

A Modified Nonlinear Conjugate Gradient Algorithm Using Secant Conditions

Jing Liang*, Guodong Ma#, Yuting Shi, Zhimei Lin, Wenting Zou, Liuna Li

School of Mathematics and Statistics, Yulin Normal University, Yulin Guangxi
Email: #mgd2006@163.com

Received: Apr. 2nd, 2019; accepted: Apr. 17th, 2019; published: Apr. 24th, 2019

Abstract

In this paper, based on the idea of Ref. [1], we propose a modified conjugate gradient method using secant conditions for unconstrained optimization problems. The proposed algorithm improves the method in Ref. [1], which possesses the following properties: the search direction has the sufficient descent property; the global convergence of the given algorithm will be established under suitable assumptions; numerical results are reported to test its efficiency.

Keywords

Conjugate Gradient Method, Sufficient Descent Property, Global Convergence

基于拟牛顿方程一个改进的非线性共轭梯度算法

梁 静*, 马国栋#, 时瑜婷, 林志梅, 邹文婷, 李柳娜

玉林师范学院, 数学与统计学院, 广西 玉林
Email: #mgd2006@163.com

收稿日期: 2019年4月2日; 录用日期: 2019年4月17日; 发布日期: 2019年4月24日

摘 要

基于拟牛顿方程, 借鉴文[1]的思想, 本文给出一个改进的具有全局收敛非线性共轭梯度算法。该文的算法对文[1]中算法进行了改进, 所产生的搜索方向具有充分下降性。在温和的假设下, 新算法具有全局收

*第一作者。

#通讯作者。

文章引用: 梁静, 马国栋, 时瑜婷, 林志梅, 邹文婷, 李柳娜. 基于拟牛顿方程一个改进的非线性共轭梯度算法[J]. 应用数学进展, 2019, 8(4): 676-683. DOI: 10.12677/aam.2019.84076

敛性。最后，数值结果检验其有效性。

关键词

共轭梯度法，充分下降性，全局收敛性

Copyright © 2019 by authors and Hans Publishers Inc.

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

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



Open Access

1. 引言

本文考虑求解如下无约束优化问题

$$\min_{x \in R^n} f(x), \quad (1.1)$$

其中 $f(x): R^n \rightarrow R$ 连续可微，此问题在经济管理、生产运作、工程设计等领域具有广泛的应用背景。共轭梯度法是求解问题(1.1)的有效方法之一，该方法具有算法结构简单、计算存储量少、数值效果明显的优点，其迭代公式的一般形式为：

$$x_{k+1} = x_k + \alpha_k d_k, k = 0, 1, 2, \dots$$

其中 x_k 为第 k 次迭代点， $\alpha_k > 0$ 为搜索步长， d_k 为搜索方向且其更新方式为

$$d_k = \begin{cases} -g_k + \beta_k d_{k-1}, & k \geq 1, \\ -g_k, & k = 0, \end{cases} \quad (1.2)$$

其中 $\beta_k \in \mathfrak{R}$ 是方向调控参数。数值优化方法是根据搜索方向的选择来定义其方法类型，从上式可以看出，搜索方向 d_k 是由参数 β_k 决定的，所以根据 β_k 的选取方式可以定义不同的共轭梯度公式，下面给出几个著名的公式：

$$\beta_k^{PRP} = \frac{g_{k+1}^T (g_{k+1} - g_k)}{\|g_k\|^2} \quad [2] [3], \quad \beta_k^{HS} = \frac{g_{k+1}^T (g_{k+1} - g_k)}{(g_{k+1} - g_k)^T d_k} \quad [4], \quad \beta_k^{FR} = \frac{g_{k+1}^T g_{k+1}}{\|g_k\|^2} \quad [5],$$

$$\beta_k^{DY} = \frac{g_{k+1}^T g_{k+1}}{(g_{k+1} - g_k)^T d_k} \quad [6], \quad \beta_k^{CD} = \frac{g_{k+1}^T g_{k+1}}{-d_k^T g_k} \quad [7], \quad \beta_k^{LS} = \frac{g_{k+1}^T (g_{k+1} - g_k)}{-g_k^T d_k} \quad [8],$$

其中 $g_k = \nabla f(x_k)$ 和 $g_{k+1} = \nabla f(x_{k+1})$ 表示函数 $f(x)$ 在 x_k 和 x_{k+1} 的梯度值， $\|\cdot\|$ 是欧氏向量范数。众多优化专家都希望能找到理论性质良好且数值表现又好的算法，已取得众多成果(见[9]-[25])，其中 Yuan [9]给出如下 PRP 修改公式：

$$\beta_k^{MPRP} = \beta_k^{PRP} - \min \left\{ \beta_k^{PRP}, \frac{\mu \|y_k\|^2}{\|g_k\|^4} g_{k+1}^T d_k \right\},$$

其中 $\mu > \frac{1}{4}$ 是常数， $y_k = g_{k+1} - g_k$ ，同时又将此公式推广到了其它 5 个公式中，得到了修改的 FR 公式、修改的 HS 公式、修改的 DY 公式、修改的 CD 公式和修改的 LS 公式，其中文[1]修改的 LS 为：

$$\beta_k^{MMLS+} = \beta_k^{MMLS} - \min \left\{ \beta_k^{MMLS}, \frac{\mu \|y_k^m\|^2}{(-d_k^T g_k)^2} g_{k+1}^T d_k \right\}, \quad (1.3)$$

其中 $y_k^m = g_{k+1} - \frac{\|g_{k+1}\|}{\|g_k\|} g_k$, $\beta_k^{MMLS} = \frac{g_{k+1}^T y_k^m}{-d_k^T g_k}$.

本文将在此公式的基础上进一步研究, 从上式可以看出公式中不含函数值信息, 这势必影响此方法的有效性。众所周知, 拟牛顿方法不仅含有梯度值信息也含有函数值信息, 且具有更好的理论和实际表现[10] [11]。也有许多学者将拟牛顿法的技术思想应用到共轭梯度公式中, 从而获得更好的理论性质和实际数值效果[12] [13]。Zhang 等[11]给出了一个如下形式的拟牛顿方程

$$B_{k+1} s_k = y_k^m, \quad (1.4)$$

其中 $y_k^m = y_k + \gamma_k^1 s_k$, $s_k = x_{k+1} - x_k$ 及

$$\gamma_k^1 = \frac{3(g_{k+1} + g_k)^T s_k + 6(f(x_k) - f(x_{k+1}))}{\|s_k\|^2},$$

此公式包含有梯度值信息和函数值信息, 理论上能更高阶地近似目标函数的 Hesse 矩阵。基于公式(1.3), (1.4)和文[12] [13]的思想, 本文给出如下修改的 LS 共轭梯度公式

$$\beta_k^{MMLS*} = \beta_k^{MMLS} - \min \left\{ \beta_k^{MMLS}, \frac{\mu \|y_k^m\|^2}{(-d_k^T g_k)^2} g_{k+1}^T d_k \right\}, \quad (1.5)$$

其中 $\beta_k^{MMLS} = \frac{g_{k+1}^T y_k^m}{-d_k^T g_k}$ 。相对于原 LS 方法, 本文的创新点主要有: 1) 新公式能保证方向调控参数 $\beta_k^{MMLS*} \geq 0$; 2) 新方法具有充分下降性; 3) 新方法不仅使用了梯度值信息还有函数值信息。

2. 算法的描述

基于搜索方向, 给出一个基于拟牛顿方程改进的非线性共轭梯度算法。

算法 1:

步骤 0: 给定 $x_0 \in \mathfrak{R}^n, \delta \in (0, 1/2), \sigma \in (\delta, 1), \varepsilon > 0$, 令 $d_0 = -g_0 = -\nabla f(x_0)$, 置 $k := 0$ 。

步骤 1: 若 $\|g_k\| \leq \varepsilon$, 停止。否则, 进入步骤 2。

步骤 2: 利用弱 Wolfe-Powell(WWP)线搜索技术产生步长 α_k

$$f(x_k + \alpha_k d_k) \leq f_k + \delta \alpha_k g_k^T d_k, \quad (2.1)$$

$$g(x_k + \alpha_k d_k)^T d_k \geq \sigma g_k^T d_k. \quad (2.2)$$

步骤 3: 令 $x_{k+1} = x_k + \alpha_k d_k$ 。如果 $\|g_{k+1}\| \leq \varepsilon$, 停止。

步骤 4: 利用公式(1.5)计算 β_k^{MMLS*} , 并按如下公式计算搜索方向

$$d_{k+1} = -g_{k+1} + \beta_k^{MMLS*} d_k, \quad (2.3)$$

步骤 5: 置 $k := k+1$, 转步骤 2。

3. 算法的充分下降性和全局收敛性

引理 3.1: 对所有 $k \geq 0$, 搜索方向 d_k 满足下面两式

$$d_k^T g_k \leq -c \|g_k\|^2 \quad (3.1)$$

和

$$d_k^T y_k \geq c(1-\sigma) \|g_k\|^2 \quad (3.2)$$

$c > 0$ 是常数。

证明: 首先证明(3.1)成立。根据算法 1, 如果 $k = 0$, 则 $g_0^T d_0 = -\|g_0\|^2$, 式(3.1)显然成立。下面利用归纳法, 当 $k \geq 1$, 假如公式(2.3)满足(3.1), 对 $k+1$, 有

$$\begin{aligned} g_{k+1}^T d_{k+1} &= -\|g_{k+1}\|^2 + \beta_k^{MMLS^*} d_k^T g_{k+1} \\ &= -\|g_{k+1}\|^2 + \left[\frac{g_{k+1}^T y_k^m}{-d_k^T g_k} - \min \left\{ \frac{g_{k+1}^T y_k^m}{-d_k^T g_k}, \frac{\mu \|y_k^m\|^2}{(-d_k^T g_k)^2} g_{k+1}^T d_k \right\} \right] d_k^T g_{k+1} \end{aligned} \quad (3.3)$$

由 $-d_k^T g_k > 0$. 取 $u = \frac{\sqrt{-d_k^T g_k}}{\sqrt{2\mu}} g_{k+1}$, $v = \frac{\sqrt{2\mu} g_{k+1}^T d_k}{\sqrt{-d_k^T g_k}} y_k^m$. 下面我们分两种情形分别讨论(3.3)式:

情形 I: 如果 $\frac{g_{k+1}^T y_k^m}{-d_k^T g_k} < \frac{\mu \|y_k^m\|^2}{(-d_k^T g_k)^2} g_{k+1}^T d_k$, 显然 $g_{k+1}^T d_{k+1} = -\|g_{k+1}\|^2$ 成立。

情形 II: 如果 $\frac{g_{k+1}^T y_k^m}{-d_k^T g_k} \geq \frac{\mu \|y_k^m\|^2}{(-d_k^T g_k)^2} g_{k+1}^T d_k$, (3.3)式可化为

$$\begin{aligned} g_{k+1}^T d_{k+1} &= -\|g_{k+1}\|^2 + \left(\frac{g_{k+1}^T y_k^m}{-d_k^T g_k} - \frac{\mu \|y_k^m\|^2}{(-d_k^T g_k)^2} g_{k+1}^T d_k \right) d_k^T g_{k+1} \\ &= \frac{d_k^T g_{k+1} g_{k+1}^T y_k^m - \|g_{k+1}\|^2 (-d_k^T g_k) - \frac{\mu \|y_k^m\|^2}{-d_k^T g_k} (g_{k+1}^T d_k)^2}{-d_k^T g_k} \\ &= \frac{u^T v - \frac{1}{2} (\|u\|^2 + \|v\|^2)}{-d_k^T g_k} + \frac{-\left(1 - \frac{1}{4\mu}\right) \|g_{k+1}\|^2 d_k^T y_k^m}{-d_k^T g_k} \\ &\leq -\left(1 - \frac{1}{4\mu}\right) \|g_{k+1}\|^2, \end{aligned}$$

上述不等式利用了 $u^T v \leq \frac{1}{2} (\|u\|^2 + \|v\|^2)$ 的关系。取 $c = 1 - \frac{1}{4\mu}$, 则(3.1)成立。根据线搜索技术(2.2)可推出(3.2)也成立。证毕。

我们将采用反证法来证明算法 1 的全局收敛性, 假设存在常数 $\varepsilon_0 > 0$ 满足

$$\|g_k\| \geq \varepsilon_0, \forall k \geq 0. \quad (3.4)$$

根据(3.4)导出矛盾, 从而证明 $\|g_k\| \rightarrow 0, k \rightarrow \infty$ 成立。

为证明算法 1 的收敛性, 还需要下面的常规假设条件。

假设 A: 1) 定义水平集 $\Omega = \{x \in \mathbb{R}^n : f(x) \leq f(x_0)\}$ 且有界, 存在 $L_0 > 0$ 满足

$$\|\nabla^2 f(x)\| \leq L_0, x \in \Omega.$$

2) 目标函数 f 在水平集 Ω 上连续可微并有下界, 目标函数梯度满足 Lipschitz 条件, 所谓 Lipschitz 条件就是存在常数 $L > 0$ 满足下式

$$\|g(x) - g(y)\| \leq L \|x - y\|, \forall x, y \in \Omega. \quad (3.5)$$

下面引理 3.2 和引理 3.3 在共轭梯度算法文献中有类似的结论, 本文只给出引理 3.3 证明过程。

引理 3.2: 设假设 A 成立, 序列 $\{g_k\}$ 和 $\{d_k\}$ 由算法 1 产生, 则 $d_k \neq 0$ 及 $\sum_{k=0}^{\infty} \|u_{k+1} - u_k\|^2 < \infty$, 其中

$$u_k = \frac{d_k}{\|d_k\|}.$$

Gilbert 和 Nocedal [14]给出下面性质(P), 具体内容是:

性质(P)对于两参数 $\gamma_1, \gamma_2 > 0$, 且满足

$$0 < \gamma_1 \leq \|g_k\| \leq \gamma_2. \tag{3.6}$$

若对所有 k , 存在常数 $b > 1$ 和 $\lambda > 0$ 满足 $|\beta_k| \leq b$ 和 $\|s_k\| \leq \lambda$, 有 $|\beta_k| \leq \frac{1}{2b}$ 成立.

引理 3.3: 如果假设 A 满足且序列 $\{g_k\}$ 和 $\{d_k\}$ 由算法 1 产生, 且存在常数 $M > 0$ 使得 $\|d_k\| \leq M$ 成立, 则 $\beta_k^{MMLS^*}$ 满足性质(P).

证明: 对于公式(2.3), 如果 $\frac{g_{k+1}^T y_k^m}{-d_k^T g_k} \leq \frac{\mu \|y_k^m\|^2}{(-d_k^T g_k)^2} g_{k+1}^T d_k$ 成立, 结论显然成立. 否则, 利用假设 A(1),

可推出存在常数 $M_1 > 0$ 使下式

$$\|s_k\| \leq M_1 \tag{3.7}$$

成立. 利用 $\|d_k\| \leq M$, (3.1), (3.2), (3.5)~(3.7), 有

$$\begin{aligned} |\beta_k^{MMLS^*}| &\leq \left| \frac{g_{k+1}^T y_k^m}{d_k^T g_k} + \frac{\mu \|y_k^m\|^2}{(-d_k^T g_k)^2} |g_{k+1}^T d_k| \right| \leq \frac{\|g_{k+1}\| [\|g_{k+1} - g_k\| + 3[\|g_{k+1} - g_k\| + \|\nabla^2 f(\zeta_k) s_k\|]]}{c \|g_k\|^2} \\ &\quad + \frac{\mu \|g_{k+1}\| \|d_k\| [\|g_{k+1} - g_k\| + 3[\|g_{k+1} - g_k\| + \|\nabla^2 f(\zeta_k) s_k\|]]}{c^2 \|g_k\|^4} \\ &\leq \frac{[L\gamma_2 + 3(L + L_0)] \|s_k\|}{c\gamma_1^2} + \frac{[\mu\gamma_2 M (L + 3(L + L_0))^2 M_1] \|s_k\|}{c^2 \gamma_1^4} \\ &= \left(\frac{[L\gamma_2 + 3(L + L_0)] c\gamma_1^2 + [\mu\gamma_2 M (L + 3(L + L_0))^2 M_1]}{c^2 \gamma_1^4} \right) \|s_k\|, \end{aligned}$$

取 $b = \max \left\{ 2, \frac{[L\gamma_2 + 3(L + L_0)] c\gamma_1^2 + [\mu\gamma_2 M (L + 3(L + L_0))^2 M_1]}{c^2 \gamma_1^4} \right\}$ 和

$$\lambda = \frac{c^2 \gamma_1^4}{b \left\{ [L\gamma_2 + 3(L + L_0)] c\gamma_1^2 + [\mu\gamma_2 M (L + 3(L + L_0))^2 M_1] \right\}}.$$

利用(3.8), λ 和 $b > 1$, 则 $|\beta_k^{MMLS^*}| \leq b$ 和

$$\begin{aligned} |\beta_k^{MMLS^*}| &\leq \frac{[L\gamma_2 + 3(L + L_0)] c\gamma_1^2 + [\mu\gamma_2 M (L + 3(L + L_0))^2 M_1]}{c^2 \gamma_1^4} \|s_k\| \\ &\leq \frac{[L\gamma_2 + 3(L + L_0)] c\gamma_1^2 + [\mu\gamma_2 M (L + 3(L + L_0))^2 M_1]}{c^2 \gamma_1^4} \lambda = \frac{1}{2b}. \end{aligned}$$

因此公式(2.3)满足性质(P), 引理得证。

利用假设 A, 引理 3.1~3.3, 与文献[15]中的定理 3.2 的证明类似, 可得到算法 1 的全局收敛性定理, 定理的证明请参照文献[15]中的定理 3.2 完成。

定理 3.1: 序列 $\{d_k, g_k\}$ 由算法产生, 若假设 A 成立, 则 $\lim_{k \rightarrow \infty} \inf \|g_k\| = 0$ 成立。

4. 数值结果

这部分将给出数值检验, Benchmark 问题[16]在工程领域具有广泛应用背景。

1) Sphere 函数: $f_{Sph}(x) = \sum_{i=1}^n x_i^2, x_i \in [-5.12, 5.12], f_{Sph}(x^*) = 0$.

2) Schwefel's 函数: $f_{SchDS}(x) = \sum_{i=1}^n \left(\sum_{j=1}^i x_j \right)^2, x_i \in [-65.536, 65.536], f_{SchDS}(x^*) = 0$.

3) Rastrigin 函数: $f_{Ras}(x) = 10n + \sum_{i=1}^n (x_i^2 - 10 \cos(2\pi x_i)), x_i \in [-5.12, 5.12], f_{Ras}(x^*) = 0$.

4) Griewank 函数: $f_{Gri}(x) = 1 + \sum_{i=1}^n \frac{x_i^2}{4000} - \prod_{i=1}^n \cos \frac{x_i}{i}, x_i \in [-600, 600], f_{Gri}(x^*) = 0$.

参数选取如下: $\varepsilon = 10^{-5}, \delta = 0.1, \sigma = 0.9$, 停止准则采用 Himmeblau 准则: 如果 $|f(x_k)| > e_1$, 令 $\text{stop1} = \frac{|f(x_k) - f(x_{k+1})|}{|f(x_k)|}$; 否则, 令 $\text{stop1} = |f(x_k) - f(x_{k+1})|$ 。如果 $\|g(x)\| < \varepsilon$ 或者 $\text{stop1} < e_2$ 满足, 算法终止, $e_1 = e_2 = 10^{-5}$ 。若迭代次数超过 1000 次, 程序也将终止。为比较算法 1 的有效性, 也给出通常 LS 方法的数值检验, 并进行比较。以下是各代码含义:

x_0 : 初始点; Dim: 问题的维数; NI: 迭代次数; NFG: 函数值与梯度值迭代次数和; Time: 以秒为单位的计算机 CPU 时间; $f(x)$: 算法终止时的函数值。

为比较算法 1 与原 LS 算法的效率, 我们采用下述技术即两算法的所有 NFG 的乘积的比值再开二十四分之一(结果的总个数)次方, 以通常 LS 算法作为底, 定义为 1, 比值见表 2, 此技术见文献[17]。

Table 1. Numerical results

表 1. 数值结果

| | | 算法 1 | | 原 LS 算法 | |
|------------|-------|-----------------------------|-----------------------------|-----------------------------|-----------------------------|
| | | NI/NFG/ $f(\bar{x})$ /Time | NI/NFG/ $f(\bar{x})$ /Time | NI/NFG/ $f(\bar{x})$ /Time | NI/NFG/ $f(\bar{x})$ /Time |
| Sphere | x_0 | (-4, -4, ..., -4) | (3, 3, ..., 3) | (-4, -4, ..., -4) | (3, 3, ..., 3) |
| | 10 | 2/6/7.888609e-030/0 | 2/6/7.888609e-030/0 | 2/6/7.888609e-030/0.0468003 | 2/6/7.888609e-030/0 |
| Dim | 100 | 2/6/3.478877e-026/0 | 2/6/1.262177e-027/0.0312002 | 2/6/3.478877e-026/0 | 2/6/1.262177e-027/0 |
| | 300 | 2/6/1.855401e-025/0 | 2/6/2.863565e-026/0 | 2/6/1.855401e-025/0.0312002 | 2/6/2.863565e-026/0 |
| Schwefel's | x_0 | (-0.001, ..., -0.001) | (0.001, ..., -0.001) | (-0.001, ..., -0.001) | (0.001, ..., -0.001) |
| | 10 | 2/5/4.378593e-008/0 | 2/5/4.378593e-010/0 | 2/5/4.378593e-008/0 | 2/5/4.378593e-010/0 |
| Dim | 100 | 3/8/3.711002e-006/0.0468003 | 2/5/3.979128e-007/0.0312002 | 3/8/3.711002e-006/0.0936006 | 2/5/3.979128e-007/0.0312002 |
| | 300 | 4/11/1.871432e-005/2.043613 | 3/8/9.937482e-007/1.326009 | 4/11/1.871432e-005/1.950012 | 3/8/9.937482e-007/1.310408 |
| Rastrigin | x_0 | (0.01, 0.01, ..., 0.01) | (0.001, ..., 0.001) | (0.01, 0.01, ..., 0.01) | (0.001, ..., 0.001) |

Continued

| | | | | | |
|-----------|-------|-------------------------------|-------------------------------|-------------------------------|-----------------------------|
| | 10 | 4/12/0.000000e+000/0 | 2/5/3.208869e-006/0 | 3/10/0.000000e+000/0.0312002 | 2/5/3.208869e-006/0 |
| Dim | 100 | 3/8/3.612627e-009/0.0468003 | 3/8/0.000000e+000/0 | 3/9/0.000000e+000/0 | 3/9/0.000000e+000/0 |
| | 300 | 3/8/2.728484e-012/0 | 3/8/0.000000e+000/0 | 3/9/0.000000e+000/0.0312002 | 3/9/0.000000e+000/0 |
| Griewank | x_0 | (-100,-100,...,-100) | (30,30,...,30) | (-100,-100,...,-100) | (30,30,...,30) |
| | 10 | 2/19/7.250909e+000/0 | 10/47/3.316156e-006/0.0312002 | 2/19/7.250909e+000/0.0468003 | 9/43/3.715464e-006/0 |
| Dim | 100 | 4/32/3.509751e-002/0.0468003 | 2/6/0.000000e+000/0 | 4/32/2.276154e-002/0.0624004 | 2/6/0.000000e+000/0.0312002 |
| | 300 | 19/54/8.028683e-005/0.5772037 | 2/6/0.000000e+000/0.0624004 | 23/64/8.635447e-005/0.6708043 | 2/6/0.000000e+000/0.0468003 |
| 总的 CUP 时间 | | 4。243227 | | 4。383628 | |

Table 2. The Efficiency of NFG

表 2. NFG 的效率

| 算法 1 | 原 LS 算法 |
|------|---------|
| 0.98 | 1 |

从表 1 的结果可看, 算法 1 和 LS 算法对上述 4 个问题都能有效地求解, 迭代次数可以接受, 最终函数值很接近最优函数值, 新算法的 CPU 时间相对少一些, 更具竞争力。表 2 的效率表明, 算法 1 相对于原 LS 算法, 效率提高 2%。

基金项目

2017 年国家级大学生创新创业训练计划项目(201710606041), 广西自然科学基金(2018JJA110039)和玉林师范学院校级科研项目(2019YJKY16)。

参考文献

- [1] 陈海. 一个修改的 LS 非线性共轭梯度算法[J]. 应用数学进展, 2013(2): 48-54.
- [2] Polak, E. and Ribiere, G. (1969) Note sur la convergence de directions conjugees. *Rev. Francaise informat Recherche Operatinelle, 3e Annee*, **16**, 35-43.
- [3] Polyak, B.T. (1969) The Conjugate Gradient Method in Extreme Problems. *USSR Computational Mathematics and Mathematical Physics*, **9**, 94-112
- [4] Hestenes, M.R. and Stiefel, E. (1952) Method of Conjugate Gradient for Solving Linear Equations. *Journal of Research of the National Bureau of Standards*, **49**, 409-436. <https://doi.org/10.6028/jres.049.044>
- [5] Fletcher, R. and Reeves, C. (1964) Function Minimization bu Conjugate Gradients. *Compute Journal*, **7**, 149-154.
- [6] Dai, Y. and Yuan, Y. (1999) A Nonlinear Conjugate Gradient with a Strong Global Convergence Properties. *SIAM Journal on Optimization*, **10**, 177-182. <https://doi.org/10.1137/S1052623497318992>
- [7] Fletcher, R. (1980) Practical Method of Optimization, Vol. I: Unconstrained Optimization. 2nd Edition, Wiley, Hoboken.
- [8] Liu, Y. and Storey, C. (1992) Efficient Generalized Conjugate Gradient Algorithms, Part 1: Theory. *Journal of Optimization Theory and Application*, **69**, 17-41.
- [9] Yuan, G. (2009) Modified Nonlinear Conjugate Gradient Methods with Sufficient Descent Property for Large-Scale Optimization Problems. *Optimization Letters*, **3**, 11-21. <https://doi.org/10.1007/s11590-008-0086-5>
- [10] Yuan, G. and Wei, Z. (2010) Convergence Analysis of a Modified BFGS Method on Convex Minimizations. *Computational Optimization and Applications*, **47**, 237-255. <https://doi.org/10.1007/s10589-008-9219-0>
- [11] Zhang, J., Deng, N. and Chen, L. (1999) New Quasi-Newton Equation and Related Methods for Unconstrained Opti-

- mization. *Journal of Optimization Theory and Application*, **102**, 147-167. <https://doi.org/10.1023/A:1021898630001>
- [12] Yuan, G., Wei, Z. and Zhao, Q. (2014) A Modified Polak-Ribière-Polyak Conjugate Gradient algorithm for Large-Scale Optimization Problems. *IIE Transactions*, **46**, 397-413. <https://doi.org/10.1080/0740817X.2012.726757>
- [13] Yuan, G. and Zhang, M. (2013) A Modified Hestenes-Stiefel Conjugate Gradient Algorithm for Large-Scale Optimization. *Numerical Functional Analysis and Optimization*, **34**, 914-937. <https://doi.org/10.1080/01630563.2013.777350>
- [14] Gilbert, J.C. and Nocedal, J. (1992) Global Convergence Properties of Conjugate Gradient Methods for Optimization. *SIAM Journal on Optimization*, **2**, 21-42. <https://doi.org/10.1137/0802003>
- [15] 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>
- [16] Yao, S., He, D. and Shi, L. (2018) An Improved Perry Conjugate Gradient Method with Adaptive Parameter Choice. *Numerical Algorithms*, **78**, 1255-1269. <https://doi.org/10.1007/s11075-017-0422-x>
- [17] Yuan, G. and Lu, X. (2009) A Modified PRP Conjugate Gradient Method. *Annals of Operations Research*, **66**, 73-90. <https://doi.org/10.1007/s10479-008-0420-4>
- [18] Dai, Y. and Liao, L. (2001) New Conjugacy Conditions and Related Nonlinear Conjugate Methods. *Applied Mathematics and Optimization*, **43**, 87-101. <https://doi.org/10.1007/s002450010019>
- [19] Hager, W.W. and Zhang, H. (2006) Algorithm 851: CGDESCENT, A Conjugate Gradient Method with Guaranteed Descent. *ACM Transactions on Mathematical Software*, **32**, 113-137. <https://doi.org/10.1145/1132973.1132979>
- [20] Li, G., Tang, C. and Wei, Z. (2007) New Conjugacy Condition and Related New Conjugate Gradient Methods for Unconstrained Optimization Problems. *Journal of Computational and Applied Mathematics*, **202**, 532-539.
- [21] Wei, Z., Li, G. and Qi, L. (2006) New Nonlinear Conjugate Gradient Formulas for Large-Scale Unconstrained Optimization Problems. *Applied Mathematics and Computation*, **179**, 407-430. <https://doi.org/10.1016/j.amc.2005.11.150>
- [22] Wei, Z., Li, G. and Qi, L. (2008) Global Convergence of the PRP Conjugate Gradient Methods with Inexact Line Search for Nonconvex Unconstrained Optimization Problems. *Mathematics of Computation*, **77**, 2173-2193. <https://doi.org/10.1090/S0025-5718-08-02031-0>
- [23] Wei, Z., Yao, S. and Lin, L. (2006) The Convergence Properties of Some New Conjugate Gradient Methods. *Applied Mathematics and Computation*, **183**, 1341-1350. <https://doi.org/10.1016/j.amc.2006.05.150>
- [24] Yuan, G., Lu, X. and Wei, Z. (2009) A Conjugate Gradient Method with Descent Direction for Unconstrained Optimization. *Journal of Computational and Applied Mathematics*, **102**, 519-530. <https://doi.org/10.1016/j.cam.2009.08.001>
- [25] 李向荣. 修改的 DY 和 HS 共轭梯度算法及其全局收敛性[J]. 理论数学, 2011(1): 1-7.

知网检索的两种方式:

1. 打开知网页面 <http://kns.cnki.net/kns/brief/result.aspx?dbPrefix=WWJD>
下拉列表框选择: [ISSN], 输入期刊 ISSN: 2324-7991, 即可查询
2. 打开知网首页 <http://cnki.net/>
左侧“国际文献总库”进入, 输入文章标题, 即可查询

投稿请点击: <http://www.hanspub.org/Submission.aspx>
期刊邮箱: aam@hanspub.org