

# Les inclusions différentielles et l'optimisation convexe

Azzouz Dermoune

Université de Sciences et Technologies de Lille.  
Laboratoire Paul Painlevé-UMR-CNRS 8524, France.

22-24 septembre 2016 Kénitra

- 1) Optimisation convexe et inclusion différentielle.
- 2) Oscillation autour des points d'équilibres.
- 3) Outils mathématiques pour résoudre les inclusions différentielles.
- 4) Schémas numériques.
- 5) Outils mathématiques pour résoudre les oscillations autour des points d'équilibres.

Soit

$$\varphi : \mathbb{R}^p \rightarrow \mathbb{R}$$

une fonction convexe. Les minimums de  $\varphi$  sont solutions de l'inclusion

$$0 \in \partial\varphi(\mathbf{x}).$$

Se sont les points d'équilibre de l'inclusion différentielle

$$0 \in \frac{dx(t)}{dt} + \partial\varphi(x(t)).$$

La sous différentielle de  $\varphi$  au point  $\mathbf{x}$  est définie par

$$\partial \varphi(\mathbf{x}) = \{\mathbf{y} \in \mathbb{R}^p : \forall \mathbf{h} \in \mathbb{R}^p, \varphi(\mathbf{x} + \mathbf{h}) - \varphi(\mathbf{x}) \geq \langle \mathbf{h}, \mathbf{y} \rangle\}.$$

Si  $\varphi$  est différentiable en  $\mathbf{x}$ , alors

$$\partial \varphi(\mathbf{x}) = \{\nabla \varphi(\mathbf{x})\}.$$

Si  $\varphi$  n'est pas différentiable en  $\mathbf{x}$ , alors  $\partial \varphi(\mathbf{x})$  est une partie non vide, fermée et convexe de  $\mathbb{R}^p$ .

$$\begin{aligned}\partial|x| &= \{\text{sgn}(x)\}, \quad x \neq 0, \\ \partial|0| &= [-1, 1].\end{aligned}$$

# Exemple : La loi de Coulomb

$$0 \in \frac{dv(t)}{dt} + \mu \partial |v(t)| \quad \text{inclusion différentielle}$$

La vitesse  $v(t)$  converge vers le minimum de la fonction convexe  $|v|$ .



Les algorithmes pour trouver les minimums de  $\varphi$  sont liés à l'inclusion différentielle

$$0 \in \frac{dx(t)}{dt} + \partial\varphi(x(t)).$$

Une solution à l'inclusion différentielle

$$f(t)dt \in dx(t) + \partial\varphi(x(t))dt$$

est un couple  $(x, \eta)$  avec  $x$  une fonction continue et  $\eta$  une fonction mesurable telle que

$$x(t) + \int_0^t \eta(s)ds = \int_0^t f(s)ds + x(0), \quad t \geq 0,$$

$dt$  p.p.  $\eta(t) \in \partial\varphi(x(t)).$

On suppose que

$$Z_\varepsilon = \int_{\mathbb{R}^p} \exp\left\{-\frac{2\varphi(x)}{\varepsilon}\right\} dx < +\infty.$$

Les oscillations autour de l'inclusion différentielle sont les solutions de l'inclusion différentielle stochastique suivante :

$$\varepsilon dw(t) \in dx(t) + \partial \varphi(x(t))dt,$$

où  $w$  est le mouvement brownien et  $\varepsilon > 0$ . A chaque instant  $t$ ,  $x^\varepsilon(t)$  est une variable aléatoire.

1)

$$P(x^\varepsilon(t) \in A) \rightarrow \int_A \exp\left\{-\frac{2\varphi(x)}{\varepsilon}\right\} \frac{dx}{Z_\varepsilon}$$

lorsque  $t \rightarrow +\infty$ .

2)  $\lim_{\varepsilon \rightarrow 0} \lim_{t \rightarrow +\infty} x^\varepsilon(t)$  sont les points d'équilibres (minimums de  $\varphi$ ).

# Outils mathématiques pour étudier les inclusions différentielles

1) La fonction

$$\varphi_\lambda(\mathbf{x}) = \min\left\{\varphi(\mathbf{z}) + \frac{\|\mathbf{z} - \mathbf{x}\|_2^2}{2\lambda} : \mathbf{z} \in \mathbb{R}^p\right\}$$

converge vers  $\varphi$  en croissant lorsque  $\lambda \rightarrow 0$ . C'est une fonction convexe de classe  $C^1$ .

2)

$$\nabla \varphi_\lambda(\mathbf{x}) = \frac{\mathbf{x} - \arg \min \varphi_\lambda(\mathbf{x})}{\lambda}.$$

3) Le vecteur  $z^* = \arg \min \varphi_\lambda(\mathbf{x})$  est l'unique solution de l'inclusion

$$\mathbf{x} \in \mathbf{z} + \lambda \partial \varphi(\mathbf{z}), \quad \mathbf{x} \text{ fixé.}$$

En analyse convexe

$$\mathbf{z}^* = (\mathbf{I} + \lambda \partial \varphi)^{-1}(\mathbf{x}).$$

4) L'application

$$\mathbf{x} \in \mathbb{R}^p \rightarrow (I + \lambda \partial \varphi)^{-1}(\mathbf{x})$$

est une contraction.

5)  $\nabla \varphi_\lambda$  est lipschitzienne de constante de lipschitz égale à  $\frac{1}{\lambda}$ .



$$k = 0, \dots, N, \quad \Delta t = (t_{k+1} - t_k) = \frac{1}{N},$$

$$f(t_k)\Delta t = \mathbf{x}^N(t_{k+1}) - \mathbf{x}^N(t_k) + \Delta t \partial \varphi(\mathbf{x}^N(t_{k+1}))$$

est appelé schéma d'Euler implicite de l'inclusion différentielle

$$f(t)dt \in d\mathbf{x}(t) + \partial \varphi(\mathbf{x}(t))dt.$$

Sachant  $\mathbf{x}^N(t_k)$ , le vecteur  $\mathbf{x}^N(t_{k+1})$  est solution de

$$\mathbf{x}^N(t_k) + f(t_k)\Delta t = \mathbf{x}^N(t_{k+1}) + \Delta t \partial \varphi(\mathbf{x}^N(t_{k+1})).$$

Donc

$$\mathbf{x}^N(t_{k+1}) = (\mathbf{I} + \Delta t \partial \varphi)^{-1}(\mathbf{x}^N(t_k) + f(t_k)\Delta t).$$

En interpolant les points  $(t_k, \mathbf{x}^N(t_k))$  :  $k = 0, \dots, N$  on obtient la trajectoire absolument continue

$$\mathbf{x}^N : [0, 1] \rightarrow \mathbb{R}^p.$$

Elle vérifie

$$\mathbf{x}^N(t) = \mathbf{x}(0) + \int_0^t \mathbf{f}^N(s) ds - \int_0^t \eta^N(s) ds,$$

où

$$\mathbf{f}^N(s) = \mathbf{f}(t_k), \quad \eta^N(s) = \partial \varphi(\mathbf{x}^N(t_{k+1})) \quad s \in [t_k, t_{k+1}).$$

Elle est basée sur la propriété maximale monotone de  $\partial\varphi$ .

$$\langle \mathbf{y}(1) - \mathbf{y}(2), \mathbf{x}(1) - \mathbf{x}(2) \rangle \geq 0, \quad \forall \mathbf{x}(1), \mathbf{x}(2) \in \mathbb{R}^p, \\ \forall \mathbf{y}(1) \in \partial\varphi(\mathbf{x}(1)), \quad \mathbf{y}(2) \in \partial\varphi(\mathbf{x}(2)).$$

Si  $\mathbf{x}(n) \rightarrow \mathbf{x}$ , et  $\mathbf{y}(n) \rightarrow \mathbf{y}$  avec  $\mathbf{y}(n) \in \partial\varphi(\mathbf{x}(n))$ , alors  $\mathbf{y} \in \partial\varphi(\mathbf{x})$ .

Hypothèse de croissance linéaire : 1) Il existe  $C > 0$  telle que pour tout  $\mathbf{y} \in \partial\varphi(\mathbf{x})$

$$\|\mathbf{y}\| \leq C(1 + \|\mathbf{x}\|).$$

2) La fonction  $f \in L^\infty[0, 1]$ .

*Théorème Bernardin (2000). La suite  $(\mathbf{x}^N, \eta^N)$  converge vers une solution  $(\mathbf{x}, \eta)$  de l'inclusion différentielle. De plus*

$$\sup_{t \in [0,1]} \|\mathbf{x}^N(t) - \mathbf{x}(t)\|_2 \leq \frac{C}{\sqrt{N}}.$$



Soient  $(\mathbf{x}^1, \eta^1)$ ,  $(\mathbf{x}^2, \eta^2)$  deux solutions qui partent du même point  $\mathbf{x}(0)$ . Alors *dt* p.p.

$$\frac{d}{dt} \|\mathbf{x}^1(t) - \mathbf{x}^2(t)\|^2 = 2\langle \mathbf{x}^1(t) - \mathbf{x}^2(t), \eta^2(t) - \eta^1(t) \rangle \leq 0.$$

Ceci implique  $\mathbf{x}^1(t) = \mathbf{x}^2(t)$  pour tout  $t$ , et alors  $\eta^1(t) = \eta^2(t)$  p.p.

On perturbe l'inclusion différentielle

$$0 \in dx(t) + \partial\varphi(x(t))dt$$

par les oscillations browniennes

$$dw(t) \in dx(t) + \partial\varphi(x(t))dt.$$

*Théorème (Pettersson 97) : Soit  $\frac{1}{N} = t_{k+1} - t_k$  une partition de  $[0, 1]$ , et  $\mathbf{w}^N$  l'interpolation linéaire des points  $(t_k, \mathbf{w}(t_k))$ . On considère la solution*

$$\begin{aligned}\mathbf{x}^N(t) &= \mathbf{x}(0) + \mathbf{w}^N(t) - \int_0^t \eta^N(s) ds, \\ \eta^N(t) &\in \partial\varphi(\mathbf{x}^N(t)) \quad dt \text{ p.p.}\end{aligned}$$

# Oscillation autour de l'équilibre

Alors  $\mathbf{x}^N \rightarrow \mathbf{x}$  dans  $C[0, 1]$  et  $\eta^N \rightarrow \eta$  faiblement dans  $L^1[0, 1]$  lorsque  $N \rightarrow +\infty$  et

$$\begin{aligned}\mathbf{x}(t, \mathbf{w}) &= \mathbf{x}(0) + \mathbf{w}(t) - \int_0^t \eta(s, \mathbf{w}) ds, \\ \eta(t, \mathbf{w}) &\in \partial\varphi(\mathbf{x}(t, \mathbf{w})) \quad dt \text{ p.p.}\end{aligned}$$

De plus

$$\mathbf{E} \left[ \sup_{t \in [0, 1]} \|\mathbf{x}^N(t) - \mathbf{x}(t)\|_2^2 \right] \leq C \frac{\sqrt{\ln(N)}}{\sqrt{N}}.$$

*Proposition (Dermoune, Ouknine, Sbai). L'application*

$$(t, \mathbf{w}) \in [0, 1] \times C[0, 1] \rightarrow \mathbf{x}(t, \mathbf{w}) \in \mathbb{R}^p$$

*est localement lipschitzienne.*

Tibshirani 1996 : La régression linéaire

$$\mathbf{y} = \mathbf{A}\mathbf{x} + \mathbf{e} \in \mathbb{R}^n, \quad \mathbf{x} \in \mathbb{R}^p$$

lorsque  $n < p$  se résout par l'optimisation

$$\arg \min \left\{ \frac{\|\mathbf{A}\mathbf{x} - \mathbf{y}\|_2^2}{2} + \mu \|\mathbf{x}\|_1 : \mathbf{x} \in \mathbb{R}^p \right\} := \text{Lasso},$$

où  $\mu > 0$ ,  $\mathbf{A}$  une matrice  $n \times p$  et  $\mathbf{y} \in \mathbb{R}^n$  sont donnés,

$$\|\mathbf{x}\|_2^2 = \sum_{i=1}^p x_i^2, \quad \|\mathbf{x}\|_1 = \sum_{i=1}^p |x_i|.$$

Thèse Daoud Ounaissi (Lille 1) 2016 : Etude numérique des oscillations autour de lasso :

$$\varepsilon d\mathbf{w}(t) \in d\mathbf{x}^\varepsilon(t) + \partial \left\{ \frac{\|\mathbf{A}\mathbf{x}^\varepsilon - \mathbf{y}\|_2^2}{2} + \mu \|\mathbf{x}^\varepsilon\|_1 \right\} dt.$$

$$\bigcup_{i=1}^p \{t \in [0, 1] : x_i^\varepsilon(t) = 0\}$$

et de mesure de Lebesgue nulle. L'inclusion différentielle stochastique devient une équation différentielle stochastique avec dérive discontinue :

$$dx^\varepsilon(t) = -\{\mathbf{A}^\top(\mathbf{A}x^\varepsilon(t) - \mathbf{y}) + \mu \operatorname{sgn}(x^\varepsilon(t))\}dt + \varepsilon d\mathbf{w}(t).$$



En dimension 1, cette équation a été utilisée par P.G. Degennes 1990 (Prix Nobel de Chimie). Dans ce cas  $x$  représente la vitesse de la dynamique de Coulomb soumise à la force extérieure

$$f(x) = -\mathbf{A}^\top (\mathbf{A}x - y).$$

Nous allons considérer le cas général

$$dv^\varepsilon(t) = \{f(t, v^\varepsilon(t)) - \mu \operatorname{sgn}(v^\varepsilon(t))\} dt + \varepsilon dw(t),$$

où  $f$  est continue et à croissance linéaire.

$$\begin{aligned}\nu^{\varepsilon,-}(ds, t)dt &= \mathbf{1}_{[v^\varepsilon(t) \leq 0]} \delta_{\text{sgn}(v^\varepsilon(t))}(ds)dt, \\ \nu^{\varepsilon,+}(ds, t)dt &= \mathbf{1}_{[v^\varepsilon(t) > 0]} \delta_{\text{sgn}(v^\varepsilon(t))}(ds)dt.\end{aligned}$$

Les familles  $v^\varepsilon$ ,  $\nu^{\varepsilon,-}$ ,  $\nu^{\varepsilon,+}$ , sont tendues. Par extraction d'une sous suite les limites  $v$ ,  $\nu^-$ ,  $\nu^+$  sont solutions de

$$dv(t) = \{f(t, v(t)) - \mu(\nu^+(\mathbb{R}, t) - \nu^-(\mathbb{R}, t))\} dt$$

Les quantités  $\nu^+(\mathbb{R}, t)$ ,  $\nu^-(\mathbb{R}, t)$  indiquent dans quel sens le solide glisse :

$v(t) < 0$  implique  $\nu^-(\mathbb{R}, t) = 1$ ,  $\nu^+(\mathbb{R}, t) = 0$ ,  
le solide glisse vers la gauche.

$v(t) > 0$  implique  $\nu^-(\mathbb{R}, t) = 0$ ,  $\nu^+(\mathbb{R}, t) = 1$ ,  
le solide glisse vers la droite.

$$v(t) = 0 \text{ implique } 0 < \nu^-(\mathbb{R}, t) < 1, \quad 0 < \nu^+(\mathbb{R}, t) < 1, \\ \nu^-(\mathbb{R}, t) + \nu^+(\mathbb{R}, t) = 1.$$

Le solide s'arrête.

La solution limite  $v$  est la solution de la dynamique de Coulomb soumise à la force extérieure  $f$  :

$$dv(t) \in f(t, v(t))dt - \mu \partial |v(t)|dt.$$

Elles consistent à contrôler les probabilités

$$\limsup_{\varepsilon \rightarrow 0} \ln\{\mathbf{P}(v^\varepsilon \in F)\}, \quad \liminf_{\varepsilon \rightarrow 0} \ln\{\mathbf{P}(v^\varepsilon \in O)\}$$

pour les fermés  $F$  et les ouverts  $O$  de  $C([0, 1])$ .

Si

$$dv^\varepsilon(t) = b(t, v^\varepsilon(t))dt + \varepsilon dw(t)$$

avec  $b$  lipschitzienne, alors

$$\limsup_{\varepsilon \rightarrow 0} \varepsilon^2 \ln \{ \mathbf{P}(v^\varepsilon \in F) \} \leq -I(F),$$

$$\liminf_{\varepsilon \rightarrow 0} \varepsilon^2 \ln \{ \mathbf{P}(v^\varepsilon \in O) \} \geq -I(O),$$

avec la fonction de taux

$$I(A) := \inf \left\{ \int_0^1 \| \mathbf{b}(\varphi(t)) - \varphi'(t) \|^2 dt : \varphi \in A \right\}.$$



Intuitivement

$$P(v^\varepsilon \approx \varphi) \approx \exp\left\{-\frac{1}{\varepsilon^2} \int_0^1 \|\mathbf{b}(\varphi(t)) - \varphi'(t)\|^2 dt\right\}$$

est maximale lorsque  $\varphi'(t) = \mathbf{b}(\varphi(t))$ .

Dans le cas

$$\mathbf{b}(\mathbf{v}) = \mathbf{f}(\mathbf{v}) - \mu \operatorname{sgn}(\mathbf{v}),$$

on pose

$$b_i^-(\mathbf{v}) := f_i(\mathbf{v}) + \mu,$$

$$b_i^+(\mathbf{v}) := f_i(\mathbf{v}) - \mu,$$

$$L_i^-(\mathbf{v}, \beta_i) = |b_i^-(\mathbf{v}) - \beta_i|^2,$$

$$L_i^+(\mathbf{v}, \beta_i) = |b_i^+(\mathbf{v}) - \beta_i|^2,$$

$$L_i^0(\mathbf{v}, \beta_i) = \inf\{\alpha |b_i^-(\mathbf{v}) - \beta_i^-|^2 + (1 - \alpha) |b_i^+(\mathbf{v}) - \beta_i^+|^2\}.$$

L'inf est pris sur  $\alpha \in (0, 1)$  et  $\beta_i^- \geq 0$ ,  $\beta_i^+ \leq 0$  tels que

$$\alpha \beta_i^- + (1 - \alpha) \beta_i^+ = \beta_i.$$

**Proposition (Dermoune, Ouknine, Sbai).** *Nous avons les grandes déviations avec la fonction de taux*

$$I(\varphi) = \int_0^1 \tilde{L}(\varphi(t), \varphi'(t)) dt,$$

où

$$\tilde{L}(\mathbf{v}, \beta) = \sum_{i=1}^p \tilde{L}_i(\mathbf{v}, \beta_i),$$

$$\tilde{L}_i(\mathbf{v}, \beta_i) = L_i^-(\mathbf{v}, \beta_i), \quad \text{si } v_i < 0,$$

$$\tilde{L}_i(\mathbf{v}, \beta_i) = L_i^+(\mathbf{v}, \beta_i), \quad \text{si } v_i > 0,$$

$$\tilde{L}_i(\mathbf{v}, \beta_i) = L_i^0(\mathbf{v}, \beta_i), \quad \text{si } v_i = 0.$$

$$P(\mathbf{v}^\varepsilon \in A) \approx \exp\left(-\frac{I(A)}{\varepsilon^2}\right)$$

En particulier

$$P(\mathbf{v}^\varepsilon \approx \mathbf{v}) \approx \exp\left(-\frac{1}{\varepsilon^2} \int_0^1 \tilde{L}(\mathbf{v}(t), \mathbf{v}'(t)) dt\right).$$

Elle est donc maximale lorsque  $\mathbf{v}$  est solution de la dynamique de Coulomb.

Ceci est une autre explication de la limite  $\mathbf{v}^\varepsilon \rightarrow \mathbf{v}$ .

- 1) P.G. Degennes 2005, Brownien motion with dry friction, J. Stat. Phys. 119, 953-962.
- 2) R. Tibshirani, Regression shrinkage and selection via LASSO, J. R. Stat. Soc. Ser. B Stat. Methodol. vol. 58 no. 1 267-288 (1996).
- 3) R. Tibshirani, The LASSO problem and uniqueness, Electron. J. Stat. vol. 7 1456-1490 (2013).
- 4) A. Dermoune, D. Ounaissi, N. Rahmania, MCMC convergence diagnosis using geometry of Bayesian LASSO, arXiv :1512.01366v1 [math.ST] (2015).

- 5) A. Dermoune, D. Ounaissi, N. Rahmania, Multilevel Monte Carlo simulation of a diffusion with non-smooth drift, arXiv :1504.06441v1 [math.ST] (2015).
- 6) A. Dermoune, D. Ounaissi, N. Rahmania, Oscillation of Metropolis-Hastings and simulated annealing algorithms around LASSO estimator, Math. Comput. Simulation (2015).
- 7) A. Beck, M. Teboulle, A Fast Iterative Shrinkage-thresholding algorithm for linear inverse problem, SIAM J. Imaging Sci. 183–202 (2009).
- 8) D. Ounaissi, Thèse Lille 1 (Juin 2016).