DOI:10.19431/j. cnki. 1673-0062. 2023. 05. 012

# 求解最小二乘问题的带动量的 Gauss-Seidel 方法

# 尹素素,欧阳自根\*

(南华大学 数理学院,湖南 衡阳 421001)

摘要:最小二乘问题是重要的数学与统计模型,广泛用于回归分析、参数估计、最优控制和数据拟合等领域。基于古典的 Gauss-Seidel 方法,推导了求解最小二乘问题的迭代格式。结合 Gauss-Seidel 方法和 Polyak's Heavy-Ball 技术,提出了动量型 Gauss-Seidel 方法的算法框架。根据贪婪的策略选择指标,建立了贪婪的动量型 Gauss-Seidel 方法的线性收敛性。最后,数值实验表明贪婪的动量型 Gauss-Seidel 方法。
关键词:最小二乘问题;Gauss-Seidel 方法;动量
中图分类号:0241.6 文献标志码:A
文章编号:1673-0062(2023)05-0081-07

### Gauss-Seidel Method with Momentum for Solving Least-Squares Problems

### YIN Susu, OUYANG Zigen\*

(School of Mathmatics and Physics, University of South China, Hengyang, Hunan 421001, China)

Abstract: The least-squares problem is an important mathematical and statistical model, which is widely used in regression analysis, parameter estimation, optimal control and data fitting. Based on the classical Gauss-Seidel method, the iterative scheme for solving the least-squares problem is deduced. Combining Gauss-Seidel method and Polyak's Heavy-Ball technique, an algorithm framework of Gauss-Seidel method with momentum is proposed. The linear convergence of the greedy Gauss-Seidel method with momentum is established by selecting the column index according to the greedy strategy. Finally, numerical experiments show that the greedy Gauss-Seidel method with momentum outperforms the greedy Gauss-Seidel method in terms of iteration steps and computation time.

key words: least squares problem; Gauss-Seidel method; momentum

收稿日期:2023-06-27

基金项目:湖南省自然科学基金项目(2019JJ40240)

作者简介:尹素素(1997—),女,硕士研究生,主要从事数值线性代数及其应用方面的研究。E-mail;yinsusu3072@ 163.com。\*通信作者:欧阳自根(1965—),男,教授,博士,主要从事微分方程及动力学系统方面的研究。 E-mail;zigenouyang@163.com

2)

### 0 引 言

给定线性最小二乘问题  
$$\min_{x \in \mathbb{R}^n} \|Ax - b\|_2^2, \qquad (1)$$

其中 $A = (A_1, A_2, \dots, A_n)$ 是 $m \times n$ 阶的列满秩矩 阵, $b \ge n$ 维列向量。最小二乘问题(1)与其正规 方程 $A^TAx = A^Tb$ 是同解的,其极小范数最小二乘 解为 $x_* = A^{\dagger}b = (A^TA)^{-1}Ab$ ,其中 $A^{\dagger} \ge A$ 的广 义说<sup>[1]</sup>。

最小二乘问题是重要的数学与统计模型,广 泛用于回归分析、参数估计、最优控制和数据拟合 等领域。随着大数据的发展,最小二乘问题是大 规模的,如果运用直接方法求解此类问题,运算量 和储存量都巨大,而迭代法由于运算速度快、储存 量少等优势广受到人们的欢迎。Gauss-Seidel 方 法是求解最小二乘问题的一类重要方法,对于 Gauss-Seidel 方法的已经有很深入的研究<sup>[2-5]</sup>。在 2010年,受T. Strohmer 和R. Vershynin<sup>[6]</sup>的工作启 发, D. Leventhal 和 A. S. Lewis<sup>[7]</sup>提出了随机的 Gauss-Seidel 方法。最近,随机的 Gauss-Seidel 方 法进一步推广或拓展<sup>[8-17]</sup>。Heavy-Ball 技术是 B. T. Polvak 在 1964 年首次提出的<sup>[18]</sup>. 它是梯度型 方法中经典的加速技术<sup>[19]</sup>。本文结合 Gauss-Seidel 方法和 Heavy-Ball 技术,构造了带动量的 Gauss-Seidel 方法(命名为 mG-S)。根据贪婪规则 选择指标 i, 建立了贪婪的 mG-S 方法的线性收敛 性。数值实验进一步表明贪婪的 mG-S 方法求解 大型最小二乘问题(1)时比贪婪的 G-S 方法收敛 得更快.且更有效。

以下是本文中常用的符号列表。

 $A^{\mathrm{T}}, A^{\dagger}$ :矩阵 A 的转置和广义逆;

*e<sub>i</sub>*:n 维标准基向量,第*i*个分量处为1,其余 分量为0;

 $A_i$ :矩阵A的第i列;

 $\sigma_{\min}(A)$ :矩阵A的最小非零奇异值;

∥ · ∥<sub>2</sub>:Euclidean 范数;

‖ · ‖<sub>F</sub>:Frobenius 范数;

 $\| x \|_{A^{T_A}}^2 = \| Ax \|_2^2$ : 加权范数;

 $x^{(k)}$ :第 k 次迭代产生的向量。

### 1 Gauss-Seidel 方法

将 Gauss-Seidel 方法的迭代格式应用到正规 方程  $A^{T}Ax = A^{T}b$  上可以得到 Gauss-Seidel 方法求 解最小二乘问题(1)的迭代格式如下:

$$\boldsymbol{x}_{i}^{(k+1)} = \frac{\boldsymbol{A}_{i}^{\mathrm{T}}\boldsymbol{b}}{\boldsymbol{A}_{i}^{\mathrm{T}}\boldsymbol{A}_{i}} - \frac{\sum_{j=1}^{i-1} \boldsymbol{A}_{i}^{\mathrm{T}}\boldsymbol{A}_{j}\boldsymbol{x}_{j}^{(k+1)}}{\boldsymbol{A}_{i}^{\mathrm{T}}\boldsymbol{A}_{i}} - \frac{\sum_{j=i+1}^{n} \boldsymbol{A}_{i}^{\mathrm{T}}\boldsymbol{A}_{j}\boldsymbol{x}_{j}^{(k)}}{\boldsymbol{A}_{i}^{\mathrm{T}}\boldsymbol{A}_{i}}, \qquad ($$

其中指标 *i* 的选取有很多方式,常见的有如下两种:

随机规则<sup>[7]</sup>:
$$P(\text{index}=i) = \frac{\|A_i\|_2^2}{\|A\|_F^2}$$
。  
贪婪规则<sup>[9]</sup>:

$$i = \underset{j \in [1,2,\cdots,n]}{\arg \max} \left\{ \frac{|A_j^T(b - Ax^{(k)})|^2}{\|A_j\|_2^2} \right\}_{\circ}$$
(3)

在很多情况下,它比简单迭代法收敛快,它和 简单迭代法的不同点在于计算  $x_i^{(k+1)}$  时,利用了 刚刚迭代出的  $x_1^{(k+1)}, x_2^{(k+1)}, \dots, x_{i-1}^{(k+1)}$ 。由于系数 矩阵  $A^{T}A$  是对称正定的,所以 Gauss-Seidel 方法 必收敛。

从当前迭代 **x**<sup>(k)</sup> 到下一步迭代 **x**<sup>(k+1)</sup> 只改变 了第 *i* 个分量的值,因此

 $\mathbf{x}_{j}^{(k+1)} = \mathbf{x}_{j}^{(k)}, j = 1, \dots, i - 1, i + 1, \dots, n_{\circ}$ 进一步

$$\sum_{j=1}^{i-1} \boldsymbol{A}_{i}^{\mathrm{T}} \boldsymbol{A}_{j} \boldsymbol{x}_{j}^{(k+1)} + \sum_{j=i+1}^{n} \boldsymbol{A}_{i}^{\mathrm{T}} \boldsymbol{A}_{j} \boldsymbol{x}_{j}^{(k)} =$$

$$\sum_{j=1}^{i-1} \boldsymbol{A}_{i}^{\mathrm{T}} \boldsymbol{A}_{j} (\boldsymbol{x}_{j}^{(k+1)} - \boldsymbol{x}_{j}^{(k)}) +$$

$$\sum_{j=1}^{n} \boldsymbol{A}_{i}^{\mathrm{T}} \boldsymbol{A}_{j} \boldsymbol{x}_{j}^{(k)} - (\boldsymbol{A}_{i}^{\mathrm{T}} \boldsymbol{A}_{i}) \boldsymbol{x}_{i}^{(k)} =$$

$$\boldsymbol{A}_{i}^{\mathrm{T}} \boldsymbol{A} \boldsymbol{x}^{(k)} - (\boldsymbol{A}_{i}^{\mathrm{T}} \boldsymbol{A}_{i}) \boldsymbol{x}_{i}^{(k)} \circ$$

因此迭代格式(2)化简为

$$\boldsymbol{x}_{i}^{(k+1)} = \frac{\boldsymbol{A}_{i}^{\mathrm{T}}\boldsymbol{b} - \boldsymbol{A}_{i}^{\mathrm{T}}\boldsymbol{A}\boldsymbol{x}^{(k)} + (\boldsymbol{A}_{i}^{\mathrm{T}}\boldsymbol{A}_{i})\boldsymbol{x}_{i}^{(k)}}{A_{i}^{\mathrm{T}}A_{i}} = \boldsymbol{x}_{i}^{(k)} + \frac{\boldsymbol{A}_{i}^{\mathrm{T}}(\boldsymbol{b} - \boldsymbol{A}\boldsymbol{x}^{(k)})}{\|\boldsymbol{A}_{i}\|_{2}^{2}} \circ \qquad (4)$$

本节利用优化理论和 Kaczmarz 的有关理论, 分别解释了 Gauss-Seidel 方法求解最小二乘问题 的迭代原理。

#### 1.1 利用优化理论

最小二乘问题可以看成是无约束优化的最小 值问题,即 $\min_{x \in \mathbb{R}^d} (x), 其中f(x) = \|Ax - b\|_2^2$ 。在 第 k 步迭代,可以给定一个坐标分量  $e_i$  作为精确 的搜索方向,求解优化问题(1),可以得到下一步 迭代

$$\boldsymbol{x}^{(k+1)} = \boldsymbol{x}^{(k)} + \boldsymbol{\alpha}_k \boldsymbol{e}_i,$$

其中  $e_i$  是搜索方向( $\mathbb{R}^n$  中的标准基向量,即第 i个分量为 1,其余分量为 0), $\alpha_k$  是搜索步长。步 长  $\alpha_k$  的选择使得  $f(\mathbf{x}^{(k)} + \alpha_k e_i)$ 达到最小值,即 minf( $\mathbf{x}^{(k)} + \alpha_k e_i$ )。

因此

$$\frac{\partial f(\mathbf{x}^{(k)} + \alpha_k e_i)}{\partial \alpha} = 2\mathbf{e}_i^{\mathrm{T}} [\mathbf{A}^{\mathrm{T}} \mathbf{A} (\mathbf{x}^{(k)} + \alpha_k e_i) - \mathbf{A}^{\mathrm{T}} b] = 0,$$

解得

$$\boldsymbol{\alpha}_{k} = \frac{\boldsymbol{e}_{i}^{\mathrm{T}}\boldsymbol{A}^{\mathrm{T}}\boldsymbol{b} - \boldsymbol{e}_{i}^{\mathrm{T}}\boldsymbol{A}^{\mathrm{T}}\boldsymbol{A}\boldsymbol{x}^{(k)}}{\boldsymbol{e}_{i}^{\mathrm{T}}\boldsymbol{A}^{\mathrm{T}}\boldsymbol{A}\boldsymbol{e}_{i}} = \frac{\boldsymbol{A}_{i}^{\mathrm{T}}(\boldsymbol{b} - \boldsymbol{A}\boldsymbol{x}^{(k)})}{\|\boldsymbol{A}_{i}\|_{2}^{2}} \circ$$

从而

$$\boldsymbol{x}^{(k+1)} = \boldsymbol{x}^{(k)} + \frac{\boldsymbol{A}_{i}^{\mathrm{T}}(\boldsymbol{b} - \boldsymbol{A}\boldsymbol{x}^{(k)})}{\|\boldsymbol{A}_{i}\|_{2}^{2}}\boldsymbol{e}_{i}, \qquad (5)$$

由标准基向量的性质  $\boldsymbol{e}_i^{\mathrm{T}} \boldsymbol{e}_i = 1$  可得 Gauss-Seidel 方法的迭代格式(4)。

#### 1.2 利用 Kaczmarz 算法

Kaczmarz 算法是求解线性系统 *Ay* = *b* 的一类 重要方法<sup>[19-21]</sup> 其第 *k* 步迭代格式为

$$\mathbf{y}^{(k+1)} = \mathbf{y}^{(k)} + \frac{\mathbf{b}_i - \mathbf{A}^{(i)} \mathbf{y}^{(k)}}{\|\mathbf{A}^{(i)}\|_2^2} (\mathbf{A}^{(i)})^{\mathrm{T}},$$

对于最小二乘问题的正规方程  $A^{T}Ax = A^{T}b$ , 令 r = b - Ax, 正规方程变为  $A^{T}r = 0$ 。将 Kaczmarz 迭代格 式应用到上述方程, 可以得到

$$r^{(k+1)} = r^{(k)} - \frac{A_i^{T} r^{(k)}}{\|A_i\|_{2}^{2}} A_{i\circ}$$
  

$$\exists \exists r^{(k)} = b - A x^{(k)}, \exists A_i = A e_{i\circ} \text{ ff V},$$
  

$$A x^{(k+1)} = A x^{(k)} + \frac{A_i^{T} (b - A x^{(k)})}{\|A_i\|_{2}^{2}} A e_i,$$

即

$$A\left(x^{(k+1)} - x^{(k)} - \frac{A_i^{\mathrm{T}}(b - Ax^{(k)})}{\|A_i\|_2^2}e_i\right) = 0$$

由于 A 是列满秩的,所以齐次线性方程组 Az=0 只有零解,从而

$$\mathbf{x}^{(k+1)} - \mathbf{x}^{(k)} - \frac{\mathbf{A}_{i}^{\mathrm{T}}(\mathbf{b} - \mathbf{A}\mathbf{x}^{(k)})}{\|\mathbf{A}_{i}\|_{2}^{2}}\mathbf{e}_{i} = \mathbf{0}_{\circ}$$

显然,得到了与式(5)相同的表达式。

# 2 带动量贪婪的 Gauss-Seidel 方法

本节结合 Gauss-Seidel 方法和 Heavy-Ball 得到如下迭代:

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} + \alpha_k \frac{\mathbf{A}_i^{\mathrm{T}} (\mathbf{b} - \mathbf{A} \mathbf{x}^{(k)})}{\|\mathbf{A}_i\|_2^2} \mathbf{e}_i + \beta_k (\mathbf{x}^{(k)} - \mathbf{x}^{(k-1)})_{\circ}$$
(6)

当 $\alpha_k = 1, \beta_k = 0,$ 迭代格式(6)退化为式(5)。动 量型 Gauss-Seidel 方法的算法框架如下: 算法 1:带动量的 Gauss-Seidel 方法(mG-S)。 输入: $A, b, \alpha_k, \beta_k, \pi N,$ 选择初始值 $x^{(0)} = x^{(1)};$ 输出: $x^{(N)}$ 。

for  $k = 1, 2, \dots, N$  do

根据某一规则选择指标 *i* ∈ {1,2,…,*n*}; 计算迭代格式

$$\boldsymbol{x}^{(k+1)} = \boldsymbol{x}^{(k)} + \alpha_k \frac{\boldsymbol{A}_i^{\mathrm{T}} (b - \boldsymbol{A} \boldsymbol{x}^{(k)})}{\|\boldsymbol{A}_i\|_2^2} \boldsymbol{e}_i + \beta_k (\boldsymbol{x}^{(k)} - \boldsymbol{x}^{(k-1)});$$

endfor

根据贪婪规则(3)选择指标  $i \in \{1, 2, \dots, n\}$ , 算法 1 为贪婪的带动量的 Gauss-Seidel。下面给 出贪婪的 mG-S 方法的全局线性收敛性理论。

定理1 假设0<α<sub>k</sub><2,β<sub>k</sub>>0。令

$$\gamma_1 := 1 + 3\beta_k + 2\beta_k^2 - \alpha_k(2 - \alpha_k + \beta_k) \frac{\sigma_{\min}^2(A)}{\|A\|_F^2}$$

$$\gamma_2 := \beta_k + 2\beta_k^2 + \alpha_k \beta_k,$$

且满足  $\gamma_1 + \gamma_2 < 1$ 。则算法 1 生成的迭代序列  $\{x^{(k)}\}_{k=0}^{\infty}$  收敛到最小二乘解  $x_* = A^{\dagger}b$ 。此外,取

$$\begin{split} \delta &= \frac{-\gamma_1 + \sqrt{\gamma_1^2 + 4\gamma_2}}{2},$$
序列 { $\mathbf{x}^{(k)}$  }   
  $_{k=0}^{\infty}$  满足  
  $\| \mathbf{x}^{(k+1)} - \mathbf{x}_* \|_{A^{T_A}}^2 \leq \rho^k (1 + \delta) \| \mathbf{x}^{(0)} - \mathbf{x}_* \|_{A^{T_A}}^2,$   
 其中 0  $\leq \rho = \delta + \gamma_1 < 1_\circ$ 

证明:令 $z_k = x^{(k)} - x_*$ ,使用算法1中的符号可以得到

$$\boldsymbol{z}_{k+1} = (\boldsymbol{x}^{(k)} - \boldsymbol{x}_{*}) - \alpha_{k} \frac{\boldsymbol{A}_{i}^{\mathrm{T}} \boldsymbol{A} (\boldsymbol{x}^{(k)} - \boldsymbol{x}_{*})}{\|\boldsymbol{A}_{i}\|_{2}^{2}} \boldsymbol{e}_{i} + \beta_{k} (\boldsymbol{x}^{(k-1)} - \boldsymbol{x}^{(k)}) = \boldsymbol{z}_{k} - \alpha_{k} \frac{\boldsymbol{A}_{i}^{\mathrm{T}} \boldsymbol{A} \boldsymbol{z}_{k}}{\|\boldsymbol{A}_{i}\|_{2}^{2}} \boldsymbol{e}_{i} + \beta_{k} (\boldsymbol{x}^{(k)} - \boldsymbol{x}^{(k-1)})_{\circ}$$

则

$$\| \boldsymbol{z}_{k+1} \|_{\boldsymbol{A}^{\mathrm{T}}\boldsymbol{A}}^{2} = \| \boldsymbol{z}_{k} - \boldsymbol{\alpha}_{k} \frac{\boldsymbol{A}_{i}^{\mathrm{T}}\boldsymbol{A}\boldsymbol{z}_{k}}{\| \boldsymbol{A}_{i} \|_{2}^{2}} \boldsymbol{e}_{i} + \beta_{k}(\boldsymbol{x}^{(k)} - \boldsymbol{x}^{(k-1)}) \|_{\boldsymbol{A}^{\mathrm{T}}\boldsymbol{A}}^{2} = \| \boldsymbol{A}\boldsymbol{z}_{k} - \boldsymbol{\alpha}_{k} \frac{\boldsymbol{A}_{i}^{\mathrm{T}}\boldsymbol{A}\boldsymbol{z}_{k}}{\| \boldsymbol{A}_{i} \|_{2}^{2}} \boldsymbol{A}_{i} + \beta_{k}\boldsymbol{A}(\boldsymbol{x}^{(k)} - \boldsymbol{x}^{(k-1)}) \|_{2}^{2} = \| (\boldsymbol{I} - \boldsymbol{\alpha}_{k}\boldsymbol{P}_{i})\boldsymbol{A}\boldsymbol{z}_{k} + \beta_{k}\boldsymbol{A}(\boldsymbol{x}^{(k)} - \boldsymbol{x}^{(k-1)}) \|_{2}^{2}, \quad (7)$$

其中 
$$P_i = \frac{A_i A_i^T}{\|A_i\|_2^2}$$
是正交投影。将式(7)展开得到  
 $\|z_{k+1}\|_{A^TA}^2 = \|(I - \alpha_k P_i)Az_k\|_2^2 + \beta_k^2 \|A(x^{(k)} - x^{(k-1)})\|_2^2 + 2\beta_k \langle Az_k, A(x^{(k)} - x^{(k-1)}) \rangle - 2\alpha_k \beta_k \langle P_i Az_k, A(x^{(k)} - x^{(k-1)}) \rangle$   
(8)  
将式(8)的第一项化简为

$$\| (\boldsymbol{I} - \boldsymbol{\alpha}_{k} \boldsymbol{P}_{i}) \boldsymbol{A} \boldsymbol{z}_{k} \|_{2}^{2} = \| \boldsymbol{A} \boldsymbol{z}_{k} \|_{2}^{2} - \alpha_{k} (2 - \boldsymbol{\alpha}_{k}) \| \boldsymbol{P}_{i} \boldsymbol{A} \boldsymbol{z}_{k} \|_{2}^{2}$$

$$(9)$$

将式(8)的第二项化简为  
$$\|A(\mathbf{x}^{(k)} - \mathbf{x}^{(k-1)})\|_{2}^{2} = \|A(\mathbf{z}_{k} - \mathbf{z}_{k-1})\|_{2}^{2} \leq (\|A\mathbf{z}_{k}\|_{2} + \|A\mathbf{z}_{k-1}\|_{2})^{2} \leq 2 \|A\mathbf{z}_{k}\|_{2}^{2} + 2 \|A\mathbf{z}_{k-1}\|_{2}^{2} (10)$$

特式(8)的第三项化间为  

$$2\langle Az_{k}, A(x_{k} - x_{k-1}) \rangle =$$

$$\|Az_{k}\|_{2}^{2} - \|Az_{k-1}\|_{2}^{2} + \|A(x_{k} - x_{k-1})\|_{2}^{2} \leq$$

$$3\|Az_{k}\|_{2}^{2} + \|Az_{k-1}\|_{2}^{2}, \quad (11)$$
其中第一个不等式用的是平行四边形恒等式  

$$2\langle u, v \rangle = \|u\|_{2}^{2} - \|u - v\|_{2}^{2} + \|v\|_{2}^{2},$$
将式(8)的第四项化简为  

$$2\langle P_{i}Az_{k}, A(x^{(k)} - x^{(k-1)}) \rangle =$$

$$\frac{2}{\|A_{i}\|_{2}^{2}}\langle A_{i}^{T}Az_{k}, A_{i}^{T}A(x^{(k)} - x^{(k-1)}) \rangle =$$

$$\frac{1}{\|A_{i}\|_{2}^{2}}(|A_{i}^{T}Az_{k}|^{2} + |A_{i}^{T}A(x^{(k)} - x^{(k-1)})|^{2} -$$

$$|A_{i}^{T}Az|^{2}) \ge \frac{|A_{i}^{T}Az_{k}|^{2}}{\|A_{i}\|_{2}^{2}} - \frac{|A_{i}^{T}Az_{k-1}|^{2}}{\|A_{i}\|_{2}^{2}}, \quad (12)$$
根据贪婪规则(3)选择的指标 *i* 使下面式子成立:  

$$\|P_{i}Az_{k}\|_{2}^{2} = \frac{|A_{i}^{T}Az_{k}|^{2}}{\|A_{i}\|_{2}^{2}} \ge \sum_{i=1}^{m} \frac{|A_{i}^{T}Az_{k}|^{2}}{\|A_{i}\|_{2}^{2}} \|Az_{k}\|_{F}^{2} =$$

$$\frac{\|A^{T}Az_{k}\|_{2}^{2}}{\|A\|_{F}^{2}} \ge \frac{\sigma_{\min}^{2}(A)}{\|A\|_{F}^{2}} \|Az_{k}\|_{2}^{2},$$

且.

$$\frac{|A_{i}^{T}Az_{k-1}|^{2}}{\|A_{i}\|_{2}^{2}} \leq \|Az_{k-1}\|_{2}^{2}, \|Az_{k}\|_{2}^{2} = \|z_{k}\|_{A^{T}A^{\circ}}^{2}$$
(14)  

$$\# \mathfrak{K}(9) \sim (14) \# \mathfrak{K} \mathfrak{K}(8) \# \mathfrak{Y} \|z_{k+1}\|_{A^{T}A}^{2} \leq (1 + 3\beta_{k} + 2\beta_{k}^{2} -$$

$$\rho^{k}(1+\delta) \| \mathbf{z}_{0} \|_{A^{\mathrm{T}}A^{\mathrm{o}}}^{2}$$

$$\rho = \delta + \gamma_1 = \frac{\gamma_1 + \sqrt{\gamma_1^2 + 4\gamma_2}}{2} < \frac{\gamma_1 + \sqrt{\gamma_1^2 + 4(1 - \gamma_1)}}{2} = 1_{\circ}$$

进一步,序列满足关系

$$\| z_{k+1} \|_{A^{\mathrm{T}}A}^{2} \leq \| z_{k+1} \|_{A^{\mathrm{T}}A}^{2} + \delta \| z_{k} \|_{A^{\mathrm{T}}A}^{2} \leq \rho^{k} (1 + \delta) \| z_{0} \|_{A^{\mathrm{T}}A^{\mathrm{O}}}^{2}$$

因此 $\lim_{k \to +\infty} \| \mathbf{z}_{k+1} \|_{A^{T}A}^{2} = 0$ ,由于 $A^{T}A$ 是正定矩阵,这意味着当 $k \to \infty$ 时,序列 $\mathbf{x}^{(k)}$ 收敛于 $\mathbf{x}_{*}$ 。

# 3 数值实验

(13)

本节通过数值实验来比较贪婪的 G-S(greedy Gauss-Seidel, gG-S)方法和贪婪的 mG-S(greedy Gauss-Seidel method with momentum, gmG-S)方法 求解大规模最小二乘问题(1)的有效性。为了构造一个最小二乘问题,设b=Ax+r,其中x是一个向量,用 MATLAB 函数x=randn(n,1)生成的,残差r在矩阵 $A^{T}$ 的零空间里面,其中 $A^{T}$ 的零空间 是利用 MATLAB 函数 null(A')生成的。测试矩 阵为由 MATLAB 函数A=randn(m,n)生成的高斯矩阵或从 Florida 稀疏矩阵集<sup>[22]</sup>选择的实矩 阵。在贪婪的 mG-S 方法中,参数 $\alpha_{k}=1,\beta_{k}=\left(\frac{\sigma_{max}(A)-\sigma_{min}(A)}{\sigma_{max}(A)+\sigma_{min}(A)}\right)^{2}$ 。迭代步数(IT)和计算时间(CPU)是50次独立重复实验所需迭代步数和 CPU 时间的平均数。贪婪的 G-S 方法相对贪婪的 mG-S 方法的加速度定义为:

### speed-up= gG-S的CPU时间 gmG-S的CPU时间。

所有实验都是用个人电脑计算机上的 MATLAB(R2017b)实现。所有的计算都是从初 始向量 $x^{(0)} = zeros(n,1)$ 开始的,一旦解的相对误 差(relative error,RE)小于10<sup>-6</sup>,迭代终止,其中相 对误差定义为:

$$\operatorname{RE} = \frac{\parallel \boldsymbol{x}^{(k)} - \boldsymbol{x}_* \parallel_2^2}{\parallel \boldsymbol{x}_* \parallel_2^2} \circ$$

对于随机生成的矩阵,将 gG-S 和 gmG-S 方法 的迭代步数(IT)和计算时间(CPU)列在表1~表 3中。从 Florida 稀疏矩阵集<sup>[22]</sup>选择4个具有代 表性的系数矩阵,其矩阵性质见表4,相应数值结 果也列在表4中。从这些表中,可以看到 gmG-S 方法在迭代次数和计算时间方面优于 gG-S 方法, 并有显著的加速。

#### 表 1 对于稠密矩阵,当m=2000时,gG-S和gmG-S的实验结果 Table 1 Results of gG-S and gmG-S methods for dense matrices with m=2000

n		100	200	300	400	500	
gG-S	IT	254.8	642.9	1 181.0	1 905.5	2 864.3	
	CPU	1.3×10 <sup>-3</sup>	3.0×10 <sup>-3</sup>	5.9×10 <sup>-3</sup>	$1.1 \times 10^{-2}$	$2.2 \times 10^{-2}$	
gmG-S	IT	237.8	551.6	925.7	1 359.3	1 875.4	
	CPU	1.3×10 <sup>-3</sup>	2.9×10 <sup>-3</sup>	5.4×10 <sup>-3</sup>	$1.0 \times 10^{-2}$	$1.8 \times 10^{-2}$	
speed-up		1.012	1.049	1.083	1.130	1.260	

表 2 对于稠密矩阵,当m=5000时,gG-S和gmG-S的实验结果 Table 2 Results of gG-S and gmG-S methods for dense matrices with m=5000

n		100	200	300	400	500
gG-S	IT	208.6	480.0	800.6	1 175.6	1 599.0
	CPU	1.2×10 <sup>-3</sup>	3.7×10 <sup>-3</sup>	6.5×10 <sup>-3</sup>	9.5×10 <sup>-3</sup>	$1.4 \times 10^{-2}$
gmG-S	IT	205.6	455.9	740.5	1 048.0	1 380.1
	CPU	$1.1 \times 10^{-3}$	3.3×10 <sup>-3</sup>	6.1×10 <sup>-3</sup>	9.0×10 <sup>-3</sup>	$1.4 \times 10^{-2}$
speed-up		1.062	1.107	1.063	1.051	1.039

表 3 对于稠密矩阵,当m=5000时,gG-S和gmG-S的实验结果 Table 3 Results of gG-S and gmG-S methods for dense matrices with m=5000

n		600	700	800	900	1 000
gG-S	IT	2 088.2	2 639.6	3 247.1	3 946.3	4 775.1
	CPU	1.5×10 <sup>-2</sup>	2.5×10 <sup>-2</sup>	3.3×10 <sup>-2</sup>	4.3×10 <sup>-2</sup>	5.0×10 <sup>-2</sup>
gmG-S	IT	1 731.2	2 108.0	2 518.3	2 941.5	3 407.0
	CPU	1.5×10 <sup>-2</sup>	$2.4 \times 10^{-2}$	$2.8 \times 10^{-2}$	3.5×10 <sup>-2</sup>	4.3×10 <sup>-2</sup>
speed-up		1.008	1.048	1.201	1.240	1.161

图 1 绘制了贪婪的 G-S 和贪婪的 mG-S 方法 的以 10 为基数的对数相对误差(RE)与 IT(每组 的左边)和 CPU 时间(每组的右边)的曲线。从 图 1 可以看到贪婪的 G-S 方法所需的 IT 大约是 贪婪的 mG-S 方法的 1.5 倍。更好的是,贪婪的 mG-S 方法比贪婪的 G-S 方法快 1 到 2 倍。 总之,从数值结果可以看出,对于稠密和 Florida 稀疏线性最小二乘法,贪婪的 mG-S 方法 不仅比贪婪的 G-S 方法需要更少的 IT,而且贪婪 的 mG-S 方法比婪的 G-S 方法需要更少的 CPU 时间。





表 4 稀疏矩阵,gG-S 和 gmG-S 的实验结果 Table 4 Results of gG-S and gmG-S methods for Florida sparse matrices

	riorida sparse matrices							
名称		ash958	bibd_14_7	divorce	df2177			
m		958	91	50	630			
n		292	3 432	9	10 358			
密度		0.68%	23.08%	50.00%	0.34%			
条件数		3.2	8.12	19.39	2.01			
gG-S	IT	935.9	801.6	418.1	1 599.0			
	CPU	4.8×10 <sup>-3</sup>	3.1×10 <sup>-3</sup>	1.2×10 <sup>-3</sup>	$1.2 \times 10^{-2}$			
gmG-S	IT	831.0	347.7	234.2	1 547.0			
	CPU	4.4×10 <sup>-3</sup>	$1.7 \times 10^{-3}$	9.1×10 <sup>-4</sup>	$1.0 \times 10^{-2}$			
speed-up		1.089	1.821	1.366	1.202			

### 4 结 论

本文提出了求解大规模最小二乘问题的带动 量的 Gauss-Seidel 方法,并结合指标选择的贪婪规 则证明研究了贪婪的 mG-S 方法的收敛性。通过 数值实验表明,贪婪的 mG-S 方法求解最小二乘 问题在迭代步数和 CPU 时间上都优于贪婪的 G-S 方法。

#### 参考文献:

- [1] 王国荣.矩阵与算子广义逆[M].北京:科学出版社, 1994:1-6.
- [2] 赵丹. 雅可比迭代法与高斯-塞德尔迭代法研究[J]. 兴义民族师范学院学报,2012(2):108-112.
- [3] HUANG Y H. The convergence analysis for the preconditioned Gauss-Seidel iterative method[J]. Journal of xichang college(natural science edition), 2011,25(1):15-17.
- [4] 李庆扬, 王能超, 易大义. 数值分析 [M]. 5 版. 武汉: 华中科技大学出版社, 2018: 205-207.

- [5] 李庆扬, 王能超, 易大义. 数值分析[M]. 5 版. 北京: 清华大学出版社, 2008:188-190.
- [6] STROHMER T, VERSHYNIN R. A randomized Kaczmarz algorithm with exponential convergence [J]. Journal of fourier analysis and applications, 2009, 15(2):262-278.
- [7] LEVENTHAL D, LEWIS A S. Randomized methods for linear constraints; Convergence rates and conditioning[J]. Mathematics of operations research, 2010, 35(3):641-654.
- [8] GOWER R M,RICHTÁRIK P. Randomized iterative methods for linear systems [J]. SIAM journal on matrix analysis and applications,2015,36(4):1660-1690.
- [9] NUTINI J, SCHMIDT M, LARADJI I H, et al. Coordinate descent converges faster with the Gauss-Southwell rule than random selection [J]. International journal of technology management, 2015, 43(1):1632-1641.
- [10] HEFNY A, NEEDELL D, RAMDAS A. Rows versus columns:Randomized Kaczmarz or Gauss-Seidel for ridge regression [J]. SIAM journal on scientific computing, 2017,39(5):S528-S542.
- [11] MA A, NEEDELL D, RAMDAS A. Convergence properties of the randomized extended Gauss-Seidel and Kaczmarz methods[J]. SIAM journal on matrix analysis and applications, 2015, 36(4):1590-1604.
- [12] LIU Y, JIANG X L, GU C Q. On maximum residual block and two-step Gauss-Seidel algorithms for linear least-squares problems [J]. Calcolo, 2021, 58(2):13.
- [13] DU K, SUN X H. A doubly stochastic block Gauss-Seidel algorithm for solving linear equations [J]. Applied mathematics and computation, 2021, 408(1):126373.
- [14] RAZAVIYAYN M, HONG M Y, REYHANIAN N, et al. A linearly convergent doubly stochastic Gauss-Seidel algorithm for solving linear equations and a certain class of over-parameterized optimization problems[J]. Mathematical programming, 2019, 176(1):465-496.

(下转第96页)

# 3 结 论

通过过硫酸铵浸渍重铀酸铵的改性处理,可 有效提升 UO<sub>3</sub> 的表面酸性,显著提高其催化乙醇 脱水制乙烯的性能。NH<sub>3</sub>-TPD-MS 测定表面酸性 的实验结果表明,S<sub>2</sub>O<sup>2-</sup><sub>8</sub> 的引入能将 UO<sub>3</sub> 的表面 酸位密度提升 11 倍;经 550 ℃ 焙烧制得的固体 酸,在 275 ℃、乙醇重时空速为 1.63 h<sup>-1</sup> 的反应条 件下,乙醇的转化率及乙烯收率均可达 100%。 本研究对拓宽贫铀的应用领域,实现其高价值利 用及醇脱水制乙烯的高效催化有重要意义。

#### 参考文献:

- PHUNG T K, BUSCA G. Diethyl ether cracking and ethanol dehydration: Acid catalysis and reaction paths [J]. Chemical engineering journal, 2015, 272:92-101.
- [2] CHEN Y, WU Y L, TAO L, et al. Dehydration reaction of bio-ethanol to ethylene over modified SAPO catalysts
   [J]. Journal of industrial and engineering chemistry, 2010,16(5):717-722.
- [3] FROSI M, TRIPODI A, CONTE F, et al. Ethylene from renewable ethanol: Process optimization and economic feasibility assessment[J]. Journal of industrial and engineering chemistry, 2021, 104:272-285.
- [4] MISHRA H K, DALAI A K, DAS D D, et al. Sulfated nanozirconia: An investigation on acid-base properties and n-butane isomerization activity[J]. Journal of colloid and interface science, 2004, 272(2):378-383.
- [5] URZHUNTSEV G A, OVCHINNIKOVA E V, CHUMA-

(上接第86页)

- [15] EDALATPOUR V, HEZARI D, SALKUYEH D K. A generalization of the Gauss-Seidel iteration method for solving absolute value equations [J]. Computational and applied mathematics, 2017, 293 (1):156-167.
- [16] CHEN L, SUN D F, TOH K C. An efficient inexact symmetric Gauss-Seidel based majorized ADMM for high-dimensional convex composite conic programming[J]. Mathematical programming, 2017, 161(1):237-270.
- [17] DU K. Tight upper bounds for the convergence of the randomized extended Kaczmarz and Gauss-Seidel algorithms[J]. Numerical linear algebra with applications, 2019,26(3):2233.
- [18] POLYAK B T. Some methods of speeding up the convergence of iteration methods [J]. USSR computational mathematics and mathematical physics, 1964, 4 (5):

CHENKO V A, et al. Isomerization of n-butane over Pd- $SO_4/ZrO_2$  catalyst: Prospects for commercial application [J]. Chemical engineering journal,2014,238:148-156.

- [6] LIU Y, WU G Q, PANG X Y, et al. Isobutane alkylation with 2-butene in novel ionic liquid/solid acid catalysts [J]. Fuel, 2019, 252:316-324.
- [7] AHMED I, KHAN N A, MISHRA D K, et al. Liquidphase dehydration of sorbitol to isosorbide using sulfated titania as a solid acid catalyst[J]. Chemical engineering science, 2013,93:91-95.
- [8] WANG J, WANG A, TIAN X, et al. Development of palygorskite-SO<sub>4</sub><sup>2-</sup>/ZnAl<sub>2</sub>O<sub>4</sub> composites as a novel solid acid catalyst for the esterification of acetic acid with n-butanol [J]. Applied clay science, 2017, 135:596-602.
- [9] SPANO T L, SHIELDS A E, BARTH B, et al. Computationally guided investigation of the optical spectra of pure  $\beta$ -UO<sub>3</sub>[J]. Inorganic chemistry, 2020, 59(16):11481-11492.
- [10] DONG Y Y, LIAO W P, SUO Z H. Uranium oxide-supported gold catalyst for water-gas shift reaction [J]. Fuel processing technology, 2015, 137:164-169.
- [11] SCHREINEMACHERS C, LEINDERS G, MODOLO G, et al. The conversion of ammonium uranate prepared via sol-gel synthesis into uranium oxides[J]. Nuclear engineering and technology, 2020, 52(5):1013-1021.
- [12] BERTEAU P, DELMON B. Modified aluminas: Relationship between activity in 1-butanol dehydration and acidity measured by NH<sub>3</sub> TPD [J]. Catalysis today, 1989, 5 (2):121-137.
- [13] 陆翠云,张叶龙,韩毓旺,等. Mo/HZSM-5 催化乙醇脱水制乙烯[J].石油化工,2011,40(12):1281-1286.

1-17.

- [19] LOIZOU N, RICHTÁRIK P. Momentum and stochastic momentum for stochastic gradient, Newton, proximal point and subspace descent methods[J]. Computational optimization and applications, 2020, 77(3):653-710.
- [20] KACZMARZ S. Angenäherte auflösung von systemen linearer gleichungen[J]. Bulletin international de l'académie polonaise des sciences et des lettres,1937,35(1):355-357.
- [21] VAN LITH B, HANSEN P C, HOCHSTENBACH M E. A twin error gauge for Kaczmarz's iterations [J]. SIAM journal on scientific computing, 2021, 43(5):S173-S199.
- [22] DAVIS T A, HU Y F. The university of florida sparse matrix collection [J]. ACM transactions on mathematical software, 2011, 38(1):1-25.