

文章编号: 0253-374X(2014)05-0804-03

DOI: 10.3969/j.issn.0253-374x.2014.05.023

一类多项式全局优化的差分算法

朱经浩, 何似菡

(同济大学 数学系, 上海 200092)

摘要: 引入一类 n 元多项式的倒向微分流以求解全局优化问题. 沿着倒向微分流, 建立一个差分-牛顿混合算法, 并证明了由算法所得迭代点的绝对误差受到差分步长的一致界. 应用所建立的算法, 给出了一个数值计算的例子.

关键词: 多项式全局优化; 倒向微分方程; 差分-牛顿混合算法

中图分类号: O224

文献标志码: A

A Difference Algorithm to Find Global Minimizers of a Polynomial

ZHU Jinghao, HE Sihan

(Department of Mathematics, Tongji University, Shanghai 200092, China)

Abstract: This paper presents a differential flow concerning the global optimization with polynomials. Along the flow which leads to a global minimizer there is posed a mixed difference algorithm with Newton method. An error analysis of the algorithm is given with a numerical example to demonstrate the mixed difference method.

Key words: global optimization with polynomial; backward differential flow; mixed difference algorithm with Newton method

考虑如下多项式全局优化问题(P):

$$\begin{aligned} & \min P(\mathbf{x}) \\ & \text{s. t. } \mathbf{x} \in \mathbb{R}^n \end{aligned}$$

其中对于 $\mathbf{x} = (x_1, x_2, \dots, x_n)^T \in \mathbb{R}^n$

$$P(\mathbf{x}) = \sum_{i=1}^n x_i^{2m} + \frac{1}{2} \mathbf{x}^T \mathbf{A} \mathbf{x} - \mathbf{f}^T \mathbf{x} \quad (1)$$

这里 $m \geq 2$, $\mathbf{A} = (a_{i,j})_{i,j=1,2,\dots,n}$ 是半正定矩阵, 而 $\mathbf{f} = (f_1, \dots, f_n)^T$ 是一个 n 维非零向量. 多项式 $P(\mathbf{x})$ 的梯度为

$$\begin{aligned} \nabla P(\mathbf{x}) = & (2mx_1^{2m-1}, 2mx_2^{2m-1}, \dots, \\ & 2mx_n^{2m-1})^T + \mathbf{A} \mathbf{x} - \mathbf{f} \end{aligned}$$

且其 Hesse 矩阵为

$$\begin{aligned} \nabla^2 P(\mathbf{x}) = & \text{diag}(2m(2m-1)x_1^{2m-2}, \\ & 2m(2m-1)x_2^{2m-2}, \dots, \\ & 2m(2m-1)x_n^{2m-2}) + \mathbf{A} \end{aligned}$$

此矩阵中除了对角线上为非负项外其他处均为 0. 可见, 对于 $\forall \mathbf{x} \in \mathbb{R}^n$, 有 $\nabla^2 P(\mathbf{x}) \geq 0$.

这类多项式具有一定的实际意义, 在文献[1-2]阐述了下述问题:

$$\min_{\mathbf{x} \in \mathbb{R}^n} \left\{ P(\mathbf{x}) = W(\mathbf{x}) + \frac{1}{2} \mathbf{x}^T \mathbf{A} \mathbf{x} - \mathbf{f}^T \mathbf{x} \right\} \quad (2)$$

其中

$$W(\mathbf{x}) = \sum_{k=1}^p \frac{1}{2} \alpha_k \left(\frac{1}{2} \|\mathbf{B}_k \mathbf{x}\|^2 - \mu_k \right)^2$$

这个问题经常出现在许多复杂系统中, 涵盖相变的非凸分析、网络设计及通信的离散优化等方面. 如果 $A \geq 0$, 令式(2)中 $\mu_k = 0$, $\frac{1}{2} \alpha_k = 4$, $p = n$, $\mathbf{B}_k = \mathbf{E}_{kk}$ (\mathbf{E}_{kk} 为只有在第 k 行与第 k 列交叉位置的元素为 1, 其余元素都为 0 的 n 阶方阵), 于是得到 $W(\mathbf{x}) = \sum_{k=1}^n x_k^4$, 这样问题(2)所涉及的目标函数即为本文所关注的一类多项式.

1 全局最优化

1.1 一个球约束优化问题

文献[3-4]证明了多项式全局优化问题(P)的所有最优点都含于一个以原点为中心的闭球内部, 以下记此闭球为

$$D := \{\mathbf{x} \mid \mathbf{x}^T \mathbf{x} \leq d^2\}$$

这样无约束多项式全局优化问题(P)就等价地转化

收稿日期: 2013-06-24

基金项目: 国家自然科学基金(10671145)

第一作者: 朱经浩(1949—), 男, 教授, 博士生导师, 主要研究方向为最优控制理论与应用. E-mail: jinghaok@online.sh.cn

通讯作者: 何似菡(1990—), 女, 硕士生, 主要研究方向为最优控制理论与应用. E-mail: hesihan0804@foxmail.cn

为以下球约束优化问题:

$$\begin{aligned} \min P(\mathbf{x}) &= \sum_{i=1}^n x_i^{2m} + \frac{1}{2} \mathbf{x}^\top \mathbf{A} \mathbf{x} - \mathbf{f}^\top \mathbf{x}, \\ \text{s. t. } \|\mathbf{x}\| &\leq d. \end{aligned} \quad (3)$$

显然这里的关键问题是如何得到闭球的半径 d , 按照文献[4]给出的计算公式可得到

$$d = \max \left\{ 1, \frac{(2m)! \left(n + \frac{n^2}{2!} + \cdots + \frac{n^{2m-1}}{(2m-1)!} \right) M}{J_{2m}^*} \right\} \quad (4)$$

其中

$$M = \max \{ |a_{ij}|, |f_i| \}_{1 \leq i \leq n, 1 \leq j \leq n} \quad (5)$$

而 J_{2m}^* 是最优化问题 $\min J_{2m}(s) = (2m)! \sum_{i=1}^n s_i^{2m}$,
s. t. $\|\mathbf{s}\|^2 = 1$ 的最优值.

1.2 全局最优点

本文将引用文献[5]中的结果, 求解球约束下的全局优化问题(3).

由于在 \mathbf{R}^n 上, $\nabla^2 P(\mathbf{x}) \geq 0$, 从而对任意 $\rho \in (0, +\infty)$, 有 $\nabla^2 P(\mathbf{x}) + \rho \mathbf{I} > 0$. 注意到 $\nabla P(\mathbf{0}) = -\mathbf{f} \neq \mathbf{0}$, 由文献[6]中不动点定理可知: 对于适当的 $\rho^* > 0$, 存在一个非零向量 $\mathbf{x}^* \in D = \{\mathbf{x}^\top \mathbf{x} \leq d^2\}$ 满足以下方程:

$$\nabla P(\mathbf{x}^*) + \rho^* \mathbf{x}^* = 0$$

由于对 $\mathbf{x} \in \mathbf{R}^n$, $\rho > 0$, 恒有 $\nabla^2 P(\mathbf{x}) + \rho \mathbf{I} > 0$, 根据经典常微分方程理论, 由以下微分方程:

$$\frac{d\hat{\mathbf{x}}}{d\rho} + [\nabla^2 P(\hat{\mathbf{x}}) + \rho \mathbf{I}]^{-1} \hat{\mathbf{x}} = 0 \quad (6)$$

$$\hat{\mathbf{x}}(\rho^*) = \mathbf{x}^* \quad (7)$$

可以惟一得到定义在 $(0, +\infty)$ 内的微分流 $\hat{\mathbf{x}}(\rho)$, 满足

$$\nabla P(\hat{\mathbf{x}}(\rho)) + \hat{\rho} \hat{\mathbf{x}}(\rho) = 0$$

而且, 对给定的 $\rho > 0$, $\hat{\mathbf{x}}(\rho)$ 是惟一满足方程 $\nabla P(\mathbf{x}) + \rho \mathbf{x} = 0$ 的点, 当然也是 $L(\mathbf{x}, \rho) = P(\mathbf{x}) + \frac{\rho}{2} (\mathbf{x}^\top \mathbf{x} - d^2)$ 在 \mathbf{R}^n 上的惟一全局最小点. 关于微分流 $\hat{\mathbf{x}}(\rho)$, 定义如下对偶函数^[5]: 对于 $\rho > 0$, $P_d(\rho) = P(\hat{\mathbf{x}}(\rho)) + \frac{\rho}{2} \hat{\mathbf{x}}^\top(\rho) \hat{\mathbf{x}}(\rho) - \frac{\rho d^2}{2}$.

引理 1^[5]

$$\frac{dP_d(\rho)}{d\rho} = \frac{1}{2} \hat{\mathbf{x}}^\top(\rho) \hat{\mathbf{x}}(\rho) - \frac{d^2}{2}$$

$$\frac{d^2 P_d(\rho)}{d\rho^2} = - \left(\frac{d\hat{\mathbf{x}}(\rho)}{d\rho} \right)^\top [\nabla^2 P(\hat{\mathbf{x}}(\rho)) + \rho \mathbf{I}] \frac{d\hat{\mathbf{x}}(\rho)}{d\rho}$$

引理 2^[5] $\frac{dP_d(\rho)}{d\rho}$ 关于 $\rho > 0$ 单调递减, 而

$P_d(\rho)$ 是关于 $\rho > \rho^*$ 单调递减的.

定理 1^[5] 设 $\hat{\mathbf{x}}(\rho)$, $\rho \in (0, +\infty)$ 为式(6), (7) 定义的微分流, 记

$$\hat{\mathbf{x}}(0^+) = \lim_{\rho \rightarrow 0^+} \hat{\mathbf{x}}(\rho)$$

若 $\hat{\mathbf{x}}^\top(0^+) \hat{\mathbf{x}}(0^+) \leq d^2$, 则 $\hat{\mathbf{x}}(0^+)$ 是 $P(\mathbf{x})$ 在球 D 上的全局最小点.

以下说明应用定理 1 可求解球约束下的全局优化问题(3). 由引理 1 和引理 2 可知, $\|\hat{\mathbf{x}}(\rho)\|$ 关于 $\rho > 0$ 单调递减. 若存在正实数 $\hat{\rho}$ 使得 $\|\hat{\mathbf{x}}(\hat{\rho})\| = d$, 则对任意 $\mathbf{x} \in D$ 有

$$\begin{aligned} P(\mathbf{x}) &\geq P(\mathbf{x}) + \frac{\hat{\rho}}{2} [\mathbf{x}^\top \mathbf{x} - d^2] \geq \\ &\inf_D \left\{ P(\mathbf{x}) + \frac{\hat{\rho}}{2} [\mathbf{x}^\top \mathbf{x} - d^2] \right\} = \\ &P(\hat{\mathbf{x}}(\hat{\rho})) + \frac{\hat{\rho}}{2} (\hat{\mathbf{x}}^\top(\hat{\rho}) \hat{\mathbf{x}}(\hat{\rho}) - d^2) = \\ &P(\hat{\mathbf{x}}(\hat{\rho})) \end{aligned}$$

于是 $\hat{\mathbf{x}}(\hat{\rho})$ 是 $P(\mathbf{x})$ 在球 D 上的全局最小点, 但是 $\|\hat{\mathbf{x}}(\hat{\rho})\| = d$, 这与全局优化问题(P)的所有最优点都含于球 D 的内部这一事实相矛盾, 所以 $[\hat{\mathbf{x}}(0^+)]^\top \cdot \hat{\mathbf{x}}(0^+) < d^2$. 再由定理 1 推知, $\hat{\mathbf{x}}(0^+)$ 是 $P(\mathbf{x})$ 在球 D 上的全局最小点.

注 1: 由于当 $\rho > 0$, $\nabla^2 P(\hat{\mathbf{x}}(\rho)) + \rho \mathbf{I} > 0$, 且 $\|\hat{\mathbf{x}}(\rho)\|$ 关于 $\rho > 0$ 单调递减, 以及 $\hat{\mathbf{x}}^\top(0^+) \hat{\mathbf{x}}(0^+) < d^2$, 考察倒向微分方程(6)可知, 存在正数 σ 使得在 $[0, \rho^*]$ 上一致有 $\nabla^2 P(\hat{\mathbf{x}}(\rho)) + \hat{\rho} \mathbf{I} > \sigma \mathbf{I}$.

2 一个差分-牛顿混合算法

为了在数值计算上实现以上求解球约束优化问题(3)的数学过程, 本节建立一个差分-牛顿混合算法. 算法的基本依据是, 对给定的 $\rho > 0$, 微分流上的点 $\hat{\mathbf{x}}(\rho)$ 是 $L(\mathbf{x}, \rho) = P(\mathbf{x}) + \frac{\rho}{2} (\mathbf{x}^\top \mathbf{x} - d^2)$ 在 \mathbf{R}^n 上的惟一全局最小点, 而 $\hat{\mathbf{x}}(0^+)$ 是 $P(\mathbf{x})$ 在球 D 上的全局最小点. 具体做法是, 利用欧拉差分方法对倒向微分方程进行迭代求解, 而对每次由差分格式得到的点进行一次牛顿法迭代, 即对由差分格式得到的预估点进行一次牛顿法矫正.

算法 1 取误差限 $\epsilon > 0$ 和迭代次数 N .

步骤 1 给定 $\rho_0 > 0$, 对 $[0, \rho_0]$ 作 N 等分, $\rho_k = \frac{(N-k)}{N} \rho_0$, $k = 0, 1, 2, \dots, N$, 则步长为 $h = \frac{1}{N} \rho_0$. 取 $\hat{\mathbf{x}}_0 = \arg \{ \nabla P(\mathbf{x}) + \rho_0 \mathbf{x} = 0 \}$ (即 $\nabla P(\mathbf{x}) + \rho_0 \mathbf{x} = 0$ 的解). $k = 0$.

步骤2 $k=k+1$, 计算差分迭代

$$\tilde{\mathbf{x}}_k = \hat{\mathbf{x}}_{k-1} + h[\nabla^2 P(\hat{\mathbf{x}}_{k-1}) + \rho_{k-1} \mathbf{I}]^{-1} \hat{\mathbf{x}}_{k-1}$$

步骤3 进行一步牛顿法迭代

$$\hat{\mathbf{x}}_k = \tilde{\mathbf{x}}_k - [\nabla^2 P(\tilde{\mathbf{x}}_k) + \rho_k \mathbf{I}]^{-1} [\nabla P(\tilde{\mathbf{x}}_k) + \rho_k \tilde{\mathbf{x}}_k]$$

当 $k < N$, 转到步骤2, 否则转到步骤4.

步骤4 若 $\|\nabla P(\hat{\mathbf{x}}_N)\| < \epsilon$, 取优化问题(3)的最优点 $\mathbf{x}^* \approx \hat{\mathbf{x}}_N$. 否则, $N=2N$, 转到步骤1. 证毕.

注2: 由于 $L(\mathbf{x}, \rho) = P(\mathbf{x}) + \frac{\rho}{2} (\mathbf{x}^T \mathbf{x} - d^2) =$

$P(\mathbf{x}) + \frac{\rho}{2} \mathbf{x}^T \mathbf{x} - \frac{\rho d^2}{2}$, 所以对于给定的 $\rho (> 0)$,

$\min_{\mathbf{x} \in \mathbb{R}^n} L(\mathbf{x}, \rho) \Leftrightarrow \min_{\mathbf{x} \in \mathbb{R}^n} \left(P(\mathbf{x}) + \frac{\rho}{2} \mathbf{x}^T \mathbf{x} \right)$. 这表明算法1并不明显依赖于 d .

以下是关于上述差分-牛顿混合算法的误差估计, 推导中每次出现的正常数 C 有所不同, 仅依赖于多项式 $P(\mathbf{x})$ 本身, 同时也注意到上一节的注1. 由于算法是沿倒向微分流进行的欧拉格式, 所以有以下3个基本估计: 对于 $k=1, 2, \dots, N$, 有

微分流初始条件

$$\|\hat{\mathbf{x}}_0 - \hat{\mathbf{x}}(\rho_0)\| = 0 \quad (8)$$

微分流 Lipschitz 性质

$$\|\hat{\mathbf{x}}(\rho_{k-1}) - \hat{\mathbf{x}}(\rho_k)\| \leq Ch \quad (9)$$

Euler 差分公式误差

$$\|\tilde{\mathbf{x}}_k - \hat{\mathbf{x}}_{k-1}\| \leq Ch \quad (10)$$

定理2 对于 $k=1, 2, \dots, N$, 有 $\|\hat{\mathbf{x}}_k - \hat{\mathbf{x}}(\rho_k)\| \leq Ch$.

证明 基于式(8), 首先施行归纳法, 假设

$$\|\hat{\mathbf{x}}_{k-1} - \hat{\mathbf{x}}(\rho_{k-1})\| \leq Ch \quad (11)$$

由算法1中的步骤3得到

$$\begin{aligned} \|\hat{\mathbf{x}}_k - \tilde{\mathbf{x}}_k\| &= \\ &\|[\nabla^2 P(\hat{\mathbf{x}}_k) + \rho_k \mathbf{I}]^{-1} [\nabla P(\hat{\mathbf{x}}_k) + \rho_k \hat{\mathbf{x}}_k]\| \leq \\ &\|[\nabla^2 P(\hat{\mathbf{x}}_k) + \rho_k \mathbf{I}]^{-1}\| \|\nabla P(\hat{\mathbf{x}}_k) + \rho_k \hat{\mathbf{x}}_k\| \leq \\ &\|[\nabla^2 P(\hat{\mathbf{x}}_k) + \rho_k \mathbf{I}]^{-1} - [\nabla^2 P(\hat{\mathbf{x}}(\rho_{k-1})) + \rho_{k-1} \mathbf{I}]^{-1}\| + \\ &\|[\nabla^2 P(\hat{\mathbf{x}}(\rho_{k-1})) + \rho_{k-1} \mathbf{I}]^{-1}\| \|(\nabla P(\hat{\mathbf{x}}_k) + \rho_k \hat{\mathbf{x}}_k) - \\ &(\nabla P(\hat{\mathbf{x}}(\rho_{k-1})) + \rho_{k-1} \hat{\mathbf{x}}(\rho_{k-1}))\| \leq \\ &(C\|\hat{\mathbf{x}}_k - \hat{\mathbf{x}}(\rho_{k-1})\| + C)(C\|\hat{\mathbf{x}}_k - \hat{\mathbf{x}}(\rho_{k-1})\|) \end{aligned} \quad (12)$$

这里注意到, 在倒向微流上 $\nabla P(\hat{\mathbf{x}}(\rho)) + \rho \hat{\mathbf{x}}(\rho) = 0$, 又注意到(注1), 存在正数 σ 使得在 $[0, \rho^*]$ 上一致有 $\nabla^2 P(\hat{\mathbf{x}}(\rho)) + \rho \mathbf{I} > \sigma \mathbf{I}$. 进一步, 利用归纳法假设式(11)和基本估计式(9)和(10), 有以下估计:

$$\begin{aligned} \|\tilde{\mathbf{x}}_k - \hat{\mathbf{x}}(\rho_k)\| &\leq \|\tilde{\mathbf{x}}_k - \hat{\mathbf{x}}_{k-1}\| + \|\hat{\mathbf{x}}_{k-1} - \hat{\mathbf{x}}(\rho_{k-1})\| + \\ &\|\hat{\mathbf{x}}(\rho_{k-1}) - \hat{\mathbf{x}}(\rho_k)\| \leq Ch \end{aligned}$$

于是由式(12)得到

$$\|\hat{\mathbf{x}}_k - \tilde{\mathbf{x}}_k\| \leq Ch \quad (13)$$

利用式(13), 归纳法假设式(11)以及基本估计式(9)和(10), 最后得到

$$\begin{aligned} \|\hat{\mathbf{x}}_k - \hat{\mathbf{x}}(\rho_k)\| &\leq \|\hat{\mathbf{x}}_k - \tilde{\mathbf{x}}_k\| + \|\tilde{\mathbf{x}}_k - \hat{\mathbf{x}}_{k-1}\| + \\ &\|\hat{\mathbf{x}}_{k-1} - \hat{\mathbf{x}}(\rho_{k-1})\| + \|\hat{\mathbf{x}}(\rho_{k-1}) - \hat{\mathbf{x}}(\rho_k)\| \leq Ch \end{aligned}$$

证毕

3 数值计算的实例

例1 考虑如下全局优化问题:

$$\min P(\mathbf{x}) = x_1^4 + x_2^4 + 2x_1^2 + 2x_2^2 + 4x_1 x_2 + 2x_1 + 2x_2 \quad (14)$$

首先, 计算多项式 $P(\mathbf{x})$ 的梯度和 Hesse 矩阵, 得到

$$\begin{aligned} \nabla P(\mathbf{x}) &= \begin{pmatrix} 4x_1^3 + 4x_1 + 4x_2 + 2 \\ 4x_2^3 + 4x_2 + 4x_1 + 2 \end{pmatrix} \\ \nabla^2 P(\mathbf{x}) &= \begin{pmatrix} 12x_1^2 + 4 & 4 \\ 4 & 12x_2^2 + 4 \end{pmatrix} = \\ &\begin{pmatrix} 12x_1^2 & 0 \\ 0 & 12x_2^2 \end{pmatrix} + \begin{pmatrix} 4 & 4 \\ 4 & 4 \end{pmatrix} \geq 0 \end{aligned}$$

应用算法1, 取误差限 $\epsilon = 10^{-4}$ 和迭代次数 $N = 300$. 取 $\rho_0 = 0.1$, 则步长可以表示为 $h = \frac{1}{N\rho_0} = \frac{1}{10N} > 0$. 求解非线性方程组

$$\begin{pmatrix} 4x_{11}^3 + 4x_{11} + 4x_{12} + 2 \\ 4x_{12}^3 + 4x_{12} + 4x_{11} + 2 \end{pmatrix} + \begin{pmatrix} 0.1x_{11} \\ 0.1x_{12} \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \end{pmatrix}$$

得到 $\hat{\mathbf{x}}_0 = \begin{pmatrix} -0.240 & 1 \\ -0.240 & 1 \end{pmatrix}$. 计算差分迭代

$$\begin{pmatrix} (\tilde{\mathbf{x}}_k)_1 \\ (\tilde{\mathbf{x}}_k)_2 \end{pmatrix} = \begin{pmatrix} (\hat{\mathbf{x}}_{k-1})_1 \\ (\hat{\mathbf{x}}_{k-1})_2 \end{pmatrix} + h \begin{pmatrix} 12(\hat{\mathbf{x}}_{k-1})_1^2 + \rho_{k-1} + 4 & 4 \\ 4 & 12(\hat{\mathbf{x}}_{k-1})_2^2 + \rho_{k-1} + 4 \end{pmatrix}^{-1} \times \begin{pmatrix} (\hat{\mathbf{x}}_{k-1})_1 \\ (\hat{\mathbf{x}}_{k-1})_2 \end{pmatrix}$$

得到 $\hat{\mathbf{x}}_k$ 的预估值 $\tilde{\mathbf{x}}_k$. 再进一步应用牛顿法迭代, 纠正预估值得

$$\begin{pmatrix} (\hat{\mathbf{x}}_k)_1 \\ (\hat{\mathbf{x}}_k)_2 \end{pmatrix} = \begin{pmatrix} (\tilde{\mathbf{x}}_k)_1 \\ (\tilde{\mathbf{x}}_k)_2 \end{pmatrix} - h \begin{pmatrix} 12(\tilde{\mathbf{x}}_k)_1^2 + \rho_k + 4 & 4 \\ 4 & 12(\tilde{\mathbf{x}}_k)_2^2 + \rho_k + 4 \end{pmatrix}^{-1} \times \begin{pmatrix} 4(\tilde{\mathbf{x}}_k)_1^3 + (4+\rho_k)(\tilde{\mathbf{x}}_k)_1 + 4(\tilde{\mathbf{x}}_k)_2 + 2 \\ 4(\tilde{\mathbf{x}}_k)_2^3 + 4(\tilde{\mathbf{x}}_k)_1 + (4+\rho_k)(\tilde{\mathbf{x}}_k)_2 + 2 \end{pmatrix}$$

(下转第822页)