

DOI:10.13718/j.cnki.xsxb.2022.01.001

# 一种具有充分下降性的新混合型共轭梯度法<sup>①</sup>

郑宗剑<sup>1</sup>, 韩信<sup>1,2</sup>

1. 四川文理学院 数学学院, 四川 达州 635000; 2. 西南大学 电子信息工程学院, 重庆 400715

**摘要:** 对 PRP 法和 FR 法进行凸组合, 提出了一种求解无约束优化问题的新共轭梯度法. 该方法总是能生成一个充分下降方向, 且它的凸组合参数为 Babaie-Kafaki 和 Ghanbari 的推广形式. 在 Wolfe 线搜索条件下, 新算法的全局收敛性得以建立, 数值结果也说明提出的算法是有效的.

**关 键 词:** 无约束优化; 共轭梯度法; 充分下降; 全局收敛性

中图分类号: O224

文献标志码: A

文章编号: 1000-5471(2022)01-0001-07

## A New Hybrid Conjugate Gradient Method with Sufficient Descent Property

ZHENG Zongjian<sup>1</sup>, HAN Xin<sup>1,2</sup>

1. School of Mathematics, Sichuan University of Arts and Science, Dazhou Sichuan 635000, China;

2. College of Electronic and Information Engineering, Southwest University, Chongqing 400715, China

**Abstract:** In this paper, a new hybrid conjugate gradient algorithm has been developed for solving unconstrained optimization problems. The proposed method can be viewed as a convex combination of Polak-Ribi  re-Polyak method and Fletcher-Reeves method. In this method, a sufficient descent direction can always be generated, with its convex combination parameter as an extension of the parameter proposed by Babaie-Kafaki and Ghanbari. Under the Wolfe line search, the global convergence has been established. Some numerical results show that proposed method is effective.

**Key words:** unconstrained optimization; conjugate gradient method; sufficient descent; global convergence

本文考虑下面的无约束优化问题:

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

这里  $f: \mathbb{R}^n \rightarrow \mathbb{R}$  是一个光滑函数,  $\mathbb{R}^n$  表示  $n$  维欧氏空间, 函数  $f$  的梯度记为  $\mathbf{g}(\mathbf{x}) := \nabla f(\mathbf{x})$ . 在实际求

① 收稿日期: 2020-03-08

基金项目: 国家自然科学基金项目(11701470); 四川文理学院 2019 年度校级科研项目学科专业群发展研究专项重点资助项目(2019XKQ001); 四川文理学院 2017 年度科研基金自然科学研究一般项目(2017KZ010Y).

作者简介: 郑宗剑, 副教授, 主要从事最优化理论与算法、动力系统分支理论与应用研究.

通信作者: 韩信, 助教.

解大规模无约束优化问题中, 建立一些具有低存储的快速数值算法是十分重要的. 共轭梯度法是求解大型无约束优化问题(1) 的一类十分有效的方法<sup>[1]</sup>, 其通常的迭代形式如下

$$\mathbf{x}_{k+1} := \mathbf{x}_k + \alpha_k \mathbf{d}_k \quad (2)$$

这里  $\mathbf{x}_k \in \mathbb{R}^n$  是一个解的第  $k$  次逼近,  $\alpha_k > 0$  是由一种合适的线搜索所确定的步长,  $\mathbf{d}_k \in \mathbb{R}^n$  是搜索方向, 其定义如下

$$\mathbf{d}_k := \begin{cases} -\mathbf{g}_k & k = 0 \\ -\mathbf{g}_k + \beta_k \mathbf{d}_{k-1} & k > 0 \end{cases} \quad (3)$$

其中:  $\mathbf{g}_k$  表示梯度  $\mathbf{g}(\mathbf{x}_k)$ ,  $\beta_k \in \mathbb{R}$  为共轭参数. 步长  $\alpha_k$  由标准的 Wolfe 线搜索

$$\begin{cases} f(\mathbf{x}_k + \alpha_k \mathbf{d}_k) \leqslant f(\mathbf{x}_k) + \delta \alpha_k \mathbf{g}_k^\top \mathbf{d}_k \\ (\mathbf{g}(\mathbf{x}_k + \alpha_k \mathbf{d}_k))^\top \mathbf{d}_k \geqslant \sigma \mathbf{g}_k^\top \mathbf{d}_k \end{cases} \quad (4)$$

或者强 Wolfe 线搜索

$$\begin{cases} f(\mathbf{x}_k + \alpha_k \mathbf{d}_k) \leqslant f(\mathbf{x}_k) + \delta \alpha_k \mathbf{g}_k^\top \mathbf{d}_k \\ |\mathbf{g}(\mathbf{x}_k + \alpha_k \mathbf{d}_k)^\top \mathbf{d}_k| \leqslant \sigma |\mathbf{g}_k^\top \mathbf{d}_k| \end{cases}$$

确定, 其中  $0 < \delta < \sigma < 1$ . 不同的共轭梯度法对应不同的共轭参数  $\beta_k$ . 众所周知的共轭梯度法包括 Hestenes-Stiefel(HS)<sup>[2]</sup>, Polak-Ribière-Polyak(PRP)<sup>[3-4]</sup>, Dai-Yuan(DY)<sup>[5]</sup>, Liu-Storey(LS)<sup>[6]</sup>, Fletcher-Reeves(FR)<sup>[7]</sup> 和 Conjugate-Descent(CD)<sup>[8]</sup>, 它们所对应的共轭参数如下

$$\begin{aligned} \beta_k^{HS} &:= \frac{\mathbf{g}_k^\top \mathbf{y}_{k-1}}{\mathbf{d}_{k-1}^\top \mathbf{y}_{k-1}}, \quad \beta_k^{PRP} := -\frac{\mathbf{g}_k^\top \mathbf{y}_{k-1}}{\|\mathbf{g}_{k-1}\|^2}, \quad \beta_k^{DY} := \frac{\|\mathbf{g}_k\|^2}{\mathbf{d}_{k-1}^\top \mathbf{y}_{k-1}} \\ \beta_k^{LS} &:= -\frac{\mathbf{g}_k^\top \mathbf{y}_{k-1}}{\mathbf{d}_{k-1}^\top \mathbf{g}_{k-1}}, \quad \beta_k^{FR} := \frac{\|\mathbf{g}_k\|^2}{\|\mathbf{g}_{k-1}\|^2}, \quad \beta_k^{CD} := -\frac{\|\mathbf{g}_k\|^2}{\mathbf{d}_{k-1}^\top \mathbf{g}_{k-1}} \end{aligned}$$

其中  $\mathbf{y}_{k-1} := \mathbf{g}_k - \mathbf{g}_{k-1}$  且  $\|\cdot\|$  表示欧氏范数. 目标函数是一个严格凸二次函数并且步长由精确线搜索得到, 且在一般情形下, 它们的理论性质和数值表现不尽相同. 众所周知, DY 法、CD 法和 FR 法具有良好的收敛性质, 但它们的数值计算效果一般; 相反, PRP 法、HS 法和 LS 法具备出色的数值表现, 但它们可能不收敛. 为了获得收敛性数值效果的算法, 不少学者对共轭参数自身作了一些改进<sup>[9-10]</sup> 和一些混合<sup>[11-12]</sup>. 本文主要考虑共轭梯度法的混合形式. 文献[13]通过对 PRP 法和 DY 法进行凸组合, 得到一种新的共轭梯度法, 其共轭参数如下

$$\beta_k^N := (1 - \theta_k) \beta_k^{PRP} + \theta_k \beta_k^{DY}$$

其中参数  $\theta_k \in [0, 1]$  由共轭条件  $\mathbf{y}_{k-1}^\top \mathbf{d}_k = 0$  确定. 最近, 文献[14]对 PRP 法和 FR 法进行凸组合, 引进了一种混合共轭梯度法:

$$\beta_k^{HCG} := (1 - \theta_k) \beta_k^{PRP} + \theta_k \beta_k^{FR}$$

这里参数  $\theta_k \in [0, 1]$  根据求解优化问题  $\min_{\theta_k} \{\|\mathbf{d}_k^{HCG} - \mathbf{d}_k^{ZZL}\|^2 : k \geqslant 1\}$  得到. 在标准的 Wolfe 线搜索条件下, 该算法具有全局收敛性和良好的计算表现.

受文献[14]的启发, 本文构造了一种新的混合共轭梯度法

$$\beta_k^{NH+} := (1 - \theta_k) \beta_k^{PRP} + \theta_k \beta_k^{FR} \quad (5)$$

这里

$$\theta_k = \begin{cases} \theta_k^* & \text{若 } \mathbf{g}_k^\top \mathbf{g}_{k-1} \cdot \mathbf{g}_k^\top \mathbf{p}_k \neq 0 \text{ 且 } \theta_k^* \in [0, 1] \\ 0 & \text{若 } \mathbf{g}_k^\top \mathbf{g}_{k-1} \cdot \mathbf{g}_k^\top \mathbf{p}_k = 0 \text{ 或 } \theta_k^* < 0 \\ 1 & \text{若 } \theta_k^* > 1 \end{cases}$$

其中

$$\theta_k^* = -\frac{\mathbf{g}_k^\top \mathbf{d}_{k-1}}{\mathbf{g}_k^\top \mathbf{g}_{k-1}} \frac{\rho_k^\top \mathbf{d}_{k-1}}{\|\mathbf{d}_{k-1}\|^2} \frac{\mathbf{g}_k^\top \mathbf{y}_{k-1}}{\mathbf{g}_k^\top \mathbf{p}_k}$$

为优化问题  $\min_{\theta_k} \{ \| \mathbf{d}_k^{\text{NH+}} - \mathbf{d}_k^{\text{NYF}} \|^2 : k \geq 1 \}$  的最优解. 基于共轭参数  $\beta_k^{\text{NH+}}$  所得相应的共轭梯度法称作 NH + 算法或 NH + 法. 因为文献[15]提出的 ZZL 法是文献[16]提出的 NYF 法特殊情况. 因此, 文献[14]提出的方法是 NH + 法的特殊情况(当  $\mathbf{p}_k = \mathbf{g}_k$  即为文献[14]中的方法).

## 1 NH + 型共轭梯度算法

基于共轭参数  $\beta_k^{\text{NH+}}$  的计算公式(5), 所得的 NH + 算法如下:

NH + 算法

步骤 1: 给定初始点  $\mathbf{x}_1$  和精度  $\epsilon$ . 置  $k = 1$ , 令  $\mathbf{d}_1 = -\mathbf{g}_1$ .

步骤 2: 若  $\| \mathbf{g}_k \| \leq \epsilon$ , 终止. 否则, 转步骤 3.

步骤 3: 通过(3)式计算搜索方向  $\mathbf{d}_k$ .

步骤 4: 由标准的 Wolfe 线搜索(4)确定步长因子  $\alpha_k$ .

步骤 5: 由(2)式计算下一个迭代点  $\mathbf{x}_{k+1}$ .

步骤 6: 令  $k := k + 1$ , 转步骤 2.

## 2 算法 NH + 的全局收敛性分析

为了论证算法 NH + 的收敛性, 给出了如下的基本假设.

**假设 1** 水平集  $S = \{ \mathbf{x} : f(\mathbf{x}) \leq f(\mathbf{x}_0) \}$  有界, 即存在  $\bar{a} > 0$ , 对于任意  $\mathbf{x} \in S$ , 有  $\| \mathbf{x} \| \leq \bar{a}$ .

目标函数的梯度函数在  $S$  的某邻域  $U$  内 Lipschitz 连续, 即存在常数  $L > 0$ , 对任意  $\mathbf{x}, \mathbf{y} \in U$ , 有  $\| \mathbf{g}(\mathbf{x}) - \mathbf{g}(\mathbf{y}) \| \leq L \| \mathbf{x} - \mathbf{y} \|$ .

由假设可知存在常数  $\bar{\gamma} > 0$ , 对任意  $\mathbf{x} \in S$ , 有

$$\| \mathbf{g}(\mathbf{x}) \| \leq \bar{\gamma} \quad (6)$$

以 Zoutendijk 条件为基础给出如下引理 1. 这个引理在论证共轭梯度算法的全局收敛性过程中具有重要的作用.

**引理 1** 假设 1 成立, 算法 NH + 的搜索方向是下降的, 步长满足标准 Wolfe 线搜索条件, 则 Zoutendijk 条件即  $\sum_{k=0}^{\infty} \frac{(\mathbf{g}_k^T \mathbf{d}_k)^2}{\| \mathbf{d}_k \|^2} < \infty$  成立.

**证** 由标准 Wolfe 线搜索条件(4), 知

$$(\mathbf{g}_k - \mathbf{g}_{k-1})^T \mathbf{d}_{k-1} \geq (\sigma - 1) \mathbf{g}_{k-1}^T \mathbf{d}_{k-1}$$

另一方面, 由假设 1 和(2)式, 有

$$(\mathbf{g}_k - \mathbf{g}_{k-1})^T \mathbf{d}_{k-1} \leq \alpha_{k-1} L \| \mathbf{d}_{k-1} \|^2$$

再结合算法 NH + 的下降性, 得

$$\alpha_{k-1} \geq \frac{\sigma - 1}{L} \cdot \frac{\mathbf{g}_{k-1}^T \mathbf{d}_{k-1}}{\| \mathbf{d}_{k-1} \|^2} > 0$$

进一步由(4)式知

$$f(\mathbf{x}_{k-1}) - f(\mathbf{x}_k) \geq \frac{\delta(1-\sigma)}{L} \cdot \frac{(\mathbf{g}_{k-1}^T \mathbf{d}_{k-1})^2}{\| \mathbf{d}_{k-1} \|^2} > 0 \quad (7)$$

对(7)式从  $k = 1, 2, \dots, \infty$  求和, 并注意目标函数  $f(\mathbf{x})$  有下界, 即知 Zoutendijk 条件成立. 因此, 结论得证.

下面的引理是论证算法 NH + 全局收敛性的关键. 这个引理的具体论证过程可参见文献[17].

**引理 2<sup>[17]</sup>** 假设 1、充分下降性、标准 Wolfe 线搜索条件均成立. 若  $\sum_{k=0}^{\infty} \frac{1}{\| \mathbf{d}_k \|^2} = \infty$ , 则

$$\liminf_{k \rightarrow \infty} \| \mathbf{g}_k \| = 0.$$

**注** 通常利用的是引理 2 的逆否命题, 即若  $\liminf_{k \rightarrow \infty} \| \mathbf{g}_k \| \neq 0$ , 则  $\sum_{k=0}^{\infty} \frac{1}{\| \mathbf{d}_k \|^2} < \infty$ . 对于共轭梯度算法, 文献[18] 给出了性质(\*), 当  $s_k := \mathbf{x}_{k+1} - \mathbf{x}_k$  变小时,  $\beta_k$  也将变小.

**性质(\*)<sup>[18]</sup>** 对于共轭梯度算法, 若任意  $k \geq 0$ , 都有  $0 < \gamma \leq \| \mathbf{g}_k \|$ . 而且, 若常数  $b > 1, \lambda > 0$ , 使得  $|\beta_k| \leq b$  和  $\| s_k \| \leq \lambda \Rightarrow |\beta_k| \leq \frac{1}{2b}$  都成立, 就称算法具有性质(\*)。

接下来, 假设全局收敛性不在有限步发生.

**引理 3** 若假设 1、充分下降性、标准 Wolfe 线搜索条件均成立. 如果性质(\*)成立, 则  $\mathbf{d}_k \neq 0$  且

$$\sum_{k=1}^{\infty} \| \mathbf{u}_k - \mathbf{u}_{k-1} \|^2 < \infty, \text{ 其中 } \mathbf{u}_k := \frac{\mathbf{d}_k}{\| \mathbf{d}_k \|}.$$

**证** 由  $\mathbf{d}_k \neq 0, \mathbf{g}_k \neq 0$  及充分下降性知,  $\mathbf{u}_k$  的定义有意义.

现定义  $\boldsymbol{\rho}_k := \frac{-\mathbf{g}_k}{\| \mathbf{d}_k \|}$  和以下式子

$$\omega_k := \frac{\beta_k^{\text{NH+}} \| \mathbf{d}_{k-1} \|}{\| \mathbf{d}_k \|} \quad (8)$$

由(3)式和(5)式, 对任意  $k \geq 1$ , 有

$$\mathbf{u}_k = \boldsymbol{\rho}_k + \omega_k \mathbf{u}_{k-1} \quad (9)$$

基于  $\| \mathbf{u}_k \| = \| \mathbf{u}_{k-1} \| = 1$  和(9)式, 得

$$\| \boldsymbol{\rho}_k \| = \| \mathbf{u}_k - \omega_k \mathbf{u}_{k-1} \| = \| \omega_k \mathbf{u}_k - \mathbf{u}_{k-1} \| \quad (10)$$

由于  $\beta_k^{\text{NH+}} \geq 0$ , 则(8)式中的  $\omega_k \geq 0$ . 此外, 利用三角不等性和(10)式, 可得

$$\begin{aligned} \| \mathbf{u}_k - \mathbf{u}_{k-1} \| &\leq (1 + \omega_k) \| \mathbf{u}_k - \mathbf{u}_{k-1} \| = \\ &\leq \| \mathbf{u}_k - \omega_k \mathbf{u}_{k-1} + \omega_k \mathbf{u}_k - \mathbf{u}_{k-1} \| \leq \\ &\leq \| \mathbf{u}_k - \omega_k \mathbf{u}_{k-1} \| + \| \omega_k \mathbf{u}_k - \mathbf{u}_{k-1} \| = \\ &= 2 \| \boldsymbol{\rho}_k \| \end{aligned} \quad (11)$$

由 Zoutendijk 条件、充分下降条件和(8)式知

$$\sum_{k=1}^{\infty} \frac{\| \mathbf{g}_k \|^4}{\| \mathbf{d}_k \|^2} = \sum_{k=1}^{\infty} \| \mathbf{g}_k \|^2 \| \boldsymbol{\rho}_k \|^2 < \infty \quad (12)$$

利用性质(\*)、(11)式和(12)式, 有  $\sum_{k=1}^{\infty} \| \mathbf{u}_k - \mathbf{u}_{k-1} \|^2 \leq 4 \sum_{k=1}^{\infty} \| \boldsymbol{\rho}_k \|^2 < \infty$ , 结论得证.

现令  $\mathbb{N}_+$  为非零自然数集. 给定正常数  $\lambda$  和正整数  $\Delta$ , 定义

$$K_{k,\Delta}^{\lambda} := \{i \in \mathbb{N}_+: k \leq i \leq k + \Delta - 1, \| \mathbf{s}_{i-1} \| > \lambda\}$$

其中  $|K_{k,\Delta}^{\lambda}|$  表示  $K_{k,\Delta}^{\lambda}$  的元素个数.

**引理 4** 若引理 3 的所有假设条件都成立. 算法 NH+ 满足性质(\*), 则存在常数  $\lambda$  和  $k_0$ , 对任意  $\Delta \in \mathbb{N}_+$  和  $\bar{k} \geq k_0$ , 使得

$$|K_{k,\Delta}^{\lambda}| > \frac{\Delta}{2}$$

**证** 利用反证法论证. 假设存在  $\Delta \in \mathbb{N}_+$  和常数  $k_0$ , 对任意正常数  $\lambda$  和任意  $k \geq k_0$ , 有

$$|K_{k,\Delta}^{\lambda}| \leq \frac{\Delta}{2} \quad (13)$$

$b > 1$  和  $\eta > 0$  是性质(\*)中的常数. 令  $\lambda = \eta$ , 由性质(\*)和(13)式, 有

$$\prod_{k=k_0+i\Delta+1}^{k_0+(i+1)\Delta} |\beta_k| = \prod_{k \in K_{k_0+i\Delta+1,\Delta}^{\lambda}} |\beta_k| \prod_{k \notin K_{k_0+i\Delta+1,\Delta}^{\lambda}} |\beta_k| \leq b^{\frac{\Delta}{2}} \left(\frac{1}{2b}\right)^{\frac{\Delta}{2}}, \forall i \geq 0 \quad (14)$$

因此

$$\begin{aligned} \prod_{j=k_0+1}^{k_0+i\Delta} 2\beta_j^2 &= \prod_{j=k_0+1}^{k_0+\Delta} 2\beta_j^2 \cdots \prod_{j=k_0+(i-1)\Delta+1}^{k_0+i\Delta} 2\beta_j^2 \leqslant \\ 2^{i\Delta} \left[ \left( \frac{1}{2b} \right)^2 \right]^{i\Delta} &= \left( \frac{1}{2b^2} \right)^{i\Delta} \leqslant 1 \end{aligned} \quad (15)$$

对任意  $i \geqslant 1$ ,  $k_0 \leqslant l \leqslant k_0 + i\Delta$ , 存在  $i'$ , 使得

$$\begin{aligned} k_0 + i'\Delta &\leqslant l \leqslant k_0 + (i'+1)\Delta \leqslant k_0 + i\Delta \\ \prod_{j=l}^{k_0+i\Delta} 2\beta_j^2 &= \prod_{j=l}^{k_0+(i'+1)\Delta} 2\beta_j^2 \prod_{j=k_0+(i'+1)\Delta+1}^{k_0+(i'+2)\Delta} 2\beta_j^2 \cdots \prod_{j=k_0+(i-1)\Delta+1}^{k_0+i\Delta} 2\beta_j^2 \end{aligned}$$

再由  $b > 1$  和(14) 式得

$$\prod_{j=l}^{k_0+i\Delta} 2\beta_j^2 \leqslant c_1 \quad (16)$$

其中  $c_1 = (2b^2)^{\Delta+1}$ .

通过性质(\*)、(6) 式、(15) 式和(16) 式, 有

$$\begin{aligned} \|\mathbf{d}_{k_0+i\Delta}\|^2 &\leqslant (\|\mathbf{g}_{k_0+i\Delta}\| + |\beta_{k_0+i\Delta}| \|\mathbf{d}_{k_0+i\Delta-1}\|)^2 \leqslant \\ 2(\|\mathbf{g}_{k_0+i\Delta}\|^2 + |\beta_{k_0+i\Delta}|^2 \|\mathbf{d}_{k_0+i\Delta-1}\|^2) &\leqslant \\ 2\bar{\gamma}^2 + 2b^2 \sum_{l=k_0+2}^{k_0+i\Delta} (\prod_{j=l}^{k_0+i\Delta} 2\beta_j^2) + \|\mathbf{d}_{k_0}\| \prod_{j=k_0+1}^{k_0+i\Delta} 2\beta_j^2 &\leqslant \\ 2\bar{\gamma}^2 + 2b^2 \sum_{l=k_0+2}^{k_0+i\Delta} (\prod_{j=l}^{k_0+i\Delta} 2\beta_j^2) + \|\mathbf{d}_{k_0}\| &\leqslant \\ 2\bar{\gamma}^2 + 2b^2 c_1 (i\Delta - 1) + c_2 & \end{aligned}$$

其中  $c_2 = \|\mathbf{d}_{k_0}\|$ . 所以,  $\sum_{k=0}^{\infty} \frac{1}{\|\mathbf{d}_k\|^2} \geqslant \sum_{i=1}^{\infty} \frac{1}{\|\mathbf{d}_{k_0+i\Delta}\|^2} \geqslant \sum_{i=1}^{\infty} \frac{1}{2\bar{\gamma}^2 + 2b^2 c_1 (i\Delta - 1) + c_2} = \infty$ .

由引理 2 知  $\liminf_{k \rightarrow \infty} \|\mathbf{g}_k\| = 0$ , 这与假设矛盾. 因此, 原结论成立.

结合引理 3 和 4, 利用文献[14] 的论证方法易得下面的定理 1. 限于篇幅, 这里略去证明过程.

**定理 1** 若假设 1 和标准 Wolfe 线搜索都成立. 如果算法 NH+ 满足下面 3 个性质:

- (p1) 对任意  $k \geqslant 1$ , 有  $\beta_k^{\text{NH+}} \geqslant 0$ ;
- (p2) 充分下降性和 Zoutendijk 条件均满足;
- (p3) 性质(\*) 成立, 而且存在正常数  $M$ , 使得  $\theta_k \leqslant M \|s_{k-1}\|$ .

则算法 NH+ 全局收敛.

### 3 数值实验

为了比较算法 NH+ 与算法 NYF<sup>[16]</sup>、算法 HCG+<sup>[14]</sup>、算法 PRP+<sup>[18]</sup>, 对文献[19] 中的 63 个测试函数进行实验. 4 种算法均利用 Matlab 程序实现, 且在 Windows 7 操作系统、AMD Athlon(tm) II Dual-Core M320 CPU 和 2 GB 内存环境测试运行. 常数  $\sigma = 0.95$ ,  $\delta = 0.0001$ . 令  $\mathbf{p}_k = \mathbf{g}_k$ . 终止准则为  $\|\mathbf{g}_k\| \leqslant 10^{-6}$  或迭代时间超过 3 600 s. 部分数值结果见表 1. 所有数值实验具体结果请参见链接 [https://weibo.com/2145331053/IsvzxrnEi?from=page\\_1005052145331053\\_profile&wvr=6&mod=weibotime&type=comment](https://weibo.com/2145331053/IsvzxrnEi?from=page_1005052145331053_profile&wvr=6&mod=weibotime&type=comment).

此外, 利用文献[20]提出的性能理论刻画算法的计算效率和稳定性. 为此, 以迭代时间、迭代次数为度量, 纵轴为性能指标  $P_s(t)$ , 描绘出下面的性能图(图 1, 图 2). 实验结果表明: NYF 和 PRP+ 在 1.8 s 前收敛速度都比 NH+ 稍慢, 之后都与 NH+ 接近, 并都达到稳定; HCG+ 比其他 3 种算法的收敛速度都慢; NH+ 一直快于其他 3 种算法, 最终与 PRP+ 同时稳定. 原因可能是 NH+ 法充分利用了 PRP 和 NYF 的加速特性以及 FR 的良好收敛性. 因此, NH+ 是一个有效的算法.

表1 部分数值实验结果

函数名	维度/维	算法	迭代次数/次	迭代时间/s	梯度值
LIARWHD	20	NH+	138	2 137.390	9.37E-07
	20	PRP+	94	1 303.897	9.93E-07
	20	NYF	345	11 117.170	9.02E-06
	20	HCG+	340	3 605.104	1.10E-05
DIAGONAL	50	NH+	179	1 957.943	8.47E-07
	50	PRP+	132	1 292.290	7.51E-07
	50	NYF	708	2 381.197	8.95E-07
	50	HCG+	740	3 615.365	1.04E-05
QUADRATICQF1	100	NH+	181	2 089.250	0.00E+00
	100	PRP+	136	1 315.878	0.00E+00
	100	NYF	231	4 130.011	1.15E-02
	100	HCG+	282	3 613.380	9.89E-03
QUARTC	400	NH+	17	1 859.335	9.91E-07
	400	PRP+	48	3 633.389	4.55E-03
	400	NYF	50	3 643.121	3.70E-03
	400	HCG+	17	1 956.870	9.91E-07

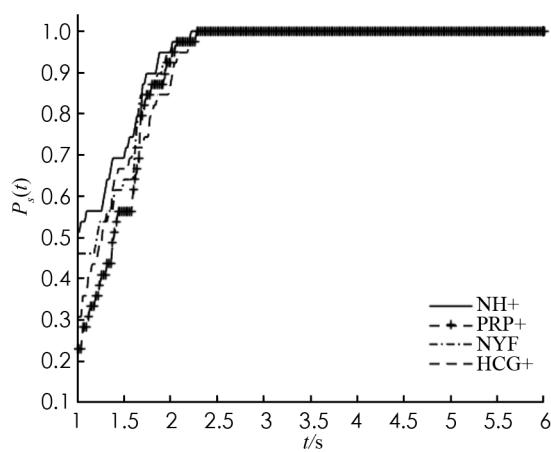


图1 迭代时间算法性能图

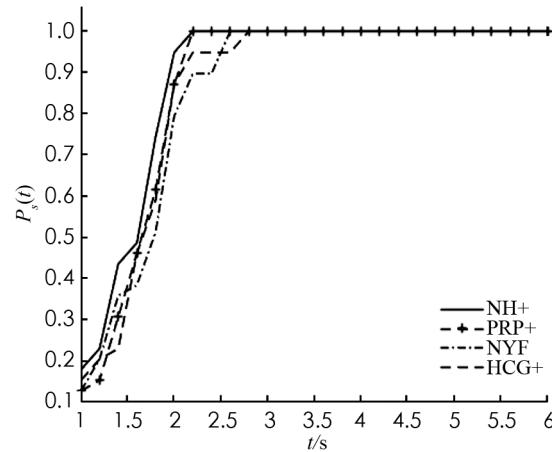


图2 迭代次数算法性能图

## 参考文献:

- [1] 唐天国. 一种求解无约束优化问题的新混合共轭梯度法 [J]. 西南师范大学学报(自然科学版), 2019, 44(9): 34-39.
- [2] HESTENES M R, STIEFEL E. Methods of Conjugate Gradients for Solving Linear Systems [J]. Journal of Research of the National Bureau of Standards, 1952, 49(6): 409-436.
- [3] POLAK E, RIBIERE G. Note Sur La Convergence de Méthodes de Directions Conjuguées [J]. Revue Française d'Informatique et De Recherche Opérationnelle Série Rouge, 1969, 3(16): 35-43.
- [4] POLYAK B T. The Conjugate Gradient Method in Extremal Problems [J]. USSR Computational Mathematics and Mathematical Physics, 1969, 9(4): 94-112.
- [5] DAI Y H, YUAN Y. A Nonlinear Conjugate Gradient Method with a Strong Global Convergence Property [J]. SIAM Journal on Optimization, 1999, 10(1): 177-182.
- [6] LIU Y, STOREY C. Efficient Generalized Conjugate Gradient Algorithms, Part 1: Theory [J]. Journal of Optimization Theory and Applications, 1991, 69(1): 129-137.
- [7] FLETCHER R, REEVES C M. Function Minimization by Conjugate Gradients [J]. The Computer Journal, 1964, 7(2):

- 149-154.
- [8] FLETCHER R. Practical Method of Optimization, Unconstrained Optimization [M]. New York: John Wiley and Sons, 1987.
- [9] SHENGWEI Y, WEI Z X, HUANG H. A Note about WYL's Conjugate Gradient Method and Its Applications [J]. Applied Mathematics and Computation, 2007, 191(2): 381-388.
- [10] DAI Z F, WEN F H. Another Improved Wei-Yao-Liu Nonlinear Conjugate Gradient Method with Sufficient Descent Property [J]. Applied Mathematics and Computation, 2012, 218(14): 7421-7430.
- [11] 韩信, 张俊容, 王森森. 一种新的混合共轭梯度算法 [J]. 西南大学学报(自然科学版), 2017, 39(5): 132-138.
- [12] LIU J K, DU X L. Global Convergence of an Efficient Hybrid Conjugate Gradient Method for Unconstrained Optimization [J]. Bulletin of the Korean Mathematical Society, 2013, 50(1): 73-81.
- [13] ANDREI N. Hybrid Conjugate Gradient Algorithm for Unconstrained Optimization [J]. Journal of Optimization Theory and Applications, 2009, 141(2): 249-264.
- [14] BABAIE-KAFAKI S, GHANBARI R. A Hybridization of the Polak-Ribi  re-Polyak and Fletcher-Reeves Conjugate Gradient Methods [J]. Numerical Algorithms, 2015, 68(3): 481-495.
- [15] ZHANG L, ZHOU W J, LI D H. A Descent Modified Polak-Ribi  re-Polyak Conjugate Gradient Method and Its Global Convergence [J]. IMA Journal of Numerical Analysis, 2006, 26(4): 629-640.
- [16] NARUSHIMA Y, YABE H, FORD J A. A Three-Term Conjugate Gradient Method with Sufficient Descent Property for Unconstrained Optimization [J]. SIAM Journal on Optimization, 2011, 21(1): 212-230.
- [17] ZOUTENDIJK G. Nonlinear Programming, Computational Methods [J]. Integer and Nonlinear Programming, 1970, 143: 37-86.
- [18] GILBERT J C, NOCEDAL J. Global Convergence Properties of Conjugate Gradient Methods for Optimization [J]. SIAM Journal on Optimization, 1992, 2(1): 21-42.
- [19] ANDREI N. An Unconstrained Optimization Test Functions Collection [J]. Environmental Science and Technology, 2008, 10(1): 6552-6558.
- [20] DOLAN E D, MOR   J J. Benchmarking Optimization Software with Performance Profiles [J]. Mathematical Programming, 2002, 91(2): 201-213.

责任编辑 张拘