
- 3  $\nabla G$  est Lipschitzienne en  $m, x$  :  $\forall m, m', x, x'$

$$|\nabla G(m, x) - \nabla G(m', x')| \leq L_G (\mathcal{W}_1(m, m') + |x - x'|).$$

# Décomposition

$$\begin{aligned}\partial_t u &= \frac{\sigma^2}{2} \Delta u - \frac{\sigma^2}{4} |\nabla u|^2 + \frac{\delta F}{\delta m}(m_t, \cdot) \\ &= \frac{\sigma^2}{2} \Delta u - \frac{\sigma^2}{4} |\nabla u|^2 + g + G(m_t, \cdot)\end{aligned}$$

On veut décomposer la fonction valeur  $u = v + w$  où  $v, w$  résolvent resp.

$$\begin{aligned}\partial_t v &= \frac{\sigma^2}{2} \Delta v - \frac{\sigma^2}{4} |\nabla v|^2 + g \\ \partial_t w &= \frac{\sigma^2}{2} \Delta w - \frac{\sigma^2}{2} \nabla v \cdot \nabla w - \frac{\sigma^2}{4} |\nabla w|^2 + G(m_t, \cdot)\end{aligned}$$

## Convexité de $v$

$$\partial_t v = \frac{\sigma^2}{2} \Delta v - \frac{\sigma^2}{4} |\nabla v|^2 + g.$$

L'équation est classique. On a l'existence et l'unicité du problème de valeur initiale. De plus, on a

### Proposition

Si  $v_0 = v(0, \cdot)$  est  $\theta_0$ -convexe, alors  $v_t = v(t, \cdot)$  est  $\theta_t$ -convexe où  $\theta_t$  résout

$$\frac{d\theta_t}{dt} = \kappa - \frac{\sigma^2}{2} \theta_t^2$$

Heuristiques :

$$\partial_t \nabla^2 v = \frac{\sigma^2}{2} \Delta \nabla^2 v - \frac{\sigma^2}{2} \nabla v \cdot \nabla \nabla^2 v - \frac{\sigma^2}{2} \nabla^2 v \nabla^2 v + \nabla^2 g$$

## Estimée a priori de $w$

### Proposition

*On suppose que  $w$  résout classiquement sur  $[0, T]$*

$$\partial_t w = \frac{\sigma^2}{2} \Delta w - \frac{\sigma^2}{2} \nabla v \cdot \nabla w - \frac{\sigma^2}{4} |\nabla w|^2 + L(t, x)$$

*où  $L$  est uniformément Lipschitzienne en  $x$  et la valeur initiale  $w_0 = w(0, \cdot)$  est aussi Lipschitzienne. On suppose de plus que  $w, \nabla w$  sont à croissance polynomiale. Alors  $w$  est uniformément Lipschitzienne en  $x$ , dont la constante peut être indépendante de  $T$ .*

## Estimée a priori de $w$ : preuve

$$\partial_t w = \frac{\sigma^2}{2} \Delta w - \frac{\sigma^2}{2} \nabla v \cdot \nabla w + \frac{\sigma^2}{2} \inf_{\alpha} \left\{ -\alpha \cdot \nabla w + \frac{1}{2} |\alpha|^2 \right\} + L(t, x)$$

On applique le théorème de vérification pour retrouver la rep. contrôle sto :

$$w(t, x) = \inf_{\alpha} \mathbb{E} \left[ \int_0^t L(t-s, X_s) + \frac{\sigma^2}{4} |\alpha_s|^2 ds + w(0, X_t) \right]$$
$$dX_s = -\frac{\sigma^2}{2} (\alpha_s + \nabla v_{t-s}(X_s)) ds + \sigma dW_s, \quad X_0 = x$$

L'infimum est atteint par  $\alpha_s^* = \nabla w_{t-s}(X_s)$ .

On définit  $X'$  partant de  $x'$ , avec le contrôle optimal pour  $x$ , en utilisant le même BM :

$$w(t, x') \leq \mathbb{E} \left[ \int_0^t L(t-s, X'_s) + \frac{\sigma^2}{4} |\alpha_s|^2 ds + w(0, X'_t) \right]$$
$$dX'_s = -\frac{\sigma^2}{2} (\alpha_s + \nabla v_{t-s}(X'_s)) ds + \sigma dW_s, \quad X'_0 = x'$$

## Estimée a priori de $w$ : preuve

$$d(X_s - X'_s) = -\frac{\sigma^2}{2} (\nabla v_{t-s}(X_s) - \nabla v_{t-s}(X'_s)) ds$$

$v_s$  est  $\theta_s$ -convexe. Alors

$$|X_s - X'_s| \leq C e^{-cs} |x - x'|$$

Soustraire les reps. de  $w(t, x), (w(t, x'))$  :

$$\begin{aligned} w(t, x) - w(t, x') &\leq \mathbb{E} \left[ \int_0^t L(t-s, X_s) - L(t-s, X'_s) ds \right. \\ &\quad \left. + w(0, X_t) - w(0, X'_t) \right] \\ &\leq \mathbb{E} \left[ \int_0^t \|L\|_{\text{Lip}} |X_s - X'_s| ds + \|\nabla w_0\|_{\infty} |X_t - X'_t| \right] \\ &\leq C |x - x'| \end{aligned}$$

# Couplage de réflexion

## Théorème (Eberle, 2011)

Soient  $b_1, b_2 : \mathbb{R}^d \rightarrow \mathbb{R}$  où  $b_1$  est strictement décroissant:

$$(x - y) \cdot (b_1(x) - b_1(y)) \leq -\theta |x - y|^2$$

et  $b_2$  est borné.  $b = b_1 + b_2$ . Si la diffusion  $dX_t = b(X_t) dt + dW_t$  n'explode pas, alors il existe cstes  $c, C$  t.q. pour toutes lois marginales  $m_t, m'_t$  de la diffusion dont  $m_0 = \delta_x, m'_0 = \delta_{x'}$ , on a

$$\mathcal{W}_1(m_t, m'_t) \leq Ce^{-ct} |x - x'|.$$



## Caractère bien posé

$$\partial_t w = \frac{\sigma^2}{2} \Delta w - \frac{\sigma^2}{2} \nabla v \cdot \nabla w - \frac{\sigma^2}{4} |\nabla w|^2 + G(m_t, \cdot)$$

Par contre, cette équation n'est pas classique. On doit montrer à la main qu'elle est bien posée.

Considérons la suite d'applications  $w \mapsto m \mapsto \bar{w}$ , où

$$m_t = \exp(-v_t - w_t)$$
$$\partial_t \bar{w} = \frac{\sigma^2}{2} \Delta \bar{w} - \frac{\sigma^2}{2} \nabla v \cdot \nabla \bar{w} - |\nabla \bar{w}|^2 + G(m_t, \cdot)$$

On mesure la différence entre  $w, w'$  par  $\sup_{t \in [0, T]} \|\nabla w - \nabla w'\|$ . Avec la normalisation c'est une vraie norme.

On veut que l'application composée  $w \mapsto \bar{w}$  soient une contraction pour  $T$  petit.

$w \mapsto m$

Soient  $\bar{m}_t = \exp(-v_t - w_t)$ ,  $\bar{m}' = \exp(-v_t - w'_t)$ .  $\bar{m}_t$  est la mesure invariante de diffusion

$$dX_h = -\nabla v_t(X_h) dh - \nabla w_t(X_h) dh + \sqrt{2}dW_t$$

et pareil pour  $\bar{m}'$ . On utilise encore la méthode de réflexion pour construire un couplage t.q.

$$\begin{aligned} \mathcal{W}_1(\bar{m}_t, \bar{m}'_t) &\leq C \mathbb{E} \left[ \int_0^\infty e^{-ch} |\nabla w_t(X_h) - \nabla w'_t(X_h)| dh \right] \\ &\leq C \|\nabla w_t - \nabla w'_t\|. \end{aligned}$$

$m \mapsto \bar{w}$

Soient  $m, m' \in C([0, T]; \mathcal{W}_1)$ . Notons  $\delta\bar{w} = \bar{w} - \bar{w}'$ .  $\delta\bar{w}$  satisfait

$$\partial_t \delta\bar{w} = \frac{\sigma^2}{2} \Delta \delta\bar{w} - \frac{\sigma^2}{2} \nabla v \cdot \nabla \delta\bar{w} - \frac{\sigma^2}{2} (\nabla \bar{w} + \nabla \bar{w}') \cdot \nabla \delta\bar{w} + G - G'$$

On a représentation probabiliste

$$\delta\bar{w}(t, x) = \mathbb{E} \left[ \int_0^t (G - G')(t - s, X_s) ds + \delta\bar{w}(0, X_t) \right]$$

$$dX_s = -\frac{\sigma^2}{2} \nabla v(t - s, X_s) - \frac{\sigma^2}{2} (\nabla \bar{w} + \nabla \bar{w}')(t - s, X_s) + \sigma dW_s, s \leq t$$

$$X_0 = x.$$

Observons que le drift de  $X = \theta_{t-s}$ -monotone + borné. On utilise le *couplage de réflexion* pour trouver un  $X'$  partant de  $x'$ , satisfaisant l'équation de diffusion t.q.  $\mathbb{E} |X_s - X'_s| \leq C |x - x'|$ .

$$\sup_{t \in [0, T]} \|\delta \nabla \bar{w}(t, \cdot)\|_\infty \leq CT \sup_{t \in [0, T]} \mathcal{W}_1(m_t, m'_t) + C \|\delta \nabla \bar{w}(0, \cdot)\|_\infty.$$

- 1 Le problème
- 2 Condition du premier ordre
- 3 La dynamique
- 4 HJB CM
- 5 Décroissance d'énergie**
- 6 Convergence
- 7 Descente de gradient

## Preuve rigoureuse

On veut rendre rigoureux la formule suivante

$$\frac{dF^\sigma(m_t)}{dt} = - \int \left| \frac{\delta F^\sigma}{\delta m}(m_t, x) \right|^2 m_t dx.$$

Outil: convexité, convergence dominée.

Convexité:

$$\begin{aligned} \int \frac{\delta F^\sigma}{\delta m}(m_{t+h}, x) (m_{t+h} - m_t) dx &\geq F^\sigma(m_{t+h}) - F^\sigma(m_t) \\ &\geq \int \frac{\delta F^\sigma}{\delta m}(m_t, x) (m_{t+h} - m_t) dx \end{aligned}$$

où  $m_t$  résout la dynamique classiquement, i.e.

$$m_{t+h} - m_t = - \int_0^h \int \frac{\delta F^\sigma}{\delta m}(m_{t+r}, x) m_{t+r} dx dr.$$

# Intégrabilité

Pour appliquer convergence dominée, on a besoin de

$$\textcircled{1} \sup_t \left| \frac{\delta F^\sigma}{\delta m}(t, x) \right| \leq C(1 + |x|^2);$$

$$\textcircled{2} \sup_t \int |x|^{4+\delta} m_t dx < +\infty.$$

Rappel :

$$\frac{\delta F^\sigma}{\delta m} = \frac{\delta F}{\delta m} + \frac{\sigma^2}{2} \Delta u - \frac{\sigma^2}{4} |\nabla u|^2$$

A noter que :

$\textcircled{1}$  On peut prouver classiquement (Bernstein, “turnpike”)

$$\sup_t |\nabla v(x)| \leq C(1 + |x|);$$

$\textcircled{2}$   $\nabla u = \nabla v + \nabla w$  dont  $\nabla v$  est à croissant linéaire,  $\nabla w$  borné;

$$\textcircled{3} \sup_t \|\nabla^2 v_t\|_\infty < +\infty;$$

$\textcircled{4}$   $m_t = \exp(-v_t - w_t)$ . On peut utiliser concentration pour montrer que  $\int |x|^p m_t dx < C_p$  pour tout  $p \geq 1$ .

Il nous reste à borner  $\Delta u$ .

## Estimée sur $\nabla^2 u$ : couplage de réflexion

$\nabla u$  résout

$$\partial_t \nabla u = \frac{\sigma^2}{2} \Delta \nabla u - \frac{\sigma^2}{2} \nabla u \cdot \nabla^2 u + \nabla \frac{\delta F}{\delta m}$$

Représentation probabiliste:

$$\begin{aligned} \nabla u(t, x) &= \mathbb{E} \left[ \int_0^t \nabla \frac{\delta F}{\delta m} (m_{t-s}, X_s) + \nabla u(0, X_t) \right] \\ dX_s &= -\sigma^2 \nabla u(t-s, X_s) ds + \sigma dW_s \\ &= -\sigma^2 (\nabla v + \nabla w)(t-s, X_s) ds + \sigma dW_s \end{aligned}$$

Drift = monotone + borné. On utilise le couplage de réflexion pour trouver une proba t.q.  $(X'$  la même diffusion dont le point de départ est  $x'$ )

$$\mathbb{E} |X_s - X'_s| \leq C e^{-cs} |x - x'|.$$

Donc  $\nabla u$  est uniformément Lipschitz en  $x$ , i.e.  $\sup_t \|\nabla^2 u_t\|_\infty < +\infty$ .

- 1 Le problème
- 2 Condition du premier ordre
- 3 La dynamique
- 4 HJB CM
- 5 Décroissance d'énergie
- 6 Convergence**
- 7 Descente de gradient



## Preuve

$$\mathcal{K} := \left\{ (m, \sqrt{m}) : \int |x|^2 m + |\nabla \sqrt{m}|^2 dx \leq C \right\}.$$

Il est connu que  $\mathcal{K}$  est  $\mathcal{W}_1 \otimes$  faible- $H^1$  compact.

$(m_t, \sqrt{m_t}) \in \mathcal{K}$  pour un certain  $C$ .

$\exists (\hat{m}, \sqrt{\hat{m}})$  un point d'accumulation de  $(m_{t_k}, \sqrt{m_{t_k}})$  pour  $t_k \rightarrow \infty$ .

L'énergie est décroissante et finie. Elle ne peut pas décroître infiniment.

$$\frac{dF^\sigma(m_t)}{dt} = - \int \left| \frac{\delta F^\sigma}{\delta m}(m_t, x) \right|^2 m_t dx.$$

Il existe une suite  $h_j \downarrow 0$  t.q.

$$\int \left| \frac{\delta F^\sigma}{\delta m}(m_{t_k+h_j}, x) \right|^2 m_{t_k+h_j} dx \rightarrow 0.$$

On prétends que  $h_j = 0$  dans la suite.

## Preuve (suite)

Pour tout  $m \in L^\infty$ ,

$$\begin{aligned} F^\sigma (m_{t_k}) &\leq F^\sigma (m) + \int \frac{\delta F^\sigma}{\delta m} (m_{t_k}, x) (m - m_{t_k}) dx \\ &\leq F^\sigma (m) + \int_K \frac{\delta F^\sigma}{\delta m} (m_{t_k}, x) (m - m_{t_k}) dx + \varepsilon \\ &\leq F^\sigma (m) + \varepsilon + \\ &\quad \left( \int_K \left| \frac{\delta F^\sigma}{\delta m} (m_{t_k}, x) \right|^2 m_{t_k} dx \right)^{1/2} \left( \int_K \frac{(m - m_{t_k})^2}{m_{t_k}} \right)^{1/2} \end{aligned}$$

On peut prouver que  $m_{t_k}^{-1} \in L_{loc}^\infty$ . Donc

$$F(\hat{m}) \leq \liminf F^\sigma (m_{t_k}) \leq F^\sigma (m).$$

Puis approcher  $m$  quelconque par des mesure borné et conclure.

- 1 Le problème
- 2 Condition du premier ordre
- 3 La dynamique
- 4 HJB CM
- 5 Décroissance d'énergie
- 6 Convergence
- 7 Descente de gradient**

## GD à la JKO (heuristiques)

On mesure la distance entre mesures par l'entropie relative.

A chaque étape,

$$m_{k+1} = \arg \min_m h^{-1} H(m|m_k) + F^\sigma(m)$$

Calculs du premier ordre formels:

$$\begin{aligned} 0 &= h^{-1} \delta \int \log \frac{m}{m_k} m + \delta F^\sigma(m) \\ &= h^{-1} \int \log \frac{m}{m_k} \delta m + \int \frac{\delta F^\sigma}{\delta m}(m, \cdot) \delta m \end{aligned}$$

de sorte que

$$m_{k+1} = \frac{m_k}{Z_k} \exp \left( -h \frac{\delta F^\sigma}{\delta m}(m_{k+1}, \cdot) \right) \approx m_k \left( 1 - h \frac{\delta F^\sigma}{\delta m}(m_{k+1}, \cdot) \right).$$

On espère  $m_{kh} \rightarrow m_t$  quand  $h \rightarrow 0$ .

# Conclusions

- 1 Problème d'optimisation champ-moyen avec Fisher, FOC
- 2 Dynamique (Schrödinger CM, HJB CM, GD entropie-Fisher)
- 3 Convergence (pas de vitesse, encore...)
- 4 Pas du tout de numérique