

A Nonmonotonic Self-Adaptive Trust Region Algorithm*

Dan Hang, Xiaoyan Wang, Jianzhong Hao, Ya Wang

Department of Basic Education, Air Force Logistics College, Xuzhou
Email: hazel-hang@sohu.com

Received: Jun. 18th, 2013; revised: Jul. 24th, 2013; accepted: Aug. 3rd, 2013

Copyright © 2013 Dan Hang et al. This is an open access article distributed under the Creative Commons Attribution License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited.

Abstract: We propose an improved nonmonotonic trust region algorithm. Our method is to use the non-monotone technique and if the trial step is rejected, the stepsize is computed by a fixed formula. The trust region radius is updated at a variable rate. Numerical experiment results show that the new algorithm is effective. Under mild conditions, we prove that the algorithm is global convergence.

Keywords: Unconstrained Optimization; Trust Region; Fixed Stepsize; Nonmonotonic Technique; Global Convergence

一种非单调自适应信赖域法*

杭丹, 王晓燕, 郝建忠, 王娅

空军勤务学院基础部, 徐州
Email: hazel-hang@sohu.com

收稿日期: 2013年6月18日; 修回日期: 2013年7月24日; 录用日期: 2013年8月3日

摘要: 求解无约束优化问题, 本文给出了一种改进的非单调信赖域算法。采用了非单调技术, 当试探步不被接受时, 下一步的迭代步长由一个固定公式给出。并直接给出调整信赖域半径公式。数值试验结果表明新算法的有效性。在适当的条件下, 证明了算法的全局收敛性。

关键词: 无约束最优化; 信赖域; 固定步长; 非单调技术; 全局收敛性

1. 引言

求解无约束优化问题:

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

其中 $f(x): R^n \rightarrow R^1$ 是二阶连续可微的函数, 信赖域方法是解决问题(1)一类有效的迭代方法, 而且保证了很强的收敛性。在每个迭代点 x_k , 通过解如下的子问题产生一个试探步 d_k :

$$\min \phi_k(d) = g_k^T d + \frac{1}{2} d^T B_k d \quad (2)$$

$$\text{s.t. } \|d\| \leq \Delta_k \quad (3)$$

其中 g_k 是目标函数在当前点 x_k 处的梯度。 B_k 为精确 Hessian 阵或其近似 $\Delta_k > 0$ 是信赖域的半径。

*基金项目: 安徽省教育厅自然科学基金项目(编号: KJ2012B125), 安徽省高等学校省级优秀青年人才基金项目(编号: 2012SQRL155)。

d_k 是子问题(2)~(3)的一个精确或近似解, 得到 d_k 后计算比率:

$$r_k = \frac{\text{Ared}_k}{\text{Pred}_k} = \frac{f(x_k) - f(x_k + d_k)}{\phi_k(0) - \phi_k(d_k)} \quad (4)$$

检验试探步 d_k 是否被接受, 然后信赖域半径 Δ_k 根据 r_k 值调整。对于传统的信赖域方法, 信赖域半径 Δ_k 在给定的比率下调整, 然而, HEI LONG^[1]中提出了自适应信赖域方法, 其中 Δ_k 根据 r_k 的一个函数值进行调整, 数值结果显示是有效的。本文在其启示下, 改进 Hei Long^[1]中调整信赖域半径的公式即采用 $\Delta_{k+1} = R_{c_2}(r_k)\Delta_k$ 公式进行调整信赖域半径; 同时采用了非单调技术, 且当试探步 d_k 不被接受时, 不再重解子问题, 而是通过一个固定的公式 $x_{k+1} = x_k - \frac{\delta g_k^T d_k}{d_k^T B_k d_k} d_k$ 直接得到下一个迭代点。数值试验表明, 这样做大大减少了计算量。在适当的条件下, 证明了新算法的全局收敛性。

2. 算法^[2]: 算法中 d_k 的选取有多种方法(如文[2]-[4])。

定义 1 设一维函数 $R_\eta(t)$ 定义在 $R = (-\infty, +\infty)$, 其中 $\eta \in (0, 1)$, $R_\eta(t)$ 是 R -函数当且仅当它满足:

- 1) $R_\eta(t)$ 在 $(-\infty, +\infty)$ 不是下降的;
- 2) $\lim_{t \rightarrow -\infty} R_\eta(t) = \beta_1$, 其中 $\beta_1 \in (0, 1)$ 是小常数;
- 3) $R_\eta(t) \leq 1 - \gamma_1$, 对所有 $t < \eta$, 这里 $\gamma_1 \in (0, 1 - \beta_1)$ 是一常数;
- 4) $R_\eta(t) = 1 + \gamma_2$, 其中 $\gamma_2 \in (0, +\infty)$ 是一常数;
- 5) $\lim_{t \rightarrow +\infty} R_\eta(t) = \beta_2$, 其中 $\beta_2 \in (1 + \gamma_2, +\infty)$ 是一常数。

定理 2 R -函数 $R_\eta(t)$ (其中 $\eta \in (0, 1)$) 满足: $0 < \beta_1 \leq R_\eta(t) \leq 1 - \gamma_1 < 1, \forall t \in (-\infty, \eta)$, $1 < 1 + \gamma_2 \leq R_\eta(t) \leq \beta_2 < \infty, \forall t \in [\eta, +\infty)$ 。求解子问题(2)~(3)获得试探步 d_k 满足下面条件:

$$\phi_k(0) - \phi_k(d_k) \geq \Gamma \|g_k\| \min\{\Delta_k, \|g_k\| / \|B_k\|\} \quad (5)$$

$$d_k^T g_k \leq -\Gamma \|g_k\| \min\{\Delta_k, \|g_k\| / \|B_k\|\} \quad (6)$$

其中 $\Gamma \in (0, 1)$ 是一个常数。采用非单调技术, 设 $f_{l(k)} = f(x_{l(k)}) = \max_{0 \leq j \leq m(k)} f(x_{k-j})$ 这里 $m(0) = 0$,

$m(k) = \min\{m(k-1) + 1, M\}$, M 是一个非负整数。故获得试探步实际下降量 $\text{Ared}_k = f_{l(k)} - f(x_k + d_k)$, 由(4)计算比率, 检验试探步 d_k 是否被接受, 当试探步 d_k 不被接受时, 不再重解子问题, 而是用固定公式直接给出步长

$x_{k+1} = x_k + \alpha_k d_k = x_k - \frac{\delta g_k^T d_k}{d_k^T B_k d_k} d_k$, 然后信赖域半径 Δ_k 根据 r_k 值调整。

算法:

步 0. 给定 $x_0, B_0, \Delta_0 > 0, \varepsilon \geq 0, 0 < \beta_1 < 1, 0 < \gamma_1 < 1 - \beta_1, \gamma_2 > 0, \beta_2 > 1 + \gamma_2, 0 < c_1 < c_2 < 1, M > 0, \delta \in (0, 1), \mu > 0, \omega > 1$ 。置 $k = 0, m(0) = 0$ 。

步 1. 计算 $g_k = g(x_k)$ 。如果 $\|g_k\| \leq \varepsilon$, 则终止。否则计算 B_k 和 $f_{l(k)}$ 。

步 2. 解子问题(2)~(3)使 d_k 满足(4)~(5)。

步 3. 计算 $\text{Ared}_k, \text{Pred}_k$, 和 $r_k = \frac{\text{Ared}_k}{\text{Pred}_k}$ 。

步 4. 如果 $r_k > c_1$, 转 Step 5。否则计算 $\alpha_k = -\frac{\delta g_k^T d_k}{d_k^T B_k d_k}$, 置 $x_{k+1} = x_k + \alpha_k d_k$, 转 Step 6。

步 5. 置 $x_{k+1} = x_k + d_k$ 。步 6. $\Delta_{k+1} = R_{c_2}(r_k)\Delta_k$ 。置 $m(k+1) = \min\{m(k) + 1, M\}, k = k + 1$, 转 Step 1。

注: 我们注意到在[1]中信赖域半径由 $\Delta_{k+1} = R_{c_2}(r_k)\|d_k\|_2$ 确定。但当 d_k 很小时会造成下一步迭代的信赖域半

径太小,使下一步试探步长过小,影响算法的效率.因此在我们的算法中采用 $\Delta_{k+1} = R_{c_2}(r_k)\Delta_k$ 公式进行迭代来避免这种缺陷.事实上,后面的数值试验也验证了这种修改的有效性.

3. 收敛性

假设 1. 1) 函数 $f(x)$ 在 R^n 是 LC^1 即存在 $\mu > 0$ 有 $\|g(x) - g(y)\| \leq \mu \|x - y\|, \forall x, y \in R^n$, 其中

$$g(x) = \nabla f(x) \quad (7)$$

2) 给定 x_0 属于 R^n , 水平集 $\Omega_0 = \{x \in R^n \mid f(x) \leq f(x_0)\}$ 是紧集.

3) 矩阵 B_k 正定且存在实数 ω 使得

$$d^T B_k d \geq \omega d^T d, \forall d \in R^n \quad k = 0, 1, \dots \quad (8)$$

定义两个指标集: $I = \{k : r_k \geq c_1\}, J = \{k : r_k < c_1\}$.

引理 2^[3] 假设 $\{x_k\}$ 是由算法产生的序列.如果假设 3.1 满足且有

$$\delta \in (0, \omega/\mu). \quad (9)$$

则

$$f(x_{k+1}) - f_{l(k)} \leq \{(1 - \mu\delta/\omega)\delta/2\} g_k^T d_k, \forall k \in J \quad (10)$$

引理 3^[3] 算法产生的序列 x_k 定义在 Ω_0 . 如果假设 3.1 和(8)成立, 则 $f_{l(k)}$ 是下降的.

引理 4 如果假设 3.1 和(9)满足, 且存在 $\varepsilon > 0$ 使得对所有的 k 有 $\|g(x_k)\| \geq \varepsilon$, 那么存在一个常数 $\gamma > 0$ 有 $\Delta_k \geq \gamma/M_k, k = 0, 1, \dots$

这里 M_k 定义为

$$M_k = \max_{0 \leq i \leq k} \|B_i\| + 1. \quad (11)$$

证明: 令 $\sigma = \Gamma\delta(1 - c_2)/2\mu$, 由 $\nabla f(x)$ 是一致连续的, 对任意 $x_k \in \Omega_0, \theta_k \in [0, 1], \|d_k\| < \sigma$ 有

$$d_k [\nabla f(x_k + \theta_k d_k) - \nabla f(x_k)] \leq \mu \|d_k\|^2 < \mu\Gamma(1 - c_2)\varepsilon \|d_k\|/2\mu = \Gamma(1 - c_2)\varepsilon \|d_k\|/2 \quad (12)$$

用归纳法证明(11)成立. 设

$$\gamma = \min\{\Delta_0 M_0, \beta_1 \sigma M_0, \beta_1 \varepsilon, \Gamma(1 - c_2) \beta_1 \varepsilon\} \quad (13)$$

当 $k = 0$, 由(13)知 $\Delta_0 \geq \gamma/M_0$ 即(11)对 $k = 0$ 成立. 假设(11)对 k 成立, 因 M_k 递增, 只要证明:

$$\Delta_{k+1} \geq \gamma/M_k \quad (14)$$

当 $r_k \geq c_2$ 时, 由 $\Delta_k = R_{c_2}(r_k)\Delta_k$ 知 $\Delta_{k+1} \geq \Delta_k \geq \gamma/M_k$, 故(14)成立.

当 $r_k < c_2$ 时, 知 $\Delta_{k+1} \geq \beta_1/\Delta_k$ 如果 $\|d_k\| \geq \sigma$, 则 $\Delta_{k+1} \geq \beta_1 \Delta_k \geq \beta_1 \|d_k\| \geq \beta_1 \sigma \geq \beta_1 \sigma M_0/M_k \geq \gamma/M_k$. 设 $d_k < \sigma, r_k < c_2$, 得

$$f(x_k + d_k) - f_{l(k)} > -c_2 (\phi_k(0) - \phi_k(d_k)) = c_2 (g_k^T d_k + d_k^T B_k d_k / 2) \quad (15)$$

$$f(x_k + d_k) - f_{l(k)} \leq g(\eta)^T d_k = g_k^T d_k + (g(\eta) - g_k)^T d_k \leq g_k^T d_k + \mu \|d_k\|^2 \leq g_k^T d_k + \Gamma(1 - c_2) \|d_k\|/2 \quad (16)$$

其中 $\eta = x_k + \theta_k d_k \in [x_k, x_k + d_k]$. 根据(14)和(15), 得到

$$(1 - c_2) (g_k^T d_k + \Gamma \varepsilon \|d_k\|/2) > c_2 d_k^T B_k d_k / 2 \quad (17)$$

此外, 由(5)和 $\|g_k\| \geq \varepsilon$ 得到

$$-g_k^Y d_k - d_k^Y B_k d_k / 2 \geq \Gamma \varepsilon \min \{ \Delta_k, \varepsilon / \|B_k\| \} \quad (18)$$

上式两边乘 $1-c_2$ 与(17)相加得到

$$\begin{aligned} \Delta_k \|B_k\| &\geq -d_k^T B_k d_k > 2(1-c_2) \Gamma \varepsilon \min \{ \Delta_k, \varepsilon / \|B_k\| \} - (1-c_2) \Gamma \varepsilon \Delta_k \geq (1-c_2) \Gamma \varepsilon \min \{ \Delta_k, \varepsilon / \|B_k\| - \Delta_k \} \\ &= (1-c_2) \Gamma \varepsilon \min \{ \Delta_k, 2\varepsilon / \|B_k\| - \Delta_k \} \end{aligned} \quad (19)$$

于是

$$\Delta_k \|B_k\| \geq (1-c_2) \Gamma \varepsilon \min \{ 1, 2\varepsilon / \|B_k\| - 1 \} \quad (20)$$

若 $\Delta_k \|B_k\| \leq \varepsilon$, 则 $\Delta_k \|B_k\| > (1-c_2) \Gamma \varepsilon$, 否则 $\Delta_k \|B_k\| > \varepsilon$, 因而由(16)有

$$\Delta_k \|B_k\| \geq \min \{ (1-c_2) \Gamma \varepsilon, \varepsilon \} \geq \gamma / \beta_1, \quad (21)$$

于是 $\Delta_{k+1} > \beta_1 \Delta_k > \gamma / \|B_k\| > \gamma / M_k$ 。

定理 5 如果假设 1 和(9)满足, 同时 $\{B_k\}$ 满足

$$\sum_{k=1}^{\infty} 1/M_k = \infty \quad (22)$$

这里 $M_k = \max_{0 \leq i \leq k} \|B_i\| + 1$, 则由算法产生的序列 $\{x_k\} \subset \Omega_0$, 且满足

$$\liminf_{k \rightarrow \infty} \|g_k\| = 0 \quad (23)$$

证明: 假设(23)不成立, 则存在 $\varepsilon > 0$ 使得对任意 k 均有 $\|g_k\| \geq \varepsilon > 0$ 。当 $k \in I$ 时, 由(4)和(6)得到

$$f_{l(k)} - f(x_{k+1}) > c_1 (\phi_k(0) - \phi_k(d_k)) = c_1 \Gamma \varepsilon \min \{ \Delta_k, \varepsilon / \|B_k\| \} \quad (24)$$

当 $k \in J$ 时, 由(6)和(10)得到

$$f_{l(k)} - f(x_{k+1}) \geq \{1 - \mu\delta/\omega\} \delta/2 \{-g_k^T d_k\} \geq \{1 - \mu\delta/\omega\} \delta/2 \Gamma \varepsilon \min \{ \Delta_k, \varepsilon / \|B_k\| \} \quad (25)$$

令 $\theta = \min \{ c_1 \Gamma \varepsilon, (1 - \mu\delta/\omega) \delta/2 \}$, 则由(24)和(25)得到对任意 k 都有

$$f_{l(k)} - f(x_{k+1}) \geq \theta \min \{ \Delta_k, \varepsilon / \|B_k\| \} \quad (26)$$

由引理 3 知对任意 k 均有

$$\min \{ \Delta_k, \varepsilon / \|B_k\| \} \geq \nu / M_k \quad (27)$$

其中 $\nu = \min \{ \gamma, \varepsilon \}$. 由 $f_{l(k)}$ 递减及(26)和(27)知, 对 $s = 0, 1, \dots, M$, 均有

$$f_{l(k)} \geq f_{l(k+s)} \geq f_{k+s+1} + \theta \min \{ \Delta_k, \varepsilon / \|B_{k+s}\| \} \geq f_{k+s+1} + \theta \nu / M_{k+s} \quad (28)$$

根据引理 2 和 M_k 递增知

$$f_{l(k)} \geq \max \{ f_{k+s+1} : 0 \leq s \leq M \} + \theta \nu / M_{k+M+1} = f_{k+M+1} + \theta \nu / M_{k+M+1} \quad (29)$$

再根据假设 1 和引理 2, 即 $f_{l(k)}$ 是单调下降且收敛的故由(29)得

$$\begin{aligned} \sum_{k=1}^{\infty} 1/M_{k+M+1} &\leq (1/\nu\theta) \sum_{k \geq 1} (f_{l(k)} - f_{l(k+M+1)}) \\ &= (1/\nu\theta) \sum_{k \geq 1} \sum_{s=0}^M (f_{l(k+s)} - f_{l(k+s+1)}) \leq (M/\nu\theta) \sum_{k \geq 1} (f_{l(k)} - f_{l(k+1)}) < \infty \end{aligned} \quad (30)$$

显然(30)和(22)矛盾, 定理得证。

4. 数值结果

本节中，算法用[5]的标准无约束优化问题测试。使用和[5]同样的编号。此外，假设 $B_k = H_k$ ，系数的选择为： $\varepsilon = 10^{-8}, c_1 = 0.01, c_2 = 0.25, \beta_1 = 0.1, \beta_2 = 5, \delta = 0.1$ 。 $\gamma_1 = \gamma_2 = 0.15, M = 10$ 。

其中用 n 表示问题的维数，用 ng 表示梯度迭代次数， nf 表示函数值的迭代维数， f 表示最终的函数值， L 是标准初始点的常用对数因子，即，如果 x_0 是标准初始点，则实际的初始点为 $10^L \cdot x_0$ 。算法与黑龙[1]进行比较。结果在表 1 中，可以发现我们的算法更有效。

Table 1. Numerical results
表 1. 数值结果

NO.	n	L	本文算法(M = 10)			文[2]算法		
			nf	ng	f	nf	ng	f
8	50	0	34	34	4.3179e-004	46	46	4.3179e-004
	100	0	37	37	9.0249e-004	47	47	9.0249e-004
	200	0	41	41	0.0019	53	53	0.0019
14	50	0	16	15	2.1526e-022	27	27	0
	100	0	15	14	7.11102e-023	27	27	0
	200	0	19	17	0	27	27	0

参考文献 (References)

- [1] Long Hei, A self-adaptive trust regional gorithm, Journal of Computational Mathematics, 2003, 21: 229-236.
- [2] J. Nocedal, Y. Yuan, Combing trust region and line search techniques. In: Y. Yuan, Ed., Advances in Nonlinear Programming, Kluwer: Springer, 1998: 153-175.
- [3] J. T. Mo, K. Zhang and Z. X. Wei. A nonmonotone trust region method for unconstrained optimization. Applied Mathematics and Computation, 2005, 171(1): 371-384.
- [4] L. Grippo, F. Lampariello and S. Lucidi. A nonmonotonic line search technique for Newton's method. SIAM Journal on Numerical Analysis, 1986, 23(4): 707-716.
- [5] J. J. Mor, B. S. Garbow and K. E. Hillstrom. Testing unconstrained optimization software. ACM Transactions on Mathematical Software, 1981, 7(1): 17-41.