

Região de confiança - métodos específicos

No esquema geral, devemos calcular d^k solução
aproximada do modelo

$$\min_d m(d) = f(x^k) + \nabla f(x^k)^T d + \frac{1}{2} d^T B_k d$$

s.a. $\|d\| \leq \Delta_k$.

Para garantir convergência, d^k deve satisfazer a hipótese H3 (várias anotações sobre convergência).

O objetivo é discutir diferentes formas de fazer isso.

1^a forma: passo de Cauchy

Supomos que $d^k = -t_k \nabla f(x^k)$, onde $t_k > 0$
é solução de $\min_t m(-t \nabla f(x^k))$. ($\|\cdot\|$ = norma Euclidiana)

$$\text{s.a. } \|t \nabla f(x^k)\| \leq \Delta_k$$

Resolvendo (omitindo x^k):

- Se $\nabla f^T B_k \nabla f \leq 0$ então o termo quadrático

$d^T B_k d = t^2 \nabla f^T B_k \nabla f \leq 0$ não influencia na minimização

Caso, e a solução estará na borda:

$$\|t_k \nabla f\| = \Delta_k \Rightarrow t_k = \frac{\Delta_k}{\|\nabla f\|}.$$

- Se $\nabla f^T B_k \nabla f > 0$ então a solução pode não estar na borda. Temos que olhar para o minimizador restrito de $m(d)$:

$$\begin{aligned} \frac{d}{dt} m(t \nabla f) &= -\|\nabla f\|^2 + t(\nabla f^T B_k \nabla f) = 0 \\ \Rightarrow t^* &= \frac{\|\nabla f\|^2}{\nabla f^T B_k \nabla f} > 0. \end{aligned}$$

Caso $t^* < \frac{\Delta_k}{\|\nabla f\|}$ então $t_k = t^*$. Caso contrário, $t_k = \frac{\Delta_k}{\|\nabla f\|}$. Em resumo,

$$(*) \quad d^k = -t_k \nabla f(x^k) \quad \text{onde} \quad t_k = \begin{cases} \frac{\Delta_k}{\|\nabla f\|} & \text{se } \nabla f^T B_k \nabla f \leq 0 \\ \min \left\{ \frac{\Delta_k}{\|\nabla f\|}, \frac{\|\nabla f\|^2}{\nabla f^T B_k \nabla f} \right\} & \text{c.c.} \end{cases}$$

Com o passo de Cauchy, há convergência:

Teorema: O passo de Cauchy satisfaz

$$m(0) - m(d^k) \geq \frac{1}{2} \|\nabla f(x^k)\| \cdot \min \left\{ \Delta_k, \frac{\|\nabla f(x^k)\|}{\|B_k\|} \right\} \quad (\text{H3 com } c = \frac{1}{2})$$

Prova: Como $d^k = -t_k \nabla f$, temos

$$\begin{aligned} m(0) - m(d^k) &= f(x^k) - f(x^k) - \nabla f^T d^k - \frac{1}{2} d^k^T B_k d^k \\ &= t_k \|\nabla f\|^2 - \frac{1}{2} t_k^2 \nabla f^T B_k \nabla f. \end{aligned}$$

CASO 1: $\nabla f^T B_k \nabla f \leq 0$

De (*), $t_k = \frac{\Delta_k}{\|\nabla f\|}$ e $m(0) - m(d^k) \geq t_k \|\nabla f\|^2 = \Delta_k \|\nabla f\|^2$.

Em particular, $m(0) - m(d^k) \geq \frac{1}{2} \|\nabla f\| \Delta_k$. (1)

CASO 2: $\nabla f^T B_k \nabla f > 0$ e $\frac{\Delta_k}{\|\nabla f\|} \leq \frac{\|\nabla f\|^2}{\nabla f^T B_k \nabla f}$.

Neste caso, (*) fornece $t_k = \frac{\Delta_k}{\|\nabla f\|} \leq \frac{\|\nabla f\|^2}{\nabla f^T B_k \nabla f}$, donde

segue que $t_k^2 \nabla f^T B_k \nabla f \leq t_k \|\nabla f\|^2 = \|\nabla f\| \Delta_k$. Daí

$m(0) - m(d^k) \geq \|\nabla f\| \Delta_k - \frac{1}{2} \|\nabla f\| \Delta_k = \frac{1}{2} \|\nabla f\| \Delta_k$. (2)

CASO 3: $\nabla f^T B_k \nabla f > 0$ e $\frac{\Delta_k}{\|\nabla f\|} > \frac{\|\nabla f\|^2}{\nabla f^T B_k \nabla f}$.

De (*) tem $t_k = \frac{\|\nabla f\|^2}{\nabla f^T B_k \nabla f}$ e logo

$$m(0) - m(d^k) = \frac{\|\nabla f\|^4}{\nabla f^T B_k \nabla f} - \frac{1}{2} \cdot \frac{\|\nabla f\|^4}{\nabla f^T B_k \nabla f} = \frac{1}{2} \frac{\|\nabla f\|^4}{\nabla f^T B_k \nabla f}.$$

Pela desigualdade de Cauchy-Schwarz, temos

$$\nabla f^T(B_k \nabla f) \leq \|\nabla f\| \cdot \|B_k \nabla f\| \leq \|B_k\| \cdot \|\nabla f\|^2. \text{ Assim,}$$

$$m(0) - m(d^k) \geq \frac{1}{2} \frac{\|\nabla f\|^4}{\|B_k\| \cdot \|\nabla f\|^2} = \frac{1}{2} \frac{\|\nabla f\|}{\|B_k\|} \cdot \frac{\|\nabla f\|}{\|\nabla f\|}. \quad (3)$$

Finalmente, de (1), (2) e (3) chegamos ao resultado



Observações:

- 1) O passo de Cauchy, apesar de ter baixo custo computacional, fornece um método lento próximo à soluções pois a direção $d^k = -t_k \nabla f(x^k)$ é similar à do método do gradiente.
- 2) Note que a informação em B_k **não** é usada na direção (que é paralela à $-\nabla f(x^k)$). B_k é usada apenas para escalar $-\nabla f(x^k)$ (cálculo de t_k). Essa deficiência fica evidente para $B_k = \nabla^2 f(x^k)$, pois o modelo com essa B_k é "d livre" remonta ao

método de Newton, que é muito mais rápido que o método do gradiente.

3) Portanto é razoável aproveitar B_k ao máximo, idealmente no estilo Newton / Quase-Newton.

O próximo método procura fazer isso!

2^a forma: método dogleg

Neste método, a solução aproximada d^k do modelo $\min_d m(d)$ s.a. $\|d\| \leq \Delta_k$ aproxima melhor B_k .

Ele se aplica à B_k definida positiva e simétrica (opções para tal B_k em aula anterior). Quando é possível

$B_k = \nabla^2 f(x^k)$, o passo do método dogleg coincide

com Newton caso a direção Newtoniana satisfaca

$\|d\| \leq \Delta_k$.

Dado o modelo ao redor de x^k , considere

os seguintes pontos:


- x_u^k : minimizador irrestrito de m na direção $-\nabla f(x^k)$, isto é,

$$x_u^k = x^k - t^* \nabla f(x^k), \quad t^* = \operatorname{argmin}_t m(-t \nabla f(x^k)).$$
- x_N^k : minimizador irrestrito de m , isto é,

$$x_N^k = x^k + d_N^*, \quad d_N^* = \operatorname{argmin}_d m(d).$$

Supondo B_k definida positiva, esses pontos estão bem definidos pois $m(d)$ é uma quadrática estritamente convexa.

O motivo do dogleg minimiza $m(d)$ sobre a poligonal que liga x^k , x_u^k e x_N^k , respeitando $\|d\| \leq \Delta_k$. Algumas situações:





$$1) \|x^k - x_N^k\| \leq \Delta_k$$

A direção será $d^k = x_N^k - x^k$.

Um sopa, o ponto dogleg é x_N^k .

Se $B_k = \nabla^2 f(x^k)$, este é o passo

de Newton.



Outra situação pode ocorrer? NÃO!

Teorema: (i) $\|x_p - x^k\|$ cresce quando o ponto x_p sobre a poligonal vai de x^k à x_N^k .


(a poligonal corta a borda no máximo 1 vez)

(ii) $m(x_p - x^k)$ é não decrescente ao longo

da poligonal.

(a fim de minimizar m , devemos caminhar de x^k à x_N^k . Neste sentido, x_N^k é o melhor ponto — de fato é aquele que vem da minimização em $\|d\| \leq \Delta_k$ com d livre)

* Veja o Lema 5.40 do livro de Karas e Ribeiro ou o Lema 4.2 de Nocedal e Wright.



$$x^k \xrightarrow{d_v^k} x_v^k \quad x^k \xrightarrow{d_N^k} x_N^k$$

(***)

Direções

$$d_v^k = x_v^k - x^k = -t^* \nabla f(x^k)$$

$$d_N^k = x_N^k - x^k \text{ (tipo Newton)}$$

d^k (direção dogleg)

Calculando d_v^k :

$$\min_t m(-t \nabla f(x^k))$$

$$0 = \frac{d}{dt} m(-t \nabla f(x^k)) = -\|\nabla f\|^2 + t^* \nabla f^T B_k \nabla f \Rightarrow t^* = \frac{\nabla f^T \nabla f}{\nabla f^T B_k \nabla f}$$

$$\Rightarrow d_v^k = - \left(\frac{\nabla f^t \nabla f}{\nabla f^t B_k \nabla f} \right) \nabla f$$

Calculando d_N^k : $\min_d m(d)$

$$0 = \nabla m(d_N^k) = \nabla f + B_k d_N^k \Rightarrow [B_k d_N^k = -\nabla f(x^k)]$$


Algoritmo dogleg (para cálculo de d^k)

Entrada: x^k , $\Delta_k > 0$, B_k simétrica e def. positiva

→ calcule $d_v^k = - \left(\frac{\nabla f(x^k)^t \nabla f(x^k)}{\nabla f(x^k)^t B_k \nabla f(x^k)} \right) \nabla f(x^k)$

→ Se $\|d_v^k\| > \Delta_k$

$$d^k = - \frac{\Delta_k}{\|\nabla f(x^k)\|} \nabla f(x^k)$$




senão

→ resolva $B_k d_N^k = -\nabla f(x^k)$, obtendo d_N^k (por exemplo usando Cholesky)

→ Se $\|d_N^k\| \leq \Delta_k$

$$d^k = d_N^k$$

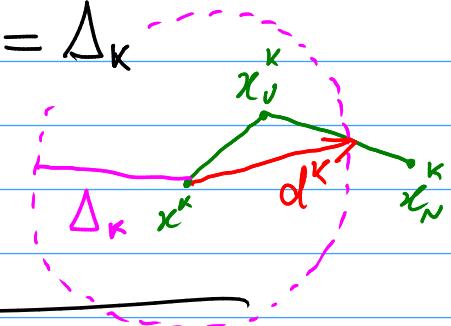
senão



→ calcule $\alpha_k \in [0,1]$ tal que

$$\|d_v^k + \alpha_k(d_N^k - d_v^k)\| = \Delta_k$$

$$d^k = d_v^k + \alpha_k(d_N^k - d_v^k)$$



No último caso ($\|x_v^k - x^k\| \leq \Delta_k < \|x_N^k - x^k\|$),

a direção do dogleg é combinação convexa das direções d_v^k e d_N^k (veja a figura (**)):

$$d^k = d_v^k + \alpha_k(d_N^k - d_v^k) = (1 - \alpha_k)d_v^k + \alpha_k d_N^k, \quad \alpha_k \in [0,1]$$

Exercício: mostre que é possível calcular α_k como raiz positiva de uma equação do 2º grau.

Damos mostras agora que o método de região de confiança com passo dogleg converge, mostrando que H3 é satisfeita.

Teorema: O passo dogleg satisfaz

$$m(0) - m(d^k) \geq \frac{1}{2} \|\nabla f(x^k)\| \cdot \min \left\{ \Delta_k, \frac{\|\nabla f(x^k)\|}{\|B_k\|} \right\}.$$

Prova: Seja d_c^k a direção de Cauchy. Como mostramos,

$m(0) - m(d_c^k) \geq \frac{1}{2} \| \nabla f \|^2 \cdot \min \left\{ \Delta_k, \frac{\| d \|^2}{\| B_k \|^2} \right\}$. Agora, como $m(x - x^*)$ não cresce ao longo da poligonal saindo de x^* à x_N^* (comentário anterior), temos

$$m(d^k) = m(x_{\text{dogleg}} - x^*) \leq m(x_{\text{Cauchy}} - x^*) = m(d_c^k).$$

Logo $m(0) - m(d^k) \geq m(0) - m(d_c^k)$, donde segue o resultado.

3^a forma: gradientes conjugados de Steinhaus

Gradientes conjugados (GC) é aplicado à minimizações irrestritas de quadráticas (disciplina "Otimização I").

Dequi, GC é adaptado para lidar com a restrição

$$\| d \|^2 \leq \Delta_k. \quad \text{Este método é adequada à problemas}$$

grandes. Veja o livro de Karas e Ribiero para mais detalhes.