

Metodi per l'ottimizzazione non vincolata

$$(P) \quad \min \{ f(x) : x \in \mathbb{R}^n \} \quad (f: \mathbb{R}^n \rightarrow \mathbb{R})$$

METODI ITERATIVI

$x^0, x^1, x^2, \dots, x^k, \dots \dots$

Ricerca dei punti stazionari: $\nabla f(x^*) = 0$ (ipotesi minimale: f diff.)

Convergenza

$\exists \bar{k}$ t.c. $\nabla f(x^{\bar{k}}) = 0$ (FINITEZZA)
 $\exists \lim x^k = x^*$ e $\nabla f(x^*) = 0$
 Tutti i punti di accumulazione di $\{x^k\}$ sono stazionari
 Almeno un punto di accumulazione di $\{x^k\}$ è stazionario

- DI DISCESA: $f(x^0) > f(x^1) > f(x^2) > \dots > f(x^k) > \dots \dots$

$$[f(x^{k+1}) < f(x^k)]$$

("descesa non monotona": $\exists m \in \mathbb{N}$ t.c. $f(x^{k+m}) < f(x^k)$)

- DI RICERCA MONODIMENSIONALE ('line search'):

$$x^{k+1} = x^k + t_k \underbrace{d^k}_{\text{passo di spostamento}} \quad \overbrace{d^k}^{\text{direzione di spostamento}} \quad (t_k \in \mathbb{R}, d^k \in \mathbb{R}^n)$$

Come scegliere t_k e d^k in modo t.c. il metodo sia di discesa?

\bar{x} punto non stazionario, cioè $\nabla f(\bar{x}) \neq 0$

$$f(\bar{x} + td) - f(\bar{x}) = t \nabla f(\bar{x})^T d + r(td)$$

$$\lim_{t \rightarrow 0} \frac{f(\bar{x} + td) - f(\bar{x})}{t} = \nabla f(\bar{x})^T d$$

Se $\nabla f(\bar{x})^T d < 0$, allora $f(\bar{x} + td) < f(\bar{x})$ se t è suff. te piccolo


Per rendere (asintoticamente) massima la decrescita, conviene scegliere $d \in \mathbb{R}^n$ tale che $\nabla f(\bar{x})^T d$ sia minimo:

$$(P_d) \quad \min \left\{ \nabla f(\bar{x})^T d : \|d\|_2 = 1 \right\}$$

Il vincolo $\|d\|_2 = 1$ è fondamentale, altrimenti $\nabla f(\bar{x})^T d < 0 \Rightarrow \nabla f(\bar{x})^T(td) \xrightarrow[t \rightarrow +\infty]{} -\infty$

$$\nabla f(\bar{x})^T d = \|\nabla f(\bar{x})\|_2 \|d\|_2 \cos \theta, \text{ dove } \theta \text{ è l'angolo}$$

compresso tra $\nabla f(\bar{x})$ e d (note: per f è \bar{x} fuori, $\theta = \Theta(d)$)



$\nabla f(\bar{x})^T d = \|\nabla f(\bar{x})\|_2 \|d\|_2 \cos \theta = \|\nabla f(\bar{x})\|_2 \cos \theta \rightarrow (P_d) \text{ può essere riscritto}$
nella forma $\|\nabla f(\bar{x})\|_2 \min \left\{ \cos \theta : \|d\|_2 = 1 \right\},$ il cui minimo si ottiene

quando $\cos \theta = -1$, ovvero per $\theta = \pi \rightarrow d$ con $\bar{d} = -\nabla f(\bar{x}) / \|\nabla f(\bar{x})\|_2$

["il gradiente è la direzione di massima crescita" / "l'opposto del gradiente è la direzione di massima decrescita"]

METODO DEL GRADIENTE

$$d^k = -\nabla f(x^k) \rightsquigarrow x^{k+1} = x^k - t_k \nabla f(x^k)$$

ipotesi:
 f differenziabile
con continuità

Scelta (ideale) per il passo di spostamento

$$t_k \in \operatorname{argmin} \left\{ f(x^k - t \nabla f(x^k)) : t \geq 0 \right\}$$

RICERCA
ESATTA

$$(\text{ovvero } f(x^{k+1}) \leq f(x^k - t \nabla f(x^k)) \quad \forall t \geq 0)$$

(In un generico algoritmo 'line search': $t_k \in \operatorname{argmin} \left\{ f(x^k + t d^k) : t \geq 0 \right\}$)

METODO DEL GRADIENTE ESATTO (più estesamente: "con ricerca esatta")

- 1) Scegliere $x^0 \in \mathbb{R}^n$; $k = 0$
- 2) Se $\nabla f(x^k) = 0$, allora STOP
- 3) Calcolare $t_k \in \arg\min \{f(x^k - t \nabla f(x^k)) : t \geq 0\}$
- 4) $x^{k+1} = x^k - t_k \nabla f(x^k)$
- 5) $k = k + 1$ e ritornare a 2)

Prop 1 Il metodo del gradiente esatto è un metodo di discesa

$$\underline{\text{dim}} \quad \varphi(t) := f(x^k - t \nabla f(x^k))$$

$$f(x^k) = \varphi(0) \geq \varphi(t_k) = f(x^{k+1}) \quad [\text{per def. di } t_k]$$

Supponiamo $\varphi(0) = \varphi(t_k) : t=0$ punto di minimo di φ su $t \geq 0$

φ è derivabile con continuità

$$\varphi'(t) = \nabla f(x^k - t \nabla f(x^k))^T (-\nabla f(x^k)) \quad [**]$$

$$\varphi'(0) = -\|\nabla f(x^k)\|_2^2 < 0 \quad (\text{a meno che } x^k \text{ non sia stazionario})$$

quindi φ è localmente decrescente in $0 : \varphi(t) < \varphi(0) \quad \forall t \in (0, \bar{t})$ contraddizione

Pertanto $\varphi(0) > \varphi(t_k)$ e quindi $f(x^k) > f(x^{k+1})$

Prop 2 Due direzioni successive del metodo del gradiente esatto sono ortogonali,

ovvero $\nabla f(x^{k+1})^T \nabla f(x^k) = 0$

$$\underline{\text{dim}} \quad 0 = \varphi'(t_k) = \nabla f(x^{k+1})^T \nabla f(x^k)$$

[**] $\phi : \mathbb{R}^n \rightarrow \mathbb{R}^m$ derivabile in $\bar{t} \in \mathbb{R}$, $g : \mathbb{R}^m \rightarrow \mathbb{R}$ diff. bili in $\phi(\bar{t}) \in \mathbb{R}^m \Rightarrow g \circ \phi$ differentiabile in \bar{t} e
 $(g \circ \phi)'(\bar{t}) = \nabla g(\phi(\bar{t}))^T \dot{\phi}(\bar{t})$ (dove $\dot{\phi} = (\phi'_1, \dots, \phi'_m)$, $\phi = (\phi_1, \dots, \phi_m)$, $\phi_i : \mathbb{R} \rightarrow \mathbb{R}$)

© 2010 G.BIGI

(3)

Teorema (convergenza) Supponiamo che $\lim_{k \rightarrow \infty} x^k = x^* \in \mathbb{R}^n$. Allora $\nabla f(x^*) = 0$

$$\dim 0 = \nabla f(x^{k+1})^T \nabla f(x^k) \xrightarrow{x^{k+1} \rightarrow x^*} \nabla f(x^*)^T \nabla f(x^*) = \|\nabla f(x)\|_2^2$$

Quindi $\|\nabla f(x^*)\|_2 = 0$, da cui $\nabla f(x^*) = 0$ □

E' possibile dimostrare che ogni punto di accumulazione di $\{x^k\}$ è stazionario.

La ricerca esatta nel caso quadratico

$$f(x) = \frac{1}{2} x^T Q x + b^T x + c, \quad Q = Q^T \in \mathbb{R}^{n \times n}, b \in \mathbb{R}^n, c \in \mathbb{R}$$

$$\nabla f(x) = Qx + b$$

Possiamo supporre che Q sia semidefinita positiva. Infatti, in caso contrario $\exists \bar{x} \in \mathbb{R}^n$

$$\text{t.c. } \bar{x}^T Q \bar{x} < 0 \text{ e } f(t\bar{x}) = \frac{1}{2} t^2 (\bar{x}^T Q \bar{x}) + t b^T \bar{x} + c \xrightarrow{t \rightarrow +\infty} -\infty$$

$$\begin{aligned} \varphi(t) &= f(x - t \nabla f(x)), \quad \varphi'(t) = -\nabla f(x - t \nabla f(x))^T \nabla f(x) = \\ &= -[Q(x - t \nabla f(x)) + b]^T \nabla f(x) = \\ &\quad \uparrow \\ &(\text{perché } \nabla f(x)^T Q \nabla f(x) > 0) \quad = -[Qx - t Q \nabla f(x) + b]^T \nabla f(x) = \\ &= -[\nabla f(x) - t Q \nabla f(x)]^T \nabla f(x) = \\ &= -\nabla f(x)^T \nabla f(x) + t \nabla f(x)^T Q \nabla f(x) \end{aligned}$$

$$\varphi'(t) = 0 \iff t = \nabla f(x)^T \nabla f(x) / (\nabla f(x)^T Q \nabla f(x)) \quad \text{se } \nabla f(x)^T Q \nabla f(x) > 0$$

(sempre se Q definita positiva)

Se invece $\nabla f(x)^T Q \nabla f(x) = 0$, allora

$$\varphi'(t) = -\nabla f(x)^T \nabla f(x) = -\|\nabla f(x)\|_2^2 < 0 \quad \text{da cui}$$

$$f(x - t \nabla f(x)) = \varphi(t) = -\|\nabla f(x)\|_2^2 t + \text{cost.} \xrightarrow{t \rightarrow +\infty} -\infty : f \text{ infante illimitata}$$

Critica del metodo del gradiente esatto

- Gli spostamenti sono ortogonali tra loro: crea "rigidità" negli spostamenti quando si è vicini ad un punto stazionario \Rightarrow passi brevi e tante iterazioni;

$$(Eg: f(x_1, x_2) = x_1^2 + 5x_2^2)$$

La ricerca esatta nel caso quadratico (cont.)

Se Q è semidefinita positiva ma non definita positiva, non è detto che f sia inferiormente illimitata. Ad esempio se $b=0$, allora

$$\min \{ f(x) : x \in \mathbb{R}^n \} = c \quad \text{e} \quad \bar{x}=0 \quad \text{è un punto di minimo.}$$

Più in generale, f ammette [un punto di] minimo (globale) se e solo se tutti gli autovettori relativi all'autovettore nullo di Q sono ortogonali al vettore b , ovvero $Qx=0 \Rightarrow b^T x=0$.

$$\text{Esempio: } Q = \begin{bmatrix} 1 & 2 \\ 2 & 4 \end{bmatrix}, \quad b = \begin{bmatrix} 1 \\ 2 \end{bmatrix}, \quad c = 0$$

Gli autovettori di Q sono $\lambda_{\max} = 5$ e $\lambda_{\min} = 0$ e i relativi autovettori sono $\bar{x} = \begin{bmatrix} 1 \\ 2 \end{bmatrix}$ e $\hat{x} = \begin{bmatrix} 2 \\ -1 \end{bmatrix}$. Nota $b^T \hat{x} = 0$

$$x \in \mathbb{R}^2 \rightarrow x = \alpha \bar{x} + \beta \hat{x} \quad \text{con } \alpha, \beta \in \mathbb{R}$$

$$f(x) = f(\alpha \bar{x} + \beta \hat{x}) \underset{\nearrow}{=} f(\alpha \bar{x}) = 25\alpha^2 + 5\alpha$$

$(Q\hat{x}=0 \text{ e } b^T \hat{x}=0)$

$$\min \{ f(x) : x \in \mathbb{R}^2 \} = \min \{ 25\alpha^2 + 5\alpha : \alpha \in \mathbb{R} \} = -\frac{1}{4}$$

$\bar{x} = -\frac{1}{10}$ punto di minimo

$$x = \bar{x} = \begin{bmatrix} -1/10 \\ -1/5 \end{bmatrix} \quad \text{punto di minimo di } f$$

Algoritmo 'finito' per il caso quadrattico strettamente convesso

$$f(x) = \frac{1}{2} x^T Q x + b^T x + c \quad Q = Q^T \in \mathbb{R}^{n \times n} \text{ definita positiva}, \quad b \in \mathbb{R}^n, \quad c \in \mathbb{R}$$

Siano $\lambda_0, \lambda_1, \dots, \lambda_{n-1} > 0$ gli autovalori di Q .

$$\boxed{x^{k+1} = x^k - \frac{1}{\lambda_k} \nabla f(x^k)} \quad k=0, 1, \dots, n-1$$

L'algoritmo individua un punto stazionario (e quindi di minimo) in al più ~~n~~ passi.

Prop Esiste $j \leq n$ tale che $\nabla f(x^j) = 0$

dim Supponiamo $\nabla f(x^j) \neq 0$ per ogni $j < n$.

$$\begin{aligned} \nabla f(x^n) &= Qx^n + b = Qx^{n-1} - \frac{1}{\lambda_{n-1}} Q \nabla f(x^{n-1}) + b = \nabla f(x^{n-1}) - \frac{1}{\lambda_{n-1}} Q \nabla f(x^{n-1}) = \\ &= \left(I - \frac{1}{\lambda_{n-1}} Q \right) \nabla f(x^{n-1}). \end{aligned}$$

Iterando il procedimento $(n-1)$ volte si ottiene: $\nabla f(x^n) = \prod_{j=0}^{n-1} \left(I - \frac{1}{\lambda_j} Q \right) \nabla f(x^0)$

Siano $u_0, u_1, \dots, u_{n-1} \in \mathbb{R}^n$ autovettori relativi a $\lambda_0, \lambda_1, \dots, \lambda_{n-1}$ ($Qu_i = \lambda_i u_i$) tali da costituire una base di \mathbb{R}^n . Allora $\nabla f(x^0) = \sum_{i=0}^{n-1} \alpha_i u_i$ per opportuni $\alpha_i \in \mathbb{R}$. Quindi:

$$\begin{aligned} \nabla f(x^n) &= \left[\prod_{j=0}^{n-1} \left(I - \frac{1}{\lambda_j} Q \right) \right] \sum_{i=0}^{n-1} \alpha_i u_i = \sum_{i=0}^{n-1} \alpha_i \left(\prod_{j=0}^{n-1} \left(I - \frac{1}{\lambda_j} \lambda_i \right) u_i \right) = \\ &= \sum_{i=0}^{n-1} \alpha_i \left[\prod_{j=0}^{n-1} \left(1 - \frac{1}{\lambda_j} \lambda_i \right) \right] u_i = 0 \end{aligned}$$

$\circlearrowleft j=i \rightarrow 0$

- La 'ricerca esatta' è computazionalmente onerosa: è un problema esso stesso di ottimizzazione ma monodimensionale ← algoritmi richiedono criteri di STOP approx.
- La 'ricerca esatta' può condurre a passi molto brevi se la funzione ha curve di livello particolarmente "schiazzate" (tipo la fz. "banana" di Rosenbrock)

$$f(x_1, x_2) = 100(x_2 - x_1^2)^2 + (1 - x_1)^2$$

Possibili DIREZIONI di DISCESA

$$d^k = -D_k \nabla f(x^k) \quad \text{con } D_k \in \mathbb{R}^{n \times n} \text{ definita positiva}$$

(d^k è una direzione di discesa: $\nabla f(x^k)^T d^k = -\nabla f(x^k)^T D_k \nabla f(x^k) < 0$)


Garantire che il metodo s.s. di discesa può non essere sufficiente:

$$n=1, f(x) = x^2 - 1$$

$$x^k = (-1)^k [2 - k/(k+1)], \quad d^k = (-1)^{k+1}$$

$$f(x^k) = [2 - k/(k+1)]^2 - 1 \xrightarrow{k \rightarrow +\infty} 1$$

$$f(x^{k+1}) < f(x^k) \text{ ma } x^{2k+1} \rightarrow -1, x^{2k} \rightarrow 1 \text{ e } f(-1) = f(1) = 0 > f(0) = -1$$



Possibili SCELTE PER IL PASSO

- 1) Ricerca esatta: $t_k^{\min} \in \arg\min \{ f(x^k + t d^k) : t \geq 0 \}$
- 2) Minimizzazione limitata: $t_k \in \arg\min \{ f(x^k + t d^k) : t \in [0, T] \}, \quad T > 0$ fissato
- 3) Costante: $t_k = \bar{t}$ per qualche $\bar{t} > 0$
- 4) Passi decrescenti: $t_k \downarrow 0$ con $\sum_{k=0}^{\infty} t_k = +\infty$ (ad es. $t_k = 1/k$)

Versioni approssimate di 1) \rightsquigarrow RICERCA IMESATTA

Siano $x^k \in \mathbb{R}^n$ e $d^k \in \mathbb{R}^n$ t.c. $\nabla f(x^k)^T d^k < 0$

Sia $\varphi(t) = f(x^k + t d^k)$: $\varphi'(t) = \nabla f(x^k + t d^k)^T d^k$

Per fornire la diminuzione del valore di f a partire da x^k lungo d^k (ovvero del valore di $\varphi(t)$) ~~per ad essere di una certa consistenza~~, si può imporre la CONDIZIONE DI ARMIJO :

$$(AJO) \quad f(x^k + t d^k) \leq f(x^k) + c_1 t \nabla f(x^k)^T d^k \quad c_1 \in (0, 1) \text{ fissato}$$

• Se f è inf.nte limitata, (AJO) impedisce il caso $t \rightarrow +\infty$ (altrimenti si avrebbe $f(x^k + t d^k) \xrightarrow{t \rightarrow +\infty} -\infty$ in quanto $\nabla f(x^k)^T d^k < 0$).

• Poiché $\lim_{t \rightarrow 0} (f(x^k + t d^k) - f(x^k))/t = \varphi'(0) = \nabla f(x^k)^T d^k < 0$, dalla def. di limite segue che $\exists \bar{t}$ per cui (AJO) vale per ogni $t \in [0, \bar{t}]$ (si noti che $\nabla f(x^k)^T d^k < 0$ garantisce ' $\nabla f(x^k)^T d^k < c_1 \nabla f(x^k)^T d^k$ ')

Per evitare che il passo di spostamento sia eccessivamente piccolo (cioè è ammesso per (AJO)), si può richiedere che $\varphi'(t)$ differisca sufficienmente da $\varphi'(0)$:

$$(CUR) \quad \nabla f(x^k + t d^k)^T d^k \geq c_2 \nabla f(x^k)^T d^k \quad c_2 \in (c_1, 1) \text{ fissato}$$

Infatti: $t \approx 0 \Rightarrow \nabla f(x^k + t d^k) \approx \nabla f(x^k)$ e quindi: $\varphi'(t) = \nabla f(x^k + t d^k)^T d^k$

Questa coppia di condizioni è nota come CONDIZIONI DI WOLFE: $\varphi'(0) = \nabla f(x^k)^T d^k$

$$(AJO) \quad f(x^k + t_k d^k) \leq f(x^k) + c_1 t_k \nabla f(x^k)^T d^k \quad c_1 \in (0, 1) \text{ fissato}$$

$$(CUR) \quad \nabla f(x^k + t d^k)^T d^k \geq c_2 \nabla f(x^k)^T d^k \quad c_2 \in (c_1, 1) \text{ fissato}$$

Oss: il passo fornito delle ricerche esatta verifica le condizioni di Wolfe (CUR)

$$\varphi'(t_k^{min}) = 0 \quad \text{e} \quad \varphi'(0) < 0 \Rightarrow (CUR)$$

Sia t suff.nte piccolo da soddisfare (AJO): $f(x^k + t_k^{min} d^k) = \varphi(t_k^{min}) \leq \varphi(t) =$

$$= f(x^k + t d^k) \leq f(x^k) + c_1 t \nabla f(x^k)^T d^k$$

~~$\Rightarrow t \text{ soddisfa (AJO)}$~~
 $t \text{ non soddisfa (AJO)}$ ma può non garantire (AJO) per t_k^{min} (accade nella "pratica")

Prop: Supponiamo che f sia inf.nte limitata. Allora esiste un intervallo (a, b) per cui entrambe le condizioni di Wolfe valgono per ogni $t \in (a, b)$.

dim: Sia $T_1 := \sup \{ T \mid (\text{AJO}) \text{ vale per ogni } t \in [0, T] \} : T_1 > 0$

f inf.nte limitata $\Rightarrow T_1 < +\infty$. Per il teo (riformulato) $\exists T_2 \in (0, T_1)$

$$\text{t.c. } f(x^k + T_1 d^k) - f(x^k) = T_1 \nabla f(x^k + T_2 d^k)^T d^k$$

Inoltre $f(x^k + T_1 d^k) - f(x^k) = c_1 T_1 \nabla f(x^k)^T d^k$ (se fosse $<$, per la permanenza del segno T_1 non sarebbe il max dell'insieme). Quindi:

$$\nabla f(x^k + T_2 d^k)^T d^k = c_1 \nabla f(x^k)^T d^k \geq c_2 \nabla f(x^k)^T d^k \quad (c_2 > c_1 \text{ e } \nabla f(x^k)^T d^k < 0)$$

Poiché ∇f è continua, la diseguaglianza vale in un intorno I_1 di T_2 $\rightarrow I_1 \cap I_2$ è l'intervallo cercato

METODI DEL 'GRADIENTE' CON RICERCA INESATTA


- 1) Scegliere $x^0 \in \mathbb{R}^n$; $k=0$
- 2) Se $\nabla f(x^k) = 0$, allora STOP
- 3) Scegliere $d^k \in \mathbb{R}^n$ tale che $\nabla f(x^k)^T d^k < 0$
- 4) Calcolare $t_k > 0$ che soddisfa (AJO) e (CUR)
(condizioni di Wolfe)
- 5) $x^{k+1} = x^k + t_k d^k$
- 6) $k=k+1$ e ritornare a 2)

3) + (AJO)

metodo di
discesa

Siano $\{x^k\}$, $\{t_k\}$ e $\{d^k\}$ le successioni generate dall'algoritmo e sia θ_k l'angolo compreso tra $\nabla f(x^k)$ e d^k :

$$\nabla f(x^k)^T d^k = \|\nabla f(x^k)\|_2^T \|d^k\|_2 \cos \theta_k$$



Lemma Supponiamo che

- f sia inf.nte limitata ($\exists M \in \mathbb{R}$ t.c. $f(x) \geq M \quad \forall x \in \mathbb{R}^n$)
- ∇f sia Lipschitziana, ovvero $\exists L > 0$ tale che

$$\|\nabla f(x) - \nabla f(y)\|_2 \leq L \|x - y\|_2 \quad \forall x, y \in \mathbb{R}^n$$

Allora $\sum_{k=0}^{\infty} \cos^2 \theta_k \|\nabla f(x^k)\|_2^2 < +\infty$.

dim Sottrivendo $-\nabla f(x^k)^T d^k$ ad entrambi i membri di (CVR) si ottiene la diseguaglianza $(\nabla f(x^k + t_k d^k) - \nabla f(x^k))^T d^k \geq (c_2 - 1) \nabla f(x^k)^T d^k$.

$$(c_2 - 1) \nabla f(x^k)^T d^k = (c_2 - 1) \|\nabla f(x^k)\|_2 \|d^k\|_2 \cos \theta_k$$

$$(\nabla f(x^k + t_k d^k) - \nabla f(x^k))^T d^k \stackrel{-\nabla f(x^k)}{\leq} \|\nabla f(x^k + t_k d^k)\|_2 \|d^k\|_2 \stackrel{(\text{dis. Schwartz})}{\leq} L t_k \|d^k\|_2^2 \stackrel{(\nabla f \text{ Lipschitziana})}{\leq}$$

da cui $t_k \geq \frac{(c_2 - 1)}{L} \frac{\|\nabla f(x^k)\|_2}{\|d^k\|_2} \cos \theta_k > 0$ ($\cos \theta_k < 0$ e $c_2 < 1$)

Posti $f_{k+1} = f(x^k + t_k d^k)$ e $f_k = f(x^k)$, la condizione (AJO) si riscrive come

$$\begin{aligned} f_{k+1} &\leq f_k + c_1 t_k \nabla f(x^k)^T d^k = f_k + c_1 t_k \underbrace{\|\nabla f(x^k)\|_2 \|d^k\|_2 \cos \theta_k}_{(< 0 \text{ e } \rightarrow)} \leq \\ &\leq f_k - \boxed{c_1 \frac{(1 - c_2)}{L} \|\nabla f(x^k)\|_2^2 \cos^2 \theta_k} \end{aligned}$$

$\longrightarrow f_{k+1} \leq f_k - c \|\nabla f(x^k)\|_2^2 \cos^2 \theta_k$

Iterando a ritroso la diseguaglianza si ottiene: $f_{k+1} \leq f_0 - c \sum_{j=0}^k \|\nabla f(x^j)\|_2^2 \cos^2 \theta_j$

Quindi $\sum_{j=0}^k \|\nabla f(x^j)\|_2^2 \cos^2 \theta_j \leq (f_0 - f_{k+1})/c \leq \underbrace{(f_0 - M)/c}_{\text{costante}}$

Per $k \rightarrow +\infty$ si ottiene $\sum_{j=0}^{\infty} \|\nabla f(x^j)\|_2^2 \cos^2 \theta_j \leq (f_0 - M)/c < +\infty$

$$\sum_{k=0}^{\infty} \|\nabla f(x^k)\|_2^2 \cos^2 \theta_k < +\infty \Rightarrow \|\nabla f(x^k)\|_2^2 \cos \theta_k \xrightarrow{k \rightarrow \infty} 0$$

Teorema (convergenza) Supponiamo che

- f sia inf. nte limitata
- ∇f sia Lipschitz
- $\exists \delta > 0$ tale che $\cos \theta_k \leq -\delta \forall k$
(equivolentemente: $\exists \sigma \in (0, \pi/2]$ t.c. $\theta_k \geq \pi/2 + \sigma$).


Allora ogni punto di accumulazione di $\{x^k\}$ è un punto stazionario.

dim Sia x^* un punto di accumulazione: $\exists \{x^{k_j}\}$ sottosuccessione t.c. $x^{k_j} \rightarrow x^*$


$$0 \leftarrow \overline{\cos^2 \theta_{k_j}} \|\nabla f(x^{k_j})\|_2^2 \geq \delta^2 \|\nabla f(x^{k_j})\|_2^2 \geq 0$$

dove $\|\nabla f(x^{k_j})\|_2 = \lim_{j \rightarrow \infty} \|\nabla f(x^{k_j})\|_2 = 0$, ovvero $\nabla f(x^*) = 0$ ■

Not: $d^k = -\nabla f(x^k) \Rightarrow \cos \theta_k = -1 \quad (\theta_k = \pi)$



Esempio in cui la ricerca esatta non soddisfa (AJO)



IL METODO DI NEWTON

Metodo di Newton-Raphson per risolvere il sistema di equazioni:

$$F(x) = 0 \quad \text{con} \quad F: \mathbb{R}^n \rightarrow \mathbb{R}^n$$

$$x^{k+1} = x^k - [JF(x^k)]^{-1} F(x^k)$$

dove $JF(x^k)$ è la matrice jacobiana di F in x^k .

Teorema (III) Supponiamo che F sia differenziabile 2 volte e sia $x^* \in \mathbb{R}^n$ tale che $F(x^*) = 0$. Se $JF(x^*)$ è invertibile, allora $\exists \delta > 0$ tale che per ogni $x^0 \in B(x^*, \delta)$, $x^k \rightarrow x^*$ ed inoltre esiste $M > 0$ t.c.

$$\|x^{k+1} - x^*\|_2 \leq M \|x^k - x^*\|_2^2.$$

Oss Per la continuità di $JF: x \mapsto JF(x)$ e della f.z. determinante, $JF(x^*)$ invertibile ($\det JF(x^*) \neq 0$) $\Rightarrow JF(x)$ è invertibile ($\det JF(x) \neq 0$) in un intorno di x^* .

(P) $\{ \min f(x) : x \in \mathbb{R}^n \} \rightarrow$ applicare Newton-Raphson a $F = \nabla f$ per trovare punti stazionari di f : $J(\nabla f)(x) = \nabla^2 f(x)$.

$d^k = -[\nabla^2 f(x^k)]^{-1} \nabla f(x^k)$ è una direzione di discesa se $\nabla^2 f(x^k)$ è definita positiva ma non in generale: Newton non è necessariamente un metodo di discesa e può convergere a punti stazionari, che siano punti di massimo.

Note: se $\nabla^2 f(x)$ è definita positiva per ogni x , allora f è strettamente convessa.

Per garantire la discesa, si possono rafforzare le ipotesi: invertibile \Rightarrow definita positiva $\nabla^2 f(x^*)$ definita positiva $\Rightarrow \nabla^2 f(x)$ definita positiva per ogni x in intorno di x^* .

(continuità di $\nabla^2 f$ richiesta)

Se $x^k \rightarrow x^*$, allora x^k appartiene definitivamente a tale intorno, e quindi d^k è una direzione di discesa per k suff. grande (metodo definito di discesa)

Teorema Supponiamo che f sia differentiabile 3 volte con continuità e sia $x^* \in \mathbb{R}$ un punto stationario ($\nabla f(x^*) = 0$) per cui $\nabla^2 f(x^*)$ è definita positiva. Allora $\exists \delta > 0$ tale che per ogni $x^0 \in B(x^*, \delta)$, $x^k \rightarrow x^*$ ed inoltre $\exists M > 0$ tale che

$$\|x^{k+1} - x^*\|_2 \leq M \|x^k - x^*\|_2^2$$

$$(x^{k+1} = x^k - [\nabla^2 f(x^k)]^{-1} \nabla f(x^k))$$

Oss le ipotesi su x^* garantiscono che sia un punto di minimo locale

Note 1: il metodo è di natura locale: la convergenza è garantita, ma esclusivamente se il punto di partenza x^0 è sufficientemente vicino a x^* ; altrimenti il metodo potrebbe non convergere o convergere ad un punto di max locale.

Note 2: il passo $t_k = 1$ (si possono comunque applicare anche 'ricerche monodim' (line search))

Note 3: Ad ogni iterazione è richiesto il calcolo della matrice hessiana $\nabla^2 f(x^k)$ e della sua inversa \leftarrow computazionalmente oneroso \rightsquigarrow metodi quasi-Newton: non $\nabla^2 f(x^k)$ ma una sua approssimazione, aggiornata iterazione per iterazione tramite formule che utilizzano il risultato dell'iterazione collegando le derivate seconde alla variazione del gradiente.

Altro punto di vista per la derivazione del metodo di Newton

$$f(x+d) \approx f(x) + \nabla f(x)^T d \quad \rightsquigarrow d = -\nabla f(x) \quad (\rightarrow \text{sviluppo I° ordine n. vitt. gradiente})$$

$$\text{Sviluppo II° ordine: } f(x+d) \approx f(x) + \nabla f(x)^T d + \frac{1}{2} d^T \nabla^2 f(x) d = m_2(d)$$

$\nabla^2 f(x)$ semi-definita positiva $\Rightarrow m_2(d)$ convessa

$$\nabla m_2(d) = \nabla f(x) + \nabla^2 f(x) d; \quad \nabla^2 f(x) \text{ definita positiva} \Rightarrow (\nabla m_2(d) = 0 \Leftrightarrow d = -[\nabla^2 f(x)]^{-1} \nabla f(x))$$

La direzione di Newton $-[\nabla^2 f(x)]^{-1} \nabla f(x)$ minimizza $m_2(d)$ se $\nabla^2 f(x)$ def. positiva.

Sviluppo I° ordine con resto esatto: $f(x+d) = f(x) + \nabla f(x)^T d + \frac{1}{2} d^T \nabla^2 f(x+Td) d \quad T \in (0,1) \text{ opp.}$
 $m_2(d)$ sostituire $\nabla^2 f(x+Td)$ con $\nabla^2 f(x)$: l'approssimazione è "accurata" per $\|d\| \ll 1$.

Se f è una funzione quadratica, allora $f \equiv m_2$ ed il metodo di Newton termina in una unica iterazione.

Verifica ulteriore: $f(x) = \frac{1}{2}x^T Q x + b^T x$ con $Q = Q^T$ definita positiva.

$$f(x+d) = \frac{1}{2}(x+d)^T Q(x+d) + b^T(x+d) = \frac{1}{2}x^T Q x + b^T x + x^T Q d + b^T d + \frac{1}{2}d^T Q d$$

$$= \frac{1}{2}x^T Q x + b^T x + (Qx+b)^T d + \frac{1}{2}d^T Q d = f(x) + \nabla f(x)^T d + \frac{1}{2}d^T Q d = m_2(d)$$

$$\nabla f(x) = Qx + b, \quad \nabla^2 f(x) = Q \quad (\rightarrow \nabla f(x) = 0 \Leftrightarrow Qx = -b \Leftrightarrow x = Q^{-1}b).$$

$$x^* = x^0 - Q^{-1}(Qx^0 + b) = x^0 - x^0 - Q^{-1}b = -Q^{-1}b \quad \text{quale che sia } x^0 \in \mathbb{R}^n$$

Nota 4: il teorema fornisce anche un risultato sulla VELOCITÀ DI CONVERGENZA:

$$\|x^{k+1} - x^*\|_2 \leq M \|x^k - x^*\|_2^p \rightarrow \text{il metodo di Newton ha convergenza superlineare di ordine 2}$$

Ricordi: sia $x^k \rightarrow x^*$, con $x^k \neq x^* \forall k$, e sia $p \geq 1$.

$$\lim_{k \rightarrow +\infty} \frac{\|x^{k+1} - x^*\|}{\|x^k - x^*\|_2^p} = \gamma \quad \begin{array}{l} \nearrow p=1, \quad \gamma \in (0,1) \quad \text{convergenza lineare} \\ \nearrow p=1, \quad \gamma=1 \quad \text{convergenza sublineare} \\ \searrow p > 1 \quad \text{convergenza superlineare di ordine } p \end{array}$$

$$\|x^{k+1} - x^*\|_2 \leq \beta \|x^k - x^*\|_2^p \quad \text{con } \beta \in (0,1) \rightarrow \text{convergenza di ordine (almeno) } p \rightarrow$$

VELOCITÀ DI CONVERGENZA DEL METODO DEL GRADIENTE ESATTO

Sia $\{x^k\}$ la successione generata dal metodo del gradiente esatto

Teo 1 Supponiamo che f sia differentiabile 2 volte con continuità, e che $x^k \rightarrow x^*$ con $\nabla^2 f(x^*)$ definita positiva. Allora

$$f(x^{k+1}) - f(x^*) \leq \left[(\lambda_{\max} - \lambda_{\min}) / (\lambda_{\max} + \lambda_{\min}) \right]^2 (f(x^k) - f(x^*)),$$

dove $\lambda_{\max} \geq \lambda_{\min} > 0$ sono il più grande ed il più piccolo autovalore di $\nabla^2 f(x^*)$.

Teo 2 Supponiamo che f sia differentiabile con continuità e ∇f sia Lipschitziana, che f sia convessa e che l'insieme dei punti di minimo sia non vuoto e limitato. Allora

$$(valore ottimo) \quad \underbrace{f(x^k) - f^*}_{\rightarrow} = O(1/k)$$

ovvero $\forall \epsilon > 0 \exists \bar{k}$ tale che $f(x^k) \leq f^* + \frac{\epsilon}{k} \quad \forall k \geq \bar{k}$

I METODI DEL GRADIENTE CONIUGATO

• CASO LINEARE

Risolvere $Ax = b$ con $b \in \mathbb{R}^n$, $A = A^T \in \mathbb{R}^{n \times n}$ definita positiva tramite la minimizzazione della funzione quadratica convessa $f(x) = \frac{1}{2} x^T A x - b^T x$ (in quanto risulta $\nabla f(x) = Ax - b$) modificando opportunamente la direzione di discesa del metodo del gradiente [esso] ("coniugazione").

(HESTENES-STIEFEL 1952)

- 1) Scegliere $x^0 \in \mathbb{R}^n$; $k=0$
- 2) Se $r_k = b - Ax_k = 0$, allora STOP
- 3) $\beta_k = r_k^T r_k / r_{k-1}^T r_{k-1}$, se $k \geq 1$, $\beta_0 = 0$
- 4) $d_k = r_k + \beta_k d_{k-1}$, se $k \geq 1$, $d_0 = r_0$ ← coniugazione
- 5) $t_k = r_k^T r_k / d_k^T A d_k$
- 6) $x_{k+1} = x_k + t_k d_k$
- 7) $k=k+1$ e ritornare a 2)

Oss
$$r_k = -\nabla f(x_k)$$

Prop (i) $r_k^T r_j = 0 \quad j=0, 1, \dots, k-1$ (ii) $d_k^T A d_{k-1} = 0$ (iii) $r_k^T d_j = 0 \quad j=0, 1, \dots, k-1$

Oss (i) garantisce che il metodo è diretto: la convergenza si ottiene in max n iterazioni

La formula al passo 5) fornisce il passo di ricerca esatta, infatti se $\psi'_k(t) = f(x_k + t d_k)$,

risulta: $0 = \psi'_k(t_k) = \nabla f(x_k + t_k d_k)^T d_k = (Ax_k + t_k A d_k - b)^T d_k =$

$$= (t_k A d_k - r_k)^T d_k = t_k d_k^T A d_k - r_k^T r_k - \beta_k r_k^T d_{k-1} = t_k d_k^T A d_k - r_k^T r_k$$

da cui $0 = \psi'_k(t_k) \Leftrightarrow t_k = r_k^T r_k / d_k^T A d_k$

d_k è una direzione di discesa:

$$\nabla f(x_k)^T d_k = -r_k^T d_k = -r_k^T r_k - \beta_k r_k^T d_{k-1} = -r_k^T r_k < 0 \quad (\text{e } r_k \neq 0).$$

- (ASO) NONLINEARE

Applicare la tecnica di conjugazione per la minimizzazione di $f: \mathbb{R}^n \rightarrow \mathbb{R}$ non necessariamente quadratica (Fletcher-Reeves 1964)

Idee base: sostituire il residuo r_k con $-\nabla f(x_k)$

Dificoltà: non esiste una formula esplicita per la ricerca esatta, e nel caso di ricerca inesatta bisogna garantire che il metodo sia di discesa.

$$d_k = -\nabla f(x_k) + \beta_k d_{k-1} : \quad \nabla f(x_k)^T d_k = -\|\nabla f(x_k)\|_2^2 + \beta_k \nabla f(x_k)^T d_{k-1}$$

Nel caso della ricerca esatta si ha $\nabla f(x_k)^T d_{k-1} = 0$ (infatti se $\varphi_{k-1}'(t) = f(x_{k-1} + t d_{k-1})$, si ha $0 = \varphi_{k-1}'(0) = \nabla f(x_{k-1} + t_{k-1} d_{k-1})^T d_{k-1} = \nabla f(x_k)^T d_{k-1}$) e quindi il metodo è di discesa. Con la ricerca inesatta non c'è garanzia che $\nabla f(x_k)^T d_{k-1} \leq 0$. Ciò può essere ottenuto imponendo le condizioni forti di Wolfe:

$$(AJO) \quad f(x_k + t d_k) \leq f(x_k) + c_1 t \nabla f(x_k)^T d_k$$

$$(CUR1) \quad |\varphi_k'(t)| \leq |\varphi_k'(0)| \quad (\varphi_k(t) = f(x_k + t d_k))$$

dove $0 < c_1 < c_2 < \frac{1}{2}$. Nelle condizioni di Wolfe la condizione (AJO) è la medesima, mentre si richiede $c_2 < 1$ (invece di $c_2 < \frac{1}{2}$) e la condizione di curvatura è

$$(CUR) \quad \varphi_k'(t) \geq c_2 \varphi_k'(0).$$

Se d_k è una direzione di discesa, e quindi $\varphi_k'(0) = \nabla f(x_k)^T d_k < 0$, allora (CUR1) può essere riscritta come $-|\varphi_k'(t)| \geq -c_2 |\varphi_k'(0)| = c_2 \varphi_k'(0)$ e pertanto implica (CUR) essendo $\varphi_k'(t) \geq -|\varphi_k'(t)|$.

METODO DEL GRADIENTE CONIUGATO DI FLETCHER-REEVES

- 1) Scegliere $x^0 \in \mathbb{R}^n$; $k = 0$
- 2) Se $\nabla f(x^k) = 0$, allora STOP
- 3) $\beta_k = \frac{\nabla f(x^k)^T \nabla f(x^k)}{\nabla f(x^{k-1})^T \nabla f(x^{k-1})}$ se $k \geq 1$, $\beta_0 = 0$
- 4) $d^k = -\nabla f(x^k) + \beta_k d^{k-1}$ se $k \geq 1$, $d^0 = -\nabla f(x^0)$
- 5) Calcolare $t_k > 0$ che soddisfa (AJO) e (CUR1)
(condizioni f.t. di Wolfe)
- 6) $x^{k+1} = x^k + t_k d^k$
- 7) $k = k+1$ e ritornare a 2)

Ipotesi: f inferiormente limitata

Lemme: Se i passi t_k soddisfano (CUR1), allora il metodo genera direzioni d^k tali che

$$-\frac{1}{1-c_2} \leq \frac{\nabla f(x^k)^T d^k}{\|\nabla f(x^k)\|_2^2} \leq \frac{2c_2 - 1}{1-c_2}.$$

Oss: $c_2 \in (0, \frac{1}{2})$ garantisce che $(2c_2 - 1)/(1 - c_2) < 0$ (infatti: $\ell(c) = (2c - 1)/(1 - c)$ è monotona crescente e $\ell(0) = -1$, $\ell(\frac{1}{2}) = 0$), quindi il metodo è di discesa e con dim analogo a quella di pagina 7 si può dimostrare che esiste un intervallo (a, b) in cui entrambe le condizioni (AJO) e (CUR1) risalgono.

Supponendo che ∇f sia lipschitziana, si può dimostrare $\sum_{k=0}^{\infty} \cos^2 \theta_k \|\nabla f(x^k)\|_2^2 < +\infty$ dove θ_k è l'angolo compreso tra $\nabla f(x^k)$ e $-d^k$ (opportuna modifica delle dim. di pagina 8).

Teo (convergenza): Supponiamo che ∇f sia lipschitziana. Allora $\liminf_{k \rightarrow \infty} \|\nabla f(x^k)\|_2 = 0$

È una forma molto debole di convergenza: garantisce soltanto l'esistenza di una

sottosuccessione $\{x^k\}$, tale che $\|\nabla f(x^k)\|_2 \xrightarrow[k \rightarrow \infty]{} 0$, mentre la sottosuccessione $\{x^k\}$ potrebbe non convergere. Ovviamente se $x^k \rightarrow x^*$, allora è un punto stazionario di f , ma se $x^k \xrightarrow[k \rightarrow \infty]{} x^*$ per qualche sottosuccessione $\{x^{k_s}\}$, ma $x^k \not\rightarrow x^*$ (cioè x^* è un punto di accumulazione della successione ma non è l'unico) allora la stazionarietà di x^* non è garantita.

Nel metodo del gradiente (con ricerca esatta) risulta $\cos \theta_k = 1$ per ogni k , mentre nel metodo del gradiente coniugato (nonlineare) non è garantito che esista un qualche $\delta > 0$ per cui $\cos \theta_k \geq \delta$ per ogni k .

Esaminiamo il caso $\cos \theta_k \approx 0$:

$$0 \approx \cos \theta_k = - \frac{\nabla f(x^k)^T d^k}{\|\nabla f(x^k)\|_2 \|d^k\|_2} \stackrel{\text{lemma}}{\geq} \left(\frac{1-2c_2}{1-c_2} \right) \frac{\|\nabla f(x^k)\|_2}{\|d^k\|_2}$$

e quindi $\|\nabla f(x^k)\|_2 \ll \|d^k\|_2$. Inoltre $\cos \theta_k \approx 0$ rende molto probabile che si abbia $t_k \approx 0$ in quanto la direzione d^k è quasi ortogonale alla direzione di massima decresesta $-\nabla f(x^k)$:

$$t_k \approx 0 \Rightarrow x_{k+1} \approx x_k \Rightarrow \nabla f(x^{k+1}) \approx \nabla f(x^k)$$

In questo caso abbiamo $\beta_{k+1} \approx 1$ e $\|\nabla f(x^{k+1})\|_2 \approx \|\nabla f(x^k)\|_2 \ll \|d^k\|_2$, e pertanto

$$d^{k+1} = -\nabla f(x^{k+1}) + \beta_{k+1} d^k \approx -\nabla f(x^{k+1}) + d^k \approx d^k$$

Quindi $\cos \theta_k \approx 0$ rende probabile che l'algoritmo produca una lunga sequenza di iterazioni poco utili.

Tecnica di restart

Ogni n iterazioni porre $\beta_k = 0$, cioè effettuare un passo del metodo del gradiente con $d^k = -\nabla f(x^k)$. In questo modo si cancella la "memoria" delle direzioni precedenti (da cui "restart")

Oss Sia $\{x^{\bar{n}}\}_j$ la sottosuccessione fornita da queste iterazioni. Poiché

$$\cos^2 \theta_{\bar{n}j} = 1, \text{ risulta } \sum_{j=0}^{\infty} \|\nabla f(x^{\bar{n}})\|_2^2 < +\infty \text{ e quindi } \|\nabla f(x^{\bar{n}})\|_2 \xrightarrow{j \rightarrow +\infty} 0$$

(analogamente nel caso in cui il "restart" non viene eseguito dopo un numero prefissato e costante di iterazioni --- in genere $\bar{n} \approx n$).

Variante di Polak-Ribiere (1969)

Nel caso lineare abbiamo

$$\beta_k = r_k^T r_k / r_{k-1}^T r_{k-1} \quad \text{ma anche} \quad \beta_k = r_k^T (r_k - r_{k-1}) / r_{k-1}^T r_{k-1}$$

poiché $r_k^T r_{k-1} = 0$. Questa variante utilizza, per analogia, questa seconda formula per calcolare il coefficiente β_k :

$$\beta_k^{PR} = \nabla f(x^k)^T (\nabla f(x^k) - \nabla f(x^{k-1})) / \nabla f(x^{k-1})^T \nabla f(x^{k-1})$$

Quindi, se $\nabla f(x^k) \approx \nabla f(x^{k-1})$, risulta $\beta_k^{PR} \approx 0$ e la tecnica di restart viene applicata (in maniera approssimata) automaticamente.

Non è possibile dimostrare alcun risultato di convergenza (se non in casi molto particolari [f fortemente convessa + ricerca edatta]) ed inoltre d^k potrebbe non essere una direzione di discesa.

Oss È possibile avere $\beta_k^{PR} < 0$, da cui la variante $\beta_k^{PR+} = \max\{\beta_k^{PR}, 0\}$ per cui con una opportuna variazione delle condizioni fort. d. Wolfe è possibile dimostrare la convergenza del metodo nel caso generale.

METODI SENZA DERIVATE

(P) $\min \{f(x) : x \in \mathbb{R}^n\}$ ← metodi che richiedono soltanto il calcolo di valori della fz. obiettivo f .

Motivazioni:

- f non differentiabile
oppure
- difficoltà nel calcolo delle derivate

Calcolo derivate

- Differenze finite (via svilupp. di Taylor)

$$\frac{\partial f}{\partial x_i}(x) = \frac{f(x+te_i) - f(x)}{t} + O(t) \quad (r_x(t)/t \rightarrow 0)$$

$$\frac{\partial f}{\partial x_i}(x) = \frac{f(x+te_i) - f(x-te_i)}{2t} + O(t^3)$$

$$\frac{\partial f}{\partial x_i \partial x_j}(x) = \frac{f(x+te_i+te_j) - f(x+te_i) - f(x+te_j) + f(x)}{t^2} + O(t)$$

- Differentiazione automatica

"Scomposizione fz. + regole differentiazione fz. composte"

L

Consideriamo $\{e_1, \dots, e_n\} \subseteq \mathbb{R}^n$ la "base canonica" e $D = \{d_1, \dots, d_n, d_{n+1}, \dots, 2d_n\}$


$$\text{con } d_i = \begin{cases} e_i & 1 \leq i \leq n \\ -e_{i-n} & n+1 \leq i \leq 2n \end{cases}$$

Oss. Ogni $\zeta \in \mathbb{R}^n$ è combinazione lineare a coefficienti non negativi dei vettori di D

$$\zeta = \sum_{i=1}^n d_i e_i \text{ con } d_i \in \mathbb{R} \Rightarrow \zeta = \sum_{i=1}^n |d_i| \hat{d}_i \text{ con } \hat{d}_i = \begin{cases} d_i (-e_i) & \text{se } d_i > 0 \\ d_{i-n} & \text{se } d_i < 0. \end{cases}$$

Idea: valutare f nei punti $\{x + t_i d_i\}_{i=1 \dots 2^n}$ per qualche fisso t ; se si individua un valore migliore, iterare a partire dal nuovo punto, altrimenti diminuire t .

ALGORITMO DI RICERCA DIRETTA "A COMPASSO"



1) Scegliere $x^0 \in \mathbb{R}^n$, $t_0 > 0$; $k = 0$, $\ell = 0$

2) Se esiste $d \in D$ tale che $f(x^k + t_k d) < f(x^k)$,

allora $x^{k+1} = x^k + t_k d$, $t_{k+1} = t_k$

altrimenti $x^{k+1} = x^k$, $t_{k+1} = t_k/2$, $\ell = \ell + 1$, $z^\ell = x^k$

$$t_\ell = t_k$$

3) $k = k + 1$ e ritornare a 2)

Note: $\{z^\ell\}$ costituisce la sequenza delle ~~successioni~~^{iterazioni} "fallimentari"

CRITERIO DI ARRESTO: $t_k \leq \delta$ per una tolleranza fissata $\delta > 0$.

Se la curva di livello $L_f(x^0) = \{x \in \mathbb{R}^n \mid f(x) \leq f(x^0)\}$ è compatto, allora

il passo di ricerca t_k viene aggiornato dopo un numero finito di iterazioni.

Infatti la griglia $H_k = \{x_k + t_k \left(\sum_{i=1}^{2^n} u_i d_i \right) : u_i \in \mathbb{Z}_+\}$ individua tutti i punti visitabili senza aggiornare il passo e $H_k \cap L_f(x^0)$ è un insieme finito poiché $L_f(x^0)$ è compatto.

Teo (convergenza). Sia f differenziabile su \mathbb{R}^n . Supponiamo che

- $L_f(x^0)$ sia compatto

- Df sia Lipschitziana (ovvero $\exists L > 0$ t.c. $\|Df(x) - Df(y)\|_2 \leq L \|x - y\|$ $\forall x, y$),

allora $\lim_{\ell \rightarrow +\infty} \|Df(z^\ell)\|_2 = 0$

dim Sia $\gamma \in \mathbb{R}^n$ con $\|\gamma\|_2 = 1$: $\gamma = \sum_{i=1}^n \gamma_i \hat{d}_i$ con $\gamma_i \geq 0$.

$$1 = \gamma^T \gamma = \left(\sum_{i=1}^n \gamma_i \hat{d}_i \right)^T \left(\sum_{j=1}^n \gamma_j \hat{d}_j \right) = \sum_{i=1}^n \sum_{j=1}^n \gamma_i \gamma_j \hat{d}_i^T \hat{d}_j = \sum_{i=1}^n \gamma_i^2$$

quindi esiste k tale che $\gamma_k \geq 1/\sqrt{n}$. Inoltre $-(-\hat{d}_k)^T \gamma = \hat{d}_k^T \gamma = \gamma_k$.

Poiché $(-\hat{d}_k) \in D$, possiamo concludere : $\exists d \in D$ t.c. $-d^T \gamma \geq 1/\sqrt{n}$.

Supponiamo $\nabla f(z^e) \neq 0$: $\gamma = \nabla f(z^e) / \|\nabla f(z^e)\|_2 \Rightarrow \exists d \in D$ t.c. $-\nabla f(z^e)^T d \geq \frac{\|\nabla f(z^e)\|_2}{\sqrt{n}}$

Poiché z^e è ottenuto in una iterazione fallimentare, risulta $f(z^e + t_e d) \geq f(z^e)$ e dal teo (valore medio) : $0 \leq f(z^e + t_e d) - f(z^e) = \nabla f(z^e + \gamma t_e d)^T d$ per $\gamma \in (0,1)$ opportuno.

Quindi :

$$0 \leq \frac{\|\nabla f(z^e)\|_2}{\sqrt{n}} \leq -\nabla f(z^e)^T d \leq [\nabla f(z^e + t_e d) - \nabla f(z^e)]^T d \stackrel{(dis. Schwarz)}{\leq}$$

$$\leq \|\nabla f(z^e + \gamma t_e d) - \nabla f(z^e)\|_2 \|d\|_2 \leq L \|\gamma t_e d\|_2 = L \gamma t_e \xrightarrow{e \rightarrow \infty} 0$$

$(\|d\|_2 = 1, \nabla f \text{ Lipschitziana}) \quad (t_{e+1} = \overrightarrow{t_e / z^e})$

Cor Ogni punto di accumulazione di $\{z^e\}$ è un punto stationario di f .

dim z^* punto di accumulazione $\Rightarrow \exists \{z^{e_j}\}$ sottosequenza t.c. $z^{e_j} \rightarrow z^*$ e $\|\nabla f(z^{e_j})\|_2 \xrightarrow{j \rightarrow \infty} \|\nabla f(z^*)\|_2$ per la continuità di ∇f e $\|\cdot\|_2$. Del teo (convergenza) segue $\|\nabla f(z^*)\|_2 = 0$ e quindi $\nabla f(z^*) = 0$ per l'unicità del limite.

Note: Poiché $\{z^e\} \subseteq L_f(x^0)$, la compattità di $L_f(x^0)$ garantisce l'esistenza di un punto di accumulazione.

Nel caso non differentiabile $\{z^e\}$ potrebbe convergere a punti "non stationari".

Generalizzazioni dello schema algoritmico

- $D \ni \{ \pm b_1, \pm b_2, \dots, \pm b_n \}$ con $\{b_1, \dots, b_n\} \subseteq \mathbb{R}^n$ base \rightarrow

- possibilità di considerare D_K differenti per ciascuna iterazione

