

Gradient à pas optimal:

① Introduction

Les méthodes du gradient sont des méthodes itératives où on remplace un système linéaire par un problème de minimisation. L'algorithme du gradient à pas optimal consiste à déterminer un pas optimal pour minimiser une fonction.

- But:
- Minimiser une distance (optimisation)
 - trouver état d'équilibre d'un système

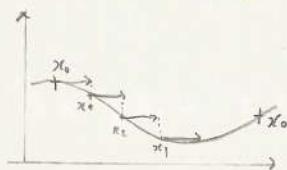
Ex: (Méthodes sans gradient)

- Dichotomie
- méthode de la règle d'or.

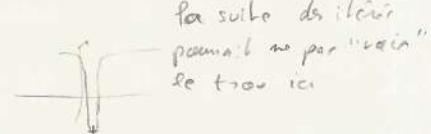
Ex: (Méthodes du gradient)

On connaît x_0 et on a $x_{k+1} = x_k + d_k \cdot g_k$ \checkmark pas de descente \checkmark direction de descente $g_k = -\frac{df}{dx}|_{x_k}$

① Gradient à pas fixe:



Tant que $\|\nabla f(x)\| > \varepsilon$
 $\leftarrow x \mapsto x - \text{pas } \times \nabla f(x)$
 répéter



problème: marche lentement pour fonctions dures et pour x_0 proche de la solution.

② Gradient à pas optimal:

on choisit la longueur du pas à chaque étape!

la contrainte: il faut connaître la dérivée seconde.

astuce: DL de $f(x)$ au point x_k :

on dérive $f(x_k + dx_k) = f(x_k) + dx_k \cdot \frac{\delta f}{\delta x}(x_k) + \frac{dx_k^2}{2} \cdot \frac{\delta^2 f}{\delta x^2}(x_k) + o(dx_k^2)$
 $f'(x_k + dx_k) = f'(x_k) + dx_k \cdot \frac{\delta^2 f}{\delta x^2}(x_k) + \dots$

et on pose $f'(x_k + dx_k) \approx f'(x_k) + dx_k \cdot \frac{\delta^2 f}{\delta x^2}(x_k) = 0$ pour avoir un point critique.

Ainsi $dx_k = \frac{-f'(x_k)}{\left(\frac{\delta^2 f}{\delta x^2}(x_k)\right)}$

minimum (c'est "profond")

étape 1 : placer x_0 , on trace la droite

étape 2 : on regarde le min de S . Et on réécrit !



On a convergence linéaire.

Définition: (fonction α -convexe)

Soit $\varphi \in C^1(\mathbb{R}^d, \mathbb{R})$. Soit $\alpha > 0$. On dit que φ est α -convexe lorsque $\forall x, y \in \mathbb{R}^d, \forall t \in [0, 1]$,

$$\varphi(tx + (1-t)y) \leq t\varphi(x) + (1-t)\varphi(y) - \alpha \cdot t \cdot (1-t) \|x-y\|^2.$$

Une telle fonction est en particulier strictement convexe.

Développement

Lemme: Soit $\varphi \in C^1(\mathbb{R}^d, \mathbb{R})$. Alors (i) et (ii) sont équivalents:

(i) φ est α -convexe

(ii) $\forall x, y \in \mathbb{R}^d, \varphi(y) \geq \varphi(x) + \langle \nabla \varphi(x), y-x \rangle + \alpha \|y-x\|^2$.

i \Rightarrow ii Soit φ α -convexe.

$$\text{Alors } \varphi(x+t(y-x)) \leq \varphi(x) + t(\varphi(y) - \varphi(x)) - \alpha \cdot t \cdot (1-t) \|y-x\|^2$$

$$\text{donc } \frac{\varphi(x+t(y-x)) - \varphi(x)}{t} \leq \varphi(y) - \varphi(x) - \alpha(1-t) \|y-x\|^2$$

calculer ce donc en passant à la limite, pour $t \rightarrow 0^+$:

$$\text{terme pour } \begin{cases} \text{rôle} \\ \text{convexité} \end{cases} \quad \text{si } [\varphi(x+t(y-x))]_{t=0} \leq \varphi(y) - \varphi(x) - \alpha \|y-x\|^2$$

$$\text{i.e. } \langle \nabla \varphi(x), y-x \rangle \leq \varphi(y) - \varphi(x) - \alpha \|y-x\|^2$$

ii \Rightarrow i Posons $z = t x + (1-t)y$. On a $z-x = (1-t)(y-x)$, d'où la majoration:

$$\varphi(x) \geq \varphi(z) + \langle \nabla \varphi(z), x-z \rangle + \alpha \|x-z\|^2 \quad (\text{ii}) \text{ pour } x \text{ et } z$$

$$\begin{aligned}\Rightarrow \varphi(z) &\leq \varphi(x) + \langle \nabla \varphi(x), z - x \rangle - \alpha \|z - x\|^2 \\ &\leq \varphi(x) + (1-t) \langle \nabla \varphi(x), y - x \rangle - \alpha \cdot (1-t)^2 \cdot \|y - x\|^2\end{aligned}$$

et de même pour z et y , $z-y = -t(y-x)$ d'où

$$\begin{aligned}\varphi(z) &\leq \varphi(y) + \langle \nabla \varphi(z), z - y \rangle - \alpha \|z - y\|^2 \\ &\leq \varphi(y) - t \cdot \langle \nabla \varphi(z), y - x \rangle - \alpha \cdot t^2 \cdot \|y - x\|^2.\end{aligned}$$

donc en considérant la moyenne pondérée de deux applications,

$$\begin{aligned}\varphi(z) &\leq t \varphi(x) + (1-t) \varphi(y) + [t(1-t) - t(1-t)] \cdot \langle \nabla \varphi(z), y - x \rangle \\ &\quad - [t(1-t)^2 + (1-t)t^2] \cdot \alpha \cdot \|y - x\|^2 \\ &\leq t \varphi(x) + (1-t) \varphi(y) - \alpha \cdot \|y - x\|^2 \cdot t(1-t)\end{aligned}$$

■

Théorème: Soit $\varphi \in C^1(\mathbb{R}^d, \mathbb{R})$ une fonction α -convexe. φ admet un unique minimum (local et global) atteint en x^* .

Soit $x_0 \in \mathbb{R}^d$ fixé. On considère la suite $x_{n+1} = x_n + \lambda_n \nabla \varphi(x_n)$ où $\lambda_n = 0$ si $x_n = x^*$ ou λ_n tq $\varphi(x_n + \lambda_n \nabla \varphi(x_n)) = \min_{\mu \in \mathbb{R}} \{\varphi(x_n + \mu \nabla \varphi(x_n))\}$. Pour tout $x_0 \in \mathbb{R}^d$, cette suite est bien définie et $(x_n) \xrightarrow{n \rightarrow \infty} x^*$.

Preuve:

► Étape 1: φ admet un unique minimum atteint en x^* , qui est le seul point critique de φ .

D'après le lemme, on a $\varphi(x) \geq \varphi(0) + \langle \nabla \varphi(0), x \rangle + \alpha \cdot \|x\|^2$ donc φ est une fonction coercive. Ainsi, φ admet un minimum en x^* (par coercivité). Ce minimum global est a fortiori un minimum local, donc $\nabla \varphi(x^*) = 0$. En outre on a l'inégalité $\varphi(x^*) \geq \varphi(y) + \langle \nabla \varphi(y), x^* - y \rangle + \alpha \cdot \|y - x^*\|^2$

donc $\langle \nabla \varphi(y), y - x^* \rangle \geq \underbrace{\varphi(y) - \varphi(x^*)}_{\geq 0} + \alpha \cdot \|y - x^*\|^2$

$$\geq \alpha \cdot \|y - x^*\|^2$$

> 0 dès que $y \neq x^*$.

En particulier $\nabla \varphi(x^*) \neq 0$ donc x^* est le seul point critique, donc le seul minimum local.

► Etape 2: La suite est bien définie et orthogonalité de $\nabla \varphi(x_n)$, $\nabla \varphi(x_{n+1})$

* Considérons la fonction $\varphi_n(\lambda) = \varphi(x_n + \nabla \varphi(x_n) \cdot \lambda)$!

$$\begin{aligned} \text{On a } \varphi_n(t\lambda + (1-t)\mu) &= \varphi\left(x_n + \nabla \varphi(x_n)(t\lambda + (1-t)\mu)\right) \\ &= \varphi(tx_n + (1-t)x_n + \nabla \varphi(x_n) \cdot (t\lambda + (1-t)\mu)) \\ &= \varphi(t[x_n + \lambda \nabla \varphi(x_n)] + (1-t)[x_n + \mu \nabla \varphi(x_n)]) \end{aligned}$$

φ α -convexe $\leq t \cdot \varphi_n(\lambda) + (1-t) \cdot \varphi_n(\mu) - \alpha \cdot \|\nabla \varphi(x_n)\|^2 \cdot t \cdot (1-t) \cdot \|\lambda - \mu\|^2$

donc φ_n est $\alpha \cdot \|\nabla \varphi(x_n)\|^2$ -convexe. Dès lors que $x_n \neq x^*$, φ_n admet un unique minimum (global et local) en λ_n . La suite (x_n) est donc bien définie.

* φ_n étant C^1 , elle se déroule en $\varphi'_n(\lambda) = \langle \nabla \varphi(x_n + \lambda \nabla \varphi(x_n)), \nabla \varphi(x_n) \rangle$
(en effet $\varphi'_n(\lambda) = \nabla \varphi(x_n) \cdot \underbrace{\nabla \varphi(x_n + \nabla \varphi(x_n) \cdot \lambda)}_{\varphi(x_n)} = \langle \nabla \varphi(x_n + \nabla \varphi(x_n) \cdot \lambda), \nabla \varphi(x_n) \rangle$)

donc $\varphi'_n(0) = \|\nabla \varphi(x_n)\|^2 \neq 0$ d'où $\varphi(x_{n+1}) < \varphi(x_n)$ pour $x \neq x^*$.

(car la suite $x_{n+1} = x_n + \lambda_n \cdot \nabla \varphi(x_n) \Rightarrow \varphi(x_{n+1}) = \varphi(x_n + \lambda_n \nabla \varphi(x_n)) \Rightarrow \varphi(x_{n+1}) = \varphi_n(\lambda_n)$
on λ_n le min global de φ_n . Donc $\varphi_n(0) > \varphi_n(\lambda_n)$.)

De manière générale, $(\varphi(\lambda_n))_{n \in \mathbb{N}}$ est décroissante, minorée par $\varphi(x^*)$
(car x^* minimum de φ) et donc $(\varphi(\lambda_n))_{n \in \mathbb{N}}$ converge, donc $\varphi(x_{n+1}) - \varphi(x_n) \xrightarrow[n \rightarrow \infty]{} 0$

φ_n admet un minimum en λ_n donc $\langle \nabla \varphi(x_{n+1}), \nabla \varphi(x_n) \rangle = \varphi'_n(\lambda_n) = 0$

Ainsi, pour $x \neq x^*$, $\langle \nabla \varphi(x_{n+1}), \nabla \varphi(x_n) \rangle = 0$.

► Etape 3

$x_{n+1} - x_n$ et $\nabla \varphi(x_n)$ étant colinéaires (car $x_{n+1} = x_n + \lambda_n \nabla \varphi(x_n)$)

on en déduit que $\langle x_{n+1} - x_n, \nabla \varphi(x_n) \rangle = 0$.

Ainsi, φ α -convexe et donc (par la borne)

$$\varphi(x_n) \geq \varphi(x_{n+1}) + \langle \nabla \varphi(x_{n+1}), x_n - x_{n+1} \rangle + \alpha \cdot \|x_{n+1} - x_n\|^2$$

$$\Leftrightarrow \varphi(x_n) - \varphi(x_{n+1}) \geq \alpha \cdot \|x_{n+1} - x_n\|^2$$

donc la suite $(x_{n+1} - x_n)_{n \geq 0}$ converge vers 0. Quitte à se restreindre au compact $\varphi^{-1}([0, \varphi(x_0)])$ (car x_0 est dans $\varphi^{-1}(0)$), $\nabla \varphi$ est uniformément continue, donc en particulier $\|\nabla \varphi(x_{n+1}) - \nabla \varphi(x_n)\| \xrightarrow[n \rightarrow +\infty]{} 0$.
 (car $x_{n+1} - x_n \xrightarrow[n \rightarrow +\infty]{} 0$)

$$\|\nabla \varphi(x_n)\|^2 \leq \|\nabla \varphi(x_n)\|^2 + \|\nabla \varphi(x_{n+1})\|^2 \stackrel{\text{orthogonalité}}{=} \|\nabla \varphi(x_n) - \nabla \varphi(x_{n+1})\|^2 \xrightarrow[n \rightarrow +\infty]{} 0$$

donc $\|\nabla \varphi(x_n)\| \xrightarrow[n \rightarrow +\infty]{} 0$.

Soit \bar{x} une valeur d'adhérence de (x_n) . Par continuité de $\nabla \varphi$, on a $\nabla \varphi(\bar{x}) = 0$, d'où nécessairement $\bar{x} = x^*$. La suite (x_n) est bornée et admet une unique valeur d'adhérence, donc $x_n \xrightarrow[n \rightarrow +\infty]{} x^*$.

Application:

Soit $A \in S_m^{++}(\mathbb{R})$, $b \in \mathbb{R}^d$. On veut résoudre le système linéaire $Ax = b$.

On considère $\varphi(x) = \frac{1}{2} \langle Ax, x \rangle - \langle b, x \rangle$. On vérifie aisément que $\nabla \varphi(x) = Ax - b$, donc x est solution du système précédent si et seulement si $\nabla \varphi(x) = 0$.

φ est convexe donc $\exists!$ solution de $Ax = b$ que l'on peut approcher avec la méthode du gradient à pas optimal.

Question du juge:

Thm: Une suite bornée avec une unique valeur d'adhérence converge.

Preuve: Par l'absurd.

Soit (v_n) suite bornée admettant une unique valeur d'adhérence ℓ et ne convergeant pas vers ℓ :

$$\exists \varepsilon > 0 \text{ tq } \forall N \in \mathbb{N}, \exists n \in \mathbb{N} \text{ tq } n > N \text{ tq } |v_n - \ell| \geq \varepsilon.$$

Alors l'ensemble $A := \{n \in \mathbb{N}; |v_n - \ell| \geq \varepsilon\}$ est infini.

Soit $\sigma : N \rightarrow A$ strictement croissante.

$$\text{Ainsi } \forall n \in \mathbb{N} \quad |v_{\sigma(n)} - \ell| > \varepsilon.$$

Or $(v_{\sigma(n)})$ bornée car (v_n) bornée donc on peut extraire une sous-suite convergente:

$$\exists \sigma' : N \rightarrow \mathbb{N} \text{ tq } v_{\sigma(\sigma'(n))} \rightarrow \ell'.$$

On a alors $\forall n \in \mathbb{N}, |v_{\sigma(\sigma'(n))} - \ell'| \geq \varepsilon$ et par passage à la limite $|\ell' - \ell| \geq \varepsilon$. Donc $\ell' \neq \ell$. (v_n) aurait alors deux valeurs d'adhérence distinctes. \blacksquare

Exercice 1

$$f: \mathbb{R}^2 \rightarrow \mathbb{R}$$

$$\begin{pmatrix} x \\ y \end{pmatrix} \mapsto 2x_1^2 + x_2^2 - x_1 x_2 - 3x_1 - x_2 + 4$$

1) Mg $\exists ! \bar{x} \in \mathbb{R}^2 ; \bar{x} = \min_{x \in \mathbb{R}^2} f(x)$ et le calcul.

$$Df(u, v) = [4x_1 - x_2 - 3; 2x_2 - x_1 - 1]$$

$$\text{Hess}_{(x_1, x_2)} f = \begin{bmatrix} 4 & -1 \\ -1 & 2 \end{bmatrix} = \begin{bmatrix} n & s \\ s & t \end{bmatrix}$$

Propriété: $|\text{Hess}| > 0 \Rightarrow f$ convexe ou concave
 \nearrow convexe si $n > 0$ (min global)
 \searrow concave si $n < 0$ (max global)

$|\text{Hess}| < 0$. On répète les ds.

donc f est convexe.

Si Hess est dég. pos, alors strictement convexe.

Donc f strictement convexe.

De plus, f est clairement coercive. Donc $\exists !$ sol à $\bar{x} = \min_{x \in \mathbb{R}^2} f(x)$.

Trouver là! Trouver les pts critiques de f :

Soit (u, v) tq $[4x_1 - x_2 - 3; 2x_2 - x_1 - 1] = (0, 0)$

$$\begin{cases} 4x_1 - x_2 = 3 \\ 2x_2 - x_1 = 1 \end{cases} \Rightarrow \begin{cases} 4x_1 - x_2 = 3 \\ -4x_1 + 8x_2 = 4 \end{cases} \Rightarrow \begin{cases} x_2 = 1 \\ x_1 = 1 \end{cases}$$

$$\hookrightarrow (x_1, x_2) = (1, 1)$$

unique pt fixe

C'est le minimum.

2) Calculer le premier état donné par l'algo du gradient à pas optimal (en partant de $(x_1^{(0)}, x_2^{(0)}) = (0, 0)$).

- Algo:
- $x^{(k)}$ connu
 - on calcule $w^{(k)} = -\nabla f(x^{(k)})$
 - trouver $p_k > 0$ tq $f(x^{(k)} + p_k \cdot w^{(k)}) \leq f(x^{(k)} + t \cdot w^{(k)}) \forall t > 0$
 - $x^{(k+1)} = x^{(k)} + p_k w^{(k)}$

Ici $w^{(0)} = (3, 1)$. Pour minimiser $t \mapsto \varphi(t) = f(x^{(0)} + t \cdot w^{(0)})$

$$\begin{aligned} &= f(0, 0) + t(3, 1) \\ &= f(3t, t) \end{aligned}$$

De plus, $\varphi'(p_0) = 0$
il faut

$$\hookrightarrow \varphi'(t) = f'(x^{(0)} + t \cdot w^{(0)}) \cdot w^{(0)}$$

$$\varphi'(p_0) = f'(0, 0) \cdot \begin{bmatrix} 3 \\ 1 \end{bmatrix}$$

$$= \begin{bmatrix} 11 & p_0 - 3 \\ -p_0 & 1 \end{bmatrix} \cdot \begin{bmatrix} 3 \\ 1 \end{bmatrix}$$

$$= 32p_0 - 10$$

$$\Rightarrow p_0 = \frac{5}{16}$$

$$\text{Ainsi } x^{(1)} = (0, 0) + \frac{5}{16}(3, 1) = \left(\frac{15}{16}, \frac{5}{16}\right)$$

Qust: Pouvez-vous l'appliquer avec l'algorithme du gradient à pt fixe?
(dès que $\alpha = qS$)

- Algo:
- $x^{(k)}$ connu
 - $w^{(k)} = -\nabla f(x^{(k)})$
 - $x^{(k+1)} = x^{(k)} + p \cdot w^{(k)}$
 $f(x) = S$

Ici $w^{(0)} = (+3, +1)$

$$x^{(1)} = (3, 1) \cdot \frac{1}{2} = \left(\frac{3}{2}, \frac{1}{2}\right)$$

Moins précis