

# 一个非单调 BFGS 信赖域算法

## A Nonmonotone BFGS-Trust-Region Algorithm

吴庆军

WU Qing-jun

(玉林师范学院数学与计算机科学系,广西玉林 537000)

(Department of Mathematics and Computer Science, Yulin Teachers's College, Yulin, Guangxi, 537000, China)

**摘要:** 将新的 BFGS 校正公式  $B_{k+1} = B_k + \frac{y_k^* y_k^{*T}}{s_k^T y_k^*} - \frac{B_k s_k s_k^T B_k}{s_k^T B_k s_k}$ , 与文献[16]中的算法相结合给出一个非单调 BFGS 校正的信赖域算法. 该算法在假设条件:(i)存在常数  $c_1, c_2, c_3$ , 使得对所有的  $\Delta_k > 0, g_k \in R^n$ , 对称正定阵  $B_k \in R^{n \times n}$ , 有  $\text{pred}_k \geq c_1 \|g_k\| \min\{\Delta_k, c_2 \|g_k\|, c_3 \|g_k\| / \|B_k\|\}$ ; (ii) 若  $\|B_k^{-1}\| \leq \Delta_k$ , 则  $d_k = -B_k^{-1}g_k$ ; (iii)  $f(x)$  是二次连续可微函数,  $\nabla^2 f(x_k)$  是 Lipschitz 连续, 水平集  $\phi(x_0)$  有界下, 具有全局收敛性和 Q-二次收敛性.

**关键词:** 非单调 BFGS 校正 全局收敛性 信赖域算法**中图法分类号:** O221   **文献标识码:** A   **文章编号:** 1005-9164(2006)03-0187-03

**Abstract:** A new nonmonotone BFGS-trust-region algorithm is proposed by combining the BFGS update  $B_{k+1} = B_k + \frac{y_k^* y_k^{*T}}{s_k^T y_k^*} - \frac{B_k s_k s_k^T B_k}{s_k^T B_k s_k}$ , with the algorithm given in references [16]. The global and Q-quadratic convergences of the proposed algorithm are also proved under the following conditions: (i) there are constants  $c_1, c_2, c_3$  such that  $\text{pred}_k \geq c_1 \|g_k\| \min\{\Delta_k, c_2 \|g_k\|, c_3 \|g_k\| / \|B_k\|\}$  for  $\Delta_k > 0, g_k \in R^n$  and some symmetry positive definite matrix  $B_k \in R^{n \times n}$ ; (ii)  $d_k = -B_k^{-1}g_k$  if  $\|B_k^{-1}g_k\| \leq \Delta_k$  and (iii)  $f(x)$  is a second-order continuously differentiable function,  $\nabla^2 f(x)$  is Lipschitz continuous and the level set  $\phi(x_0)$  is bounded.

**Key words:** nonmonotone, BFGS update, global convergence, trust-region algorithm

无约束最优化问题

$$\min_{x \in R^n} f(x), \quad (1)$$

其中  $f(x)$  是连续可微函数, BFGS 方法是求解无约束最优化的有效拟牛顿方法<sup>[1~3]</sup>, 文献[4~7]也给出了一些修改的 BFGS 方法并分析了其相应算法的收敛性. 一个大家都知道的、重要的 BFGS 校正公式是:

$$B_{k+1} = B_k + \frac{y_k y_k^T}{s_k^T y_k} - \frac{B_k s_k s_k^T B_k}{s_k^T B_k s_k}, \quad (2)$$

其中  $s_k = x_{k+1} - x_k$ ,  $y_k = g_{k+1} - g_k$ ,  $g_k$  和  $g_{k+1}$  分别是  $f(x)$  在  $x_k$  和  $x_{k+1}$  处的梯度值. 在文献[8]中也给出了一个新的 BFGS 校正公式

$$B_{k+1} = B_k + \frac{y_k^* y_k^{*T}}{s_k^T y_k^*} - \frac{B_k s_k s_k^T B_k}{s_k^T B_k s_k}, \quad (3)$$

其中  $y_k^* = \frac{y_k^T s_k}{|y_k^T s_k|} y_k$ . BFGS 信赖域算法是非常有效的算法, 文献[9~13]分析了信赖域算法的收敛性, 但是, 这些算法均是单调算法. 文献[16]提出了一类非单调信赖域算法, 其算法在某一步后, 每试探一步要求当前点的函数值与前不固定点(如  $M_{k+1}$ )中函数值最大的进行比较, 而且  $M_k$  可进行调整, 对目标函数, 当性态好时,  $M_k$  减少甚至为零, 即算法采用单调下降步; 当性态坏时,  $M_k$  愈大, 算法采用非单调下降步.

本文将公式(3)与文献[16]中的算法相结合给出一个新的算法, 此算法在较少的假设条件下同样具有全局收敛性和 Q-二次收敛性. 本文采用下列记号:  $\|\cdot\|$  是  $R^1$  中的 Euclid 范数,  $[b_1, \dots, b_n]$  是由向量  $b_1, \dots, b_n$  生成的  $R^n$  子空间,  $g(x) \in R^n$  是  $f$  在  $x$  处的

梯度值,  $\{x_n\}$  是由算法产生的点列, 记  $f_k := f(x_k)$ ,  $g_k := \nabla f(x_k)$ . 以下部分讨论的  $B_k$  都是在  $B_0$  为对称正定时产生的.

## 1 算法及其性质

首先给出解问题(1)的一般信赖域算法子问题的定义式:

$$\begin{aligned} \min \psi_k(d) &= f_k + g_k^T d + \frac{1}{2} d^T B_k d, d \in R^n, \\ \text{s. t. } \|d\| &\leq \Delta_k, \end{aligned} \quad (4)$$

其中,  $\Delta_k > 0$  是信赖域半径,  $d$  是试探步,  $B_k$  是  $f(x)$  在  $x_k$  的 Hessian 矩阵或其近似. 文献[14,15]给出求解信赖域子问题的一个算法并讨论其收敛性. 定义

$$f_{m(k)} = \max_{0 \leq j \leq l(k)} \{f_{k-j}\}, \quad (5)$$

其中,  $l(k) = \min\{1(k-1)+1, M_k\}$ ,  $M_k$  是非负整数,  $l(0) = 0$ , 下面给出一个非单调 BFGS 校正的信赖域算法.

**算法** 算法的步骤如下:

步骤 0: 给定  $x_0 \in R^n$ , 对称矩阵  $B_0 \in R^{n \times n}$ ,  $\Delta_0 > 0$ ,  $0 < \mu < 1$ ,  $0 < \gamma < 1$ ,  $\eta > 0$ ,  $c \geq 1$ ,  $\epsilon > 0$ , 整数  $M \geq 0$ ,  $M_0 := M$ ,  $l(0) := 0$ ,  $k := 0$ .

步骤 1: 计算  $g_k$ . 如果  $\|g_k\| < \epsilon$ , 则终止; 否则转步骤 2.

步骤 2: 解子问题(4), 得试探步  $d_k$ .

步骤 3: 计算  $\rho^k m(k) = \frac{\text{ared}_{m(k)}^k}{\text{pred}_k}$  和  $u_k = \min\{u, \eta\Delta_k \frac{\|g_k\|}{\text{pred}_k}\}$ , 其中,  $\text{ared}_{m(k)}^k = f_{m(k)} - f(x_k + d_k)$ ,  $\text{pred}_k = -g_k^T d_k - \frac{1}{2} d_k^T B_k d_k$ .

步骤 4: 如果  $\rho^k m(k) < u_k$ , 则取新信赖域半径  $\Delta_k^{new} := \gamma\Delta_k$ ,  $M_k^{new} := M_k$ , 转步骤 2(称为内循环); 否则令  $x_{k+1} = x_k + d_k$ (称为成功步),  $\Delta_{k+1} \geq \Delta_k$ , 如果  $\rho^k m(k) > c$ , 则  $M_{k+1} := 0$ , 否则  $M_{k+1} := M$ , 利用校正公式(3)产生  $B_{k+1}$ , 令  $k := k + 1$ , 转步骤 1.

当  $M = 0$  时, 算法成为一般单调信赖域算法. 当  $y_k^T s_k > 0$  时, BFGS 校正公式保持校正矩阵的正定性.  $B_k$  正定时, 由

$$y_k^T s_k = \frac{|y_k^T s_k|}{|y_k^T s_k|} y_k^T s_k = \frac{(y_k^T s_k)^2}{|y_k^T s_k|} = |s_k^T B_k s_k| + o(\|s_k\|^2) \geq |\lambda_k + o(1)| \|s_k\|^2 > 0, \quad (6)$$

其中  $\lambda_k$  是  $B_k$  的最小特征值,  $s_k = x_{k+1} - x_k$ ,  $y_k = g_{k+1} - g_k$ . 所以  $B_{k+1}$  是正定矩阵. 当  $B_0$  取为正定矩阵时, 可用数学归纳法证得由校正公式(3)产生的  $B_k$  都是正定的. 综上所述, 由  $B_k$  是正定的, 则(4)式是一个具有二次约束的严格二次规划, 且若  $\lim_{k \rightarrow \infty} x_k = x^*$ ,

则得到的  $\nabla^2 f(x^*)$  是正定的.

## 2 收敛性分析

为了证明算法的收敛性, 首先给出下面的假设条件:

(i) 存在常数  $c_1, c_2, c_3$ , 使得对所有的  $\Delta_k > 0$ ,  $g_k \in R^n$ , 对称正定阵  $B_k \in R^{n \times n}$ , 有  
 $\text{pred}_k \geq c_1 \|g_k\| \min\{\Delta_k, c_2 \|g_k\|\}$ ,  
 $c_3 \|g_k\| / \|B_k\| \}$ ;

(ii) 若  $\|B_k^{-1} g_k\| \leq \Delta_k$ , 则  $d_k = -B_k^{-1} g_k$ .

首先, 可以证明算法是适定的(其定义和证明见文献[16]).

**定理 1** 若(i)成立, 则算法是适定的.

定理 1 说明每一步迭代的内循环必在有限步终止, 否则成功步数无穷, 它产生无穷序列  $\{x_k\}$ . 定义水平集  $\phi(x_0) = \{x \in R^n : f(x) \leq f(x_0)\}$ . 由文献[16]知下面的两个引理成立.

**引理 1** 若(i)成立,  $\{x_k\} \subset \phi(x_0)$ .

**引理 2** 若(i)成立, 如果  $\{f_k\}$  有下界, 则  $\{f_{l(k)}\}$  非增且收敛.

**定理 2** 假设水平集  $\phi(x_0)$  有界且(i)成立. 如果存在正常数  $\epsilon$ , 使得对所有的  $k$ ,  $\|B_k\| \leq \epsilon$ , 则  $\liminf_{k \rightarrow \infty} \|g_k\| = 0$ .

**证明** 假设结论不成立, 则存在正常数  $\epsilon_1$ , 使得对所有的  $k$ ,  $\|g_k\| \geq \epsilon_1$ . 容易证得

$$\text{pred}_k \geq c_1 \epsilon_1 \min\{\Delta_k, c_2 \epsilon_1, c_3 \epsilon_1 / \epsilon\} > 0, \forall k, \quad (7)$$

$$f_{m(k)} - f_{k+1} \geq \min\{\eta \epsilon_1 \Delta_k, \mu c_1 \epsilon_1 \min\{\Delta_k, c_2 \epsilon_1, c_3 \epsilon_1 / \epsilon\}\}, \quad (8)$$

所以  $\lim_{k \rightarrow \infty} \Delta_{m(k)-1} = 0$ . 可以证明  $\lim_{k \rightarrow \infty} \Delta_k = 0$ . 事实上, 令  $m'(k) = m(k+M+2)$ , 因此  $m'(k) \geq k+M+2-M=k+2$ , 利用归纳法可以证明得

$$\lim_{k \rightarrow \infty} \Delta_{m'(k)-j} = 0, \lim_{k \rightarrow \infty} f_{m'(k)-j} = \lim_{k \rightarrow \infty} f_{m(k)}, \forall j \geq 1. \quad (9)$$

所以

$$x_{k+1} = x_{m'(k)} - \sum_{j=1}^{m'(k)-(k+1)} d_{m'(k)-j}. \quad (10)$$

由  $m'(k)$  的定义, 得  $m'(k)-(k+1) = m(k+2+m)-(k+1) \leq M+1$ , 于是(9)式和(10)式隐含  $\lim_{k \rightarrow \infty} \|x_{k+1} - x_{m(k)}\| = 0$ . 由  $\phi(x_0)$  的有界性可知,  $\{f_k\}$  有下界, 从而

$$\lim_{k \rightarrow \infty} f_{k+1} = \lim_{k \rightarrow \infty} f_{m'(k)} = \lim_{k \rightarrow \infty} f_{m(k)}, \forall j \geq 1. \quad (11)$$

因此(8)式和(11)式隐含  $\lim_{k \rightarrow \infty} \Delta_k = 0$ . 可以证明

$$\rho_{m(k)}^k = \frac{f_{m(k)} - f_{k+1}}{\text{pred}_k} \geq \frac{f_k - f_{k+1}}{\text{pred}_k}, \forall k$$

$$|\frac{f_k - f_{k+1}}{\text{pred}_k} - 1| \leq$$

$$\frac{\|\nabla f(x_k + \theta_k d_k) - g_k\| \|d_k\| + \frac{1}{2}\epsilon \|d_k\|^2}{c_1 \epsilon_1 \min\{\Delta_k, c_2 \epsilon_1, c_3 \epsilon_1 / \epsilon\}}, \forall k$$

(12)

其中  $\theta_k \in (0, 1)$ . 令  $k \rightarrow \infty$ , 有  $\lim_{k \rightarrow \infty} \frac{f_k - f_{k+1}}{\text{pred}_k} = 1$ .

由(12)式可得对充分大的  $k$ ,  $\frac{f_{m(k)} - f_{k+1}}{\text{pred}_k} \geq \mu \geq \mu_k$ , 因此由算法得, 对充分大的  $k$ ,  $\Delta_{k+1} \geq \Delta_k$ , 与  $\lim_{k \rightarrow \infty} \Delta_k = 0$  矛盾. 所以命题得证.

如果条件“ $g_k = \nabla f(x_k)$ ”改为“ $g_k$  是  $\nabla f(x_k)$  的近似”, 相应的定理 1,2 和引理 1,2 的结论也成立. 为证明算法的 Q- 二次收敛性, 需要下面的假设条件.

(iii)  $f(x)$  是二次连续可微函数,  $\nabla^2 f(x_k)$  是 Lipschitz 连续, 水平集  $\phi(x_0)$  有界.

**定理 3** 对所有  $k$ ,  $B_k = \nabla^2 f(x_k)$ . 如果(i), (ii) 和(iii) 成立, 则  $\{x_k\}$  Q- 二次收敛于  $x^*$ .

**证明** 由  $B_k = \nabla^2 f(x_k)$  是正定的,  $x_k \rightarrow x^*$ ,  $\nabla^2 f(x^*)$  也是正定的, 令  $\kappa = \{k : \|B_k^{-1} g_k\| > \Delta_k\}$ . 假设集合  $\kappa$  有无穷多个元素. 由(ii) 得

$$\|g_k\| \geq \frac{\Delta_k}{\|B_k^{-1}\|}, \forall k \in \kappa; \|g_k\| \geq \frac{\|d_k\|}{B_k^{-1}},$$

$\forall k$

可以证明

$$\text{pred}_k \geq \frac{c_1 \|\Delta_k^2\|}{2 \|B_*^{-1}\|} \min\{1, \frac{c_2}{\|B_*^{-1}\|}\},$$

$$\frac{c_3}{\|B_*^{-1}\| \|B_*\|} > 0, \forall k \in \kappa$$

$$\text{pred}_k \geq \frac{c_1 \|d_k^2\|}{2 \|B_*^{-1}\|} \min\{1, \frac{c_2}{\|B_*^{-1}\|}\},$$

$$\frac{c_3}{\|B_*^{-1}\| \|B_*\|} > 0, \forall k$$

其中,  $B_* = \nabla^2 f(x^*)$ ,  $B_*^{-1} = (\nabla^2 f(x^*))^{-1}$ . 从而

$$\lim_{k(\infty) \rightarrow \infty} \Delta_k = 0, \lim_{k \rightarrow \infty} \|d_k\| = 0. \quad (13)$$

易证

$$|\frac{f_k - f_{k+1}}{\text{pred}_k} - 1| \leq$$

$$\frac{L \|d_k\| \|B_*^{-1}\|}{c_1 \min\{1, \frac{c_2}{\|B_*^{-1}\|}, \frac{c_3}{\|B_*^{-1}\| \|B_*\|}\}}$$

其中  $L$  是 Lipschitz 常数. 因此对充分大的  $k$ ,  $(f_{m(k)} - f_{k+1})/\text{pred}_k \geq \mu_k$ . 于是对充分大的  $k$ ,  $\Delta_{k+1} \geq \Delta_k$  与(13)式的第一式矛盾. 因此对充分大的  $k$ ,

$\|B_k^{-1} g_k\| \leq \Delta_k$ , 由假设(ii) 可得,  $d_k = -B_k^{-1} g_k$ , 这说明  $\{x_k\}$  Q- 二次收敛  $x^*$ .

参考文献:

[1] DENNIS J E, SCHNABEL R B. Numerical methods for

unconstrained optimization and nonlinear equations[M]. NJ: Prentice-Hall Inc Englewood Cliffs, 1983.

- [2] FLETCHER R, WILEY JOHN, SONS. Practical methods of optimization[M]. Chichester: Wiley & Sons, 1987.
- [3] DENNIS J E J R, MORE J J. A characterization of superlinear convergence and its application to quasi-Newton methods[J]. Math Comp, 1974, 28: 1171-1190.
- [4] LI D, FUKUSHIMA M. A modified BFGS method and its global convergence in nonconvex minimization [J]. Journal of Computational and Applied Mathematics, 2001, 129: 15-35.
- [5] POWELL M J D. A new algorithm for unconstrained optimization[M]// ROSEN J B, MANGASARIAN O L, RITTER K, eds. Nonlinear programming. New York: Academic Press, 1970.
- [6] WEI Z, QI L, CHEN X. An SQP-type method and its application in stochastic programming [J]. Journal of Optimization Theory and Applications, 2003, 116: 205-228.
- [7] WEI Z, YU G, YUAN G, et al. The superlinear convergence of a modified BFGS-type method for unconstrained optimization [M]. Computational and Applications, 2002.
- [8] 袁功林, 韦增欣. 一个新的 BFGS 信赖域算法[J]. 广西科学, 2004, 11(3): 195-196.
- [9] BACHEM A, GROTSCHEL M, KORTE B. Mathematical programming: the state of Art [M]. Berlin: Springer-VERlag, 1983: 258-287.
- [10] SHULTZ G A, SSHNABEL R B, BYRD R H. A family of trust-region-based algorithms for unconstrained minimization with strong global convergence properties [J]. SIAM J Number Anal, 1985, 22: 47-67.
- [11] 袁亚湘. 信赖域方法的收敛性[J]. 计算数学, 1994, 16(3): 333-346.
- [12] BULEAU J P, VIAL J Ph. Curvilinear path and trust region in unconstrained optimization, a convergence analysis[J]. Math Prog Study, 1987, 30: 82-101.
- [13] BYRD R H, SCHNABEL R B, SHULTZ G A. Approximate solution of the trust region problem by minimization over two-dimensional subspaces[J]. Math Prog, 1988, 40: 247-263.
- [14] NOCEDAL J, YUAN Y Y. Combining trust-region and line search techniques [M]// Yuan Y Y. Advance in nonlinear programming. Applied Optimization, Kluwer Academic Publ, Dordrecht, 1998: 153-157.
- [15] RENDL F, WOLKOWICZ H. A semidefinite framework for trust region subproblems with applications to large scale minimization [J]. Math Program, 1997, 77: 273-299.
- [16] 柯小五, 韩继业. 无约束最优化的一类非单调信赖域算法[J]. 中国科学, 1998, 28(6): 488-492.

(责任编辑: 邓大玉 凌汉恩)