

Descente de gradient

Le 15/10/2020

$$f: \mathbb{R}^n \rightarrow \mathbb{R} \quad (n \geq 1)$$

Problème: trouver $x_* \in \mathbb{R}^n$ tq $f(x_*) = \min_{x \in \mathbb{R}^n} f(x)$.

On sup. qu'un minimiseur existe. On le note x_* .

Déf: $\forall x \in \mathbb{R}^n$, $\nabla f(x) = \left(\frac{\partial f}{\partial x_1}(x), \dots, \frac{\partial f}{\partial x_n}(x) \right)$. (gradient)
si f est différentiable

Hess $f(x) = \left(\frac{\partial^2 f}{\partial x_i \partial x_j}(x) \right)_{1 \leq i, j \leq n} \in \mathbb{R}^{n \times n}$. (Hessienne)

si f est 2 fois différentiable

Prop. informelle: si f est différentiable, $\forall x \in \mathbb{R}^n$,

pour tout y proche de x ,

$$f(y) \approx f(x) + \langle \nabla f(x), y - x \rangle.$$

$-\nabla f(x)$: direction dans laquelle f décroît le plus vite près de x .

Déf (descente de gradient):

- on part de $x_0 \in \mathbb{R}^n$;
- on définit, $\forall t \in \mathbb{N}$,

$$x_{t+1} = x_t - \alpha_t \nabla f(x_t)$$

pas (« stepsize »)

Idealement, on espère $x_t \xrightarrow{t \rightarrow +\infty} x_*$.

ou au moins $f(x_t) \xrightarrow{t \rightarrow +\infty} f(x_*) = \min f$.

But aujourd'hui: sous quelles hypothèses de f ces propriétés sont-elles vraies?

Vitesse de convergence?

1.2) Choix des pas $(\alpha_t)_{t \in \mathbb{N}}$.

α_t trop petit \rightarrow algorithme trop lent

α_t trop grand \rightarrow l'algorithme diverge.

1. Pas pré-définis

Par exemple,

$$\alpha_t = \eta \quad \forall t \in \mathbb{N} \quad (\text{pas constant})$$

(pour un $\eta > 0$)

$$\alpha_t = \frac{1}{t+1} \quad \forall t \in \mathbb{N} \quad (\text{pas décroissant})$$

2. Exact line search:

$$\forall t, \quad \alpha_t = \operatorname{argmin}_{\alpha \geq 0} f(x_t - \alpha \nabla f(x_t))$$

Difficile à calculer.

3. Backtracking line search

Principe: $\forall t, f(x_t - \alpha_t \nabla f(x_t))$

$$\approx f(x_t) + \langle \nabla f(x_t), (x_t - \alpha_t \nabla f(x_t)) - x_t \rangle$$
$$\approx f(x_t) - \alpha_t \|\nabla f(x_t)\|^2$$

(si α_t est assez petit)

Algo: 1) on pose $\alpha_t = \alpha_{\max}$

(α_{\max} paramètre choisi à l'avance)

2) tant que $f(x_t - \alpha_t \nabla f(x_t))$

$$> f(x_t) - \textcircled{c} \alpha_t \|\nabla f(x_t)\|^2,$$

↳ paramètre choisi à l'avance dans $]0; 1[$

$$\alpha_t = \textcircled{\tau} \alpha_t$$

↳ paramètre choisi à l'avance dans $]0; 1[$.

3) on renvoie α_t .

1.3) Rappel: fonctions quadratiques

$$\text{Soit } f: x \rightarrow \frac{1}{2} \langle x, Mx \rangle + \langle p, x \rangle$$

où $M \in \mathbb{R}^{m \times m}$ est symétrique
et $p \in \mathbb{R}^m$.

Prop: $\forall x \in \mathbb{R}^m$, $\nabla f(x) = Mx + p$,
Hess $f(x) = M$.

f convexe $\Leftrightarrow M$ semi-définie positive ($M \succeq 0$)
 \Leftrightarrow Les valeurs propres de M sont ≥ 0 .

Thm: supposons $M \succeq 0$

Considérons la descente de gradient avec pas constant $\frac{\alpha \leq \frac{1}{\lambda_{\max}(M)}}{2}$.

(i) Si $\lambda_{\min}(M) > 0$,

$$\forall t \in \mathbb{N}, \quad \|x_t - x_{\#}\| \leq e^{-t} \|x_0 - x_{\#}\|$$

pour un $\rho \in]0; 1[$.

(ii) Même si $\lambda_{\min}(M) = 0$,

$$\forall t \in \mathbb{N}, \quad f(x_t) - f(x_{\#}) \leq \frac{\|x_0 - x_{\#}\|^2}{\tau t}$$

pour un $\tau > 0$.

II) Convergence

2.1) Fonctions lisses

Déf: soit $M > 0$. On dit que f est **M-lisse** (M-smooth) si ∇f est M-lipschitzien, c.à.d. $\forall x, y \in \mathbb{R}^n, \|\nabla f(x) - \nabla f(y)\| \leq M \|x - y\|$

Rq: si f est deux fois différentiable, f est L-lisse $\iff \|\text{Hess } f'(x)\| \leq L \quad \forall x$
norme spectrale (plus grande valeur propre en valeur absolue)

Ex: pour la fonction quadratique $f: x \mapsto \frac{1}{2} \langle x, Mx \rangle + \langle x, p \rangle$, f est L-lisse si $-L \leq \lambda_{\min}(M) \leq \lambda_{\max}(M) \leq L$.

Lemme: Soit $L > 0$ fixé. Si f est L-lisse, alors $\forall x, y \in \mathbb{R}^n$,
$$f(y) \leq f(x) + \langle \nabla f(x), y - x \rangle + \frac{L}{2} \|x - y\|^2$$

Dém: soit $x, y \in \mathbb{R}^n$. $= g'(t)$ où $g(t) = f(x + t(y-x))$
$$f(y) = f(x) + \int_0^1 \langle \nabla f(x + t(y-x)), y-x \rangle dt \quad \left. \begin{array}{l} g(t) = g(0) \\ + \int_0^1 g'(t) dt \end{array} \right\}$$

$$= f(x) + \int_0^1 \left[\langle \nabla f(x + t(y-x)) - \nabla f(x), y-x \rangle + \langle \nabla f(x), y-x \rangle \right] dt$$

$$\leq f(x) + \int_0^1 \langle \nabla f(x), y-x \rangle dt + \int_0^1 \underbrace{\|\nabla f(x + t(y-x)) - \nabla f(x)\|}_{\leq L \|t(y-x)\| = Lt \|y-x\|} \|y-x\| dt$$

$$= f(x) + \int_0^1 \langle \nabla f(x), y-x \rangle dt + \int_0^1 Lt \|y-x\|^2 dt$$

$$= f(x) + \langle \nabla f(x), y-x \rangle + \frac{L}{2} \|y-x\|^2. \quad \square$$

Corollaire: pour tout t ,

$$f(x_{t+1}) \leq f(x_t) + \langle \nabla f(x_t), x_{t+1}-x_t \rangle + \frac{L}{2} \|x_{t+1}-x_t\|^2$$

$$\begin{aligned} & \left(\begin{aligned} \text{Or } x_{t+1} &= x_t - \alpha_t \nabla f(x_t) \\ \text{donc } x_{t+1}-x_t &= -\alpha_t \nabla f(x_t) \end{aligned} \right. \\ & \rightarrow = f(x_t) - \alpha_t \|\nabla f(x_t)\|^2 + \frac{L}{2} \alpha_t^2 \|\nabla f(x_t)\|^2 \\ & = f(x_t) - \alpha_t \left(1 - \frac{L\alpha_t}{2}\right) \|\nabla f(x_t)\|^2. \end{aligned}$$

$$\text{Si } \alpha_t = \frac{1}{L}, \quad \forall t, \quad f(x_{t+1}) \leq f(x_t) - \frac{1}{2L} \|\nabla f(x_t)\|^2.$$

Corollaire: Soit $L > 0$. Supposons f L -lisse et bornée inférieurement. Alors:

- (i) $(f(x_t))_{t \in \mathbb{N}}$ converge vers une valeur finie.
- (ii) $\|\nabla f(x_t)\| \xrightarrow{t \rightarrow \infty} 0$.

→ pour la descente de gradient à pas constant $\alpha_t = \frac{1}{L} \forall t$

Pour des résultats de convergence plus forts, il faut plus d'hypothèses.

2.2) Fonctions convexes lisses

Déf.: f est **convexe** si $\forall x, y \in \mathbb{R}^m, \forall t \in [0; 1]$,

$$f((1-t)x + ty) \leq (1-t)f(x) + tf(y).$$

Prop: si f est différentiable, f est convexe ssi
 $\forall x, y \in \mathbb{R}^n$,
 $f(y) \geq f(x) + \langle \nabla f(x), y-x \rangle$.

Rq: si f est deux fois différentiable, f est convexe ssi
 $\text{Hess } f(x) \succeq 0$ pour tout $x \in \mathbb{R}^n$.

Thm: Soit $L > 0$. On suppose f L -lisse et convexe.
 On considère la descente de gradient à pas constant
 égal à $1/L$.

$$\forall t \in \mathbb{N}, f(x_t) - f(x_*) \leq \frac{2L \|x_0 - x_*\|^2}{t+4}$$

$\underbrace{\hspace{10em}}_{O(1/t)}$

Dém: première étape:

$$\forall t \in \mathbb{N}, \|x_{t+1} - x_*\| \leq \|x_t - x_*\|$$

(Admis).

Deuxième étape:

on trouve une inégalité qui relie $f(x_{t+1}) - f(x_*)$ et
 $f(x_t) - f(x_*)$.

$$f(x_{t+1}) - f(x_*) \leq f(x_t) - f(x_*) - \frac{1}{2L} \|\nabla f(x_t)\|^2 \quad (*)$$

(propriété)

$$f(x_*) \geq f(x_t) + \langle \nabla f(x_t), x_t - x_* \rangle$$

(par convexité de f)

$$\text{donc } f(x_t) - f(x_*) \leq \langle \nabla f(x_t), x_* - x_t \rangle \leq \|\nabla f(x_t)\| \|x_* - x_t\|$$

$$\leq \|\nabla f(x_t)\| \|x_* - x_0\|$$

$$\text{donc } \|\nabla f(x_t)\| \geq \frac{f(x_t) - f(x_*)}{\|x_* - x_0\|}$$

$$\text{Avec } (*): f(x_{t+1}) - f(x_*) \leq f(x_t) - f(x_*) - \frac{1}{2L} \left(\frac{f(x_t) - f(x_*)}{\|x_* - x_0\|} \right)^2$$

$$\forall t, \frac{1}{f(x_{r+1}) - f(x_*)} \geq \frac{1}{(f(x_r) - f(x_*)) \left(1 - \frac{f(x_r) - f(x_*)}{2L \|x_0 - x_*\|^2}\right)}$$

$$\geq \frac{1}{f(x_r) - f(x_*)} \left(1 + \frac{f(x_r) - f(x_*)}{2L \|x_0 - x_*\|^2}\right)$$

$$(\forall c \in [0; 1], \frac{1}{1-c} \geq 1+c)$$

$$= \frac{1}{f(x_r) - f(x_*)} + \frac{1}{2L \|x_0 - x_*\|^2}$$

$$\text{Donc } \forall t, \frac{1}{f(x_r) - f(x_*)} \geq \frac{1}{f(x_0) - f(x_*)} + \frac{t}{2L \|x_0 - x_*\|^2}$$

$$\geq \frac{2}{L \|x_0 - x_*\|^2} + \frac{t}{2L \|x_0 - x_*\|^2}$$

(admis)

$$= \frac{t+4}{2L \|x_0 - x_*\|^2}$$

$$\text{Donc } \forall t, f(x_r) - f(x_*) \leq \frac{2L \|x_0 - x_*\|^2}{t+4} \quad \square$$

2.3) Fonctions lisses et fortement convexes

Déf: si f est différentiable, on dit qu'elle est μ -fortement convexe (pour un $\mu > 0$) si $\forall x, y,$

$$f(y) \geq f(x) + \langle \nabla f(x), y-x \rangle + \frac{\mu}{2} \|x-y\|^2.$$

Rq: f μ -fortement convexe

$$\Leftrightarrow f_\mu : x \rightarrow f(x) - \frac{\mu}{2} \|x\|^2 \text{ est convexe.}$$

Rq: si f est deux fois dérivable,
 f μ -fortement convexe

$$\Leftrightarrow \forall x \in \mathbb{R}^n, \text{Hess } f(x) - \mu \text{Id} \geq 0.$$

$$\Leftrightarrow \text{Les valeurs propres de Hess } f(x) \text{ sont } \geq \mu.$$

Ex: pour $f: x \rightarrow \frac{1}{2} \langle x, Mx \rangle + \langle x, b \rangle$,
 f est fortement convexe si $\lambda_{\min}(M) > 0$.

Si $\lambda_{\min}(M) > 0$, f est $(\lambda_{\min}(M))$ -fortement convexe.

Thm: Soient $0 < \mu < L$ fixés. Soit f L -lisse et
 μ -fortement convexe.

On considère la descente de gradient à pas constant
 $\alpha_t = \frac{1}{L} \forall t$.

Pour tout $t \in \mathbb{N}$,

$$f(x_t) - f(x_*) \leq \frac{L}{2} \left(\frac{L-\mu}{L+\mu} \right)^t \|x_* - x_0\|^2.$$

$\in]0; 1[\rightarrow$ vitesse géométrique

$$\text{Rq: } \frac{L-\mu}{L+\mu} = \frac{L/\mu - 1}{L/\mu + 1}$$

$\frac{L}{\mu}$ est le « conditionnement »

Plus $\frac{L}{\mu}$ est proche de 1, plus la vitesse de convergence est rapide.

III) Accélération

Revenons au cas où f est L -lisse et convexe mais pas
fortement convexe.

On a vu que la descente de gradient converge à
vitesse $O(1/t)$. Résultat optimal: pour certaines fonctions
 f , c'est réellement la vitesse observée.

Algorithme plus rapide que la descente de gradient?

Oui, descente accélérée, algorithme de Nesterov

On se limite aux algos de 1^{er} ordre (qui n'ont accès qu'à des valeurs de f et ∇f).

Deux "erreurs" faites par la descente de gradient:

- oubli de l'info des étapes précédentes
- regarde $\nabla f(x_t)$ alors que la valeur du gradient serait peut-être plus informative en un autre point.

Algo de Nesterov:

2 suites définies en parallèle,

$$(x_t)_{t \in \mathbb{N}}$$

(minimiseurs approchés)

$$(y_t)_{t \in \mathbb{N}}$$

(points où évaluer le gradient)

Définition de x_{t+1} et y_{t+1} $\forall t$:

$$x_{t+1} = y_t - \frac{1}{L} \nabla f(y_t)$$

$$y_{t+1} = x_{t+1} + \underbrace{\gamma_t (x_{t+1} - x_t)}_{\text{moment}}$$

où $(\gamma_t)_{t \in \mathbb{N}}$ est définie par

$$\left\{ \begin{array}{l} \lambda_{-1} = 0 \\ \forall t \in \mathbb{N}, \lambda_t = 1 + \frac{\sqrt{1 + 4\lambda_{t-1}^2}}{2} \\ \forall t, \gamma_t = \frac{\lambda_t - 1}{\lambda_{t+1}} \end{array} \right.$$

Thm: soit $L > 0$. On suppose f est convexe et L -lisse.

Pour tout $t \in \mathbb{N}$,

$$f(x_t) - f(x_*) \leq \frac{2L}{(t+1)^2} \|x_0 - x_*\|^2. \quad) \quad O(1/t^2)$$