

凸约束优化问题的杂交三阶投影HS-PRP方法

周姣利

长沙理工大学数学与统计学院, 湖南 长沙

收稿日期: 2022年7月15日; 录用日期: 2022年8月9日; 发布日期: 2022年8月18日

摘要

本文提出了一种杂交三阶投影HS-PRP共轭梯度法求解凸约束优化问题并证明了该算法的全局收敛性, 该方法是求解无约束优化问题的三阶HS共轭梯度法的推广。数值实验结果表明, 该算法是有效的。

关键词

投影, 共轭梯度法, 线搜索, 全局收敛

A Hybrid Three-Term Projected HS-PRP Method for Optimization with Convex Constraint

Jiaoli Zhou

School of Mathematics and Statistics, Changsha University of Science and Technology, Changsha Hunan

Received: Jul. 15th, 2022; accepted: Aug. 9th, 2022; published: Aug. 18th, 2022

Abstract

In this paper, we propose a hybrid third-term projected HS-PRP conjugate gradient method for solving convex constrained optimization problems and establish its global convergence, which is a generalization of the third-term HS conjugate gradient method for unconstrained optimization. Numerical experimental results show that the algorithm is effective.

Keywords

Projected, Conjugate Gradient Method, Line Search, Global Convergence

Copyright © 2022 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

自共轭梯度法被提出以来, 因其具有良好的收敛性质, 且所需存储量小, 因此被广泛用于求解大规模无约束优化问题。

共轭梯度法的基本迭代格式如下:

$$x_{k+1} = x_k + \alpha_k d_k,$$

$$d_k = \begin{cases} -g_k, & k = 0 \\ -g_k + \beta_k d_k, & k > 0 \end{cases},$$

其中 α_k 为步长因子, 由某种线搜索确定; d_k 为搜索方向, β_k 为共轭参数, $g_k = \nabla f(x_k)$ 。

共轭参数 β_k 的经典选取方式有 Fletcher-Reeves [1], Polak-Ribière-Polyak [2], Hestenes-Stiefel [3], Dai-Yuan [4], Conjugate Descent [5], Liu-Storey [6] 六种, 其具体表达式如下:

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

$$\beta_k^{DY} = \frac{\|g_k\|^2}{d_{k-1}^T (g_k - g_{k-1})}, \quad \beta_k^{CD} = -\frac{\|g_k\|^2}{g_{k-1}^T d_{k-1}}, \quad \beta_k^{LS} = -\frac{g_k^T (g_k - g_{k-1})}{g_{k-1}^T d_{k-1}}.$$

其中 $\|\cdot\|$ 表示 Euclidean 范数, $y_{k-1} = g_k - g_{k-1}$ 。由于分子不同, 可将这六种经典的共轭梯度法分为两类。第一类如 FR、CD 和 DY 方法, 其共轭参数 β_k 有共同的分子 $\|g_k\|^2$, 虽然它们具有良好的全局收敛性, 但数值表现一般; 第二类如 PRP、HS 和 LS 方法, 其共轭参数 β_k 有共同的分子 $g_k^T (g_k - g_{k-1})$, 虽然它们拥有良好的数值表现, 但对全局收敛的条件要求较强。为得到数值实验和理论结果都较好的共轭梯度法, 许多学者对这些经典方法做了修正[7] [8] [9] [10]。

2007 年, Zhang 等人在[11] [12] [13]的基础上, 提出了三阶 HS 共轭梯度法[14], 即 TTHS 方法, 搜索方向 d_k 的取法如下:

$$d_k = -g_k + \beta_k^{HS} d_{k-1} + \theta_k y_{k-1}, \quad \theta_k = \frac{g_k^T d_{k-1}}{d_{k-1}^T y_{k-1}}.$$

该方法的优点在于: 生成的搜索方向 d_k 总满足 $g_k^T d_k = -\|g_k\|^2$, 即不依赖任何线搜索而具有充分下降性。为了得到 TTHS 方法在标准 Wolf 线搜索下的全局收敛性, Zhang 等人提出了以下两种算法。一种是截断 TTHS 方法(CTTHS 方法):

$$d_k = \begin{cases} -g_k, & \text{if } s_k^T y_k \geq \varepsilon_1 \|g_k\|^r s_k^T s_k, \\ -g_k + \beta_k^{HS} d_{k-1} + \theta_k y_{k-1}, & \text{if } s_k^T y_k < \varepsilon_1 \|g_k\|^r s_k^T s_k, \end{cases}$$

其中 ε_1 和 γ 是任意正常数。另一种是改进的 TTHS 方法(MTTHS 方法):

$$d_k = \begin{cases} -g_k & \text{if } k = 0, \\ -g_k + \beta_k^{MHS} d_{k-1} - \theta_k^M z_{k-1} & \text{if } k > 0, \end{cases}$$

其中

$$\beta_k^{MHS} = \frac{\mathbf{g}_k^T \mathbf{z}_{k-1}}{\mathbf{d}_{k-1}^T \mathbf{z}_{k-1}}, \quad \theta_k^M = \frac{\mathbf{g}_k^T \mathbf{d}_{k-1}}{\mathbf{d}_{k-1}^T \mathbf{z}_{k-1}}, \quad \mathbf{z}_{k-1} = \mathbf{y}_{k-1} + t \|\mathbf{g}_k\|^\gamma \mathbf{s}_{k-1}.$$

t 和 γ 为任意正常数, $\mathbf{y}_{k-1} = \mathbf{g}_k - \mathbf{g}_{k-1}$, $\mathbf{s}_{k-1} = \mathbf{x}_k - \mathbf{x}_{k-1}$ 。

为保证 MTHS 方法在修改的 Armijo 线搜索下的全局收敛性, 考虑做如下修改:

$$\mathbf{d}_k = \begin{cases} -\mathbf{g}_k & \text{if } k = 0, \\ -\mathbf{g}_k + \beta_k^{MHS} \mathbf{d}_{k-1} - \theta_k^M \mathbf{z}_{k-1} & \text{if } k > 0, \end{cases}$$

其中

$$\beta_k^{MHS} = \frac{\mathbf{g}_k^T \mathbf{z}_{k-1}}{\mathbf{d}_{k-1}^T \mathbf{z}_{k-1}}, \quad \theta_k^M = \frac{\mathbf{g}_k^T \mathbf{d}_{k-1}}{\mathbf{d}_{k-1}^T \mathbf{z}_{k-1}}, \quad \mathbf{z}_k = \mathbf{y}_k + t_k \mathbf{s}_k,$$

其中

$$\mathbf{y}_k = \mathbf{g}_{k+1} - \mathbf{g}_k, \quad \mathbf{s}_k = \mathbf{x}_{k+1} - \mathbf{x}_k, \quad r \geq 0, \quad t_k = 1 + \max \left\{ \frac{-\mathbf{y}_k^T \mathbf{s}_k}{\|\mathbf{s}_k\|^2}, 0 \right\}.$$

1990 年, Touati-Ahmed 和 Storey 首次引入了杂交共轭梯度法[15], 其共轭参数 β_k 的取法为:

$\beta_k^{TS} = \max \{0, \min \{\beta_k^{FR}, \beta_k^{PRP}\}\}$, 杂交共轭梯度法的提出, 使得共轭梯度法的理论性质和数值试验都表现更佳。随后, 许多学者对杂交共轭梯度法做了进一步研究, 见文献[16][17]。

在杂交共轭梯度法的启发下, 本文考虑杂交三项 HS-PRP 共轭梯度法:

$$\mathbf{d}_k = \begin{cases} -\mathbf{g}_k & \text{if } k = 0, \\ -\mathbf{g}_k + \beta_k \mathbf{s}_{k-1} - \theta_k \mathbf{z}_{k-1} & \text{if } k > 0, \end{cases}$$

其中

$$\beta_k = \frac{\mathbf{g}_k^T \mathbf{z}_{k-1}}{\max \{ \mathbf{s}_{k-1}^T \mathbf{z}_{k-1}, \mu \|\mathbf{g}_{k-1}\|^2 \}}, \quad \theta_k = \frac{\mathbf{g}_k^T \mathbf{s}_{k-1}}{\max \{ \mathbf{s}_{k-1}^T \mathbf{z}_{k-1}, \mu \|\mathbf{g}_{k-1}\|^2 \}}, \quad \mathbf{z}_k = \mathbf{y}_k + t_k \mathbf{s}_k.$$

其中

$$\mathbf{y}_k = \mathbf{g}_{k+1} - \mathbf{g}_k, \quad \mathbf{s}_k = \mathbf{x}_{k+1} - \mathbf{x}_k, \quad t_k = 1 + \max \left\{ \frac{-\mathbf{y}_k^T \mathbf{s}_k}{\|\mathbf{s}_k\|^2}, 0 \right\} > 0, \quad \mu \text{ 为任意正常数.}$$

我们注意到, 上述共轭梯度法旨在求解无约束优化问题, 该方法并不适合直接用于求解约束优化问题。2021 年, Zhou 提出了一种求解凸约束优化问题的投影 PRP 方法[18], 利用投影的性质证明了该算法在修改的 Armijo 线搜索下具有全局收敛性。本文的目的是推广杂交三阶 HS-PRP 共轭梯度法求解凸约束优化问题, 并证明该算法在修改的 Armijo 线搜索下的全局收敛性。

本文其余部分组织如下: 第二部分详细介绍了求解凸约束优化问题的杂交三阶投影 HS-PRP 共轭梯度法; 第三部分证明该算法的全局收敛性; 第四部分给出数值实验结果。

2. 杂交三阶投影 HS-PRP 共轭梯度法

本文的目的是推广求解无约束优化问题的杂交三阶 HS-PRP 共轭梯度法用于求解以下凸约束优化问题:

$$\min_{x \in \Omega} f(x). \quad (1)$$

其中 $\Omega \subseteq R^n$ 是闭凸集, $f(x)$ 为 $R^n \rightarrow R$ 的光滑函数。显然, 若 x^* 是问题(1)的局部极小点, 那么 x^* 一定是满足定义 2.1 的稳定点。

定义 2.1. $x^* \in \Omega$ 是问题(1)的稳定点当且仅当: $g(x^*)^T(x-x^*) \geq 0, \forall x \in \Omega$ 。

定义 2.2. 从 R^n 到闭凸集 Ω 的投影算子为:

$$P_{\Omega} = \arg \min_{y \in \Omega} \|y - x\|. \quad (2)$$

令

$$r_k = P_{\Omega}(x_k - g_k) - x_k. \quad (3)$$

显然, x_k 是问题(1)的稳定点当且仅当 $r_k = 0$ 。

算法 1. (杂交三阶投影 HS-PRP 方法)

步 0. 取初始点 $x_0 \in \Omega$, $\delta > 0$, $\mu > 0$, $\rho \in (0, 1)$, $0 < \lambda_{\min} < \lambda_{\max} < \infty$ 。选取一个正序列 $\{\eta_k\}$ 满足:

$$\sum_{k=0}^{\infty} \eta_k \leq \eta < \infty. \quad \text{令}$$

$$d_0 = -g_0, \quad k := 0. \quad (4)$$

步 1. 若 $r_k = 0$, 则停止计算; 否则, 转步 2。

步 2. 按如下公式计算 d_k

$$d_k = \begin{cases} -g_k & \text{if } k = 0, \\ -g_k + \beta_k s_{k-1} - \theta_k z_{k-1} & \text{if } k > 0, \end{cases} \quad (5)$$

其中

$$\beta_k = \frac{g_k^T z_{k-1}}{\max\{s_{k-1}^T z_{k-1}, \mu \|g_{k-1}\|^2\}}, \quad \theta_k = \frac{g_k^T s_{k-1}}{\max\{s_{k-1}^T z_{k-1}, \mu \|g_{k-1}\|^2\}}, \quad z_k = y_k + t_k s_k. \quad (6)$$

其中

$$y_k = g_{k+1} - g_k, \quad s_k = x_{k+1} - x_k, \quad t_k = 1 + \max\left\{\frac{-y_k^T s_k}{\|s_k\|^2}, 0\right\} > 0. \quad (7)$$

步 3. 计算 $\alpha_k = \max\{\sigma_k \rho^j, j = 0, 1, 2, \dots\}$ 满足:

$$f(P_{\Omega}(x_k + \alpha_k d_k)) \leq f(x_k) - \delta \|\alpha_k d_k\|^2 + \eta_k, \quad (8)$$

其中 $\sigma_k \in [\lambda_{\min}, \lambda_{\max}]$ 。

步 4. 令 $x_{k+1} := P_{\Omega}(x_k + \alpha_k d_k)$, $k := k + 1$, $s_k = x_{k+1} - x_k = P_{\Omega}(x_k + \alpha_k d_k) - x_k$, 转步 1。

注 2.2.

1) 由(3)可知, 若 $g_k = 0$, 则 $r_k = 0$, 则 x_k 是问题(1)的稳定点;

2) 若 $\max\{s_{k-1}^T z_{k-1}, \mu \|g_{k-1}\|^2\} = 0$, 则 $\|g_{k-1}\| = 0$, 这也就意味着 x_{k-1} 是问题(1)的稳定点;

3) 由 d_k 的定义可知:

$$d_k^T g_k = -\|g_k\|^2; \quad (9)$$

4) 由投影算子的连续性和 $\eta_k > 0$ 可知线搜索(8)对任意充分小的 $\alpha > 0$ 都成立。线搜索(8)来自文献 [19]。

接下来我们将介绍投影算子的一些重要性质，这些性质对我们后面证明该算法的全局收敛性非常有用。引理 2.3 和引理 2.4 来自文献[20]。

引理 2.3. 若 $z \in \Omega$ ，则有：

$$(P_{\Omega}(x) - x)^{\top} (z - P_{\Omega}(x)) \geq 0, \quad \forall x \in R^n, \quad (10)$$

$$\|P_{\Omega}(x) - P_{\Omega}(y)\| \leq \|x - y\|, \quad \forall x, y \in R^n, \quad (11)$$

引理 2.4. 对任意 $x \in \Omega$ ， $\frac{\|P_{\Omega}(x - \alpha g(x)) - x\|}{\alpha}$ 在 $\alpha > 0$ 上非增。

引理 2.5. 对任意 $x_k \in \Omega$ 。有：

$$g_k^{\top} (x_k - P_{\Omega}(x_k - \alpha g_k)) \geq \frac{\|P_{\Omega}(x_k - \alpha g_k) - x_k\|^2}{\alpha}, \quad \forall \alpha > 0, \quad (12)$$

证明：由(10)和 $x_k \in \Omega$ 可知：

$$\begin{aligned} & g_k^{\top} (x_k - P_{\Omega}(x_k - \alpha g_k)) \\ &= \frac{1}{\alpha} (x_k - P_{\Omega}(x_k - \alpha g_k) + P_{\Omega}(x_k - \alpha g_k) - (x_k - \alpha g_k))^{\top} (x_k - P_{\Omega}(x_k - \alpha g_k)) \\ &= \frac{\|P_{\Omega}(x_k - \alpha g_k) - x_k\|^2}{\alpha} + \frac{1}{\alpha} (P_{\Omega}(x_k - \alpha g_k) - (x_k - \alpha g_k))^{\top} (x_k - P_{\Omega}(x_k - \alpha g_k)) \\ &\geq \frac{\|P_{\Omega}(x_k - \alpha g_k) - x_k\|^2}{\alpha} \end{aligned}$$

证毕。

3. 全局收敛性

在这一部分，我们将讨论算法 1 在以下假设条件下的全局收敛性。首先，我们定义水平集：

$$\Omega_1 = \{x \mid f(x) \leq f(x_0) + \eta\} \cap \Omega, \quad (13)$$

其中 η 满足(4)。显然 $x_k \in \Omega_1$ 对任意 $k \geq 0$ 都成立。

假设 A.

- 1) 由(13)定义的水平集 Ω_1 是有界的；
- 2) 存在 Ω_1 的某些凸邻域 N ，使得梯度函数 $g(x)$ 在 $N \cap \Omega$ 上 Lipschitz 连续，即存在常数 $L > 0$ ，使得：

$$\|g(x) - g(y)\| \leq L \|x - y\|, \quad \forall x, y \in N \cap \Omega \quad (14)$$

由假设 A 可知存在常数 $M > 0$ ，使得：

$$g(x) \leq M, \quad \forall x \in N \cap \Omega \quad (15)$$

显然，由线搜索(8)和(4)我们可以得到：

$$\lim_{k \rightarrow \infty} \alpha_k d_k = 0 \quad (16)$$

引理 3.1. 设 $\{x_k\}$ 是由算法 1 产生的序列且假设 A 成立，则对任意的 $k \geq 0$ ，有：

$$\|z_k\| \leq \|y_k\| + t_k \|s_k\| \leq (L + t_k) \|s_k\|. \quad (17)$$

$$\begin{aligned} s_k^T z_k &= s_k^T y_k + t_k \|s_k\|^2 \\ &= \begin{cases} s_k^T y_k + \|s_k\|^2 \geq \|s_k\|^2, & s_k^T y_k \geq 0 \\ s_k^T y_k + \|s_k\|^2 - s_k^T y_k = \|s_k\|^2, & s_k^T y_k < 0 \end{cases} \end{aligned} \quad (18)$$

由(18)可知: $s_k^T z_k \geq \|s_k\|^2$ 。

引理 3.2. 若假设 A 成立, 则存在常数 $C > 0$ 使得:

$$\|d_k\| \leq C, \quad \forall k \geq 0. \quad (19)$$

证明: 由(5)、(6)、(15)、(17)、(18)可知:

$$\begin{aligned} \|d_k\| &\leq \|g_k\| + \frac{2\|g_k\|\|z_{k-1}\|}{\max\{s_{k-1}^T z_{k-1}, \mu\|g_{k-1}\|^2\}} \|s_{k-1}\| \\ &\leq \|g_k\| + \frac{2\|g_k\|\|z_{k-1}\|}{s_{k-1}^T z_{k-1}} \|s_{k-1}\| \\ &\leq M + \frac{2M(L + t_{k-1})\|s_{k-1}\|}{\|s_{k-1}\|^2} \|s_{k-1}\| \\ &= M + 2M(L + t_{k-1}) \end{aligned}$$

令 $C = M + 2M(L + t_{k-1})$ 即得(19), 证毕。

定理 3.3. 设 $\{x_k\}$ 是由算法 1 产生的序列且假设 A 成立, 则有:

$$\liminf_{k \rightarrow \infty} \|r_k\| = 0. \quad (20)$$

证明: 反证法, 假设结论不成立, 则存在常数 $\tau > 0$ 使得:

$$\|r_k\| \geq \tau, \quad \forall k \geq 0. \quad (21)$$

由(21)可知存在常数 $\varepsilon > 0$, 使得:

$$\|g_k\| \geq \varepsilon, \quad \forall k \geq 0. \quad (22)$$

否则存在无限子集 $K \subseteq \{0, 1, 2, \dots\}$ 使得:

$$\lim_{k \in K, k \rightarrow \infty} \|r_k\| = \lim_{k \in K, k \rightarrow \infty} \|P_\Omega(x_k - g_k) - x_k\| \leq \lim_{k \in K, k \rightarrow \infty} \|g_k\| = 0. \quad (23)$$

最后一个不等式由(11)和 $P_\Omega(x_k) = x_k$ 可得, 因此上式与(21)矛盾, 即(22)成立。

1) 若 $\limsup_{k \rightarrow \infty} \alpha_k > 0$, 由(9)和(16)可得: $\liminf_{k \rightarrow \infty} \|g_k\| = 0$ 。这与(22)式矛盾。

2) 若 $\limsup_{k \rightarrow \infty} \alpha_k = 0$, 则存在 $\alpha'_k = \frac{\alpha_k}{\rho}$ 不满足不等式(8), 即:

$$f(P_\Omega(x_k + \alpha'_k d_k)) - f(x_k) > -\delta \|\alpha'_k d_k\|^2 + \eta_k > -\delta \|\alpha'_k d_k\|^2. \quad (24)$$

由拉格朗日中值定理和引理 2.5 可得:

$$\begin{aligned}
& \frac{f(P_\Omega(x_k + \alpha'_k d_k)) - f(x_k)}{\alpha'_k} \\
&= \frac{g(\xi_k)^\top (P_\Omega(x_k + \alpha'_k d_k) - x_k)}{\alpha'_k} \\
&= \frac{g_k^\top (P_\Omega(x_k - \alpha'_k g_k) - x_k)}{\alpha'_k} + \frac{(g(\xi_k) - g_k)^\top (P_\Omega(x_k + \alpha'_k d_k) - x_k)}{\alpha'_k} \\
&\quad + \frac{g_k^\top (P_\Omega(x_k + \alpha'_k d_k) - P_\Omega(x_k - \alpha'_k g_k))}{\alpha'_k} \\
&= \frac{g_k^\top (P_\Omega(x_k - \alpha'_k g_k) - x_k)}{\alpha'_k} + \Delta_k \\
&\leq -\frac{\|P_\Omega(x_k - \alpha'_k g_k) - x_k\|^2}{\alpha_k'^2} + \Delta_k,
\end{aligned}$$

其中 ξ_k 介于 x_k 和 $P_\Omega(x_k + \alpha'_k d_k)$ 之间。上述不等式结合(24)可得:

$$\frac{\|P_\Omega(x_k - \alpha'_k g_k) - x_k\|^2}{\alpha_k'^2} \leq |\Delta_k| + \delta \alpha'_k \|d_k\|^2. \quad (25)$$

由(11)和(15)可得:

$$\begin{aligned}
|\Delta_k| &\leq \|g(\xi_k) - g_k\| \left\| \frac{P_\Omega(x_k + \alpha'_k d_k) - x_k}{\alpha'_k} \right\| + \|g_k\| \left\| \frac{P_\Omega(x_k + \alpha'_k d_k) - P_\Omega(x_k - \alpha'_k g_k)}{\alpha'_k} \right\| \\
&\leq \|g(\xi_k) - g_k\| \|d_k\| + M \|d_k + g_k\| \\
&\leq C \|g(\xi_k) - g_k\| + M \|d_k + g_k\|,
\end{aligned}$$

由(5)、(6)、(11)、(15)、(17)、(22)以及 $\alpha_k \rightarrow 0$ 可得:

$$\begin{aligned}
\lim_{k \rightarrow \infty} \|d_k + g_k\| &\leq \lim_{k \rightarrow \infty} \frac{2 \|g_k\| \|z_{k-1}\|}{\max\{s_{k-1}^\top z_{k-1}, \mu \|g_{k-1}\|^2\}} \|s_{k-1}\| \\
&\leq \lim_{k \rightarrow \infty} \frac{2M(L+t_{k-1}) \|s_{k-1}\|}{\mu \|g_{k-1}\|^2} \|s_{k-1}\| \\
&\leq \lim_{k \rightarrow \infty} \frac{2M(L+t_{k-1}) \|\alpha_{k-1} d_{k-1}\|^2}{\mu \varepsilon^2} \\
&= 0
\end{aligned} \quad (26)$$

因此, 由 $g(x)$ 的连续性和 $\alpha'_k \rightarrow 0$ 以及(26)可知: $\Delta_k \rightarrow 0$ 。

由(3)、(19)、(25), 引理 2.4 以及 $\alpha'_k \rightarrow 0$, 我们可以得到:

$$\|r_k\|^2 = \|P_\Omega(x_k - g_k) - x_k\|^2 \leq \frac{\|P_\Omega(x_k - \alpha'_k g_k) - x_k\|^2}{\alpha_k'^2} \leq |\Delta_k| + \delta \alpha'_k \|d_k\|^2 \rightarrow 0.$$

这与(21)矛盾, 证毕。

4. 数值实验

在这一部分我们将通过数值实验来验证本文所提出算法的有效性。实验测试在 PC 机上完成, PC 机

配置：联想，Intel(R) Core(TM) i7-8700 CPU @ 3.20GHz 3.19GHz，8Gb 内存，Windows10 操作系统，所有代码用 Matlab R2016b 编写并运行。

测试对象：函数来自文献[18]，表达式如下：

$$f(x) = \frac{1}{2} \sum_{i=1}^{n-1} (x_i - x_{i-1})^2 + \frac{1}{12} \sum_{i=1}^{n-1} \gamma_i (x_i - x_{i-1})^4 + \frac{1}{2} x^T x.$$

约束集 $\Omega = \{x | -10 \leq x_i \leq 10, i = 1, 2, \dots, n\}$ ，其中 $\gamma_i \geq 0 (i = 1, 2, \dots, n-1)$ 为任意常数。

令 $\gamma = [\gamma_1, \gamma_2, \dots, \gamma_{n-1}]^T$ 。

测试参数： $\delta = 0.1$ ， $\rho = 0.1$ ， $\mu = 1$ ， $\lambda_{\max} = \lambda_{\min} = 1$ ， $\eta_k = 0.5^k$ 。

初始点： $x_0 = (-1.2, 1, -1.2, 1, \dots, -1.2, 1)^T$ 。

终止条件：迭代次数 $k \geq 500$ 或 $\|r_k\|_{\infty} \leq 10^{-5}$ ，其中 $\|r_k\|_{\infty}$ 表示迭代终止时 r_k 的无穷范数。

采用本文提出的算法与 Zhou 在文献[18]中提出的投影 PRP 算法求解上述测试问题，分别记为算法 1 和算法 2，测试结果见表 1 和表 2。

Table 1. Test function with $\gamma = (1, 2, \dots, n-1)^T$

表 1. 测试函数中 $\gamma = (1, 2, \dots, n-1)^T$

n	算法 1			算法 2		
	迭代次数	$\ r_k\ _{\infty}$	运行时间	迭代次数	$\ r_k\ _{\infty}$	运行时间
100	59	4.8442e-06	0.012253	61	5.6059e-06	0.012401
500	60	5.9954e-06	0.034103	61	5.8328e-06	0.037267
1000	61	5.7462e-06	0.060199	66	5.5730e-06	0.068930
1500	61	5.6193e-06	0.086749	65	4.9437e-06	0.093655
2000	62	5.7995e-06	0.113949	67	5.7311e-06	0.135631
2500	62	5.6215e-06	0.143358	69	3.3973e-06	0.164831
3000	68	5.4984e-06	0.211251	67	5.3184e-06	0.235544
3500	64	5.0719e-06	0.226145	72	5.8803e-06	0.278549
4000	65	5.5317e-06	0.254342	64	4.8939e-06	0.279823
5000	63	5.4201e-06	0.323782	76	5.0309e-06	0.410873
8000	66	5.5433e-06	0.590516	78	5.9169e-06	0.690034
10,000	65	5.2372e-06	0.718816	78	5.0175e-06	0.866920

Table 2. Test function with $\gamma = \frac{1}{n}(1^2, 2^2, \dots, (n-1)^2)^T$

表 2. 测试函数中 $\gamma = \frac{1}{n}(1^2, 2^2, \dots, (n-1)^2)^T$

n	算法 1			算法 2		
	迭代次数	$\ r_k\ _{\infty}$	运行时间	迭代次数	$\ r_k\ _{\infty}$	运行时间
100	59	5.4539e-06	0.011914	63	5.3978e-06	0.012365

Continued

500	61	5.9797e-06	0.034167	68	5.8648e-06	0.040849
1000	61	6.0657e-06	0.061715	71	5.0363e-06	0.076477
1500	62	6.0061e-06	0.087842	70	5.5089e-06	0.102981
2000	61	5.9748e-06	0.111671	70	5.2283e-06	0.133247
2500	70	5.9399e-06	0.169478	73	5.2351e-06	0.186600
3000	66	5.8496e-06	0.208617	77	5.7209e-06	0.236102
3500	71	6.0309e-06	0.278274	76	5.2187e-06	0.30158
4000	72	5.8991e-06	0.326091	74	5.5217e-06	0.309192
5000	63	5.9061e-06	0.339857	73	4.3854e-06	0.405272
8000	65	5.1095e-06	0.541414	83	4.9824e-06	0.75573
10,000	67	5.2209e-06	0.708486	86	5.4213e-06	0.959144

由表 1 和表 2 的数据我们可以知道, 在迭代次数和运行时间两个方面, 本文提出的算法优于[18]提出的投影 PRP 方法。

5. 结束语

本文提出了一种求解凸约束优化问题的杂交三阶投影 HS-PRP 共轭梯度法, 它是求解无约束优化问题的共轭梯度法的推广。利用投影的相关性质, 我们证明了该算法在修改的 Armijo 线搜索下的全局收敛性。数值结果表明, 本文所提出的算法较投影 PRP 算法更优。

参考文献

- [1] Fletcher, R. and Reeves, C.M. (1964) Function Minimization by Conjugate Gradients. *The Computer Journal*, **7**, 149-154. <https://doi.org/10.1093/comjnl/7.2.149>
- [2] Polyak, B.T. (1969) The Conjugate Gradient Method in Extreme problems. *USSR Computational Mathematics and Mathematical Physics*, **9**, 94-112. [https://doi.org/10.1016/0041-5553\(69\)90035-4](https://doi.org/10.1016/0041-5553(69)90035-4)
- [3] Hestenes, M.R. and Stiefel, E. (1952) Method of Conjugate Gradient for Solving Linear System. *Journal of Research of the National Bureau of Standards*, **49**, 409-436. <https://doi.org/10.6028/jres.049.044>
- [4] Dai, Y.H. and Yuan, Y. (1999) A Nonlinear Conjugate Gradient Method with a Strong Global Convergence Property. *SIAM Journal on Optimization*, **10**, 177-182. <https://doi.org/10.1137/S1052623497318992>
- [5] Fletcher, R. (1987) *Practical Methods of Optimization*, Vol. 1: Unconstrained Optimization. Wiley & Sons, New York.
- [6] Liu, Y. and Storey, C. (1991) Efficient Generalized Conjugate Gradient Algorithms, Part 1: Theory. *Journal of Optimization Theory and Applications*, **69**, 129-137. <https://doi.org/10.1007/BF00940464>
- [7] Zhou, W. and Li, D. (2014) On the Convergence Properties of the Unmodified PRP Method with a Non-Descent Line Search. *Optimization Methods Software*, **29**, 484-496. <https://doi.org/10.1080/10556788.2013.811241>
- [8] Hager, W.W. and Zhang, H. (2005) A New Conjugate Gradient Method with Guaranteed Descent and an Efficient Line Search. *SIAM Journal on Optimization*, **16**, 170-192. <https://doi.org/10.1137/030601880>
- [9] Gilbert, J.C. (1994) Convergence Properties of Conjugate Descent Method for Optimization. *SIAM Journal on Optimization*, **2**, 24-32.
- [10] 杨萌, 王祥玲. 修正 HS 共轭梯度法的全局收敛性[J]. 桂林电子科技大学学报, 2009, 29(4): 300-302.
- [11] Zhang, L., Zhou, W. and Li, D. (2006) A Descent Modified Polak-Ribière-Polyak Conjugate Gradient Method and Its Global Convergence. *IMA J Numerical Analysis*, **26**, 629-640. <https://doi.org/10.1093/imanum/drl016>
- [12] Zhang, L., Zhou, W. and Li, D. (2006) Global Convergence of a Modified Fletcher Reeves Conjugate Gradient Method with Armijo-Type Line Search. *Numerische Mathematik*, **104**, 561-572. <https://doi.org/10.1007/s00211-006-0028-z>
- [13] Li, D.H. and Fukushima, M. (2001) A Modified BFGS Method and Its Global Convergence in Nonconvex Minimization.

-
- tion. *Journal of Computational and Applied Mathematics*, **129**, 15-35. [https://doi.org/10.1016/S0377-0427\(00\)00540-9](https://doi.org/10.1016/S0377-0427(00)00540-9)
- [14] Zhang, L., Zhou, W. and Li, D. (2007) Some Descent Three-Term Conjugate Gradient Methods and Their Global Convergence. *Optimization Methods and Software*, **22**, 697-711. <https://doi.org/10.1080/10556780701223293>
- [15] Touati-Ahmed, D. and Story, C. (1990) Global Convergent Hybrid Conjugate Gradient Method. *Journal of Optimization Theory and Applications*, **64**, 379-397. <https://doi.org/10.1007/BF00939455>
- [16] Dai, Y.H. and Yuan, Y. (2001) An Efficient Hybrid Conjugate Method for Unconstrained Optimization. *Annals of Operations Research*, **103**, 33-47. <https://doi.org/10.1023/A:1012930416777>
- [17] Dai, Z.F. and Wen, F.H. (2015) Comments on Another Hybrid Conjugate Gradient Algorithm for Unconstrained Optimization by Andrei. *Numerical Algorithms*, **69**, 337-341. <https://doi.org/10.1007/s11075-014-9899-8>
- [18] Zhou, W. (2021) A Projected PRP Method for Optimization with Convex Constraint. *Pacific Journal of Optimization*, **17**, 47-55.
- [19] Zhou W. (2013) A Short Note on the Global Convergence of the Unmodified PRP Method. *Optimization Letters*, **7**, 1367-1372. <https://doi.org/10.1007/s11590-012-0511-7>
- [20] Calamai, P.H. and Moré, J.J. (1987) Projected Gradient Methods for Linearly Constrained Problems. *Mathematical Programming*, **39**, 93-116. <https://doi.org/10.1007/BF02592073>