

Algorithmes de descente

1	Algorithmique en optimisation	1
2	Algorithmes à directions de descente	3
2.1	Principes algorithmiques	3
2.2	Exemples de directions de descente	5
2.3	Règles de recherche linéaire	8
2.4	Un résultat de convergence globale	12
3	Algorithmes à régions de confiance	14
3.1	Principes algorithmiques	14
3.2	Exemples de modèles	18
3.3	Un résultat de convergence globale	20

1) Algorithmique et optimisation

Considérons le problème sans contrainte

$$(P) \begin{cases} \min f(x) \\ x \in \mathbb{R}^n \end{cases}$$

où $f : \mathbb{R}^n \rightarrow \mathbb{R}$

Remarques

- ① Si l'on veut minimiser un polynôme $p : \mathbb{R} \rightarrow \mathbb{R}$, une première approche consiste à calculer les racines de p'

si degré $p \geq 6 \Rightarrow$ degré $p' \geq 5$

$\Rightarrow$ pas de formule par radicaux

- On s'intéresse donc ici à des méthodes approchées qui génèrent des suites $(x_n) \rightarrow$ solution
- Ces algorithmes requièrent une analyse de convergence des suites qu'ils génèrent

- ② Autre limitations : les algorithmes proposés ne pourront trouver que des minima locaux et même des points stationnaires ($\nabla f(x) = 0$)

$\rightarrow$ trouver un minimum global est proche d'un problème d'optimisation combinatoire (pensez à la minimisation d'un polynôme d'ordre 1000 sur $\mathbb{R}^{1000}$!!)

$\rightarrow$ pour la minimisation globale de polynômes, il existe des approches, mais gourmandes en place mémoire (relaxation de Lasserre)

③ Si x_k est un min local de (P) , on a

$$\nabla f(x_k) = 0. \quad (1)$$

C'est un système de n équations à n inconnues.

On connaît des algorithmes pour résoudre ces problèmes. Très souvent, les algorithmes qui résolvent (1) trouvent des min. locaux; mais ce n'est pas garanti.

④ Il y a une différence importante entre (1) et la recherche d'un zéro de $F: \mathbb{R}^n \rightarrow \mathbb{R}^n$ c-à-d. trouver x tel que

$$F(x) = 0.$$

Ici $F = \nabla f$ et donc $F'(x) = \nabla^2 f(x)$ est symétrique $\Rightarrow$ plus facile.

2) Algorithmes à directions de descente

A) Principes algorithmiques

Def d est une direction de descente de f en x si

$$f'(x) \cdot d \equiv \langle \nabla f(x), d \rangle < 0$$

Dans ce cas, $f(x + \alpha d) < f(x)$ pour tout $\alpha > 0$ petit. En effet

$$0 > f'(x) \cdot d = \lim_{\alpha \downarrow 0} \frac{1}{\alpha} \underbrace{[f(x + \alpha d) - f(x)]}_{\text{donc strictement négatif si } \alpha > 0 \text{ petit}}$$


Algorithme à direction de descente

On passe de x_k à x_{k+1} comme suit

- 1) [test d'arrêt] arrêter si x_k convient.
- 2) choisir (et calculer) d'une direction de descente d_k
- 3) [Recherche linéaire] Calcul d'un pas $\alpha_k > 0$ pas trop petit tel que

$$f(x_k + \alpha_k d_k) \leq f(x_k) + (\text{terme négatif})$$

- 4) [nouvel itère] $x_{k+1} = x_k + \alpha_k d_k$



Remarques

- 1) Le test d'arrêt en x_k dépendra de l'algorithme.
Si on utilise par des directions de descente
comme dans le schéma algorithmique ci-dessus,
on ne peut espérer mieux que $\nabla f(x) = 0$; donc
on prend comme test d'arrêt

$$\nabla f(x_k) \approx 0$$

- 2) On verra à la section suivante quelques
exemples de directions de descente
- 3) Voir la section [c] pour la recherche linéaire

B Exemples de directions de descente (la direction donne son nom à l'algorithme)

① Algorithme de la plus profonde descente ou du gradient

$$d_k = -\nabla f(x_k) \quad \text{On note } g_k := \nabla f(x_k)$$

Descente: $f'(x_k) \cdot d_k = -\|\nabla f(x_k)\|^2 < 0$

si $\nabla f(x_k) \neq 0 \quad \langle \nabla f(x_k), -\nabla f(x_k) \rangle$

Rmq: algorithme du 1^{er} ordre, lent en pratique, mais avec un résultat de convergence globale **forte**; redevenu intéressant pour les données massives.

② Algorithme du gradient conjugué

$$d_k = -g_k + \beta_k d_{k-1} \quad \text{si } k \geq 2 \quad (\beta_k = 0 \text{ si } k=1)$$

Descente: $f'(x_k) \cdot d_k = -\|g_k\|^2 + \beta_k \underbrace{\langle g_k, d_{k-1} \rangle}_{=0} < 0$

si $g_k \neq 0$ et Recherche linéaire exacte

(si on minimise $\alpha \mapsto f(x_{k-1} + \alpha d_{k-1})$ pour trouver α_{k-1})


→ OK si problème quadratique
Sinon très mauvais.

Rmq: - beaucoup de contributions sur des variantes de cet algorithme depuis ~1990 (peut-être à cause des données massives).

- algorithmes très peu gourmands en temps de calcul critique et en place mémoire.

$$\alpha_{k-1} \leftarrow \underset{\alpha > 0}{\operatorname{argmin}} f(x_{k-1} + \alpha d_{k-1})$$

$$\Rightarrow \langle \nabla f(x_k), d_{k-1} \rangle = 0$$



Differentiation automatique (mode inverse)

$$\frac{T(f(x), \nabla f(x))}{T(f(x))} \leq 5$$

③ Algorithme de Newton

$$\boxed{d_h = - \nabla^2 f(x_h)^{-1} g_h} \quad (\text{si possible})$$

Descente : $f'(x_h) \cdot d_h = - \langle \nabla^2 f(x_h)^{-1} g_h, g_h \rangle < 0$

$$\text{si } g_h \neq 0 \quad \text{et} \quad \nabla^2 f(x_h) > 0$$

- Remq :
- algorithme très rapide mais coûteux (il faut calculer $\nabla^2 f(x_h)$ et résoudre un système linéaire),
 - convergence locale seulement,
 - algorithme très étudié (pour beaucoup de problèmes différents).

④ Algorithme de quasi-Newton

$$\boxed{d_h = - M_h^{-1} g_h} \quad \text{où } M_h \approx \nabla^2 f(x_h) \text{ est aussi} \\ \text{généralisé par d'algorithme}$$

Descente : $\text{si } g_h \neq 0 \quad \text{et} \quad M_h > 0$

- Remq - très bonne famille d'algorithmes,
- moins coûteux que Newton,
 - il existe des versions pour très grands problèmes ($n \approx 10^8 \dots$).

⑤ Algorithme de Gauss-Newton

Adapté aux problèmes de moindres-carrés, c-à-d. qui s'écrivent

$$\inf_{x \in \mathbb{R}^n} f(x) \quad \text{où} \quad f(x) = \frac{1}{2} \|r(x)\|_2^2$$

$$r : \mathbb{R}^n \rightarrow \mathbb{R}^m \quad (\text{résidu})$$

Si on note $J_h := r'(x_h) \quad (m \times n)$

$$r_h := r(x_h),$$

on cherche dh comme solution de

$$\boxed{(J_h^T J_h) dh = - J_h^T r_h} \quad (\exists \text{ toujours une solution})$$

une approximation de $\nabla^2 f(x_h)$
 $\parallel$
 $-g_h$

$$f'(x) = \langle r(x), r'(x) \rangle$$

$$\Rightarrow \nabla f(x) = r'(x)^T r(x)$$

Descente : $f'(x_h) \cdot dh = - \|J_h dh\|_2^2 < 0$

si $g_h \neq 0$

Remq : - très utilisé pour les problèmes de moindres-carrés car il ne faut pas calculer $r''(x_h)$ (contrairement à l'algorithme de Newton),



- Convergence rapide si $r(x_h) \approx 0$ ou $r''(x_h) \approx 0$.

Reptes de recherche lineaire


On cherche un pas $\alpha_k > 0$ en x_k avec 2 objectifs
 - faire décroître suffisamment $h_k: \mathbb{R}_+ \rightarrow \mathbb{R}$

$$h_k(\alpha) := f(x_k + \alpha d_k)$$

de manière à éviter la situation



peut-être $f'(x_k) \cdot d_k < 0$
 on ne visite jamais cet intervalle



- ne pas prendre $\alpha_k > 0$ trop petit

$$\forall k \geq 1 \left\{ \begin{array}{l} 0 < \alpha_k \leq \frac{\epsilon}{2^k \|d_k\|} \\ f(x_k + \alpha_k d_k) < f(x_k) \end{array} \right\} \text{ toujours possible}$$

on a (x_k) est une suite de Cauchy car

$$x_k - x_\ell = \sum_{i=\ell}^{k-1} \alpha_i d_i$$

$$\|x_k - x_\ell\| \leq \sum_{i=\ell}^{k-1} \alpha_i \|d_i\| \leq$$


$$\leq \epsilon \sum_{i \geq \ell} \frac{1}{2^i} = \frac{\epsilon}{2^{\ell-1}} \rightarrow 0 \text{ si } \ell \rightarrow \infty$$

Donc $x_k \rightarrow \bar{x} \in \bar{B}(x_1, \epsilon)$

Si x_1 n'est pas solution et $\epsilon > 0$ petit, $\bar{x}$ n'est pas solution ($\Rightarrow$ fausse convergence).

① Règle de Cauchy (ou recherche linéaire exacte)

$$x_h \in \underset{x \in \mathbb{R}_+}{\operatorname{argmin}} h_h(x)$$



Rmq

- ça semble très bien, mais c'est à proscrire car

⊗ c'est un problème de minimisation en
 soit $\Rightarrow$ demande beaucoup d'itérations
 donc coûteux (en calcul de gradients)

⊗ il faut 1 test d'arrêt (minimisation
 exacte impossible) ; donc mieux vaut
 avoir 1 test d'arrêt qui assure la
 convergence globale de l'algorithme
 sans devoir faire une minimisation
 précise.

⊗ le minimum peut ne pas exister

- à réserver pour les problèmes quadratiques

② Règle d'Armijo

- on fait de même f suffisamment en demandant

$$f(x_h + \alpha_h dh) \leq f(x_h) + \omega \alpha_h \underbrace{\langle g_h, dh \rangle}_{< 0} \quad (A)$$

toujours possible


$$\omega \in]0, \frac{1}{2}] \quad (\text{typiquement } \omega \approx 10^{-4})$$

c'est le terme négatif

- on empêche le pas d'être trop petit en prenant

$$\alpha_h = \beta^{i_h} \alpha_h^0 \rightarrow \in \text{compacts de } \mathbb{R}_{++} \quad (\text{souvent } \alpha_h^0 = 1)$$

où i_h est le plus petit entier ≥ 0 tel que (A) soit vraie.



Rmq - souvent utilisé pour l'algorithme de Newton

③ Règle de Wolfe

- on fait décroître f suffisamment en demandant (comme dans la règle d'Armijo)

$$f(x_k + \alpha_k d_k) \leq f(x_k) + w_1 \alpha_k \langle g_k, d_k \rangle \quad (w_1)$$


$\uparrow$
 $\in]0, \frac{1}{2}]$ (typiquement $w_1 \leq 10^{-4}$)

- on empêche le pas d'être trop petit en demandant

$$\langle g(x_k + \alpha_k d_k), d_k \rangle \geq w_2 \langle g_k, d_k \rangle \quad (w_2)$$

$\uparrow$
 $\in]w_1, 1[$ (typiquement $w_2 = 0.99$)

$h'_k(\alpha_k) = f'(x_k + \alpha_k d_k) \cdot d_k$



Rmq - très utilisé pour l'algorithme de quasi-Newton (car permet d'assurer $H_k \succ 0$)

(D) Un résultat de convergence globale

Si . algorithme à directions de descente du
avec recherche linéaire de Wolfe,

• $\{f(x_h)\}$ bornée inférieurement,


• f est $C^{1,1}$, i.e., $\exists L > 0$: $\forall x, y \in \mathbb{R}^n$
 $\| \nabla f(x) - \nabla f(y) \| \leq L \|x - y\|$

alors on a la condition de Zoutendijk

$$\sum_{h \geq 1} \|g_h\|^2 \cos^2 \theta_h < +\infty$$

On a noté θ_h = l'angle entre d_h et $-g_h$:

$$\cos \theta_h = - \frac{\langle g_h, d_h \rangle}{\|g_h\| \|d_h\|}$$



toutes les directions de
descente de f en x_h
(pour le p.s. euclidien ici)

Exemples d'utilisation


• algorithme du gradient $\Rightarrow d_h = -g_h \Rightarrow \theta_h = 0$

$$\Rightarrow \sum_{h \geq 1} \|g_h\|^2 < \infty \Rightarrow g_h \rightarrow 0$$

(on ne peut pas dire
beaucoup plus que ça!)

• plus généralement, si $\cos \theta_h \geq \gamma > 0$

$$\Rightarrow g_h \rightarrow 0$$



Dem