

Algorithmes pour l'optimisation semi-algébrique

Guillaume Garrigos

Institut de Mathématiques et de Modélisation de Montpellier
Universidad Tecnica Federico Santa Maria

Journées MODE Rennes
26 Mars 2014

Soit $A \in \mathbb{R}^{M \times N}$ t.q. $M \ll N$. On veut résoudre $Ax = b$ dans \mathbb{R}^N .

Soit $A \in \mathbb{R}^{M \times N}$ t.q. $M \ll N$. On veut résoudre $Ax = b$ dans \mathbb{R}^N .
Définissons $\|x\|_0 = \#\{x_i \mid x_i \neq 0\}$ et considérons :

$$(P_1) \quad \min_{x \in \mathbb{R}^N} \|x\|_0 + \delta_{Ax=b}(x)$$

Introduction : Problèmes semi-algébriques (1)

Soit $A \in \mathbb{R}^{M \times N}$ t.q. $M \ll N$. On veut résoudre $Ax = b$ dans \mathbb{R}^N .
Définissons $\|x\|_0 = \#\{x_i \mid x_i \neq 0\}$ et considérons :

$$(P_1) \quad \min_{x \in \mathbb{R}^N} \|x\|_0 + \delta_{Ax=b}(x)$$

Peut être relaxé en :

$$(P'_1) \quad \min_{x \in \mathbb{R}^N} \alpha \|x\|_0 + \frac{1}{2} \|Ax - b\|^2$$

$$(P''_1) \quad \min_{x, y \in \mathbb{R}^N} \alpha \|x\|_0 + \delta_{Ay=b}(y) + \frac{1}{2} \|x - y\|^2$$

Soit $A \in \mathbb{R}^{M \times N}$. On veut une décomposition $A = X + Y$ sous la contrainte $\text{rank } X \leq r, \|Y\|_0 \leq s$.

Soit $A \in \mathbb{R}^{M \times N}$. On veut une décomposition $A = X + Y$ sous la contrainte $\text{rank } X \leq r, \|Y\|_0 \leq s$.

Revient à résoudre

$$(P_2) \quad \min_{X, Y} \frac{1}{2} \|A - X - Y\|_F^2 + \delta_{\text{rank} \leq r}(X) + \delta_{\|\cdot\|_0 \leq s}(Y)$$

$$(P'_1) \quad \min_{x \in \mathbb{R}^N} \alpha \|x\|_0 + \frac{1}{2} \|Ax - b\|^2$$

$$(P''_1) \quad \min_{x, y \in \mathbb{R}^N} \alpha \|x\|_0 + \delta_{Ay=b}(y) + \frac{1}{2} \|x - y\|^2$$

$$(P_2) \quad \min_{X, Y} \frac{1}{2} \|A - X - Y\|_F^2 + \delta_{\text{rank} \leq r}(X) + \delta_{\|\cdot\|_0 \leq s}(Y)$$

→ Problèmes non triviaux car non lisses non convexes (non continus !)

→ Problèmes structurés : parties lisses/non lisses.

Soit $f : \mathbb{R}^N \longrightarrow \mathbb{R} \cup \{+\infty\}$ semi-algébrique.

Nous allons voir une classe d'algorithmes de décomposition qui vérifient :

Théorème (Frankel, G., Peypouquet, 2013 - Attouch et al., 2010)

- 1 Toute suite bornée est de longueur finie et convergente vers un point critique de f .
- 2 Si le point initial x_0 est suffisamment proche d'un minimum global alors la suite est de longueur finie et converge vers un minimum global de f .

Soit $f : \mathbb{R}^N \longrightarrow \mathbb{R} \cup \{+\infty\}$ semi-algébrique.

Nous allons voir une classe d'algorithmes de décomposition qui vérifient :

Théorème (Frankel, G., Peypouquet, 2013 - Attouch et al., 2010)

- 1 Toute suite bornée est de longueur finie et convergente vers un point critique de f .
- 2 Si le point initial x_0 est suffisamment proche d'un minimum global alors la suite est de longueur finie et converge vers un minimum global de f .

→ Se généralise en espaces de Hilbert

→ Remplacer "semi-algébrique" par "Kurdyka-Lojasiewicz"

- 1 Descent methods
- 2 Convergence of splitting methods for semialgebraic functions

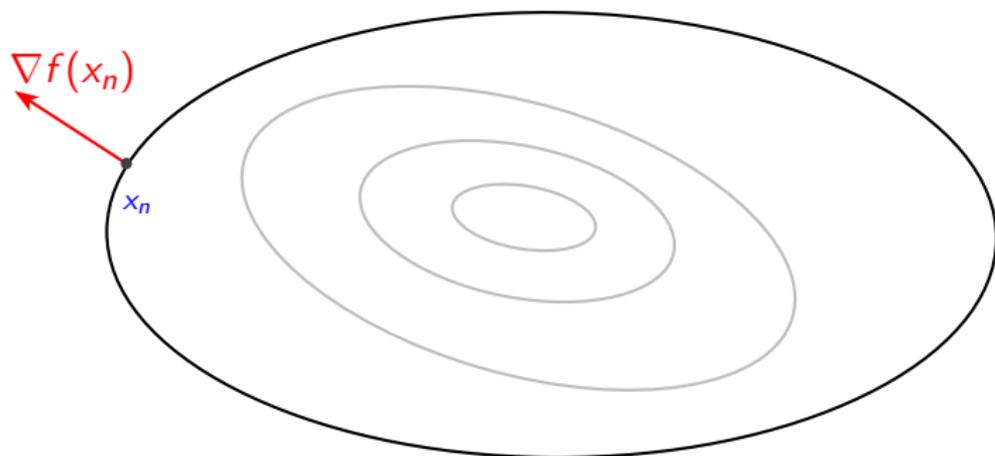
- 1 Descent methods
 - Explicit gradient method
 - Implicit gradient method
- 2 Convergence of splitting methods for semialgebraic functions

- 1 Descent methods
 - Explicit gradient method
 - Implicit gradient method

- 2 Convergence of splitting methods for semialgebraic functions

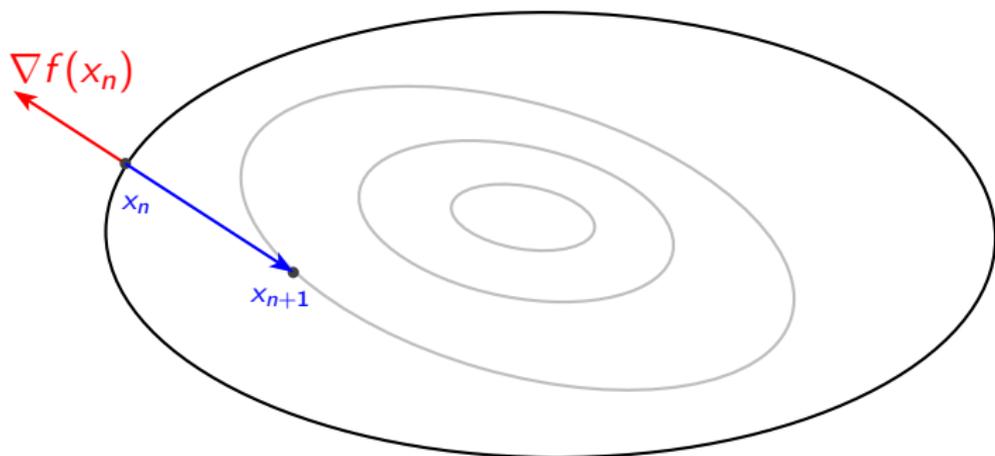
Méthode du gradient explicite (pas classique)

Méthode gradient explicite : $x_{n+1} = x_n - \lambda_n \nabla f(x_n)$



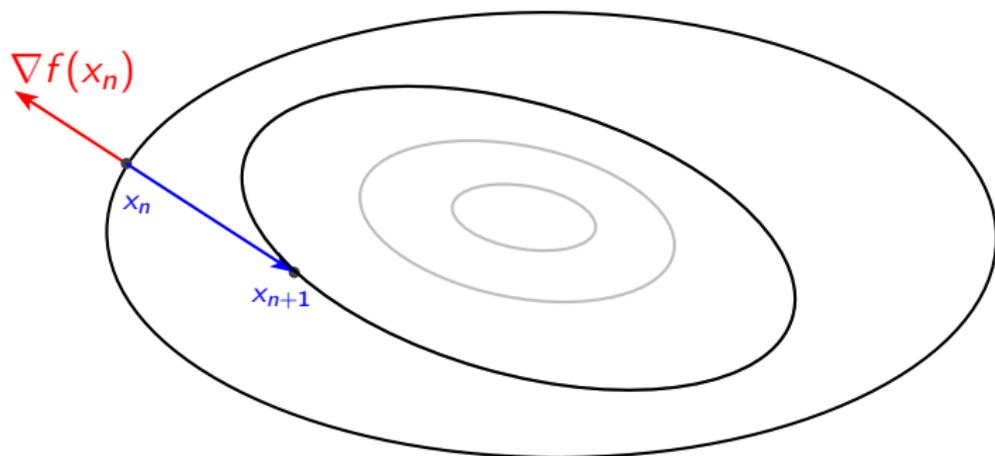
Méthode du gradient explicite (pas classique)

Méthode gradient explicite : $x_{n+1} = x_n - \lambda_n \nabla f(x_n)$



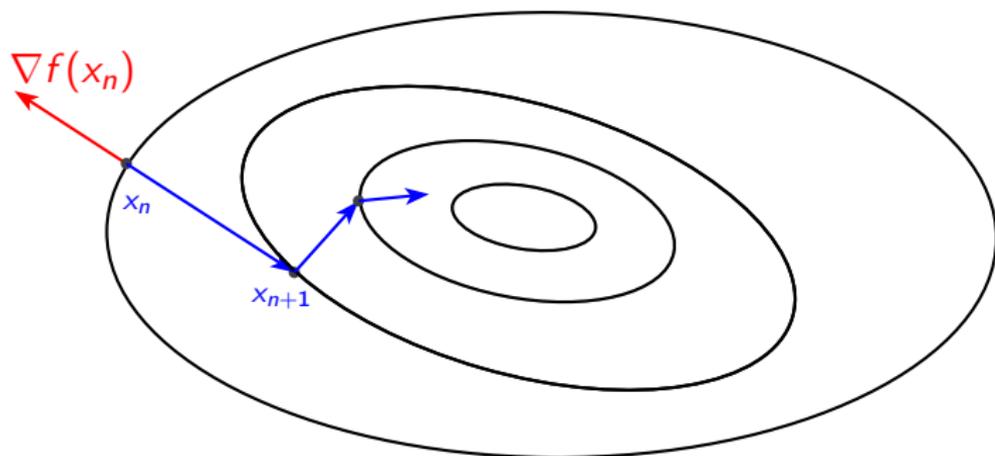
Méthode du gradient explicite (pas classique)

Méthode gradient explicite : $x_{n+1} = x_n - \lambda_n \nabla f(x_n)$



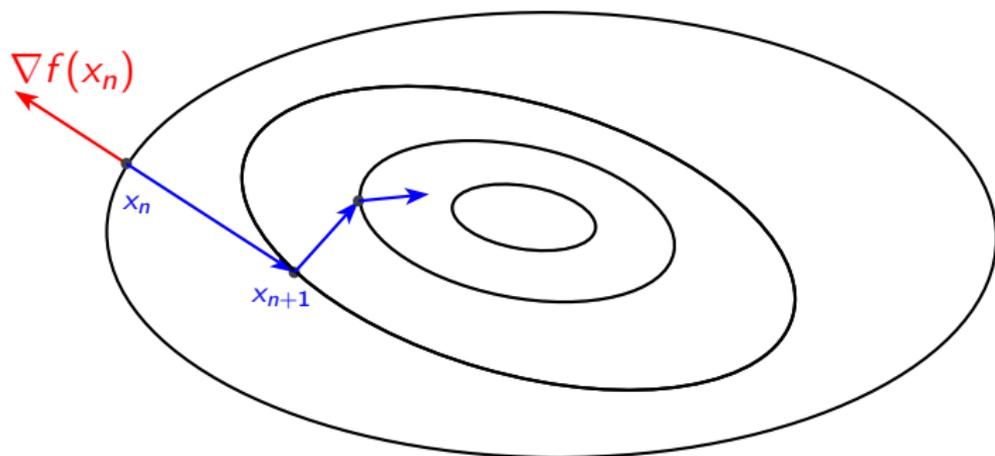
Méthode du gradient explicite (pas classique)

Méthode gradient explicite : $x_{n+1} = x_n - \lambda_n \nabla f(x_n)$



Méthode du gradient explicite (pas classique)

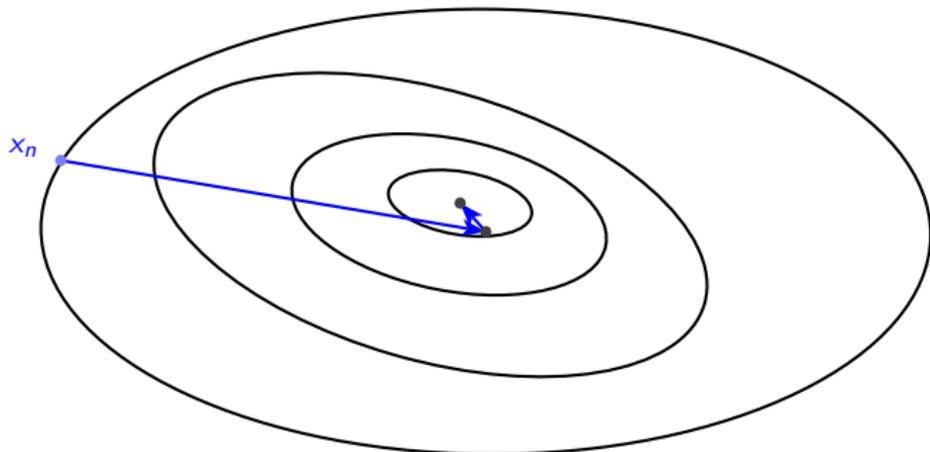
Méthode gradient explicite : $x_{n+1} = x_n - \lambda_n \nabla f(x_n)$



- Descente si ∇f est L -Lipschitz et $\lambda_n \ll \frac{2}{L}$
- Facile à calculer mais convergence lente. Corrigeable avec $\nabla^2 f(x_n)$ si DP.

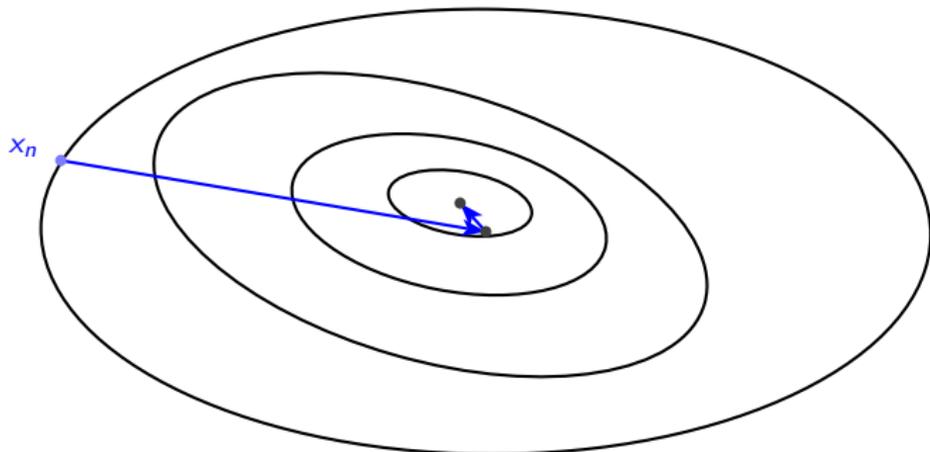
Méthode du gradient explicite (pas Newton)

Méthode de Newton : $x_{n+1} = x_n - (\nabla^2 f(x_n))^{-1} \nabla f(x_n)$



Méthode du gradient explicite (pas Newton)

Méthode de Newton : $x_{n+1} = x_n - (\nabla^2 f(x_n))^{-1} \nabla f(x_n)$



- Vitesse de convergence bien meilleure VS plus dur à calculer
- Ne marche que si $\nabla^2 f(x_n)$ existe et est inversible.

Pour $A \in L(\mathbb{R}^N)$ symétrique on note

- $\alpha(A)$ l'inf des valeurs spectrales de A ,
- $\|A\|$ le sup des valeurs spectrales en valeur absolue.

On considère $\mathcal{S}_{++}(\mathbb{R}^N)$ l'ensemble des opérateurs symétriques, définis positifs ($\alpha(A) > 0$) et bornés ($\|A\| < +\infty$).

Méthode du gradient explicite (métrique variable)

Pour $A \in L(\mathbb{R}^N)$ symétrique on note

- $\alpha(A)$ l'inf des valeurs spectrales de A ,
- $\|A\|$ le sup des valeurs spectrales en valeur absolue.

On considère $\mathcal{S}_{++}(\mathbb{R}^N)$ l'ensemble des opérateurs symétriques, définis positifs ($\alpha(A) > 0$) et bornés ($\|A\| < +\infty$).

Pour $(A_n)_{n \in \mathbb{N}} \in \mathcal{S}_{++}(\mathbb{R}^N)$ on peut définir

$$x_{n+1} = x_n - A_n^{-1} \nabla f(x_n)$$

Pour $A \in L(\mathbb{R}^N)$ symétrique on note

- $\alpha(A)$ l'inf des valeurs spectrales de A ,
- $\|A\|$ le sup des valeurs spectrales en valeur absolue.

On considère $\mathcal{S}_{++}(\mathbb{R}^N)$ l'ensemble des opérateurs symétriques, définis positifs ($\alpha(A) > 0$) et bornés ($\|A\| < +\infty$).

Pour $(A_n)_{n \in \mathbb{N}} \in \mathcal{S}_{++}(\mathbb{R}^N)$ on peut définir

$$x_{n+1} = x_n - A_n^{-1} \nabla f(x_n)$$

- Avec $A_n = \frac{1}{\lambda_n} id$ on retrouve le gradient classique.
- Avec $A_n = \nabla^2 f(x_n) \in \mathcal{S}_{++}(\mathbb{R}^N)$ on retrouve Newton.
- Sinon on essaie $A_n \simeq \nabla^2 f(x_n)$ dans $\mathcal{S}_{++}(\mathbb{R}^N)$.

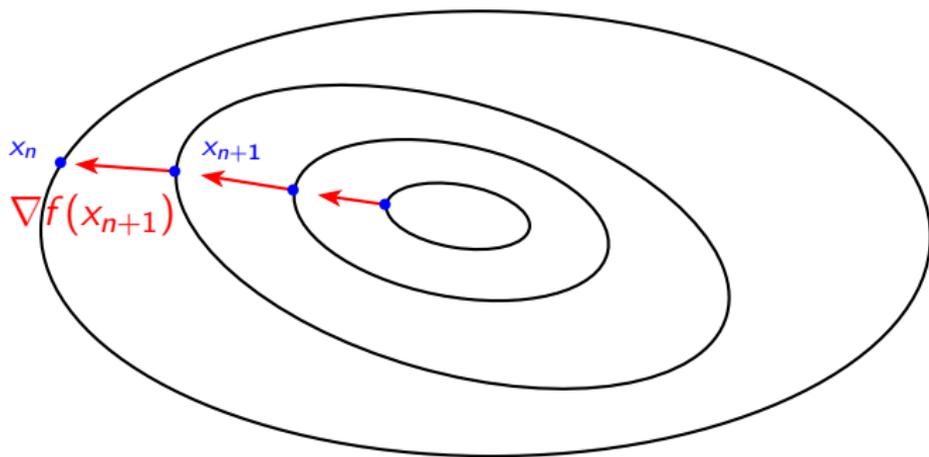
- 1 Descent methods
 - Explicit gradient method
 - Implicit gradient method

- 2 Convergence of splitting methods for semialgebraic functions

Méthode implicite : $x_{n+1} = x_n - \lambda_n \nabla f(x_{n+1})$

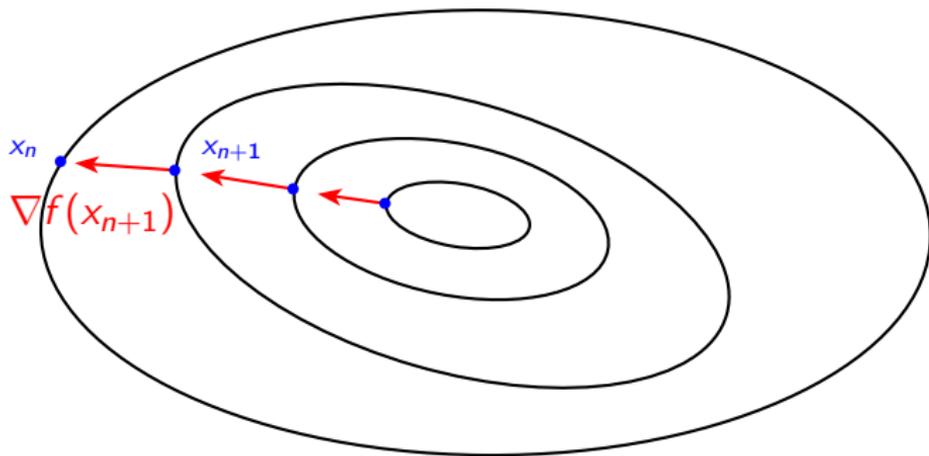
Méthode du gradient implicite (cas différentiable)

Méthode implicite : $x_{n+1} = x_n - \lambda_n \nabla f(x_{n+1})$



Méthode du gradient implicite (cas différentiable)

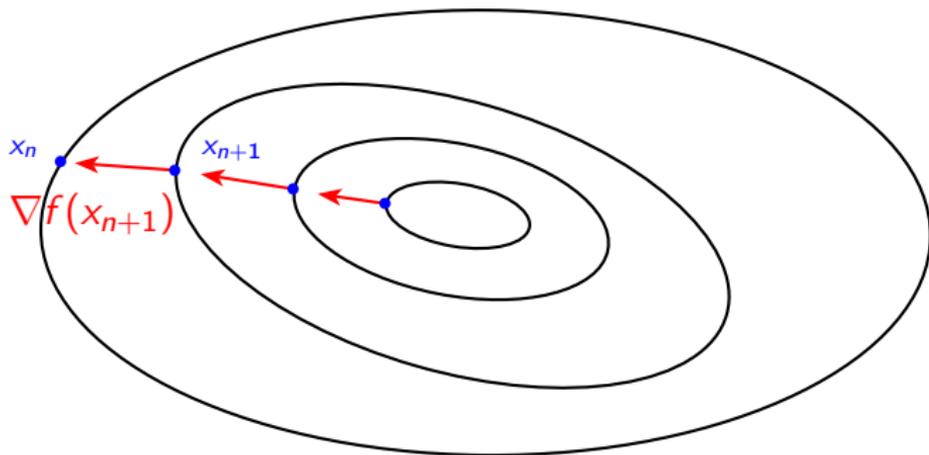
Méthode implicite : $x_{n+1} = x_n - \lambda_n \nabla f(x_{n+1})$



- Difficile à calculer mais convergence plus rapide + stabilité

Méthode du gradient implicite (cas différentiable)

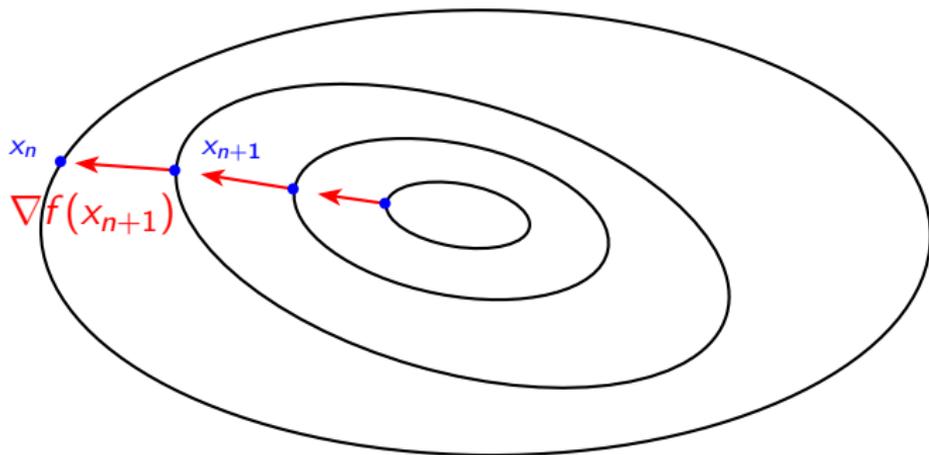
Méthode implicite : $x_{n+1} = x_n - A_n^{-1} \nabla f(x_{n+1})$



- Difficile à calculer mais convergence plus rapide + stabilité
- On peut aussi prendre en compte de la métrique variable

Méthode du gradient implicite (cas différentiable)

Méthode implicite : $x_{n+1} = x_n - A_n^{-1} \nabla f(x_{n+1})$



- Difficile à calculer mais convergence plus rapide + stabilité
- On peut aussi prendre en compte de la métrique variable
- **S'adapte facilement aux fonctions non lisses**

Supposons f convexe.

$$\begin{aligned} x_{n+1} &= x_n - A_n^{-1} \nabla f(x_{n+1}) \\ \Leftrightarrow A_n(x_{n+1} - x_n) + \nabla f(x_{n+1}) &= 0 \end{aligned}$$

Supposons f convexe. Posons $\|x\|_A^2 = \langle Ax, x \rangle$ pour $A \in \mathcal{S}_{++}(\mathbb{R}^N)$.

$$\begin{aligned} & x_{n+1} = x_n - A_n^{-1} \nabla f(x_{n+1}) \\ \Leftrightarrow & A_n(x_{n+1} - x_n) + \nabla f(x_{n+1}) = 0 \\ \Leftrightarrow & \nabla \left(\frac{1}{2} \|\cdot - x_n\|_{A_n}^2 + f(\cdot) \right) (x_{n+1}) = 0 \end{aligned}$$

Supposons f convexe. Posons $\|x\|_A^2 = \langle Ax, x \rangle$ pour $A \in \mathcal{S}_{++}(\mathbb{R}^N)$.

$$\begin{aligned} & x_{n+1} = x_n - A_n^{-1} \nabla f(x_{n+1}) \\ \Leftrightarrow & A_n(x_{n+1} - x_n) + \nabla f(x_{n+1}) = 0 \\ \Leftrightarrow & \nabla \left(\frac{1}{2} \|\cdot - x_n\|_{A_n}^2 + f(\cdot) \right) (x_{n+1}) = 0 \\ \Leftrightarrow & x_{n+1} = \mathit{Argmin}_{y \in H} \left\{ f(y) + \frac{1}{2} \|y - x_n\|_{A_n}^2 \right\} \end{aligned}$$

Supposons f convexe. Posons $\|x\|_A^2 = \langle Ax, x \rangle$ pour $A \in \mathcal{S}_{++}(\mathbb{R}^N)$.

$$\begin{aligned} x_{n+1} &= x_n - A_n^{-1} \nabla f(x_{n+1}) \\ \Leftrightarrow A_n(x_{n+1} - x_n) + \nabla f(x_{n+1}) &= 0 \\ \Leftrightarrow \nabla \left(\frac{1}{2} \|\cdot - x_n\|_{A_n}^2 + f(\cdot) \right) (x_{n+1}) &= 0 \\ \Leftrightarrow x_{n+1} &= \operatorname{Argmin}_{y \in H} \left\{ f(y) + \frac{1}{2} \|y - x_n\|_{A_n}^2 \right\} \end{aligned}$$

Definition : Opérateur proximal

Soit $f : \mathbb{R}^N \rightarrow \mathbb{R} \cup \{+\infty\}$ s.c.i propre et $A \in \mathcal{S}_{++}(\mathbb{R}^N)$.

$$\operatorname{prox}_f^A(x) := \operatorname{Argmin}_{y \in H} \left\{ f(y) + \frac{1}{2} \|y - x\|_A^2 \right\}$$

On écrit alors $x_{n+1} \in \operatorname{prox}_{f}^{A_n}(x_n)$ et on parle d'algorithme proximal.

Definitions (Sous-différentiels)

$f : \mathbb{R}^N \rightarrow \mathbb{R} \cup \{+\infty\}$ s.c.i. propre. Soit $x \in \text{dom } f$.

Sous-différentiel de Fréchet $\hat{\partial}$

$$p \in \hat{\partial}f(x) \Leftrightarrow \liminf_{y \rightarrow x, y \neq x} \frac{f(y) - f(x) - \langle p, y - x \rangle}{\|y - x\|} \geq 0$$

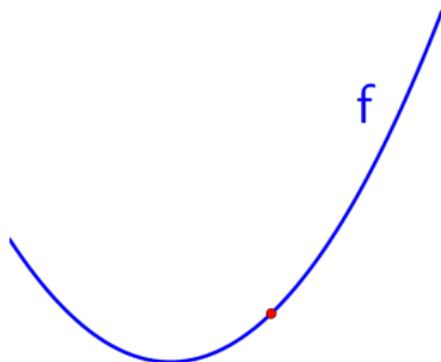
Definitions (Sous-différentiels)

$f : \mathbb{R}^N \rightarrow \mathbb{R} \cup \{+\infty\}$ s.c.i. propre. Soit $x \in \text{dom } f$.

Sous-différentiel de Fréchet $\hat{\partial}$

$$p \in \hat{\partial}f(x) \Leftrightarrow \liminf_{y \rightarrow x, y \neq x} \frac{f(y) - f(x) - \langle p, y - x \rangle}{\|y - x\|} \geq 0$$

Si f est C^1



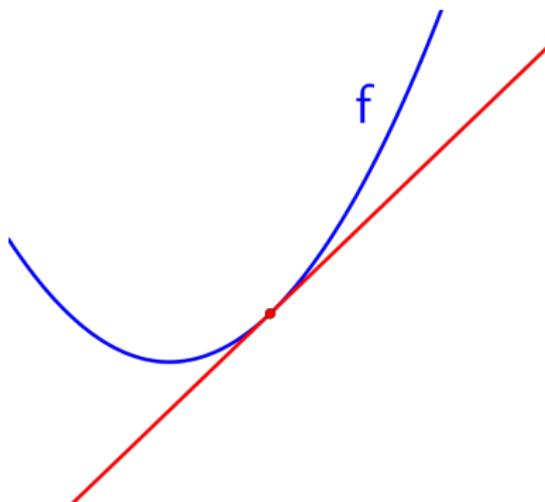
Definitions (Sous-différentiels)

$f : \mathbb{R}^N \rightarrow \mathbb{R} \cup \{+\infty\}$ s.c.i. propre. Soit $x \in \text{dom } f$.

Sous-différentiel de Fréchet $\hat{\partial}$

$$p \in \hat{\partial}f(x) \Leftrightarrow \liminf_{y \rightarrow x, y \neq x} \frac{f(y) - f(x) - \langle p, y - x \rangle}{\|y - x\|} \geq 0$$

Si f est C^1 alors
 $\hat{\partial}f(x) = \{\nabla f(x)\}$

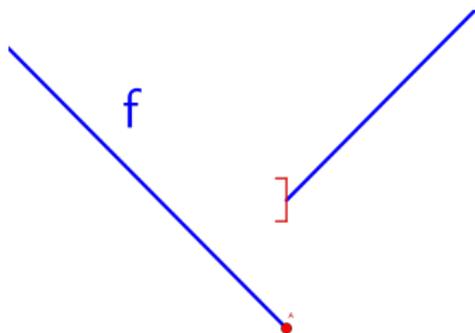


Definitions (Sous-différentiels)

$f : \mathbb{R}^N \rightarrow \mathbb{R} \cup \{+\infty\}$ s.c.i. propre. Soit $x \in \text{dom } f$.

Sous-différentiel de Fréchet $\hat{\partial}$

$$p \in \hat{\partial}f(x) \Leftrightarrow \liminf_{y \rightarrow x, y \neq x} \frac{f(y) - f(x) - \langle p, y - x \rangle}{\|y - x\|} \geq 0$$

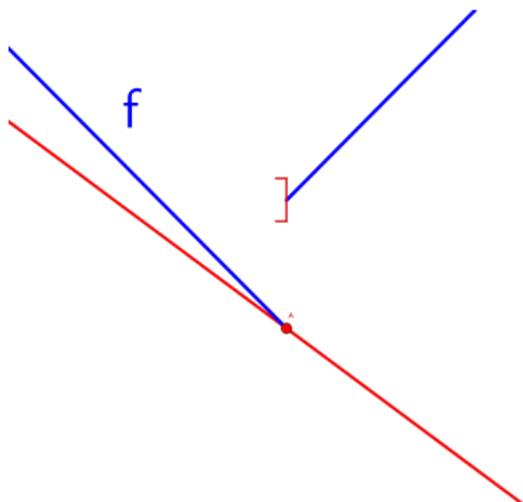


Definitions (Sous-différentiels)

$f : \mathbb{R}^N \rightarrow \mathbb{R} \cup \{+\infty\}$ s.c.i. propre. Soit $x \in \text{dom } f$.

Sous-différentiel de Fréchet $\hat{\partial}$

$$p \in \hat{\partial}f(x) \Leftrightarrow \liminf_{y \rightarrow x, y \neq x} \frac{f(y) - f(x) - \langle p, y - x \rangle}{\|y - x\|} \geq 0$$

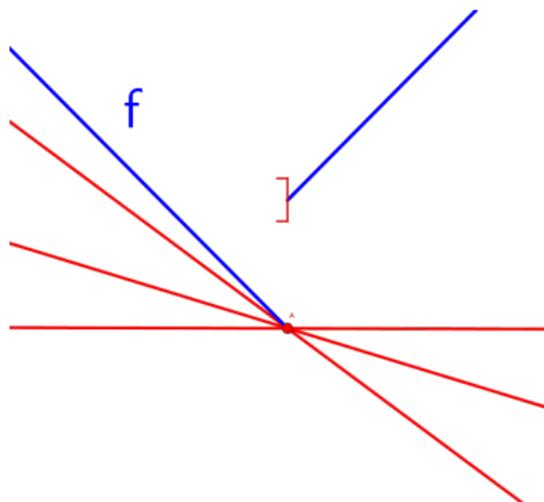


Definitions (Sous-différentiels)

$f : \mathbb{R}^N \rightarrow \mathbb{R} \cup \{+\infty\}$ s.c.i. propre. Soit $x \in \text{dom } f$.

Sous-différentiel de Fréchet $\hat{\partial}$

$$p \in \hat{\partial}f(x) \Leftrightarrow \liminf_{y \rightarrow x, y \neq x} \frac{f(y) - f(x) - \langle p, y - x \rangle}{\|y - x\|} \geq 0$$

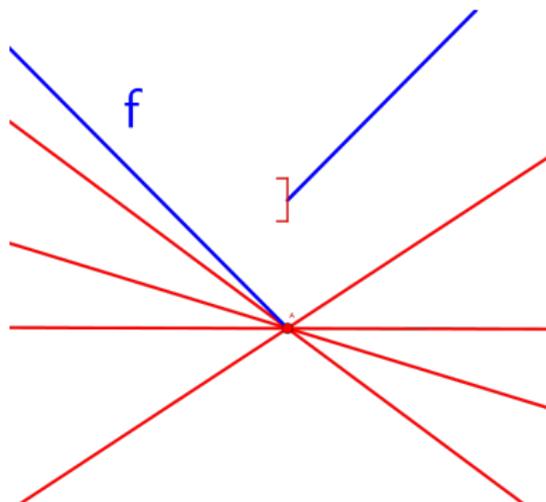


Definitions (Sous-différentiels)

$f : \mathbb{R}^N \rightarrow \mathbb{R} \cup \{+\infty\}$ s.c.i. propre. Soit $x \in \text{dom } f$.

Sous-différentiel de Fréchet $\hat{\partial}$

$$p \in \hat{\partial}f(x) \Leftrightarrow \liminf_{y \rightarrow x, y \neq x} \frac{f(y) - f(x) - \langle p, y - x \rangle}{\|y - x\|} \geq 0$$



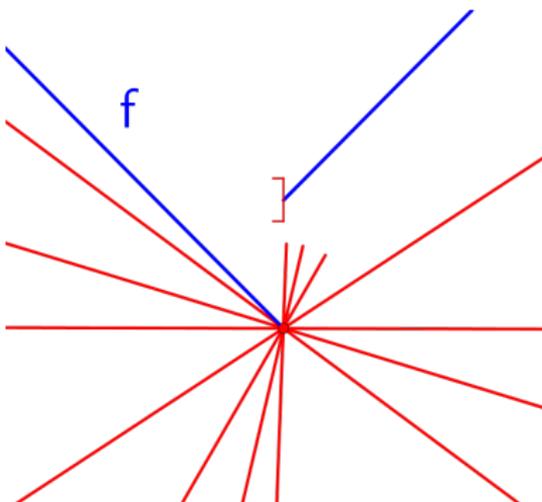
Definitions (Sous-différentiels)

$f : \mathbb{R}^N \rightarrow \mathbb{R} \cup \{+\infty\}$ s.c.i. propre. Soit $x \in \text{dom } f$.

Sous-différentiel de Fréchet $\hat{\partial}$

$$p \in \hat{\partial}f(x) \Leftrightarrow \liminf_{y \rightarrow x, y \neq x} \frac{f(y) - f(x) - \langle p, y - x \rangle}{\|y - x\|} \geq 0$$

Ici $\hat{\partial}f(x) = [-1, +\infty[$.



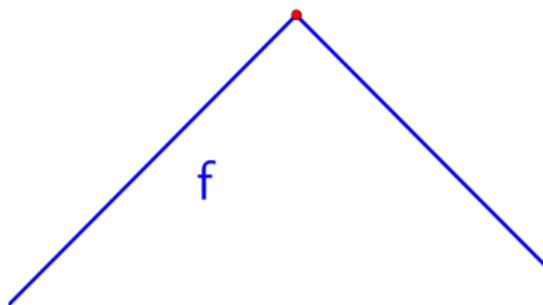
Definitions (Sous-différentiels)

$f : \mathbb{R}^N \rightarrow \mathbb{R} \cup \{+\infty\}$ s.c.i. propre. Soit $x \in \text{dom } f$.

Sous-différentiel de Fréchet $\hat{\partial}$

$$p \in \hat{\partial}f(x) \Leftrightarrow \liminf_{y \rightarrow x, y \neq x} \frac{f(y) - f(x) - \langle p, y - x \rangle}{\|y - x\|} \geq 0$$

Ici $\hat{\partial}f(x) = \emptyset$



Definitions (Sous-différentiels)

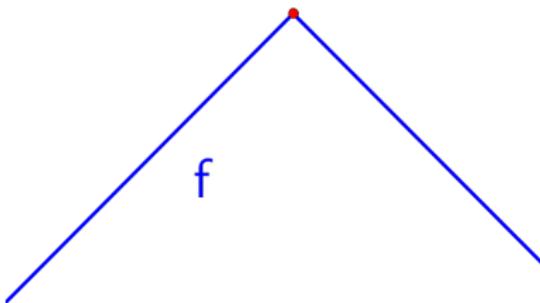
$f : \mathbb{R}^N \rightarrow \mathbb{R} \cup \{+\infty\}$ s.c.i. propre. Soit $x \in \text{dom } f$.

Sous-différentiel Fréchet limite ∂

$$p \in \partial f(x) \Leftrightarrow \begin{aligned} \exists x_n \rightarrow x \text{ avec } f(x_n) \rightarrow f(x), \\ \exists p_n \in \hat{\partial} f(x_n) \text{ t.q. } p_n \xrightarrow{w} p \end{aligned}$$

Si $x \notin \text{dom } f$, alors $\partial f(x) = \emptyset$.

Ici $\hat{\partial} f(x) = \emptyset$



Definitions (Sous-différentiels)

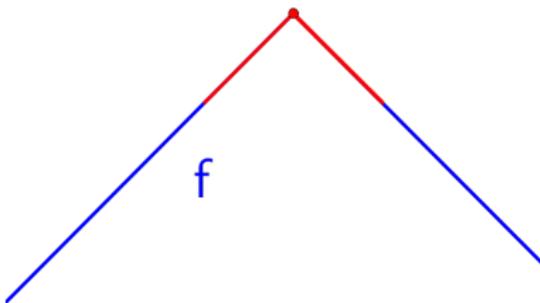
$f : \mathbb{R}^N \rightarrow \mathbb{R} \cup \{+\infty\}$ s.c.i. propre. Soit $x \in \text{dom } f$.

Sous-différentiel Fréchet limite ∂

$$p \in \partial f(x) \Leftrightarrow \begin{aligned} \exists x_n \rightarrow x \text{ avec } f(x_n) \rightarrow f(x), \\ \exists p_n \in \hat{\partial} f(x_n) \text{ t.q. } p_n \xrightarrow{w} p \end{aligned}$$

Si $x \notin \text{dom } f$, alors $\partial f(x) = \emptyset$.

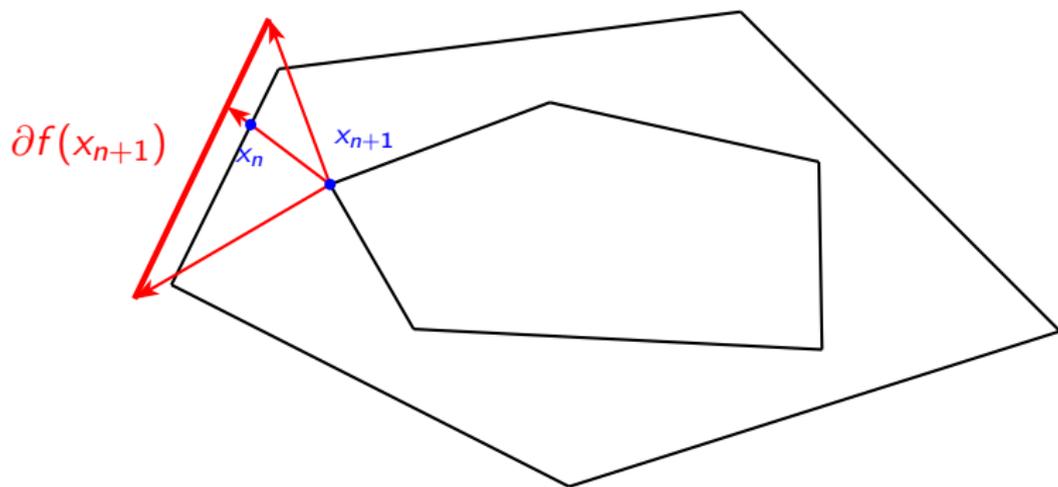
Ici $\hat{\partial} f(x) = \emptyset$ mais
 $\partial f(x) = \{-1, 1\}$.



Règle de Fermat

Si x est un minimum local de f alors $0 \in \partial f(x)$ (point critique).

En particulier si $x_{n+1} \in \text{prox}_f^{A_n}(x_n)$ alors $x_{n+1} \in x_n - \lambda_n \partial f(x_{n+1})$.

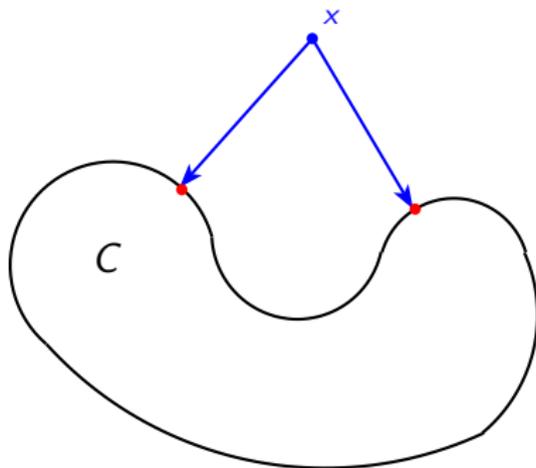


Algorithme proximal : exemples

Soient C fermé non-vidé et $f(x) = \delta_C(x) := 0$ si $x \in C$, $+\infty$ sinon.

Alors $\text{prox}_f^{\text{id}}(x) = \operatorname{argmin}_{y \in C} \|y - x\|^2$

C'est la projection de x sur C .



Soient C fermé non-vidé et $f(x) = \delta_C(x) := 0$ si $x \in C$, $+\infty$ sinon.

Alors $\text{prox}_f^{id}(x) = \operatorname{argmin}_{y \in C} \|y - x\|^2$

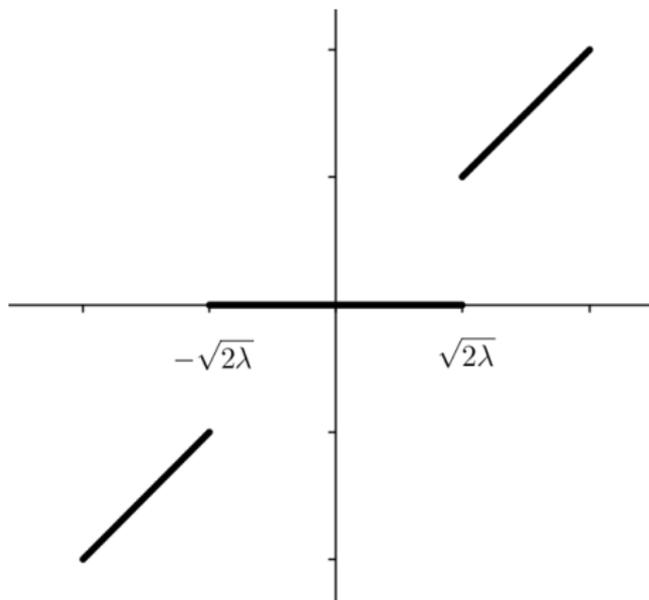
C'est la projection de x sur C .

Par exemple si $H = M_{m,n}(\mathbb{R})$ et $C = \{\operatorname{rank}(X) \leq r\}$

On sait que la projection se calcule en passant par une SVD et en mettant à 0 des valeurs singulières.

Algorithme proximal (Exemples)

Si $f(x) = \|x\|_0$ alors
 $(\text{prox}_f^\lambda(x))_i$:



- 1 Descent methods
- 2 Convergence of splitting methods for semialgebraic functions

Soit $f : \mathbb{R}^N \longrightarrow \mathbb{R} \cup \{+\infty\}$ semi-algébrique.

Nous allons voir une classe d'algorithmes de décomposition qui vérifient :

Théorème (Frankel, G., Peypouquet, 2013 - Attouch et al., 2010)

- 1 Toute suite bornée est de longueur finie et convergente vers un point critique de f .
- 2 Si le point initial x_0 est suffisamment proche d'un minimum global alors la suite est de longueur finie et converge vers un minimum global de f .

Soit $f = g + h : \mathbb{R}^N \rightarrow \mathbb{R} \cup \{+\infty\}$ semi-algébrique
 g s.c.i. et h de classe C^1 de gradient Lipschitzien.

$$x_{n+1} \in \text{prox}_g^{A_n} (x_n - A_n^{-1} \nabla h(x_n))$$

Soit $f = g + h : \mathbb{R}^N \rightarrow \mathbb{R} \cup \{+\infty\}$ semi-algébrique
 g s.c.i. et h de classe C^1 de gradient Lipschitzien.

$$x_{n+1} \in \text{prox}_g^{A_n} (x_n - A_n^{-1} \nabla h(x_n))$$

Exemple

Soit $g(x) = \delta_C(x)$ où $C \subset H$ fermé semi-algébrique et
 $A_n = \lambda_n^{-1} \text{id}_H$. On obtient alors l'algorithme du gradient projeté :

$$x_{n+1} \in \text{proj}_C (x_n - \lambda_n \nabla h(x_n))$$

Soit $f = g + h : H \rightarrow \mathbb{R} \cup \{+\infty\}$
 g s.c.i. et h de classe C^1 de gradient Lipschitzien.

$$x_{n+1} \in \text{prox}_g^{A_n} (x_n - A_n^{-1} \nabla h(x_n))$$

Le résultat de convergence s'applique si pour $\alpha_n = \alpha(A_n)$ et $\beta_n = \|A_n\|$ on a

$$L < \underline{\alpha} \leq \alpha_n \leq \beta_n \leq \bar{\beta} < +\infty.$$

Soit $f = g + h : H \longrightarrow \mathbb{R} \cup \{+\infty\}$
 g s.c.i. et h de classe C^1 de gradient Lipschitzien.

$$x_{n+1} \in \text{prox}_g^{A_n} (x_n - A_n^{-1} \nabla h(x_n))$$

Le résultat de convergence s'applique si pour $\alpha_n = \alpha(A_n)$ et $\beta_n = \|A_n\|$ on a

$$L < \underline{\alpha} \leq \alpha_n \leq \beta_n \leq \bar{\beta} < +\infty.$$

Dans le cas $f|_{\text{dom } f}$ continue on peut prendre $\beta_n \rightarrow +\infty$ si $\frac{1}{\beta_n} \notin \ell^1$ et son taux d'accroissement reste borné.

Si f est C^2 , on veut exploiter le Hessien $\nabla^2 f(x_n)$.

Si f est C^2 , on veut exploiter le Hessien $\nabla^2 f(x_n)$.

Si f est strictement convexe, $A_n = \frac{1}{\lambda_n} \nabla^2 f(x_n)$:

(Newton) $x_{n+1} = x_n - \lambda_n (\nabla^2 f(x_n))^{-1} \nabla f(x_n)$.

Si f est C^2 , on veut exploiter le Hessien $\nabla^2 f(x_n)$.

Si f est strictement convexe, $A_n = \frac{1}{\lambda_n} \nabla^2 f(x_n)$:

(Newton) $x_{n+1} = x_n - \lambda_n (\nabla^2 f(x_n))^{-1} \nabla f(x_n)$.

Si f est convexe, $A_n = \frac{1}{\lambda_n} (\nabla^2 f(x_n) + \varepsilon id)$ ($\varepsilon > 0$) :

(Levenberg-Marq.) $x_{n+1} = x_n - \lambda_n (\nabla^2 f(x_n) + \varepsilon id)^{-1} \nabla f(x_n)$.

Si f n'est pas convexe, on peut prendre $A_n = \frac{1}{\lambda_n}(P_n + \varepsilon id)$
où P_n est une approximation positive de $\nabla^2 f(x_n)$.

Par exemple $P_n = \text{proj}_{\mathcal{S}_+(\mathbb{R}^N)}(\nabla^2 f(x_n))$ en dimension finie.

Si f n'est pas convexe, on peut prendre $A_n = \frac{1}{\lambda_n}(P_n + \varepsilon id)$
où P_n est une approximation positive de $\nabla^2 f(x_n)$.

Par exemple $P_n = \text{proj}_{S_+(\mathbb{R}^N)}(\nabla^2 f(x_n))$ en dimension finie.

Et si f n'est pas C^2 mais seulement $C^{1,1}$?

Considérons la Hessienne généralisée :

$$\partial^2 f(x) = \left\{ \lim_{n \rightarrow \infty} \nabla^2 f(x_n) \mid x_n \rightarrow x \text{ avec } f \text{ différentiable en } x_n \right\}.$$

On peut alors prendre n'importe quel $H_n \in \partial^2 f(x_n)$ au lieu de $\nabla^2 f(x_n)$.

La méthode se résume à :

$$H_n \in \partial^2 f(x_n)$$

$$P_n = \text{proj}_{\mathcal{S}_+(\mathbb{R}^N)}(H_n)$$

$$x_{n+1} = x_n - \lambda_n (P_n + \varepsilon \text{id})^{-1} \nabla h(x_n).$$

- $0 < \lambda_n < \bar{\lambda} < \frac{2\varepsilon}{L}$
- $\lambda_n \notin \ell^1$
- $\sup \frac{\lambda_{n+1}}{\lambda_n} < +\infty.$

$$f(x) = h(x) + \delta_C(x)$$

avec h strictement convexe C^2 semi-algébrique

et $C \subset \mathbb{R}^N$ fermé non vide semi-algébrique. Soit $A_n = \frac{1}{\lambda_n} \nabla^2 h(x_n)$:

$$x_{n+1} \in \text{proj}_C^{\nabla^2 h(x_n)} (x_n - \lambda_n (\nabla^2 h(x_n))^{-1} \nabla h(x_n)).$$

$$f(x) = h(x) + \delta_C(x)$$

avec h strictement convexe C^2 semi-algébrique

et $C \subset \mathbb{R}^N$ fermé non vide semi-algébrique. Soit $A_n = \frac{1}{\lambda_n} \nabla^2 h(x_n)$:

$$x_{n+1} \in \text{proj}_C^{\nabla^2 h(x_n)}(x_n - \lambda_n (\nabla^2 h(x_n))^{-1} \nabla h(x_n)).$$

→ Se généralise aussi au cas non-convexe non- C^2 .

$f(x, y) = g_1(x) + g_2(y) + h(x, y)$
où g_1, g_2 s.c.i et $h \in C^{1,1}$ semi-algébriques.

$f(x, y) = g_1(x) + g_2(y) + h(x, y)$
où g_1, g_2 s.c.i et $h \in C^{1,1}$ semi-algébriques.

$$\begin{aligned} & x_{n+1} \in \text{prox}_{f(\cdot, y_n)}^{A_n}(x_n) \\ \text{(GSR)} \quad & y_{n+1} \in \text{prox}_{f(x_{n+1}, \cdot)}^{B_n}(y_n) \end{aligned}$$

$f(x, y) = g_1(x) + g_2(y) + h(x, y)$
où g_1, g_2 s.c.i et $h \in C^{1,1}$ semi-algébriques.

$$\begin{aligned} & x_{n+1} \in \text{prox}_{f(\cdot, y_n)}^{A_n}(x_n) \\ \text{(GSR)} \quad & y_{n+1} \in \text{prox}_{f(x_{n+1}, \cdot)}^{B_n}(y_n) \end{aligned}$$

- Étudié en 2008 (Attouch, Bolte, Soubeyran, Redont).

$f(x, y) = g_1(x) + g_2(y) + h(x, y)$
où g_1, g_2 s.c.i et $h \in C^{1,1}$ semi-algébriques.

$$\begin{aligned} & x_{n+1} \in \text{prox}_{f(\cdot, y_n)}^{A_n}(x_n) \\ \text{(GSR)} \quad & y_{n+1} \in \text{prox}_{f(x_{n+1}, \cdot)}^{B_n}(y_n) \end{aligned}$$

- Étudié en 2008 (Attouch, Bolte, Soubeyran, Redont).
- Ne tient pas compte de la structure lisse/non lisse.

$f(x, y) = g_1(x) + g_2(y) + h(x, y)$
où g_1, g_2 s.c.i et $h \in C^{1,1}$ semi-algébriques.

$$\begin{aligned} \text{(AFB)} \quad & x_{n+1} \in \text{prox}_{g_1}^{A_n} (x_n - A_n^{-1} \nabla_x h(x_n, y_n)) \\ & y_{n+1} \in \text{prox}_{g_2}^{B_n} (y_n - B_n^{-1} \nabla_y h(x_{n+1}, y_n)) \end{aligned}$$

$f(x, y) = g_1(x) + g_2(y) + h(x, y)$
où g_1, g_2 s.c.i et $h \in C^{1,1}$ semi-algébriques.

$$\begin{aligned} (AFB) \quad & x_{n+1} \in \text{prox}_{g_1}^{A_n} (x_n - A_n^{-1} \nabla_x h(x_n, y_n)) \\ & y_{n+1} \in \text{prox}_{g_2}^{B_n} (y_n - B_n^{-1} \nabla_y h(x_{n+1}, y_n)) \end{aligned}$$

Le résultat de convergence s'applique si avec
 $\alpha_n = \min\{\alpha(A_n), \alpha(B_n)\}$ et $\beta_n = \max\{\|A_n\|, \|B_n\|\}$ on a

$$L < \underline{\alpha} \leq \alpha_n \leq \beta_n \leq \bar{\beta} < +\infty.$$

Forward-Backward Alterné

$f(x, y) = g_1(x) + g_2(y) + h(x, y)$
où g_1, g_2 s.c.i et $h \in C^{1,1}$ semi-algébriques.

$$\begin{aligned} & x_{n+1} \in \text{prox}_{g_1}^{A_n} (x_n - A_n^{-1} \nabla_x h(x_n, y_n)) \\ \text{(AFB)} \quad & y_{n+1} \in \text{prox}_{g_2}^{B_n} (y_n - B_n^{-1} \nabla_y h(x_{n+1}, y_n)) \end{aligned}$$

Le résultat de convergence s'applique si avec $\alpha_n = \min\{\alpha(A_n), \alpha(B_n)\}$ et $\beta_n = \max\{\|A_n\|, \|B_n\|\}$ on a

$$L < \underline{\alpha} \leq \alpha_n \leq \beta_n \leq \bar{\beta} < +\infty.$$

De même si $f|_{\text{dom } f}$ est continue on peut prendre $\beta_n \rightarrow +\infty$ (+hyp).

$$(P_2) \quad \min_{X, Y} \frac{1}{2} \|A - X - Y\|_F^2 + \delta_{\text{rank} \leq r}(X) + \delta_{\|\cdot\|_0 \leq s}(Y)$$

$$X_{n+1} \in \text{proj}_{\{\text{rank} \leq r\}} \left((1 - \lambda_n)X_n - \lambda_n(Y_n - A) \right),$$

$$Y_{n+1} \in \text{proj}_{\{\|\cdot\|_0 \leq s\}} \left((1 - \mu_n)Y_n - \mu_n(X_{n+1} - A) \right)$$

- Algorithmes faciles à implémenter car décomposé en étapes simples
- Certificats de convergence dans un cadre non-lisse non-convexe (sans convexification)
- Fonctionne dans un cadre plus général que semi-algébrique :

$$\exists \varphi : \mathbb{R}_+ \rightarrow \mathbb{R} \text{ tq } \|\partial(\varphi \circ f)(x)\| \geq 1$$

- Vitesses de convergences quadratiques pour le Newton projeté ?

Merci de votre attention !