

# 基于Anderson加速分裂迭代算法求解多重线性PageRank问题

陆思雅

广东工业大学数学与统计学院, 广东 广州

收稿日期: 2024年12月5日; 录用日期: 2025年1月10日; 发布日期: 2025年1月28日

## 摘要

本文针对多重线性PageRank问题, 结合松弛技术, 提出了一般形式的张量分裂迭代算法, 并给出了相应的收敛性分析。进一步, 结合Anderson加速技术, 提出了新的张量分裂算法。

## 关键词

多重线性PageRank问题, 张量分裂, Anderson加速

# Solving Multilinear PageRank Problem Based on Anderson Accelerated Splitting Iteration Algorithm

Siya Lu

School of Mathematics and Statistics, Guangdong University of Technology, Guangzhou Guangdong

Received: Dec. 5<sup>th</sup>, 2024; accepted: Jan. 10<sup>th</sup>, 2025; published: Jan. 28<sup>th</sup>, 2025

## Abstract

In this paper, combining relaxation techniques, a general form of tensor splitting iterative algorithm is proposed for the multilinear PageRank problem, and the corresponding convergence analysis is given. Furthermore, a new tensor splitting algorithm is proposed by incorporating Anderson acceleration techniques.

## Keywords

Multilinear PageRank Problem, Tensor Splitting, Anderson Acceleration



## 1. 引言

Google 首次提出 PageRank 模型来决定一个代表网页的有向图的重要节点, 即网页排序问题[1]。给定一个有向图的随机行走, 修正后的 PageRank 模型建立一个存在唯一稳定分布的新的马尔科夫链。尽管 Google 为网络图描述了 PageRank, 但相同的方法已部署在许多应用程序中[2]-[5]。由于 PageRank 模型的广泛成功, 再根据如今实际应用中高维数据的需要, Gleich 等[6]提出了高阶 PageRank 问题, 它是一阶问题的推广。但是, 同时他们也发现了高阶 PageRank 的存储障碍[6], 之后, 他们根据 Li 和 Ng [7]提出的秩 1 对称近似估计, 希望利用这种估计的存储量小的优势, 进一步提出多重线性 PageRank 模型。

令  $\mathbb{R}$  为实数域,  $\mathbb{R}^n$ 、 $\mathbb{R}^{k \times n}$ 、 $\mathbb{R}^{[m,n]}$  分别为  $n$  维向量、 $k \times n$  维矩阵、 $m$  阶  $n$  维张量。称向量  $\mathbf{s} = (s_i) \in \mathbb{R}^n$  为随机向量, 即对于所有  $i \in n$ , 有  $s_i \geq 0$  并且  $\sum_{i=1}^n s_i = 1$ , 其中  $n = \{1, \dots, n\}$ 。  $\mathcal{P} = (p_{i_1 i_2 \dots i_m})$  是一个  $m$  阶  $n$  维张量, 具体为:

$$p_{i_1 i_2 \dots i_m} \geq 0, \sum_{i_1=1}^n p_{i_1 i_2 \dots i_m} = 1, \forall i_2 \dots i_m \in n.$$

Gleich 等[6]基于秩-1 近似估计技术[7]提出多重线性 PageRank 问题:

$$\mathbf{x} = \alpha \mathcal{P} \mathbf{x}^{m-1} + (1 - \alpha) \mathbf{v}, \quad (1.1)$$

并且

$$(\mathcal{P} \mathbf{x}^{m-1})_i \triangleq \sum_{i_2, \dots, i_m=1}^n p_{i i_2 \dots i_m} x_{i_2} \dots x_{i_m} \in \mathbb{R}^n,$$

其中,  $\alpha \in (0, 1)$ 、 $\mathbf{v} \in \mathbb{R}^n$  是随机向量,  $\mathbf{x} \in \mathbb{R}^n$  为特求的 PageRank 向量。

近年来, 多重线性 PageRank 问题引起了研究人员的极大关注。许多用于求解方程(1.1)的理论分析[8]-[11]和相关算法[12]-[17]。在现有的研究中, 多重线性 PageRank 问题的算法大致为基于梯度的相关算法和不涉及梯度计算的算法。对于基于梯度的相关算法, 在[6]中开发了一种 Newton 方法。Meini 等[12]和 Guo 等[13]分别研究了 Perron-Newton 法和多步牛顿法。对于非梯度法, 在[6]中给出定点法、移位定点法、内-外方法和反幂方法。众所周知, 梯度计算的难度可能导致高计算成本, 而非梯度算法在处理非对称张量模型时, 在计算效率方面具有天然的优势。分裂算法是张量计算中的一种经典非梯度算法。Li 等[14]和 Liu 等[18]研究了用于求解张量方程的张量分裂算法。

分裂算法在张量计算中有着重要应用, 并且分裂算法属于非梯度算法, Anderson 加速技术[17]也是一种通用且有用的技术, 用于加速矩阵情况下不动点问题的迭代非常成功, 本文将探索分裂迭代的 Anderson 加速, 用于求解基于(1.1)的多重线性 PageRank 问题。

本文的主要贡献如下: 1) 我们提出求解多重线性 PageRank 问题的分裂方法的一般形式, 并对所提出的方法进行了收敛分析; 2) 我们提出了 Anderson 加速张量分裂迭代方法来解决多重线性 PageRank 问题。

## 2. 预备知识

首先介绍我们文中用到的符号和基本知识。令  $\mathcal{S}_1 = \{\mathbf{x} \in \mathbb{R}^n : \mathbf{x} \geq 0, \|\mathbf{x}\|_1 = 1\}$ 。  $\mathcal{A}$  是一个  $m$  阶  $n$  维张量,  $\mathcal{A} = (a_{i_1 i_2 \dots i_m})$ ,  $a_{i_1 i_2 \dots i_m} \in \mathbb{R}$ ,  $i_1, i_2, \dots, i_m \in n$ 。

一个  $n$  维张量  $\mathcal{A} = (a_{ijk}) \in \mathbb{R}^{[3,n]}$  的模-1 展开如下:

$$\mathcal{A}_{(1)} = \begin{bmatrix} a_{111} & \cdots & a_{1n1} & a_{112} & \cdots & a_{1n2} & \cdots & a_{11n} & \cdots & a_{1nn} \\ a_{211} & \cdots & a_{2n1} & a_{212} & \cdots & a_{2n2} & \cdots & a_{21n} & \cdots & a_{2nn} \\ \vdots & \ddots & \vdots & \vdots & \ddots & \vdots & \cdots & \vdots & \ddots & \vdots \\ a_{n11} & \cdots & a_{nn1} & a_{n12} & \cdots & a_{nn2} & \cdots & a_{n1n} & \cdots & a_{nnn} \end{bmatrix}.$$

在本文中, 我们对张量切片作为分裂对象, 对每片切片采用同一种分裂方式. 接下来, 我们分别介绍对角面张量、下三角张量、严格下三角张量、上三角张量和严格上三角张量的定义, 这将在下文中使用.

**定义 1:** [14] 令张量  $\mathcal{D} \in \mathbb{R}^{[m,n]}$ ,  $m \geq 3$  为一个对角面张量, 其中

$$a_{ij_1j_2 \cdots j_m} = 0, \quad i \neq j.$$

张量  $\mathcal{L} (\mathcal{L}') \in \mathbb{R}^{[m,n]}$  为(严格)下三角张量, 其中

$$a_{i_1i_2 \cdots i_m} = 0, \quad i_1 \leq i_2 \quad (i_1 < i_2).$$

张量  $\mathcal{U} (\mathcal{U}') \in \mathbb{R}^{[m,n]}$  为(严格)上三角张量, 其中

$$a_{i_1i_2 \cdots i_m} = 0, \quad i_1 \geq i_2 \quad (i_1 > i_2).$$

**注 1:** 令  $\mathcal{D}$ 、 $\mathcal{L}$ 、 $\mathcal{L}'$ 、 $\mathcal{U}$  和  $\mathcal{U}'$  为张量  $\mathcal{A}$  的对角面部分、下三角部分、严格下三角部分、上三角部分、严格上三角部分. 对任意  $\mathbf{x} \in \mathbb{R}^n$ , 不难检验得出  $\mathcal{D}\mathbf{x}^{m-2}$ 、 $\mathcal{L}\mathbf{x}^{m-2}$ 、 $\mathcal{L}'\mathbf{x}^{m-2}$ 、 $\mathcal{U}\mathbf{x}^{m-2}$  和  $\mathcal{U}'\mathbf{x}^{m-2}$  为  $\mathcal{A}\mathbf{x}^{m-2}$  的对角部分、下三角部分、严格下三角部分、上三角部分、严格上三角部分.

多重线性 PageRank 问题解的唯一性一直是许多学者关注的问题[6] [8]-[11]. 本文将基于[11]中的唯一性条件给出收敛性分析. 现引入高阶遍历性系数定义.

**定义 2:** 令  $\mathcal{P} \in \mathbb{R}^{[3,n]}$  高阶遍历系数的定义如下:

$$\begin{aligned} \mathcal{T}_L(\mathcal{P}) &= \max_{\mathbf{x} \in \mathbb{S}_1} \max_{\mathbf{y} \in \mathbb{Z}_1} \|\mathcal{P}\mathbf{x}\mathbf{y}\|_1, \\ \mathcal{T}_R(\mathcal{P}) &= \max_{\mathbf{x} \in \mathbb{S}_1} \max_{\mathbf{y} \in \mathbb{Z}_1} \|\mathcal{P}\mathbf{y}\mathbf{x}\|_1, \\ \mathcal{T}(\mathcal{P}) &= \max_{\mathbf{x} \in \mathbb{S}_1} \max_{\mathbf{y} \in \mathbb{Z}_1} \|\mathcal{P}\mathbf{x}\mathbf{y} + \mathcal{P}\mathbf{y}\mathbf{x}\|_1, \end{aligned}$$

具体的计算公式为:

$$\begin{aligned} \mathcal{T}_L(\mathcal{P}) &= \frac{1}{2} \max_{j, k_1, k_2} \sum_i^n |\mathcal{P}_{ijk_1} - \mathcal{P}_{ijk_2}|, \\ \mathcal{T}_R(\mathcal{P}) &= \frac{1}{2} \max_{j_1, j_2, k} \sum_i^n |\mathcal{P}_{ij_1k} - \mathcal{P}_{ij_2k}|, \\ \mathcal{T}(\mathcal{P}) &= \frac{1}{2} \max_{j, k_1, k_2} \sum_i^n |\mathcal{P}_{ijk_1} - \mathcal{P}_{ijk_2} + \mathcal{P}_{ik_1j} - \mathcal{P}_{ik_2j}|. \end{aligned}$$

进一步, 若  $\mathcal{P} \in \mathbb{R}^{[3,n]}$  为随机张量, 容易得出,

$$\begin{aligned} \mathcal{T}_L(\mathcal{P}) &= 1 - \min_{j, k_1, k_2} \sum_i^n \min\{\mathcal{P}_{ijk_1}, \mathcal{P}_{ijk_2}\} \\ \mathcal{T}_R(\mathcal{P}) &= 1 - \min_{j_1, j_2, k} \sum_i^n \min\{\mathcal{P}_{ij_1k}, \mathcal{P}_{ij_2k}\} \\ \mathcal{T}(\mathcal{P}) &= 2 - \min_{j, k_1, k_2} \sum_i^n \min\{\mathcal{P}_{ijk_1} + \mathcal{P}_{ik_1j}, \mathcal{P}_{ijk_2} + \mathcal{P}_{ik_2j}\}. \end{aligned}$$

对于随机张量  $\mathcal{P}$ , 有  $0 \leq T_L(\mathcal{P}) \leq 1$ ,  $0 \leq T_R(\mathcal{P}) \leq 1$ , 和  $0 \leq T(\mathcal{P}) \leq T_L(\mathcal{P}) + T_R(\mathcal{P}) \leq 2$ 。

**定义 3:** 令  $A, M \in \mathbb{R}^{[2,n]}$ , 若  $M$  是非奇异矩阵, 我们称  $A = M - N$  为矩阵  $A$  的分裂, 分裂形式具体为:

- 1) 正则分裂, 若  $M^{-1} \geq 0, N \geq 0$ ; 2) 弱正则分裂, 若  $M^{-1} \geq 0, M^{-1}N \geq 0$ 。

### 3. 提出的算法及收敛性分析

令  $\mathbf{x} \in \mathbb{R}^n$  含有正元素的向量。我们定义投影算子  $\text{proj}(\mathbf{x}) = \frac{\max(\mathbf{x}, 0)}{\mathbf{e}^\top \max(\mathbf{x}, 0)}$ 。结合松弛技术[15], 我们设计

出张量分裂迭代算法如下:

---

**算法 1** 张量分裂迭代

---

输入: 给定随机向量  $\mathcal{P}$ ,  $\alpha$ , 最大迭代步数  $k_{max}$ , 停机误差  $\zeta$ , 松弛因子  $\gamma > 0$ , 初始向量  $\mathbf{x}_0$ 。令  $k = 1$

输出:  $\mathbf{x}$

1: 当  $k \leq k_{max}$

2:  $M_{x_{k-1}} = I - \alpha M x_{k-1}^2, N_{x_{k-1}} = -\alpha N x_{k-1}^2, \mathbf{y}_k = M_{x_{k-1}}^{-1} N_{x_{k-1}} \mathbf{x}_{k-1} + M_{x_{k-1}}^{-1} (1 - \alpha) \mathbf{v}$ ,

$\hat{\mathbf{x}}_k = \gamma \mathbf{y}_k + (1 - \gamma) \mathbf{x}_{k-1}, \mathbf{x}_k = \text{proj}(\hat{\mathbf{x}}_k)$

3: 若  $\|\mathbf{x}_k - \mathbf{x}_{k-1}\| < \zeta$  则终止并且输出  $\mathbf{x}_k$

4:  $k \leftarrow k + 1$ , 返回步骤 1

---

**注 2:** 若  $\mathbf{x}_k \in \mathbb{S}_1$ , 则  $\mathcal{P} \mathbf{x}_k^{m-2}$  是列随机矩阵, 且  $0 < \alpha < 1$  时,  $I - \alpha \mathcal{P} \mathbf{x}_k^{m-2}$  是非奇异的 M-矩阵。

我们对提出的算法 1 进行收敛性分析, 本文基于 Fasino 等[11]给出的 3 阶多重线性 PageRank 问题解的唯一性条件。首先给出以下引理。

**引理 1:** 若  $\alpha T(\mathcal{P}) < 1$ , 则多重线性 PageRank 问题(1.1)有唯一解。

**引理 2:** 令  $\mathcal{P} \in \mathbb{R}^{[3,n]}$  为随机张量。对于任意的  $\mathbf{x}, \mathbf{y}, \mathbf{z} \in \mathbb{S}_1$ , 以下不等式成立:

$$\|\mathcal{P}(\mathbf{x}^2 - \mathbf{y}^2)\| \leq T(\mathcal{P}) \|\mathbf{x} - \mathbf{y}\|,$$

$$\|\mathcal{P} \mathbf{z}(\mathbf{x} - \mathbf{y})\| \leq T_L(\mathcal{P}) \|\mathbf{x} - \mathbf{y}\|,$$

$$\|\mathcal{P}(\mathbf{x} - \mathbf{y})\|_{z_1} \leq T_R(\mathcal{P}) \|\mathbf{x} - \mathbf{y}\|,$$

其中,  $\mathcal{P}(\mathbf{x}^2 - \mathbf{y}^2) \equiv \mathcal{P} \mathbf{x}^2 - \mathcal{P} \mathbf{y}^2$ 。

**引理 3:** 令  $I - \alpha \mathcal{P} \mathbf{x}^2 = M_x - N_x$  是(弱)正则分裂, 则  $\|M_x^{-1}\| \leq \frac{1}{1 - \alpha}$ 。

证明: 由  $I - \alpha \mathcal{P} \mathbf{x}^2 = M_x - N_x$ , 得  $M_x^{-1} - M_x^{-1} N_x = I + \alpha M_x^{-1} \mathcal{P} \mathbf{x}^2$ , 结合  $M_x^{-1} \geq 0, M_x^{-1} N_x \geq 0$ , 我们得到  $\|M_x^{-1}\| \leq I + \alpha M_x^{-1} \mathcal{P} \mathbf{x}^2 \leq 1 + \alpha \|M_x^{-1}\|$ , 因此  $\|M_x^{-1}\| \leq \frac{1}{1 - \alpha}$ , 证毕。

**定理 1:** 令  $\tilde{\mathcal{M}}, \mathcal{P} \in \mathbb{R}^{[3,n]}$  是随机张量,

$$\alpha \in \left( 0, \frac{-\left(2T_L(\tilde{\mathcal{M}}) + T(\mathcal{P})\right) + \sqrt{\left(2T_L(\tilde{\mathcal{M}}) + T(\mathcal{P})\right)^2 + 4\left(T_L(\tilde{\mathcal{M}}) + T(\mathcal{P})\right)}}{2\left(T_L(\tilde{\mathcal{M}}) + T(\mathcal{P})\right)} \right), \text{ 且}$$

$$\gamma \in \left( \frac{2\alpha T_L(\tilde{\mathcal{M}}) + \alpha^2 T_L(\tilde{\mathcal{M}}) + \alpha}{(1 + \alpha)(1 - \alpha T(\mathcal{P}))}, \frac{2 - 2\alpha T_L(\tilde{\mathcal{M}}) - \alpha^2 T_L(\tilde{\mathcal{M}}) + \alpha}{\alpha T(\mathcal{P}) + 1 + \alpha^2 T(\mathcal{P}) + \alpha} \right), \mathbf{x}$$

为(1.1)的解, 则对于任意初始随机向量  $\mathbf{x}_1$ , 由算法 1 生成的向量序列  $\{\mathbf{x}_k\}$  收敛, 并且

$$\|\mathbf{x}_{k+1} - \mathbf{x}\|_1 \leq \theta^k \|\mathbf{x}_0 - \mathbf{x}\|_1.$$

其中,  $\theta = (1 + \alpha)\zeta$ , 并且  $\zeta = \frac{\alpha T_l(\tilde{\mathcal{M}}) + \gamma\alpha T(\mathcal{P}) + |1 - \gamma|}{1 - \alpha T_l(\tilde{\mathcal{M}})}$ .

证明: 由算法 1 的迭代格式可知

$$\begin{cases} (I - \alpha \mathcal{M} \mathbf{x}_k^{m-2}) \mathbf{y}_{k+1} = \alpha \mathcal{P} \mathbf{x}_k^{m-1} - \alpha \mathcal{M} \mathbf{x}_k^{m-1} + (1 - \alpha) \mathbf{v}, \\ \hat{\mathbf{x}}_{k+1} = \gamma \mathbf{y}_{k+1} + (1 - \gamma) \mathbf{x}_k. \end{cases}$$

得出

$$\hat{\mathbf{x}}_{k+1} = \alpha \mathcal{M} \mathbf{x}_k^{m-2} (\hat{\mathbf{x}}_{k+1} - \mathbf{x}_k) + \gamma \alpha \mathcal{P} \mathbf{x}_k^{m-1} + \gamma (1 - \alpha) \mathbf{v} + (1 - \gamma) \mathbf{x}_k.$$

由  $\alpha \in \left( 0, \frac{-(2T_l(\tilde{\mathcal{M}}) + T(\mathcal{P})) + \sqrt{(2T_l(\tilde{\mathcal{M}}) + T(\mathcal{P}))^2 + 4(T_l(\tilde{\mathcal{M}}) + T(\mathcal{P}))}}{2(T_l(\tilde{\mathcal{M}}) + T(\mathcal{P}))} \right)$ , 结合引理 1 我们得到

$\alpha T(\mathcal{P}) \leq 1$ , 故  $\mathbf{x}$  是式子的唯一解, 得到

$$\mathbf{x} = \gamma \alpha \mathcal{P} \mathbf{x}^{m-1} + \gamma (1 - \alpha) \mathbf{v} + (1 - \gamma) \mathbf{x}.$$

令  $\hat{\mathbf{e}}_{k+1} = \hat{\mathbf{x}}_{k+1} - \mathbf{x}$ ,  $\mathbf{e}_{k+1} = \mathbf{x}_{k+1} - \mathbf{x}$ , 得

$$\begin{aligned} \hat{\mathbf{e}}_{k+1} &= \alpha \mathcal{M} \mathbf{x}_k^{m-2} \hat{\mathbf{e}}_{k+1} - \alpha \mathcal{M} \mathbf{x}_k^{m-2} \mathbf{e}_k + \gamma \alpha \mathcal{P} (\mathbf{x}_k^{m-1} - \mathbf{x}^{m-1}) + (1 - \gamma) \mathbf{e}_k \\ &\leq \mathcal{M} \mathbf{x}_k^{m-2} \hat{\mathbf{e}}_{k+1} + \alpha \mathcal{M} \mathbf{x}_k^{m-2} \mathbf{e}_k + \gamma \alpha \mathcal{P} (\mathbf{x}_k^{m-1} - \mathbf{x}^{m-1}) + (1 - \gamma) \mathbf{e}_k. \end{aligned}$$

对  $\mathcal{M}$  进行单位随机化, 我们定义  $\tilde{\mathcal{M}}^+ = \text{full}(\mathcal{M})$ , 函数  $\text{full}()$  的功能为对自变量矩阵(张量)中为 0 的元素进行随机赋值, 赋值范围为  $(0, 1)$ 。令  $\tilde{\mathcal{M}}_{ijk}^+ = \frac{\tilde{\mathcal{M}}_{ijk}^+}{\sum_{i=1}^n \tilde{\mathcal{M}}_{ijk}^+}$ , 从而得到随机张量  $\tilde{\mathcal{M}}$ , 并且有  $\mathcal{M} \leq \tilde{\mathcal{M}}$ 。

从而得到

$$\|\hat{\mathbf{e}}_{k+1}\|_1 \leq \|\alpha \mathcal{M} \mathbf{x}_k^{m-2} \hat{\mathbf{e}}_{k+1}\|_1 + \|\alpha \mathcal{M} \mathbf{x}_k^{m-2} \mathbf{e}_k\|_1 + \gamma \alpha \|\mathcal{P} (\mathbf{x}_k^{m-1} - \mathbf{x}^{m-1})\|_1 + |1 - \gamma| \|\mathbf{e}_k\|_1.$$

结合引理 2, 得

$$\|\hat{\mathbf{e}}_{k+1}\|_1 \leq \alpha T_l(\tilde{\mathcal{M}}) \|\hat{\mathbf{e}}_{k+1}\|_1 + \alpha T_l(\tilde{\mathcal{M}}) \|\mathbf{e}_k\|_1 + \gamma \alpha T(\mathcal{P}) \|\mathbf{e}_k\|_1 + |1 - \gamma| \|\mathbf{e}_k\|_1.$$

记  $\zeta = \frac{\alpha T_l(\tilde{\mathcal{M}}) + \gamma \alpha T(\mathcal{P}) + |1 - \gamma|}{1 - \alpha T_l(\tilde{\mathcal{M}})}$ 。

即

$$\|\hat{\mathbf{e}}_{k+1}\|_1 \leq \zeta \|\mathbf{e}_k\|_1.$$

因为  $\mathbf{x}_1$  为随机向量, 结合  $\|\mathbf{e}_{k+1}\|_1 \leq \frac{1}{1 - \zeta} \zeta \|\mathbf{e}_k\|_1$  得到

$$\|\mathbf{e}_2\|_1 \leq \frac{1}{1 - \zeta} \zeta \|\mathbf{e}_1\|_1 \leq (1 + \alpha) \zeta \|\mathbf{e}_1\|_1 \leq \frac{\alpha}{1 + \alpha},$$

$$\|\mathbf{e}_3\|_1 \leq \frac{1}{1 - \zeta} \zeta \|\mathbf{e}_2\|_1 \leq \frac{1}{1 - \zeta} \frac{\alpha}{1 + \alpha} \zeta^2 (1 + \alpha) \|\mathbf{e}_1\|_1 \leq \zeta^2 (1 + \alpha)^2 \|\mathbf{e}_1\|_1 \leq \frac{\alpha}{1 + \alpha},$$

假设  $\|e_k\| \leq ((1+\alpha)\zeta)^{k-1} \|e_1\|$ ，当迭代次数达到  $k+1$  时，有

$$\|e_{k+1}\| \leq \frac{1}{1-\zeta\|e_k\|} \zeta \|e_k\| \leq \frac{1}{1-\zeta\frac{\alpha}{1+\alpha}} ((1+\alpha)\zeta)^{k-1} \zeta \|e_1\| \leq ((1+\alpha)\zeta)^k \|e_1\|.$$

由已知条件易证  $(1+\alpha)\zeta < 1$ ，故  $\{\mathbf{x}_k\}$  收敛与  $\mathbf{x}$ ，证毕。

接下来，我们将使用 Anderson 加速技术来提高算法 1 的收敛性能。Anderson 加速(AA) [19]最初由 Anderson 在 1965 年提出，AA 是一种序列方法已被广泛用于提高固定点迭代  $g: \mathbb{R}^n \rightarrow \mathbb{R}^n$  的收敛速度。定义残差为  $f(x) = g(x) - x$ ，则求解不动点问题等价求解残差方程  $f(x) = 0$ 。AA 方法的主要思想是通过前  $m$  步迭代计算结果来表示最新的迭代结果，即这个组合向量系数  $\beta = (\beta_1, \beta_2, \dots, \beta_m)$  通过极小化每一步相应的残差的组合得到。Anderson 加速方法是针对不动点迭代进行加速的一类算法，我们考虑以下一般定点问题

$$g(\mathbf{x}) = \gamma(I - \alpha\mathcal{M})^{-1}(-\alpha\mathcal{N}\mathbf{x}^2)\mathbf{x} + \gamma(1-\alpha)(I - \alpha\mathcal{M}\mathbf{x}^2)^{-1}\mathbf{v} + (1-\gamma)\mathbf{x}$$

并且  $f(\mathbf{x}) = g(\mathbf{x}) - \mathbf{x}$ ，其中  $\mathbf{x} \in \mathbb{S}_1$  且  $g: \mathbb{S}_1 \rightarrow \mathbb{R}^n$ 。

根据参考文献[20]中的假设 2.1，当满足

$$\left\| \sum_{i=0}^{m_k} \beta_i^{(K)} f(\mathbf{x}_{k-m_k+i-1}) \right\| \geq \|f(\mathbf{x}_{k-1})\| \text{ 或 } \|\beta^{(K)}\| \geq M_\beta,$$

其中， $M_\beta$  是  $\beta^{(K)}$  的一个控制参数时，我们不必执行 Anderson 加速步骤。

我们新提出的张量分裂迭代算法的安德森加速度如下所示：

---

算法 2 Anderson 加速张量分裂迭代

---

输入：给定随机向量  $\mathcal{P}$ ， $\alpha$ ， $m$ ，常数  $M_\beta > 1$ ，最大迭代步数  $k_{max}$ ，停机误差  $\zeta$ ，松弛因子  $\gamma > 0$ ，初始向量  $\mathbf{x}_0$ 。

令  $k = 1$

输出： $\mathbf{x}$

1: while  $k \leq k_{max}$  do

2:  $m_k = \min\{m, k\}$

3:  $g(\mathbf{x}) = \gamma(I - \alpha\mathcal{M}\mathbf{x}^2)^{-1}(-\alpha\mathcal{N}\mathbf{x}^2)\mathbf{x}_{k-1} + \gamma(1-\alpha)(I - \alpha\mathcal{M}\mathbf{x}^2)^{-1}\mathbf{v} + (1-\gamma)\mathbf{x}$

4:  $f(\mathbf{x}_{k-1}) = g(\mathbf{x}_{k-1}) - \mathbf{x}_{k-1}$

5: 令  $F_k = (f_{k-m_k}, \dots, f_k)$ ，其中  $f_i = g(\mathbf{x}_i) - \mathbf{x}_i$

6: 计算  $\min_{\beta=(\beta_0, \dots, \beta_{m_k})^T, s.t. \sum_{i=0}^{m_k} \beta_i = 1}$ ，得  $\beta^{(k)} = (\beta_0^{(k)}, \beta_1^{(k)}, \beta_2^{(k)}, \dots, \beta_{m_k}^{(k)})^T$

7: if  $\left\| \sum_{i=0}^{m_k} \beta_i^{(k)} f(\mathbf{x}_{k-m_k+i-1}) \right\| \leq \|f(\mathbf{x}_{k-1})\|$  or  $\|\beta^{(k)}\| \leq M_\beta$ , then

8:  $\hat{\mathbf{x}}_k = \sum_{i=0}^{m_k} \beta_i^{(k)} g(\mathbf{x}_{k-m_k+i-1})$

9: else

10:  $\hat{\mathbf{x}}_k = g(\mathbf{x}_{k-1})$

11: end if

12:  $\mathbf{x}_k = \text{proj}(\hat{\mathbf{x}}_k)$

13: if  $\|\mathbf{x}_k - \mathbf{x}_{k-1}\| < \zeta$  then

14: 则终止并且输出  $\mathbf{x}_k$

15: end if

---

续表

---

```

16:  $k \leftarrow k+1$ 
17: end while

```

---

**注 3:** 如参考文献[20]所述, 在实现 Anderson 加速时, 算法参数  $m$  的适当选择很重要。如果  $m$  太小, 则利用迭代步骤中的信息可能太有限, 无法实现快速收敛。如果  $m$  很大, 则最小二乘问题可能是病态的。在大多数应用中,  $m=2$  或  $m=3$  是可行且有效的选择。同时, 作为  $\beta^{(k)}$  的控制参数, 太小的  $M_\beta$  很容易导致跳过 Anderson 加速步骤。因此, 设置较大的  $M_\beta$  是合适的。在数值测试中, 我们取  $M_\beta = 30 (\leq 50)$  较为合适。

#### 4. 结语

本文基于[15]提出的求解高阶马尔科夫链和多重线性 PageRank 问题的松弛算法基础上, 结合张量分裂方法, 提出求解多重线性 PageRank 的分裂算法, 并进行相应的收敛性分析, 进一步引入 Anderson 加速技术[17], 给出 Anderson 加速张量分裂迭代的算法流程并对使用的参数进行了一定的说明。

#### 参考文献

- [1] Page, L. (1999) The Page Rank Citation Ranking: Bringing Order to the Web. Technical Report.
- [2] Freschi, V. (2007) Protein Function Prediction from Interaction Networks Using a Random Walk Ranking Algorithm. 2007 *IEEE 7th International Symposium on Bioinformatics and BioEngineering*, Boston, 14-17 October 2007, 42-48. <https://doi.org/10.1109/bibe.2007.4375543>
- [3] Gleich, D.F. (2015) Page-Rank beyond the Web. *SIAM Review*, **57**, 321-363. <https://doi.org/10.1137/140976649>
- [4] Morrison, J.L., Breitling, R., Higham, D.J. and Gilbert, D.R. (2005) Gene-Rank: Using Search Engine Technology for the Analysis of Microarray Experiments. *BMC Bioinformatics*, **6**, Article No. 233. <https://doi.org/10.1186/1471-2105-6-233>
- [5] Winter, C., Kristiansen, G., Kersting, S., Roy, J., Aust, D., Knösel, T., *et al.* (2012) Google Goes Cancer: Improving Outcome Prediction for Cancer Patients by Network-Based Ranking of Marker Genes. *PLOS Computational Biology*, **8**, e1002511. <https://doi.org/10.1371/journal.pcbi.1002511>
- [6] Gleich, D.F., Lim, L. and Yu, Y. (2015) Multilinear Page-Rank. *SIAM Journal on Matrix Analysis and Applications*, **36**, 1507-1541. <https://doi.org/10.1137/140985160>
- [7] Li, W. and Ng, M.K. (2013) On the Limiting Probability Distribution of a Transition Probability Tensor. *Linear and Multilinear Algebra*, **62**, 362-385. <https://doi.org/10.1080/03081087.2013.777436>
- [8] Li, W., Liu, D., Vong, S. and Xiao, M. (2020) Multilinear Page-Rank: Uniqueness, Error Bound and Perturbation Analysis. *Applied Numerical Mathematics*, **156**, 584-607. <https://doi.org/10.1016/j.apnum.2020.05.022>
- [9] Li, W., Liu, D., Ng, M.K. and Vong, S. (2017) The Uniqueness of Multilinear Page-Rank Vectors. *Numerical Linear Algebra with Applications*, **24**, e2107. <https://doi.org/10.1002/nla.2107>
- [10] Liu, D., Vong, S. and Shen, L. (2022) Improved Uniqueness Conditions of Solution for Multilinear Page-Rank and Its Application. *Linear and Multilinear Algebra*, **72**, 203-233. <https://doi.org/10.1080/03081087.2022.2158292>
- [11] Fasino, D. and Tudisco, F. (2020) Ergodicity Coefficients for Higher-Order Stochastic Processes. *SIAM Journal on Mathematics of Data Science*, **2**, 740-769. <https://doi.org/10.1137/19m1285214>
- [12] Meini, B. and Poloni, F. (2018) Perron-Based Algorithms for the Multilinear Page-Rank. *Numerical Linear Algebra with Applications*, **25**, e2177. <https://doi.org/10.1002/nla.2177>
- [13] Guo, P., Gao, S. and Guo, X. (2018) A Modified Newton Method for Multilinear Page-Rank. **22**, 1161-1171. <https://doi.org/10.11650/tjm/180303>
- [14] Li, D., Xie, S. and Xu, H. (2017) Splitting Methods for Tensor Equations. *Numerical Linear Algebra with Applications*, **24**, e2102. <https://doi.org/10.1002/nla.2102>
- [15] Liu, D., Li, W. and Vong, S. (2019) Relaxation Methods for Solving the Tensor Equation Arising from the Higher-Order Markov Chains. *Numerical Linear Algebra with Applications*, **26**, e2260. <https://doi.org/10.1002/nla.2260>
- [16] Bentbib, A.H., Boubekraoui, M. and Jbilou, K. (2024) Extrapolation Methods for Multilinear Page-Rank. *Numerical Algorithms*, **98**, 1013-1043.

- [17] Walker, H.F. and Ni, P. (2011) Anderson Acceleration for Fixed-Point Iterations. *SIAM Journal on Numerical Analysis*, **49**, 1715-1735. <https://doi.org/10.1137/10078356x>
- [18] Liu, D., Li, W. and Vong, S. (2018) The Tensor Splitting with Application to Solve Multi-Linear Systems. *Journal of Computational and Applied Mathematics*, **330**, 75-94. <https://doi.org/10.1016/j.cam.2017.08.009>
- [19] Anderson, D.G. (1965) Iterative Procedures for Nonlinear Integral Equations. *Journal of the ACM*, **12**, 547-560. <https://doi.org/10.1145/321296.321305>
- [20] Toth, A. and Kelley, C.T. (2015) Convergence Analysis for Anderson Acceleration. *SIAM Journal on Numerical Analysis*, **53**, 805-819. <https://doi.org/10.1137/130919398>