

# 一类分式优化问题的带非单调线搜索的近端梯度次梯度算法研究

张 景

河北工业大学理学院数学系, 天津

收稿日期: 2024年2月27日; 录用日期: 2024年3月21日; 发布日期: 2024年3月28日

## 摘要

本文主要研究一类分式优化问题, 其中分子是凸非光滑连续函数与非凸光滑函数的和, 分母为凸非光滑函数。首先给出了问题的一阶最优化条件, 然后给出了求解分式优化问题的新算法, 即带非单调线搜索的近端梯度次梯度算法(简称NL-PGSA)。此外, 基于Kurdyka-Łojasiewicz性质, 可以保证算法生成的整个序列的全局收敛性, 最后, 对 $l_1/l_2$ 稀疏信号恢复问题进行了数值实验, 验证了该算法的有效性。

## 关键词

分式优化, 近端梯度次梯度算法, 收敛性分析

# Research on the Proximal Gradient-Subgradient Algorithm with Nonmonotonic Line Search for a Class of Fractional Optimization Problems

Jing Zhang

Department of Mathematics, School of Sciences, Hebei University of Technology, Tianjin

Received: Feb. 27<sup>th</sup>, 2024; accepted: Mar. 21<sup>st</sup>, 2024; published: Mar. 28<sup>th</sup>, 2024

文章引用: 张景. 一类分式优化问题的带非单调线搜索的近端梯度次梯度算法研究[J]. 应用数学进展, 2024, 13(3): 1129-1139. DOI: 10.12677/aam.2024.133105

## Abstract

This paper mainly considers a class of fractional optimization problems where the numerator is a sum of a convex nonsmooth continuous function and a nonconvex smooth function, while the denominator is a convex nonsmooth function. We first give the first-order optimality condition of the problem, and then a new algorithm, called proximal gradient-subgradient algorithm with nonmonotonic line search (NL-PGSA), is proposed for solving the fractional optimization problems. Moreover, the global convergence of the entire sequence generated by NL-PGSA algorithm has been proven based on the Kurdyka-Łojasiewicz property. Finally, some numerical experiments on the  $l_1/l_2$  sparse signal recovery problems are conducted to demonstrate the efficiency of the proposed algorithm.

## Keywords

Fractional Optimization, Proximal Gradient-Subgradient Algorithm, Convergence Analysis

Copyright © 2024 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

本文主要考虑的是一类特殊的分式优化问题，其形式为：

$$\min \left\{ \frac{f(x) + h(x)}{g(x)} : x \in \Omega := \{x \in R^n : g(x) \neq 0\} \right\}, \quad (1.1)$$

其中  $f, g, h : R^n \rightarrow \bar{R} := (-\infty, +\infty]$  并满足如下假设：

假设条件1.1.

- (i)  $f$  是恰当凸函数，有下界并且在其有效域上是连续的；

(ii)  $h$ 是一个具有Lipschitz连续梯度的连续可微函数，即存在一个Lipschitz常数 $L$ ，满足

$$\|\nabla h(x) - \nabla h(y)\| \leq L\|x - y\|, \quad \forall x, y \in R^n.$$

(iii)  $g$ 是一个实值凸函数；

(iv)  $f + h$ 在 $R^n$ 上是非负的，在 $R^n \setminus \Omega$ 上不等于0,  $g > 0$ 在 $\text{dom}(f) \cap \Omega$ . 此外，我们还假设问题(1.1)的最优解存在并能够得到。

分式优化问题是最小化或最大化一个或多个函数比值的目标问题，分式优化问题在许多领域都有不同的应用，如人工智能 [1–3]，无线电通信 [4–7]，经济学 [8] 等。因此，针对这一问题许多学者提出了一些有效的方法。其中，参数方法是分式优化问题中常用的思想，他是求解分式优化问题中一种灵活的方法，使用参数方法，我们可以立即证明问题(1.1)的最优解 $x^* \in R^n$ 等价为下列问题的最优解

$$\min \{f(x) + h(x) - c_* g(x) : x \in \Omega\}, \quad (1.2)$$

其中 $c_*$ 代表问题(1.1)的最优值且 $c_* = \frac{f(x^*) + h(x^*)}{g(x^*)}$ ，该方法的优点是他可以求解大规模的分式优化问题，但缺点也很显然，问题(1.1)的全局最优解不易得到。为了克服这一困难，有学者提出了Dinkelbach's方法 [9]，该方法由当前迭代的函数值 $c_k$ 取代 $c_*$ ，具体迭代框架为

$$x^{k+1} \in \operatorname{argmin} \{f(x) + h(x) - c_k g(x) : x \in \Omega\}, \quad (1.3)$$

其中 $c_k = \frac{f(x^k) + h(x^k)}{g(x^k)}$ ，关于该方法的详细论述，可参考文献 [10–12]. 然而，从问题(1.3)可知，该目标函数为非凸函数，要得到全局解也比较困难。

最近，Bot等人 [13]将近端梯度算法(简称PG)应用于当函数 $g$ 为连续可微时的问题(1.1)，具体迭代框架为

$$x^{k+1} \in \operatorname{argmin} \left\{ f(x) + h(x) - c_k \langle \nabla g(x^k), x \rangle + \frac{1}{2\eta_k} \|x - x^k\|^2 : x \in \Omega \right\}, \quad (1.4)$$

其中 $c_k = \frac{f(x^k) + h(x^k)}{g(x^k)}$ ,  $\eta_k > 0$ . 从(1.4)可知，上述迭代实际上采用了 $g(x)$ 在 $x^k$ 处的线性展开。然而，从数值性能来看，当问题规模比较大时，近端梯度算法的速度相对较慢。为了提高收敛速度，许多研究人员采用了各种策略，并提出了一些高效的算法。

Zhang等人 [14]提出了一种近端梯度次梯度的算法(简称PGSA)来解决这个问题，算法的迭代框架为

$$x^{k+1} \in \operatorname{argmin} \left\{ f(x) + \langle \nabla h(x^k) - c_k y^{k+1}, x - x^k \rangle + \frac{1}{2\alpha_k} \|x - x^k\|^2 : x \in \Omega \right\}, \quad (1.5)$$

其中 $y^{k+1} \in \partial g(x^k)$ ,  $0 < \alpha_k \leq 1/L$ ,  $c_k = \frac{f(x^k) + h(x^k)}{g(x^k)}$ . 我们可以看到，上述迭代采用的是 $h(x) - c_k g(x)$ 的线性展开，这恰好是 $\alpha_k f$ 的近端算子。此外，为了加速算法，作者还提出了一种带线搜索的近端梯度次梯度算法(简称PGSA-L)，为保证收敛性，要求步长 $0 < \alpha_k < \frac{1}{L}$ ，但该算法的弊端是当 $L$ 较大时，步长会较小，因此收敛速度相对较慢。

本文受到文献 [14] 的启发, 在  $f$  是凸函数的前提下, 采用了另一种方式的BB 步长并进一步改进了步长的范围, 在函数满足Kurdyka-Łojasiewicz性质的条件下, 可以保证算法的收敛性。

## 2. 预备知识

下面简单介绍与本文相关的一些符号与定义。

定义  $R^n$  为  $n$  维欧式空间,  $\langle \cdot, \cdot \rangle$  为标准内积,  $\|\cdot\|$ ,  $\|\cdot\|_1$  分别为欧式范数与  $l_1$  范数, 集合  $S$  上的示性函数  $I_S(x)$  定义为

$$I_S(x) := \begin{cases} 0, & \text{if } x \in S, \\ +\infty, & \text{otherwise.} \end{cases} \quad (2.1)$$

对于一个扩展的实值函数  $\psi : R^n \rightarrow (-\infty, +\infty]$ , 其有效域为  $\text{dom } \psi := \{x \in R^n : \psi(x) < \infty\}$ . 若  $\forall x \in R^n$ , 都满足  $\psi > -\infty$  且  $\text{dom}(\psi)$  非空, 则  $\psi$  为恰当函数。给定一个非空闭集  $S \subseteq R^n$ , 设  $\text{dist}(\cdot, S) : R^n \rightarrow R$  表示  $x$  到  $S$  的距离函数, 即  $\text{dist}(x, S) := \inf_{y \in S} \|x - y\|, \forall x \in R^n$ .

**定义 2.1.** (*Kurdyka-Łojasiewicz 性质 [15]*) 设函数  $\psi : R^n \rightarrow \bar{R}$  为恰当的下半连续函数,  $\hat{x} \in \text{dom}(\partial\psi)$ , 如果存在  $\eta \in (0, +\infty]$ ,  $\hat{x}$  的一个领域  $O$  及满足下述条件的凹函数  $\phi : [0, \eta) \rightarrow R_+ := [0, +\infty)$

- (i)  $\phi(0) = 0$ ,
  - (ii)  $\phi$  在  $(0, \eta)$  上连续可微且  $\phi' > 0$ ,
  - (iii)  $\forall x \in O \cap \{x \in R^n : \psi(\hat{x}) < \psi(x) < \psi(\hat{x}) + \eta\}$ ,  $\phi'(\psi(x) - \psi(\hat{x})) \cdot \text{dist}(0, \partial\psi(x)) \geq 1$  成立.
- 则称  $\psi$  在点  $\hat{x}$  处满足 *Kurdyka-Łojasiewicz 性质* (简称 *KL 性质*)。

## 3. 主要算法及定理

在本节中, 我们将会给出算法的具体迭代框架, 并保证算法的收敛性证明。为简便, 定义函数  $F$ , 具体形式如下:

$$F(x) := \begin{cases} \frac{f(x) + h(x)}{g(x)}, & \text{if } x \in \Omega \cap \text{dom}(f), \\ +\infty, & \text{else,} \end{cases}$$

其中  $f, g, h$  为问题(1.1)中的目标函数, 因此可以将问题(1.1)写为以下形式:

$$\min \{F(x) : x \in R^n\}. \quad (3.1)$$

在展示算法之前, 我们先给出问题(1.1)的一阶最优化条件。下列定义与文献 [?] 中关于稳定点的定义方式相同。

**定义3.1.** 假设  $x^* \in \text{dom}(F)$ ,  $c_* = F(x^*)$ , 若

$$0 \in \partial f(x^*) + \nabla h(x^*) - c_* \partial g(x^*). \quad (3.2)$$

则  $x^*$  是  $F$  的稳定点。

接下来, 我们将给出算法NL-PGSA的完整框架。

**步骤0** 输入  $x^0 \in \text{dom}(F)$ ,  $a > 0$ ,  $0 < t < 1$ ,  $N \geq 0$ . 设  $k = 0$ .

**步骤1** 计算  $y^{k+1} \in \partial g(x^k)$ ,  $c_k = \frac{f(x^k) + h(x^k)}{g(x^k)}$ ,

选择  $\alpha_{k,0} \in (0, \frac{2}{L})$ .

**步骤2** 当  $m = 0, 1, \dots$  时

$$\alpha_k = \alpha_{k,0} t^m,$$

$$\tilde{x}^{k+1} \in \text{prox}_{\alpha_k f}(x^k - \alpha_k \nabla h(x^k) + \alpha_k c_k y^{k+1}).$$

若  $\tilde{x}^{k+1} \in \text{dom}(F)$  且

$$F(\tilde{x}^{k+1}) \leq \max_{[k-N]_+ \leq i \leq k} c_i - \frac{a}{2} \|\tilde{x}^{k+1} - x^k\|_2^2, \quad (3.3)$$

令  $x^{k+1} = \tilde{x}^{k+1}$  转 **步骤3**.

**步骤3** 令  $k \leftarrow k + 1$  转 **步骤1**.

根据不等式(3.3)可得, 当  $N = 0$  时,  $\{F(x^k) : k \in N\}$  是单调的, 当  $N > 0$  时,  $\{F(x^k) : k \in N\}$  是不单调的。为简便, 采用记号  $\Delta x = x^k - x^{k-1}$ ,  $\Delta h = \nabla h(x^k) - \nabla h(x^{k-1})$ , 关于参数  $\alpha_{k,0}$  的生成方式如下:

$$\alpha_{k,0} = \begin{cases} \max \left\{ \underline{\alpha}, \min \left\{ \bar{\alpha}, \frac{|\langle \Delta x, \Delta h \rangle|}{\|\Delta h\|_2^2} \right\} \right\}, & \text{if } \langle \Delta x, \Delta h \rangle \neq 0, \\ \bar{\alpha}, & \text{else.} \end{cases} \quad (3.4)$$

接下来, 我们给出如下引理, 该引理可以进一步帮助我们验证算法的收敛性。

**引理3.2.** 设  $\{x^k : k \in N\}$  是 NL-PGSA 为解决问题(1.1) 所生成的迭代点列, 则

$$f(x^{k+1}) + h(x^{k+1}) + \left( \frac{1}{\alpha_k} - \frac{L}{2} \right) \|x^{k+1} - x^k\|^2 \leq c_k g(x^{k+1}), \quad (3.5)$$

且  $\forall k \in N$ ,  $\{x^k\} \subseteq \text{dom}(F)$ .

**证明.** 我们采用数学归纳法进行证明, 首先初始点  $x^0 \in \text{dom}(F)$ , 设  $\forall k \in N$ , 都有  $x^0, x^1, \dots, x^k \in \text{dom}(F)$ , 由 NL-PGSA 的迭代框架以及近端算子的定义, 可得

$$\frac{1}{\alpha_k} (x^k - x^{k+1} - \alpha_k \nabla h(x^k) + \alpha_k c_k y^{k+1}) \in \partial f(x^{k+1}),$$

根据假设 1.1,  $f$  是凸函数, 可以得到

$$f(x^{k+1}) + \frac{1}{\alpha_k} \langle x^k - x^{k+1} - \alpha_k \nabla h(x^k) + \alpha_k c_k y^{k+1}, x^k - x^{k+1} \rangle \leq f(x^k)$$

进一步整理得

$$f(x^{k+1}) + \langle x^{k+1} - x^k, \nabla h(x^k) - c_k y^{k+1} \rangle + \frac{1}{\alpha_k} \|x^{k+1} - x^k\|_2^2 \leq f(x^k), \quad (3.6)$$

此外,  $\nabla h$  是 Lipschitz 连续函数, 可得

$$h(x^{k+1}) \leq h(x^k) + \langle \nabla h(x^k), x^{k+1} - x^k \rangle + \frac{L}{2} \|x^{k+1} - x^k\|^2, \quad (3.7)$$

$g$  是凸函数, 且  $\forall k \in N$ ,  $c_k = \frac{f(x^k) + h(x^k)}{g(x^k)} \geq 0$ , 因此

$$c_k g(x^k) + \langle c_k y^{k+1}, x^{k+1} - x^k \rangle \leq c_k g(x^{k+1}). \quad (3.8)$$

将 (3.6), (3.7) 和 (3.8) 相加, 结合  $c_k g(x^k) = \frac{f(x^k) + h(x^k)}{g(x^k)} g(x^k) = f(x^k) + h(x^k)$ , 故

$$f(x^{k+1}) + h(x^{k+1}) + \left( \frac{1}{\alpha_k} - \frac{L}{2} \right) \|x^{k+1} - x^k\|^2 \leq c_k g(x^{k+1}),$$

设  $x^{k+1} \notin \text{dom}(F) = \Omega \cap \text{dom}(f)$ , 因此  $g(x^{k+1}) = 0$ , 根据假设 1.1,  $f + h \geq 0$ , 由算法 NL-PGSA 可得,  $0 < \alpha_k < \frac{2}{L}$ , 结合 (3.5), 可得  $x^{k+1} = x^k$ , 这与  $x^k \in \text{dom}(F)$  矛盾, 因此  $\forall k \in N$ ,  $x^{k+1} \in \text{dom}(F)$ . 引理得证。  $\square$

借助引理 3.2, 进一步得到以下重要结果。

**引理 3.3.** 设  $\{x^k : k \in N\}$  是 NL-PGSA 生成的序列, 则

$$(i) \quad \forall k \in N, F(x^{k+1}) + \left( \frac{1}{\alpha_k} - \frac{L}{2} \right) \frac{\|x^{k+1} - x^k\|^2}{g(x^{k+1})} \leq F(x^k);$$

$$(ii) \quad \lim_{k \rightarrow \infty} \frac{\|x^{k+1} - x^k\|^2}{g(x^{k+1})} = 0;$$

$$(iii) \quad \lim_{k \rightarrow \infty} F(x^k) = \lim_{k \rightarrow \infty} c_k = c_\star;$$

**证明.** 我们首先证明 (i), 根据引理 3.2, 以及  $F(x^{k+1}) = c_{k+1} = \frac{f(x^{k+1}) + h(x^{k+1})}{g(x^{k+1})}$  且  $g(x^{k+1}) > 0$  可得

$$F(x^{k+1}) + \left( \frac{1}{\alpha_k} - \frac{L}{2} \right) \frac{\|x^{k+1} - x^k\|^2}{g(x^{k+1})} \leq F(x^k), \quad (3.9)$$

接下来, 我们证明 (ii), 将不等式 (3.9) 两边的  $k$  从  $k=0$  到  $K$  求和, 可得

$$F(x^{K+1}) + \sum_{k=0}^K \left( \frac{1}{\alpha_k} - \frac{L}{2} \right) \frac{\|x^{k+1} - x^k\|^2}{g(x^{k+1})} \leq F(x^0). \quad (3.10)$$

基于上式以及  $0 < \alpha_k < \frac{2}{L}$ , 可得  $\sum_{k=0}^K (\frac{1}{\alpha_k} - \frac{L}{2}) \frac{\|x^{k+1} - x^k\|^2}{g(x^{k+1})}$  有界, 令  $K \rightarrow \infty$ , 可得  $\lim_{k \rightarrow \infty} \frac{\|x^k - x^{k-1}\|^2}{g(x^{k+1})} = 0$ .

根据(i)和(ii), 可知(iii)成立。  $\square$

接下来, 我们分析NL-PGSA的收敛性, 在适当的假设下, 我们首先证明对于每个外部循环, 其关联的内部循环必须在有限次迭代内终止。我们首先给出下列假设。

**假设条件3.1.** 对任意的  $c_0 \in R$ , 水平集  $\{x \in R^n : F(x) \leq c_0\}$  有界。

**假设条件3.2.**  $f$  在其有效域上是局部Lipschitz连续的。

**假设条件3.3.**  $g$  在  $\Omega$  上是一个连续可微函数且  $\nabla g$  是 Lipschitz 连续的。

**引理3.4.** 在假设3.1成立的条件下, 设  $M := \sup \{g(x) : x \in \text{lev}(F(x), c_0)\}$ , 则

- (i) 在多数  $T$  次迭代中, 算法NL-PGSA的第3步会在  $\alpha_k \geq \hat{\alpha}$  时终止, 其中参数  $\hat{\alpha} = \frac{2t}{L+\alpha M}$ ,  $T := \left\lceil \frac{-\log(\hat{\alpha}(aM+L))}{\log t} + 1 \right\rceil$ ;
- (ii)  $\forall k \in N$ , 有  $x^k \in \text{lev}(F, c_0)$  且  $\{x^k : k \in N\}$  是有界的;
- (iii) 序列  $\{F(x^{l(k)}) : k \in N\}$  是非增的。

**证明.** 首先我们证明(i), 根据引理3.3中的(3.10), 可得  $\forall k \in N$ ,  $F(x^k) \leq F(x^0)$ , 借助假设3.1, 可以得到  $\{x^k : k \in N\}$  是有界的。此外, 因为  $g$  是凸函数, 故  $g$  是连续函数, 因此存在  $M \geq 0$ , 使得对任意的  $k \in N$ , 有  $g(x^k) \leq M$ , 根据算法NL-PGSA的迭代框架,  $\alpha_{k,0} < \frac{2}{L}$ , 因此算法在迭代  $T$  步之后, 对任意的  $k \in N$ , 有  $\alpha_k \leq \frac{2}{L+\alpha M} = \hat{\alpha}/t$ .

接下来, 我们对  $k$  采用数学归纳法, 显然  $x^0 \in \text{lev}(F, c_0)$ , 设  $x^i$  是由算法迭代产生的点, 并且  $x^i \in \text{lev}(F, c_0)$ ,  $i = 0, 1, \dots, k$ , 为了证明(i), 需要说明当  $\alpha_k \leq \hat{\alpha}/t$  时, 有  $\tilde{x}^{k+1} \in \text{dom}(F)$ , 且下式成立

$$F(\tilde{x}^{k+1}) \leq c_k - \frac{a}{2} \|\tilde{x}^{k+1} - x^k\|_2^2, \quad (3.11)$$

由引理3.3(i), 以及  $\alpha_k \leq \frac{2}{L+\alpha M} < \frac{2}{L}$ , 可得  $\tilde{x}^{k+1} \in \text{dom}(F)$ , 并且

$$F(x^{k+1}) \leq c_k - \left(\frac{1}{\alpha_k} - \frac{L}{2}\right) \frac{\|x^{k+1} - x^k\|^2}{g(x^{k+1})} \leq c_k - \frac{\alpha M}{2} \frac{\|x^{k+1} - x^k\|^2}{g(x^{k+1})}, \quad (3.12)$$

由上式可知  $F(\tilde{x}^{k+1}) \leq c_k \leq c_0$ , 因此  $\tilde{x}^{k+1} \in \text{lev}(F, c_0)$ , 此外, 借助  $g(\tilde{x}^{k+1}) \leq M$ , 可由(3.12)得到(3.11).

接下来, 我们证明  $x^{k+1} \in \text{lev}(F, c_0)$ , 为简单起见, 定义

$$l(k) := \max \{j : j \in \arg \max \{F(x^i) : [k-N]_+ \leq i \leq k\}\}, \quad (3.13)$$

借助上述定义以及(3.3), 可得 $\forall i \leq k$ ,  $F(x^{i+1}) \leq F(x^{l(i)})$ , 因此,

$$\begin{aligned} F(x^{l(i+1)}) &= \max_{[i+1-N]_+ \leq j \leq i+1} F(x^j) \\ &= \max \left\{ F(x^{i+1}), \max_{[i+1-N]_+ \leq j \leq i} F(x^j) \right\} \\ &\leq \max \{ F(x^{i+1}), F(x^{l(i)}) \} \\ &= F(x^{l(i)}). \end{aligned} \quad (3.14)$$

得 $F(x^{k+1}) \leq F(x^{l(k)}) \leq F(x^{l(0)}) = c_0$ . 引理得证。  $\square$

下述两个定理即文献 [14]中定理5.2与定理5.3, 定理3.5表明NL-PGSA的子序列是收敛的。定理3.6表明NL-PGSA是全局收敛的。

**定理3.5.** 在假设 1.1, 假设 3.1 成立的前提下, 设 $\{x^k : k \in N\}$ 是 NL-PGSA 生成的序列, 则 $\{x^k : k \in N\}$ 的任意聚点都是 $F$ 的临界点。

**定理3.6.** 在假设 1.1, 3.1, 3.2 以及假设 3.3 成立的前提下, 设 $F$ 在其有效域中的任意一点都满足 KL 性质,  $\{x^k : k \in N\}$ 是 NL-PGSA 生成的序列, 则 $\sum_{k=1}^{\infty} \|x^{k+1} - x^k\|_2 < +\infty$  且 $\{x^k : k \in N\}$ 收敛到 $F$ 的临界点。

## 4. 数值实验

在数值测试中, 我们主要考虑以下带约束的 $l_1/l_2$ 稀疏信号恢复问题:

$$\min \left\{ \frac{\|x\|_1}{\|x\|} : Ax = b, \underline{x} \leq x \leq \bar{x}, x \in R^n \right\}, \quad (4.1)$$

其中 $\underline{x}, \bar{x} \in R^n$ 分别代表基础信号的下限与上限, 通过引入罚参数 $\lambda > 0$ , 上述带约束的优化问题与下列问题等价:

$$\min \left\{ \frac{\lambda \|x\|_1 + \frac{1}{2} \|Ax - b\|^2}{\|x\|} : \underline{x} \leq x \leq \bar{x}, x \in R^n \right\}. \quad (4.2)$$

显然, 问题(4.2)是问题(1.1)的特例, 具体来说,  $f$ 是函数 $\lambda \|x\|_1$ 与示性函数在 $\{\underline{x} \leq x \leq \bar{x}, x \in R^n\}$ 上的和,  $h = \frac{1}{2} \|Ax - b\|^2$ ,  $g = \|x\|$ ,  $\Omega = \{x \in R^n : g(x) \neq 0\}$ , 这里 $A \in R^{m \times n}$ ,  $b \in R^m$ . 由于目标函数是一类分式优化问题, 因为要确保分母的函数值非零, 结合 $g$ 函数的具体形式, 此时初值点不能设为零向量。在这里, 我们采用真实信号 $\tilde{x}$ 来生成初值 $x_0$ . 接下来, 我们构造了一种稀疏度大小为 $K$ 的真实信号 $\tilde{x} \in R^n$ , 我们随机选择一个大小为 $K$ 的支持子集, 其最小分离度至少为 $2D$ , 并在该集合上生成一个支持向量 $\tilde{v} \in R^n$ ,  $sgn$ 代表标准符号函数, 设 $\tilde{x} = sgn(\tilde{v})$ . 最后, 设 $b \in R^m$ ,  $b = A\tilde{x}$ ,  $\underline{x} = -2 \times 1_n$ ,  $\bar{x} = 2 \times 1_n$ , 这里 $1_n$ 代表所有分量都等于1的 $n$ 维向量。

接下来, 我们需要指出 $\tilde{x}$ 满足问题(4.2)的一阶必要性条件。首先 $\tilde{x}$ 在问题(4.2)处的函数值为 $\tilde{c} = \lambda \sqrt{K}$ , 因为 $\tilde{x} \in \partial \|\cdot\|_1(\tilde{x})$ 且 $\nabla (\|\cdot\|_2)(\tilde{x}) = \tilde{x}/\sqrt{K}$ , 则 $0 \in \partial (\lambda \|\cdot\|_1)(\tilde{x}) - \tilde{c} \nabla (\|\cdot\|_2)(\tilde{x})$ . 此外,

$\underline{x} < \tilde{x} < \bar{x}$ ,  $A\tilde{x} = b$ , 可得

$$0 \in \partial \left( \lambda \|\cdot\|_1 + \iota_{\{\underline{x} \leq \underline{x} \leq \bar{x}\}} \right) (\tilde{x}) + A^T(A\tilde{x} - b) - \bar{c}\nabla(\|\cdot\|)(\tilde{x}).$$

这意味着 $\tilde{x}$ 为问题(4.2)的最优解。我们将算法NL-PGSA与算法PGSA-L [14], 进行比较, 接下来, 我们将给出算法的具体参数设置。

- NL-PGSA.  $L = \|A\|^2$ , 初始步长 $\alpha_{0,0} = 1/L$ ,  $\alpha = 10^{-3}$ ,  $t = 0.5$ ,  $N = 4$ .
- PGSA-L. 我们选择的步长参数与文献 [14]一致。

在接下来的实验中, 取维数分别为 $(m,n)=(512,8192)$ 和 $(m,n)=(640,10240)$ , 选择不同的稀疏度 $D = \{1, 5, 10, 15\}$ ,  $K = \{12, 16\}$  来测试 $l_1/l_2$ 稀疏信号恢复问题。在每个 $(D, K)$  设置中, 我们如上述所述随机生成100次数据, 并根据100次数据的平均结果比较上述两种算法。两种算法每次选取的初值为 $x_0 = \tilde{x} + 0.4\xi$ , 这里 $\xi \in R^n$ 其分量满足 $[-1, 1]$  的均匀分布, 当迭代次数达到1000或 $\|x^k - x^{k-1}\|/\max\{1, \|x^k\|\} \leq 10^{-5}$ 时迭代终止。如表 1 和表 2 所示, 我们给出两种算法在迭代次数, CPU 时间(以秒为单位)和迭代终止时的函数值。从表中我们得出结论, 我们的方法表现较好。

**Table 1.** Solving problem (4.2) when  $(m, n) = (512, 8192)$ ,  $\lambda = 5 \times 10^{-4}$

**表 1.** 解决问题(4.2),  $(m, n) = (512, 8192)$ ,  $\lambda = 5 \times 10^{-4}$

	iter		time		F_val	
	$l_1/l_2$ _PGSA-L	$l_1/l_2$ _NL-PGSA	$l_1/l_2$ _PGSA-L	$l_1/l_2$ _NL-PGSA	$l_1/l_2$ _PGSA-L	$l_1/l_2$ _NL-PGSA
D=1,K=12	482	402	2.23297	2.21622	0.098759	0.0907651
D=1,K=16	484	406	2.24221	2.21645	0.098803	0.0906339
D=5,K=12	483	403	2.23481	2.21423	0.098282	0.0907574
D=5,K=16	482	403	2.24031	2.22685	0.098458	0.0908579
D=10,K=12	482	401	2.23166	2.21356	0.098117	0.0907067
D=10,K=16	483	402	2.23102	2.21256	0.098973	0.0905531
D=15,K=12	486	402	2.23308	2.21204	0.098665	0.0909149
D=15,K=16	483	402	2.23208	2.21072	0.098606	0.0902784

**Table 2.** Solving problem (4.2) when  $(m, n) = (640, 10240)$ ,  $\lambda = 5 \times 10^{-4}$

**表 2.** 解决问题(4.2),  $(m, n) = (640, 10240)$ ,  $\lambda = 5 \times 10^{-4}$

	iter		time		F_val	
	$l_1/l_2$ _PGSA-L	$l_1/l_2$ _NL-PGSA	$l_1/l_2$ _PGSA-L	$l_1/l_2$ _NL-PGSA	$l_1/l_2$ _PGSA-L	$l_1/l_2$ _NL-PGSA
D=1,K=12	483	404	3.44432	2.99739	0.192345	0.1917892
D=1,K=16	487	402	3.43452	2.99816	0.193024	0.1915356
D=5,K=12	482	403	3.44371	2.99515	0.192964	0.1912004
D=5,K=16	483	404	3.44735	2.99225	0.192718	0.1911423
D=10,K=12	485	405	3.44345	2.99341	0.192343	0.1911445
D=10,K=16	482	403	3.44462	2.99235	0.192274	0.1911234
D=15,K=12	482	403	3.44351	2.99532	0.192494	0.1912451
D=15,K=16	483	405	3.66209	2.53988	0.254709	0.0563043

## 5. 结论

本文针对一类特殊的分式优化问题，提出了一种新的非单调线搜索的近端梯度次梯度算法。首先，在保证收敛性的前提下，我们扩大了步长的选择范围，这有利于算法更快地移动到目标函数的更优解附近。另一方面，借助数值实验，我们进一步验证了算法的有效性。

## 参考文献

- [1] Baldacci, R., Lim, A., Traversi, E. and Calvo, R.W. (2020) Optimal Solution of Vehicle Routing Problems with Fractional Objective Function. *Transportation Science*, **54**, 434-452.  
<https://doi.org/10.1287/trsc.2019.0929>
- [2] Rahimi, Y., Wang, C., Dong, H. and Lou, Y. (2019) A Scale-Invariant Approach for Sparse Signal Recovery. *SIAM Journal on Scientific Computing*, **41**, A3649-A3672.  
<https://doi.org/10.1137/18M123147X>
- [3] Studer, C. and Baraniuk, R.G. (2014) Stable Restoration and Separation of Approximately Sparse Signals. *Applied and Computational Harmonic Analysis*, **37**, 12-35.  
<https://doi.org/10.1016/j.acha.2013.08.006>
- [4] Candès, E., Romberg, J.K. and Tao, T. (2006) Stable Signal Recovery from Incomplete and Inaccurate Measurements. *Communications on Pure and Applied Mathematics*, **59**, 1207-1223.  
<https://doi.org/10.1002/cpa.20124>
- [5] Hoyer, P.O. (2004) Non-Negative Matrix Factorization with Sparseness Constraints. *Journal of Machine Learning Research*, **5**, 1457-1469.
- [6] Shen, K. and Yu, W. (2018) Fractional Programming for Communication Systems—Part I: Power Control and Beamforming. *IEEE Transactions on Signal Processing*, **66**, 2616-2630.  
<https://doi.org/10.1109/TSP.2018.2812733>
- [7] Zappone, A., Sanguinetti, L. and Debbah, M. (2017) Energy-Delay Efficient Power Control in Wireless Networks. *IEEE Transactions on Communications*, **66**, 418-431.  
<https://doi.org/10.1109/TCOMM.2017.2755644>
- [8] Konno, H. and Inori, M. (1989) Bond Portfolio Optimization by Bilinear Fractional Programming. *Journal of the Operations Research Society of Japan*, **32**, 143-158.  
<https://doi.org/10.15807/jorsj.32.143>
- [9] Clemmensen, L., Hastie, T., Witten, D. and Ersbøll, B. (2010) Sparse Discriminant Analysis. *Technometrics*, **53**, 406-413. <https://doi.org/10.1198/TECH.2011.08118>
- [10] Ibaraki, T. (1983) Parametric Approaches to Fractional Programs. *Mathematical Programming*, **26**, 345-362. <https://doi.org/10.1007/BF02591871>

- 
- [11] Pang, J.S. (1980) A Parametric Linear Complementarity Technique for Optimal Portfolio Selection with a Risk-Free Asset. *Operation Research*, **28**, 927-941.  
<https://doi.org/10.1287/opre.28.4.927>
  - [12] Schaible, S. (1976) Fractional Programming. II, on Dinkelbach's Algorithm. *Management Science*, **22**, 868-873. <https://doi.org/10.1287/mnsc.22.8.868>
  - [13] Bot, R.I. and Csetnek, E.R. (2017) Proximal-Gradient Algorithms for Fractional Programming. *Optimization*, **66**, 1383-1396. <https://doi.org/10.1080/02331934.2017.1294592>
  - [14] Zhang, N. and Li, Q. (2022) First-Order Algorithms for a Class of Fractional Optimization Problems. *SIAM Journal on Optimization*, **32**, 100-129. <https://doi.org/10.1137/20M1325381>
  - [15] Attouch, H., Bolte, J., Redont, P. and Soubeyran, A. (2010) Proximal Alternating Minimization and Projection Methods for Nonconvex Problems: An Approach Based on the Kurdyka-Łojasiewicz Inequality. *Mathematics of Operations Research*, **35**, 438-457.  
<https://doi.org/10.1287/moor.1100.0449>