

IL PROBLEMA DEI MINIMI QUADRATI

• MINIMI QUADRATI LINEARI

$A \in \mathbb{R}^{m \times n}$, $b \in \mathbb{R}^m$ (ogni colonna di A è un vettore non nullo)

$$\min \left\{ \|Ax - b\|_2 : x \in \mathbb{R}^n \right\} \stackrel{\leftarrow}{=} \min \left\{ \frac{1}{2} \|Ax - b\|_2^2 : x \in \mathbb{R}^n \right\}$$

$$f(x) = \frac{1}{2} \|Ax - b\|_2^2 = \frac{1}{2} (Ax - b)^T (Ax - b) = \frac{1}{2} x^T A^T A x - x^T A^T b + b^T b$$

\hookrightarrow funzione quadratica

$$\nabla f(x) = A^T A x - A^T b, \quad D^2 f(x) = A^T A$$

$$\nabla f(x) = 0 \iff A^T A x = A^T b \quad \text{sistema delle equazioni normali}$$

$$x^T D^2 f(\bar{x}) x = x^T A^T A x = (Ax)^T A x = \|Ax\|_2^2 \geq 0$$

$D^2 f(x)$ è semidefinita positiva per ogni $x \rightarrow f$ è una funzione convessa

punti di minimo \equiv punti stazionari \equiv soluzioni del sistema normale

Se A ha rango massimo, allora $(Ax = 0 \iff x = 0)$ e quindi $D^2 f(\bar{x})$ è definita positiva per ogni $\bar{x} \rightarrow f$ è una funzione strettamente convessa \rightarrow pb minimi quadrati ha una unica soluzione

Metodi risolutivi: decomposizione QR, SVD, gradiente coniugato (nonlineare)

$$f(x) = \frac{1}{2} \|Ax - b\|_2^2 = \frac{1}{2} \left[(A_1 x - b_1)^2 + (A_2 x - b_2)^2 + \dots + (A_m x - b_m)^2 \right]$$

• MINIMI QUADRATI NONLINEARI

$$\min \left\{ f(x) : x \in \mathbb{R}^n \right\} \text{ dove } f(x) = \frac{1}{2} \sum_{j=1}^m g_j^2(x) \text{ con } g_j : \mathbb{R}^n \rightarrow \mathbb{R} \text{ f.t. nonlineari}$$

\rightarrow Specializzare i metodi dell'ottimizzazione non vincolata, sfruttando la specifica struttura della f.t. obiettivo.

$$\begin{aligned} \phi : \mathbb{R} \rightarrow \mathbb{R} : \quad g_j^2(x) = \phi(g_j(x)) \rightarrow \nabla g_j^2(x) = \phi'(g_j(x)) \nabla g_j(x) = 2g_j(x) \nabla g_j(x) \\ \phi(t) = t^2 \end{aligned}$$

$$\nabla^2 f(x) = \frac{1}{2} \sum_{j=1}^m \nabla r_j^2(x) = \sum_{j=1}^m r_j(x) \nabla r_j(x) = \underline{\underline{J_R(x)^T R(x)}}$$

dove $R = (r_1, \dots, r_m) : \mathbb{R}^n \rightarrow \mathbb{R}^m$ e $J_R(x) = \begin{bmatrix} -\nabla r_1(x)^T \\ \vdots \\ -\nabla r_m(x)^T \end{bmatrix}$ è la matrice Jacobiana di R .

$$[\nabla^2 f(x)]_{ke} = \frac{\partial^2 f(x)}{\partial x_k \partial x_e} = \frac{\partial}{\partial x_k} \left(\frac{\partial f(x)}{\partial x_e} \right) = \frac{\partial}{\partial x_k} \left(\sum_{j=1}^m r_j(x) \frac{\partial r_j(x)}{\partial x_e} \right) =$$

$$= \sum_{j=1}^m \begin{vmatrix} \frac{\partial r_j(x)}{\partial x_k} & \frac{\partial r_j(x)}{\partial x_e} \end{vmatrix} + \sum_{j=1}^m r_j(x) \frac{\partial^2 r_j(x)}{\partial x_k \partial x_e}$$

$$J_R(x)^T J_R(x) = \begin{bmatrix} 1 & & & \\ \vdots & \ddots & & \\ & & 1 & \\ & & & \vdots \end{bmatrix} \begin{bmatrix} -\nabla r_1(x)^T \\ \vdots \\ -\nabla r_m(x)^T \end{bmatrix}$$

Quindi $\nabla^2 f(x) = J_R(x)^T J_R(x) + \sum_{j=1}^m r_j(x) \nabla^2 r_j(x)$ \circledast

METODO DI NEWTON

La direzione di ricerca d_N^k è soluzione del sistema $\nabla^2 f(x^k) d = -\nabla f(x^k)$

Se $\nabla^2 f(x^k)$ è definita positiva, d_N^k è una direzione di discesa

METODO DI GAUSS-NEWTON

Idea: approssimare $\nabla^2 f(x^k)$ tralasciando i termini del secondo ordine \circledast
 (se i residui r_j sono piccoli e/o sono funzioni "piatte" [$\|\nabla^2 r_j(x)\|_2$ è piccola], i termini del primo ordine dovrebbero "dominare" quelli del secondo).

Notazioni: $J_K = J_R(x^k)$ e $r_K = R(x^k) = (r_1(x^k), \dots, r_m(x^k))$

$$\nabla f(x^k) = J_K^T r_K, \quad \nabla^2 f(x^k) \approx J_K^T J_K$$

La direzione di ricerca d_{GN}^k è soluzione del sistema $J_K^T J_K d = -J_K^T r_K$

- Se $\nabla f(x^k) \neq 0$, allora d_{GN}^k è una direzione di discesa

$$\nabla f(x^k)^T d_{GN}^k = (J_K^T r_K)^T d_{GN}^k = -(J_K^T J_K d_{GN}^k)^T d_{GN}^k = -(J_K d_{GN}^k)^T (J_K d_{GN}^k) = -\|J_K d_{GN}^k\|_2^2 < 0$$

Inoltre $J_K d_{GN}^k = 0 \Rightarrow J_K^T r_K = 0$ ovvero $\nabla f(x^k) = 0$

Quindi il metodo di Gauss-Newton è un metodo del gradiente

- $J_K^T J_K d = -J_K r_K$ è il sistema delle equazioni normali associato a $J_K d + r_K = 0$, ovvero d_{GN}^K risolve il problema dei minimi quadrati lineari

$$\min \left\{ \frac{1}{2} \|J_K d + r_K\|_2^2 : d \in \mathbb{R}^n \right\}$$

Altro punto di vista: $f_j(x_k + d) \approx f_j(x_k) + \nabla f_j(x_k)^T d$

$$f(x_k + d) = \frac{1}{2} \sum_{j=1}^m f_j^2(x_k + d) \approx \frac{1}{2} \sum_{j=1}^m (f_j(x_k) + \nabla f_j(x_k)^T d)^2 = \frac{1}{2} \|J_K d + r_K\|_2^2$$

d_{GN}^K si ottiene minimizzando questa approssimazione di $f(x_k + d)$ su \mathbb{R}^n .

La scelta del passo unitario (stile Newton) non garantisce convergenza \rightarrow Ricerca (in)esatta

METODO DI GAUSS-NEWTON ("damped" GN)

1) Scegliere $x^0 \in \mathbb{R}^n$; $K = 0$

2) Se $\nabla f(x^K) = 0$, allora STOP

3) Calcolare $d_{GN}^K \in \mathbb{R}^n$ soluzione di $J_K^T J_K d = -J_K r_K$

4) Calcolare $t_K > 0$ che soddisfa le condizioni di Wolfe

5) $x^{k+1} = x^k + t_K d_{GN}^K$

6) $K = K + 1$ e ritornare a 2)

QR
SVD
gradiente conjugato

Teorema (convergenza) Supponiamo che

- $L_f(x^0) = \{x \in \mathbb{R}^n : f(x) \leq f(x^0)\}$ sia compatto
- f_j siano differentiabili con continuità per ogni $j = 1 \dots m$
- ∇f sia Lipschitziana
- $\exists \gamma > 0$ tale che $\|J_K z\|_2 \geq \gamma \|z\|_2 \quad \forall z \in \mathbb{R}^n \forall K$

Allora $\lim_{K \rightarrow +\infty} \|\nabla f(x^K)\|_2 = 0$

dim $J_R: x \mapsto J_R(x)$ è continua, quindi anche $x \mapsto \|J_R(x)\|_2$ è continua.

Poiché $L_f(x^0)$ è compatto, esiste $\beta > 0$ tale che $\|J_R(x)\|_2 \leq \beta$ per ogni $x \in L_f(x^0)$
 Si è θ_k l'angolo formato da $-\nabla f(x^k)$ e d_{GN}^k : (teo (Weierstrass))

$$\cos \theta_k = -\frac{\nabla f(x^k)^T d_{GN}^k}{\|\nabla f(x^k)\|_2 \|d_{GN}^k\|_2} = \frac{\|J_k d_{GN}^k\|_2^2}{\|J_k^T J_k\|_2 \|d_{GN}^k\|_2} = \frac{\|J_k d_{GN}^k\|_2^2}{\|J_k^T J_k\|_2 \|d_{GN}^k\|_2} \geq$$

$$\geq \frac{\gamma^2 \|d_{GN}^k\|_2^2}{\beta^2 \|d_{GN}^k\|_2^2} = \frac{\gamma^2}{\beta^2} > 0 \quad (\|J_k^T J_k\|_2 \leq \|J_k\|_2^2 \|d_{GN}^k\|_2 \leq \beta^2 \|d_{GN}^k\|_2^2)$$

Per il lemma a pg (8) delle note sui metodi per l'ottimizzazione non vincolata

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

■

Note 1: $\|J_k z\|_2 \geq \gamma \|z\|_2 \quad \forall k \forall z$ garantisce che i valori singolari delle matrici J_k sono uniformemente distanti da 0 ($z = v_i$ vettore singolare destro di $J_k \rightarrow \|z\|_2 = 1$ e $\|J_k z\|_2 = \sigma_i$ valore singolare corrispondente).

Note 2: f_j differentiabili con continuità $\Rightarrow \|\nabla f(x) - \nabla f(y)\|_2 \leq L \|x - y\|_2 \quad \forall x, y \in L_f(x^0)$ con $L > 0$ oppure, ovvero ∇f è lipschitziana su $L_f(x^0)$: il lemma continua a valere anche con questa restrizione $\geq L_f(x^0)$, quindi l'ipotesi ∇f Lips. può essere rimossa.

Applicazione al dato fitting

Osservazioni sperimentali: (t_j, y_j) con $t_j \in \mathbb{R}^s, y_j \in \mathbb{R}$



Che relazione esiste tra t_j e y_j ? $y_j \approx f(t_j)$ per qualche opportuna f ?

$$\min \left\{ \frac{1}{2} \sum_{j=1}^m (y_j - f(t_j))^2 \mid f \in F \right\}$$

F spazio 'funzionale' di ricerca: $F = \left\{ f(x; \cdot) : x = \underbrace{(x_1, \dots, x_n)}_{\text{parametrici}} \in \mathbb{R}^n \right\}$

$$\rightarrow \min \left\{ \frac{1}{2} \sum_{j=1}^m (y_j - f(x; t_j))^2 \mid x \in \mathbb{R}^n \right\}$$