

文章编号:1000-582x(2001)05-0153-04

求解带二次简单约束的大型二次规划问题

胡国雷, 杨振华

(南京邮电学院 应用数理系, 南京 210003)

摘要:给出了一个求解形如 $\frac{1}{2}x^T Hx + c^T x = \min, s. t. \|x\|_2 \leq a$ 的二次规划问题的方法, 该方法是由共轭斜量法(CG)和投影收缩算法(PC)的隐式方法组合而成的。对无约束问题, 首先以 $x^0 = 0$ 作为初始点, 用(CG)方法进行求解, 如果 $\|x^k\|_2 < a (k = 1, 2, \dots)$, 则原约束问题的解已经得到; 否则用(CG)方法产生的迭代点的模一旦大于 a , 则以此点为新的初始点, 改用隐式(PC)方法进行求解。数值例子的结果显示, 该算法对处理大规模问题高效的, 并且可大大提高精度。

关键词:二次规划; 共轭斜量法; 投影收缩方法

中图分类号: O 221.1

文献标识码: A

考虑如下的带二次约束的二次规划问题

$$\begin{aligned} \frac{1}{2}x^T Hx + c^T x = \min \\ s. t. \|x\|_2 \leq a \end{aligned} \quad (1)$$

其中 $H \in R^{n \times n}$, 是一个半正定对称矩阵, $c \in R^n$, a 是一个确定的参数, 有关求解问题(1)的一种基本方法是构造 Lagrange 函数:

$$L(x, \lambda) = x^T Hx + 2c^T x + \lambda(x^T x - a^2) \quad (2)$$

$$\text{由 } \nabla_x L(x, \lambda) = 0, \nabla_\lambda L(x, \lambda) = 0,$$

得

$$\begin{cases} Hx + c + \lambda x = 0 \\ \|x\| = a \end{cases} \quad (3)$$

$$\text{即 } \begin{cases} (H + \lambda I)x + c = 0 \\ \|x\| = a \end{cases}$$

从而有 $\|(H + \lambda I)^{-1}c\| = a$

$$\text{令 } \varphi(\lambda) = \|(H + \lambda I)^{-1}c\|, S(\lambda) = (H + \lambda I)^{-1}c$$

$$\text{则 } \varphi^2(\lambda) = S^T S = c^T (H + \lambda I)^{-2} c = a^2$$

$$\text{即 } \varphi(\lambda) - a = 0 \quad (4)$$

求出方程(4)的解 λ^* , 则得问题(1)的解

$$x^* = -(H + \lambda^* I)^{-1}c$$

牛顿法的求解过程一般需要求解 8 ~ 9 次线性方程组, 所以它仅适用求解小规模问题, 而对大型矩阵代价太大。因此人们还在继续寻找更有效的计算方法。

对大型的稀疏矩阵问题 Golub 和 Von Matt^[1] 给出

了一个方法, 采用一系列不完全分解, 产生一个含有上下界的 Lagrange 乘子序列, 通过求解一个线性方程组, 可求得界中的近似解 x_c 。何^[2]提出了一个求解问题(1)的有效方法, 该方法是以 $x_0 = 0$ 作为初始点, 如果 $a \geq \|H^+c\|$, 则仅采用(CG)方法求解该问题; 如果 $a \leq \|H^+c\|$, 用此方法求解, 一旦迭代点 $\|x^k\| > a$, 则改用显式(PC)方法, 本文提出的方法, 前半部分与何^[2]中(CG)方法相同, 而后半部分将何^[1]显式(PC)方法改为隐式方法, 从后面数值例子的结果显示, 隐式方法与 Golub 和 Von Matt^[1]方法、何^[2]的显式方法相比计算效率更高, 对坏条件问题的处理更有效, 且可提高求解的精确度。

第1节中给出了问题(1)的等价投影方程; 第2节介绍了(CG)方法和(PC)方法的隐式方法, 并给出了算法的收敛性定理; 第3节给出了算法的具体实现; 最后绝对化出了一个大型二次规划的算例。

1 等价的投影方程

问题(1)的 Lagrange 函数为:

$$L(x, \lambda) = x^T Hx + 2c^T x + \lambda(x^T x - a^2)$$

由凸规划的 Kuhn-Tucker 定理知, 如果存在唯一的 $\lambda^* \geq 0$ 及 x^* , 使得 (x^*, λ^*) 满足

$$Hx + c + \lambda x = 0$$

$$\text{且 } \lambda \geq 0, x^T x \leq a^2$$

• 收稿日期: 2000-09-15

作者简介: 胡国雷(1962-), 男, 江苏武进人, 南京邮电学院讲师, 主要研究方向为优化与统计。

$$\lambda(x^T x - a^2) = 0 \tag{5}$$

则 x^* 是问题(1)的解。

设 $\Omega = \{x \in R^n, \|x\|_2 \leq a\}$

$P_\Omega(\cdot)$ 表示在凸集 Ω 上的投影算子,即

$$P_\Omega(x) = \begin{cases} x, & \|x\| \leq a \\ \frac{ax}{\|x\|}, & \|x\| > a \end{cases}$$

则(5)可写成如下的等价投影方程

$$x = P_\Omega(x + \lambda x) \tag{6}$$

将 $\lambda x = -(Hx + c)$ 代入投影方程,得到下列线性投影方程(称为LPE),

$$(LPE) \quad x = P_\Omega[x - (Hx + c)] \tag{7}$$

因此,求解问题(1)等价于求解如下残差函数的零点:

$$e(x) := x - P_\Omega[x - (Hx + c)] \tag{8}$$

引入调比因子 μ 得

$$e(x, \mu) := x - P_\Omega[x - \mu(Hx + c)] \tag{9}$$

2 共轭斜量法和投影收缩的隐式方法

1) 共轭斜量法

共轭斜量法求解凸的二次函数的极小值是一个精确的线性搜寻算法

$$x^{k+1} = x^k - \alpha_k s^k$$

$$s^0 = g^0, \beta_0 = 0$$

$$s^{k+1} = g^{k+1} + \beta_k s^k$$

$$\beta_k = \frac{g^{k+1T} g^{k+1}}{g^{kT} g^k}$$

$$\alpha_k = \frac{g^{kT} g^k}{s^{kT} H s^k}$$

且

$$g = Hx + c$$

如果 H 是对称半正定矩阵,(CG)方法求解 $Hx + c = 0$ 经 $m(m \leq n)$ 步后停止。且对所有 $i(1 \leq i \leq m)$,有下列关系式成立

$$s^{iT} H s^i = 0$$

$$g^{iT} g^j = 0 \quad j = 0, 1, \dots, i-1$$

$$g^{iT} s^j = 0$$

定理1 若将 \tilde{x} 表示 $H^+ c$, 则对 $k(k \leq m)$ 有

$$\|x^{k+1} - \tilde{x}\| < \|x^k - \tilde{x}\|$$

证明见[3]。

何[2]给出了有关(CG)方法的另一个性质

定理2 若(CG)方法的初始点为 $x^0 = 0$, 则对所有 $k(k < m)$, 有

$$\|x^{k+1}\| < \|x^k\|$$

2) 投影收缩算法的隐式方法

设 $\gamma \in (0, 2)$ 是一个常数, G 是一个正定矩阵, 给定 $x^0 \in R^n$, 对 $k = 0, 1, \dots$, 如果 $x^0 \notin \Omega^*$, 则求解方程 $Q_k(x) = 0$ 得 x^{k+1} , 其中

$$Q_k(x) = x + \mu(Hx + c) - x^k - \mu(Hx^k + c) + \gamma \rho_k G^{-1} e(x^k, \mu) \tag{10}$$

$$\rho_k = \frac{\|e(x^k, \mu)\|^2}{e(x^k, \mu)^T G^{-1} e(x^k, \mu)} \tag{11}$$

若 $G = I$, 则

$$x^{k+1} = x^k + \mu(Hx^k + c) - \mu(Hx^{k+1} + c) - \gamma e(x^k, \mu)$$

$$\text{即 } x^{k+1} = x^k - \gamma(I + \mu H)^{-1} e(x^k, \mu) \tag{12}$$

3) 收敛性

定理3 设 $x^* \in \Omega^*$, 则

$$\{(I + \mu H)(x - x^*)\}^T e(x^k, \mu) \geq \|e(x^k, \mu)\|^2 + \mu^2 \|x - x^*\|_H^2 \tag{13}$$

由 F11 + F12(何[4])即可证得。

定理4

$$\|(I + \mu H)(x^{k+1} - x^*)\|_G^2 \leq \|(I + \mu H)(x^k - x^*)\|_G^2 - \gamma(2 - \gamma)\rho_k \|e(x^k, \mu)\|^2 - 2\gamma\rho_k \mu^2 \|x^k - x^*\|_H^2 \tag{14}$$

证:由

$$x^{k+1} - x^k + \mu H x^{k+1} - \mu H x^k = -\gamma \rho_k G^{-1} e(x^k, \mu)$$

$$(I + \mu H)(x^{k+1} - x^k) = -\gamma \rho_k G^{-1} e(x^k, \mu)$$

$$\|(I + \mu H)(x^{k+1} - x^k)\|_G^2 =$$

$$\|(I + \mu H)[x^{k+1} - x^k + x^k - x^*]\|_G^2 =$$

$$\|(I + \mu H)(x^k - x^*) - \gamma \rho_k G^{-1} e(x^k, \mu)\|_G^2 =$$

$$\|(I + \mu H)(x^k - x^*)\|_G^2 -$$

$$2\gamma \rho_k \{(I + \mu H)(x^k - x^*)\}^T e(x^k, \mu) +$$

$$\gamma^2 \rho_k^2 e(x^k, \mu)^T G^{-1} e(x^k, \mu) \leq$$

$$\|(I + \mu H)(x^k - x^*)\|_G^2 -$$

$$2\gamma \rho_k \{ \|e(x^k, \mu)\|^2 + \mu^2 \|x^k - x^*\|_H^2 \} +$$

$$\gamma^2 \rho_k \|e(x^k, \mu)\|^2 = \quad (\text{利用(13)和(11)式})$$

$$\|(I + \mu H)(x^k - x^*)\|_G^2 -$$

$$\gamma(2 - \gamma)\rho_k \|e(x^k, \mu)\|^2 - 2\gamma\rho_k \mu^2 \|x^k - x^*\|_H^2$$

定理5 由投影收缩算法的隐式方法产生的序列

$\{x^k\}$ 收敛于解点 x^* 。

证:由定理2得

$$\sum_{i=0}^{\infty} \gamma(2 - \gamma)\rho_i \|e(x^i, \mu)\|^2 \leq$$

$$\|(I + \mu H)(x^0 - \tilde{x})\|_G^2$$

即有

$$\lim_{k \rightarrow \infty} \|e(x^k, \mu)\|^2 = 0$$

且 $\{x^k\}$ 有界, 所以 $\{x^k\}$ 为收敛于 x^* 的子序列, 又因为

$$\|(I + \mu H)(x^{k+1} - x^*)\|_c^2 \leq \|(I + \mu H)(x^k - x^*)\|_c^2$$

所以有

$$\lim_{k \rightarrow \infty} x^k = x^*$$

3 关于算法的具体实现

步骤 1:

$x^0 = 0$, 当 $\|x^l\| \leq a$ 且 $l < n$, 由 (CG) 方法计算出 x^{l+1} , 如果 $\|x^l\| \leq a, l = 0, 1, \dots, n$, 用 (CG) 方法求解线性方程 $Hx + c = 0$ 产生的迭代点 x^n 是问题 (1) 的解; 否则一旦 $\|x^l\| > a, (l \leq n)$, 取 $\bar{x}^0 = \frac{ax^l}{\|x^l\|^2}$ 作为新的初始点, 并且转用投影收缩算法的隐式方法 (12), 在 (12) 中, 取 $\mu = \frac{a}{\|Hx^0 + c\|}$:

步骤 2:

$$x^0 = \bar{x}^0$$

$$e(x, \mu) := x - P_\Omega[x - \mu(Hx + c)]$$

$$x^{k+1} = x^k - \gamma(I + \mu H)^{-1}e(x^k, \mu) \quad k = 0, 1, \dots$$

取停机准则为

$$\max\left\{\left|\frac{\|x\| - a}{a}\right|, \frac{\|e(x)\|}{\sqrt{a\|c\|}}\right\} \leq \epsilon$$

归结起来, 算法如下

给定 K 和 ϵ

done := false

$l := 0$

$x := 0$

while not $\|x\| < a$ and $l < n$ do

(用 (CG) 步计算一个新的迭代变量 x)

$l := l + 1$

end

if $l := n$ then done := true

else

$k := 0$

$$x := \frac{ax}{\|x\|^2}$$

$$\mu := \frac{a}{\|Hx + c\|}$$

end

while not done and $k \leq K$ do

$$e(x, \mu) := x - P_\Omega[x - \mu(Hx + c)]$$

$$x := x - 1.8(I + \mu H)^{-1}e(x, \mu)$$

$k := k + 1$

$$\text{if } \max\left\{\left|\frac{\|x\| - a}{a}\right|, \frac{\|e(x)\|}{\sqrt{a\|c\|}}\right\} \leq \epsilon$$

done := true

end

4 数值实验结果

这一节我们给出一个问题 (1) 的大规模的数值例子

设 $H = A^T A, c = -A^T b, A := U \sum V^T$, 其中

$$U = I_m - 2 \frac{uu^T}{\|u\|_2^2},$$

$$V = I_n - 2 \frac{vv^T}{\|v\|_2^2}$$
 是豪斯荷尔德矩阵,

$\sum = \text{diag}(\sigma_k)$ 是一个 $m \times n$ 对角阵,

向量 u, v 和 b 是同余伪随机数:

$$u_1 = 13\ 846 + u_i = (3\ 146u_{i-1} + 13\ 846) \bmod 46$$

$$216 \quad i = 2, \dots, m$$

$$v_1 = 13\ 846$$

$$v_j = (42\ 108v_{j-1} + 13\ 846) \bmod 46\ 273 \quad j = 2, \dots, n$$

$$b_1 = 13\ 846$$

$$b_i = (45\ 278b_{i-1} + 13\ 846) \bmod 46\ 219 \quad i = 2, \dots,$$

m

取 $\epsilon_1 = 5 \times 10^{-6}$ (与 [6] 相同), $\epsilon_2 = 5 \times 10^{-12}$.

文中算法用 Matlab 语言实现, 表中 l 表示用 (CG) 方法直到 $\|x^l\| > a$ 的迭代步数, k 表示用 (PC) 方法直到满足停机准则的迭代次数。

$$\text{例: 取 } m = 2\ 000, n = 1\ 000, \sigma_i = \cos \frac{k\pi}{n+1} + 1,$$

$$k = 1, \dots, n,$$

$$\text{cond}(H) = \text{cond}(A^T A) = 1.65 \times 10^{11}, \|H^+ c\| = 4.37 \times 10^9$$

表 1 给出了 $a = 10^4, \dots, 10^7$ 的结果。

表 1 $a = 10^4, \dots, 10^7$ 的结果

m	n	$\ H^+ c\ $	a	l	μ	k	k
						$(\epsilon_1 = 5 \times 10^{-6})$	$(\epsilon_2 = 5 \times 10^{-12})$
2 000	1 000	4.37×10^9	10^4	1	0.01	22	77
2 000	1 000	4.37×10^9	10^5	1	0.14	12	23
2 000	1 000	4.37×10^9	10^6	7	11.05	11	19

m	n	$\ H^+c\ $	a	1	μ	k	
						$(\epsilon_1 = 5 \times 10^{-6})$	$(\epsilon_2 = 5 \times 10^{-12})$
2 000	1 000	4.37×10^9	2×10^6	20	47.17	13	29
2 000	1 000	4.37×10^9	3×10^6	36	97.13	18	39
2 000	1 000	4.37×10^9	5×10^6	63	215.29	24	58
2 000	1 000	4.37×10^9	8×10^6	111	573.93	24	69
2 000	1 000	4.37×10^9	10^7	146	867.98	31	79

注:在(PC)方法中适当选择参数 μ 对收敛速度能起到很关键的作用,对同样的问题,如果选择 $\mu = 1$,则迭代的次数比原来要多出许多倍,特别在 a 取值较大时迭代次数差别更大,见表2

表2 迭代次数差别

m	n	$\ H^+c\ $	a	1	μ	k	
						$(\epsilon_1 = 5 \times 10^{-6})$	$(\epsilon_2 = 5 \times 10^{-12})$
2 000	1 000	4.37×10^9	10^7	1	1	34	137
2 000	1 000	4.37×10^9	10^7	1	1	19	53
2 000	1 000	4.37×10^9	10^6	7	1	73	237
2 000	1 000	4.37×10^9	2×10^6	20	1	410	1 629
2 000	1 000	4.37×10^9	3×10^6	36	1	992	4 513
2 000	1 000	4.37×10^9	5×10^6	63	1	2 761	15 009
2 000	1 000	4.37×10^9	8×10^6	111	1	2 718	> 20 000
2 000	1 000	4.37×10^9	10^7	146	1	10 210	> 20 000

参考文献:

- [1] G H Golub U VON MATT. Quadratically constrained least squares and quadratic problems[J]. Numerische Mathematical, 1990(59):561-580.
- [2] B S HE. Solving trust region problem in large scale optimization [J]. Journal of Computational Mathematics, 2000,18(1):1-12.
- [3] M HESTENES. Conjugate Direction Methods in optimization [M]. New York:Springer-Verlag, Berlin;Heidelberg, 1980.
- [4] B S HE. A new method for a class of linear variational inequalities[J]. Mathematical Programming, 1994(66):137-144.
- [5] B S HE. A projection and contraction method for a class of linear complementary problems and its application in convex quadratic programming [J]. Applied Mathematics and Optimization, 1992,25:247-262.
- [6] B S HE. Solving a class of linear projection equations [J]. Numerische Mathematical, 1994,68:71-80.

Solving Large-scale Quadratic Programming with Simple Quadratic Constraint

HU Guo-lei, YANG Zhen-hua

(Department of Applied Mathematics and Physics, Nanjing University of Posts & Telecommunications, Nanjing 210003, China)

Abstract: A method solving the quadratic programming $\frac{1}{2} \mathbf{x}^T \mathbf{H} \mathbf{x} + \mathbf{c}^T \mathbf{x} = \min, s. t. \|\mathbf{x}\|_2 \leq a$ is established, which is combined by conjugate gradient method and implicit projection and contraction method. The unconstrained problem is solved by conjugate gradient method with the initial point $\mathbf{x}^0 = 0$. The solution of the constrained problem is obtained if $\|\mathbf{x}^k\|_2 < a$ ($k = 1, 2, \dots$), otherwise, once the norm of the interior point is greater than a , implicit PC method is used, started with this point. The numerical results show that this algorithm is very effective for large-scale problem, and the precision is improved.

Key words: quadratic programming; conjugate gradient method; projection and contraction method

(责任编辑 张小强)