

doi:10.16055/j.issn.1672-058X.2015.0009.001

一个带有干扰因子修正 PRP 共轭梯度法的全局收敛性*

陈洪敏

(重庆师范大学 数学学院,重庆 401331)

摘要:非线性共轭梯度法是解决大规模优化问题的一种非常有效的方法,提出了一个修正的 PRP 方法,该参数带有干扰因子,并证明了这一新的参数具有非负性,且在适当条件下,采用 Wolfe 线搜索,证明该算法具有全局收敛性.

关键词:共轭梯度法;强 Wolfe 条件;Wolfe 条件;干扰因子;全局收敛性

中图分类号: O224 **文献标志码:** A **文章编号:** 1672-058X(2015)09-0001-04

1 基础知识

考虑如下的无约束极小化问题:

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

其中 $f: \mathbf{R}^n \rightarrow \mathbf{R}$ 是连续可微函数,且其梯度可获得.

非线性共轭梯度法是求解此类问题的一种常用的有效方法,具有算法简便、存储需求小等优点,适用于求解大规模无约束优化问题.共轭梯度法的迭代格式为

$$x_{k+1} = x_k + \alpha_k d_k \quad (2)$$

$$d_k \begin{cases} -g_k, k=1 \\ -g_k + \beta_k d_{k-1}, k \geq 2 \end{cases} \quad (3)$$

其中 d_k 为搜索方向, $\nabla f(x_k)$ 简记为 g_k , β_k 是一个参数,不同的 β_k 对应着不同的共轭梯度法, α_k 是通过适当的线搜索获得的步长,通常使用 Wolfe 线搜索、强 Wolfe 线搜索.

Wolfe 线搜索条件为

$$f(x_k + \alpha_k d_k) \leq f(x_k) + \delta \alpha_k g_k^T d_k \quad (4)$$

$$g(x_k + \alpha_k d_k)^T d_k \geq \sigma g_k^T d_k \quad (5)$$

强 Wolfe 线搜索条件为

$$|g(x_k + \alpha_k d_k)^T d_k| \geq -\sigma g_k^T d_k \quad (6)$$

其中 $0 < \delta < \sigma < 1$.

传统共轭梯度法的参数公式 β_k 的计算公式有 Hestenes-Stiefel (HS)^[1], Fletcher-Reeves (FR)^[2], Polak-

收稿日期:2014-12-11;修回日期:2015-02-24.

* 基金项目:国家自然科学基金(10771003).

作者简介:陈洪敏(1988-),女,安徽阜阳人,硕士研究生,从事最优化理论与算法研究.

Ribiere (PRP)^[3], Dai-Yuan (DY)^[4], 它们的表达式分别为

$$\beta_k^{\text{HS}} = \frac{g_k^T(g_k - g_{k-1})}{d_k^T(g_k - g_{k-1})}, \beta_k^{\text{FR}} = \frac{\|g_k\|^2}{\|g_{k-1}\|^2}$$

$$\beta_k^{\text{PRP}} = \frac{g_k^T(g_k - g_{k-1})}{\|g_{k-1}\|^2}, \beta_k^{\text{DY}} = \frac{\|g_k\|^2}{d_{k-1}^T(g_k - g_{k-1})}$$

其中 $\|\cdot\|$ 表示欧几里德范数. FR 方法具有很好的收敛性, 且在强 Wolfe 线搜索下具有充分下降性, 但因其在一些情况下可能会产生小步长情况, 且这种情况会持续很多次迭代, 除非重新开始, 这就导致 FR 方法的数值表现不佳. PRP 和 HS 方法的数值表现非常相似, 且都优于 FR 方法, 但对于非凸的目标函数, 即使采用精确线性搜索, 它们仍有可能不收敛. 这问题启发人们找到新的共轭梯度法, 使得这种方法不仅具有好的收敛性, 而且具有很好的数值表现.

最近, 文献[5]提出了关于 β_k^{PRP} 的一种修正方案, 具体参数公式如式(7):

$$\beta_k = \frac{g_k^T \left(\frac{\|g_{k-1}\|}{\|g_k\|} g_k - g_{k-1} \right)}{\|g_{k-1}\|^2} \quad (7)$$

这种方法在适当条件下, 分别证明算法在 Wolfe 和 Grippo-Lucidi 线搜索下是全局收敛的. 文献[6]通过对参数 β_k 加入干扰因子得到两个新的 β_k , 公式如式(8):

$$\beta_k^{\text{MVP RP}} = \frac{g_k^T \left(g_k - \frac{\|g_k\|}{\|g_{k-1}\|} g_{k-1} \right)}{\eta_k \|g_{k-1}\|^2}, \beta_k^{\text{MN}} = \frac{g_k^T \left(g_k - \frac{\|g_k\|}{\|d_{k-1}\|} d_{k-1} \right)}{\tau_k \|g_{k-1}\|^2} \quad (8)$$

其中 $\eta_k = 1 - \nu \min \left\{ 0, \frac{g_k^T g_{k-1}}{\|g_k\| \|g_{k-1}\|} \right\}$ ($\nu \geq 1$), $\tau_k = 1 - \mu \min \left\{ 0, \frac{g_k^T d_{k-1}}{\|g_k\| \|d_{k-1}\|} \right\}$ ($\mu \geq 1$), 这两类方法在强 Wolfe 线搜索下不仅产生充分下降方向, 而且对于目标函数是一般的非凸函数, 都是全局收敛的. 受文献[5,6]的启发, 此处提出一个新的参数 β_k , 公式如式(9):

$$\beta_k^{\text{new}} = \frac{g_k^T \left(\frac{\|g_{k-1}\|}{\|g_k\|} g_k - g_{k-1} \right)}{\eta_k \|g_{k-1}\|^2} \quad (9)$$

2 新方法(β_k^{new})的全局收敛性

文献[7]分析了 PRP 方法, 认为限制其参数 β_k 的非负性不仅对方法的全局收敛性起到至关重要的作用, 而且能够很容易地保证算法的下降性; 文献[8]证明了 $\beta_k = \max\{0, \beta_k^{\text{PRP}}\}$ 在充分下降条件被满足, 且步长 α_k 满足 Wolfe 线搜索条件的前提下, 算法具有全局收敛性. 在接下来的引理中证明了 β_k^{new} 的非负性.

假设目标函数满足下面的假设:

- 1) 水平集 $\Omega = \{x \in \mathbf{R}^n : f(x) \leq f(x_1)\}$ 是有界的;
- 2) 目标函数 f 在 Ω 的某个领域 N 是连续可微的, 且梯度函数是 Lipschitz 连续的, 即存在常数 $L > 0$ 使得

$$\|g(x) - g(\tilde{x})\| \leq L \|x - \tilde{x}\| \quad (10)$$

对任意的 $x, \tilde{x} \in N$.

显然, 由上面的假设可知存在一个常数 $\bar{\gamma}$ 使得

$$\|g_k\| \leq \bar{\gamma} \quad (11)$$

对任意的 $x \in N$.

引理 1 对任意的 $k \geq 1$, 都有 $\beta_k^{\text{new}} \geq 0$.

证明 记 θ_k 为 g_k 和 g_{k-1} 的夹角, 即 $g_k^T g_{k-1} = \|g_k\| \|g_{k-1}\| \cos \theta_k$.

$$\begin{aligned} \beta_k^{\text{new}} &= \frac{g_k^T \left(\frac{\|g_{k-1}\|}{\|g_k\|} g_k - g_{k-1} \right)}{\eta_k \|g_{k-1}\|^2} = \frac{\|g_k\| \|g_{k-1}\| - \|g_k\| \|g_{k-1}\| \cos \theta_k}{\eta_k \|g_{k-1}\|^2} = \\ &= \frac{1 - \cos \theta_k}{\eta_k} \cdot \frac{\|g_k\|}{\|g_{k-1}\|} = \frac{1 - \cos \theta_k}{1 - \nu \min \left\{ 0, \frac{g_k^T g_{k-1}}{\|g_k\| \|g_{k-1}\|} \right\}} \cdot \frac{\|g_k\|}{\|g_{k-1}\|} \end{aligned}$$

因为 $\nu \geq 1$, 故

$$0 \leq \frac{1 - \cos \theta_k}{1 - \nu \min \{0, \cos \theta_k\}} = \begin{cases} \frac{1 - \cos \theta_k}{1 - \nu \cos \theta_k}, & \text{若 } \cos \theta_k < 0 \\ 1 - \cos \theta_k, & \text{若 } \cos \theta_k \geq 0 \end{cases} \leq 1$$

所以 $\beta_k^{\text{new}} \geq 0$.

引理 2 (性质*) 考虑形如式(2)(3)的方法, 并且假设对任意的 $k \geq 1$ 有 $0 \leq \gamma \leq \|g_k\| \leq \bar{\gamma}$, 则存在常数 $b > 1, \lambda > 0$, 使得对任意的 $k \geq 1$ 都有 $\|\beta_k^{\text{new}}\| \leq b$, 且当 $\|s_{k-1}\| \leq \lambda$ 时有 $\beta_k^{\text{new}} \leq \frac{1}{2b}$, 其中 $s_{k-1} = x_k - x_{k-1}$.

证明 取 $b = \frac{2\bar{\gamma}}{\gamma} > 2, \lambda = \frac{\gamma^3}{8L\gamma^2} > 0$, 则

$$\beta_k^{\text{new}} = \frac{g_k^T \left(\frac{\|g_{k-1}\|}{\|g_k\|} g_k - g_{k-1} \right)}{\eta_k \|g_{k-1}\|^2} = \frac{1 - \cos \theta_k}{\eta_k} \cdot \frac{\|g_k\|}{\|g_{k-1}\|} \leq \frac{2\bar{\gamma}}{\gamma} = b$$

当 $\|s_{k-1}\| \leq \lambda$ 时,

$$\begin{aligned} \beta_k^{\text{new}} &= \frac{g_k^T \left(\frac{\|g_{k-1}\|}{\|g_k\|} g_k - g_{k-1} \right)}{\eta_k \|g_{k-1}\|^2} \leq \frac{\|g_k\| \left\| \frac{\|g_{k-1}\|}{\|g_k\|} g_k - g_{k-1} \right\|}{\|g_{k-1}\|^2} = \\ &= \frac{\|g_k\| \left\| \frac{\|g_{k-1}\|}{\|g_k\|} g_k - g_k + g_k - g_{k-1} \right\|}{\|g_{k-1}\|^2} \leq \frac{\|g_k\| (\|g_{k-1}\| - \|g_k\| + \|g_k - g_{k-1}\|)}{\|g_{k-1}\|^2} \leq \\ &= \frac{2\|g_k\| \|g_k - g_{k-1}\|}{\|g_{k-1}\|^2} \leq \frac{2\bar{\gamma}L\lambda}{\gamma^2} = \frac{1}{2b} \end{aligned}$$

在共轭梯度法中, 充分下降条件

$$g_k^T d_k \leq -c \|g_k\|^2, c > 0 \quad (12)$$

非常重要, 其中假设 new 算法满足式(12).

引理 3^[8] (zoutendijk 条件) 若假设 1)2) 成立, 考虑形如式(2)(3)的方法, d_k 是下降方向, α_k 满足式(5)(6), 则 $\sum_{k \geq 1} \frac{(g_k^T d_k)^2}{\|d_k\|^2} < +\infty$.

引理 4^[8] 若假设 1)2) 成立, 考虑形如式(2)(3)的方法, α_k 满足式(5)(6), 且满足充分下降条件式(12), 若 β_k 满足性质(*)且 $0 \leq \gamma \leq \|g_k\| \leq \bar{\gamma}$ 成立, 则存在 $\lambda_1 > 0$, 使得对任意的 $\Delta \in N^*$ 和下标 k_0 , 都存在指

标 $k \geq k_0$, 满足 $|\kappa_{k,\Delta}^{\lambda_1}| > \frac{\Delta}{2}$, 其中 $|\kappa_{k,\Delta}^{\lambda_1}|$ 表示 $\kappa_{k,\Delta}^{\lambda_1}$ 的个数.

引理 5^[8] 若假设 1)2) 成立, 考虑形如式(2)(3)的方法, 满足下面 3 个条件:(i) 对任意的 $k \geq 1$, 都有 $\beta_k \geq 0$; (ii) 算法采用 Wolfe-power 线搜索, 满足 zoutendijk 条件, 满足充分下降条件式(12); (iii) 满足性质 (*), 则 $\liminf_{k \rightarrow \infty} \|g_k\| = 0$.

定理 1 若假设 1)2) 成立, 考虑形如式(2)(3)的方法, 充分下降条件式(12)成立, α_k 满足式(5)(6), β_k 取 β_k^{new} , 则 $\liminf_{k \rightarrow \infty} \|g_k\| = 0$. 即 new 算法具有全局收敛性.

参考文献:

- [1] HESTENES M R, STIEFEL E L. Method of Conjugate Gradient for Solving Linear Systems[J]. Res Natl Bur Stand, 1952(49): 409-436
- [2] FLETCHER R, REEVES C. Function Minimization by Conjugate Gradients[J]. Comput, 1964(7): 149-154
- [3] POLAK B, RIBIEREG. Note Sur la Convergence Des Meethodes de Directions Conjugees[J]. Rev Fr Inf Rech Oper, 1964, 3(1): 35-43
- [4] DAI Y H, YUAN Y X. A Nonlinear Conjugate Gradient Method with a Strong Global Convergence Property[J]. SIAM Optim, 1999(10): 177-182
- [5] 黎勇. 一类修正 PRP 共轭梯度法的全局收敛性及其数值试验结果[J]. 西南大学学报: 自然科学版, 2011, 33(11): 23-28
- [6] JIANG X Z, JIAN J B. Two Modified Nonlinear Conjugate Gradient Methods with Disturbance Factors for Unconstrained Optimization[J]. Nonlinear Dynamics, 2014, 77(1-2): 387-394
- [7] POWELL M J D. Nonconvex Minimization Calculations and the Conjugate Method[J]. Lecture Notes in Mathematics, 1984, 10(66): 122-141
- [8] GLIBERT J C, NOCEDAL J. Global Convergence Properties of Conjugate Gradient Method for Optimization[J]. SIAM Optim, 1992(2): 21-42

Global Convergence Property of a Modified PRP Conjugate Gradient Method with Disturbance Factor

CHEN Hong-min

(School of Mathematical Sciences, Chongqing Normal University, Chongqing 401331, China)

Abstract: The nonlinear conjugate gradient method is a very effective iterative method for solving large-scale optimal problems. In this paper, a modified PRP conjugate gradient method with disturbance factor is proposed and non-negative property of the formula is proved. Under suitable conditions, the global convergence of the algorithm with the Wolfe line search is discussed.

Key words: conjugate gradient method; strong Wolfe condition; Wolfe condition; disturbance factor; global convergence