

图像恢复问题的随机算法研究

罗雨倩

成都理工大学数学科学学院, 四川 成都

收稿日期: 2026年7月18日; 录用日期: 2026年8月11日; 发布日期: 2026年8月21日

摘要

经典奇异值分解(SVD)图像去噪算法常依赖全局统一的截断秩, 难以兼顾图像局部平滑与边缘结构的差异。此外, 直接将针对逆问题的截断补偿策略(如MTRSVD的尾部填充)应用于纯数据域去噪时, 会在数学上向噪声子空间注入伪能量, 导致去噪性能受损。针对上述局限, 本文提出了一种基于分块梯度排序与分组自适应随机奇异值分解(RSVD)的图像去噪算法。首先, 将图像分块并依据全变分(TV)特征对列向量进行升序重排, 人为诱导矩阵在局部空间产生强连贯的低秩流形。其次, 通过严格的矩阵代数分析, 本文揭示并证明了在全局线性正交投影条件下, 对重排操作必然导致的“数学抵消效应”。为打破该理论困境并主动顺应自然图像局部结构的非平稳性, 本文创新性地引入基于分段非线性投影的分组自适应截断机制, 结合基于Hutchinson迹估算的随机误差准则, 为不同复杂度的图像子组动态计算最优截断秩, 并执行纯粹的RSVD低秩逼近。消融实验与泛化性能对比表明, 相较于全局固定秩、不分组的自适应算法, 以及代表性的重型经典方法——三维块匹配(BM3D)与传统加权核范数最小化(WNNM)算法, 本文算法不仅有效规避了传统算法高噪易失效与缺乏局部自适应的短板, 更以仅约0.03秒的毫秒级极低开销(比传统重型算法快近1000倍), 取得了极具竞争力的去噪保真表现(PSNR/SSIM)。本文成功开辟了一条在强力去噪、细节保真与极致计算吞吐量之间取得高度平衡的新路径, 为大规模图像恢复提供了高效的数值代数方案。

关键词

图像去噪, 随机奇异值分解(RSVD), 梯度排序, 数学抵消效应, 非平稳性, 分组自适应

Research on Random Algorithms for Image Restoration Problems

Yuqian Luo

School of Mathematical Sciences, Chengdu University of Technology, Chengdu Sichuan

Received: July 18, 2026; accepted: August 11, 2026; published: August 21, 2026

Abstract

Classical singular value decomposition (SVD) image denoising algorithms often rely on a globally uniform truncation rank, making it difficult to balance the differences between local smoothness and edge structures. Furthermore, directly applying truncation compensation strategies designed for inverse problems (such as the tail-filling in MTRSVD) to pure data-domain denoising mathematically injects pseudo-energy into the noise subspace, thereby degrading denoising performance. To address these limitations, this paper proposes an image denoising algorithm based on patch gradient sorting and grouped adaptive randomized singular value decomposition (RSVD). First, images are partitioned into patches, and the column vectors are rearranged in ascending order according to their total variation (TV) characteristics, artificially inducing highly coherent low-rank manifolds in the local space. Second, through rigorous matrix algebraic analysis, this paper reveals and proves the “mathematical cancellation effect” of the rearrangement operation strictly under the condition of global linear orthogonal projection. To break through this theoretical dilemma and proactively adapt to the non-stationarity of local structures in natural images, this paper innovatively introduces a grouped adaptive truncation mechanism based on piecewise non-linear projection. Combined with a randomized error criterion based on Hutchinson’s trace estimation, the optimal truncation rank is dynamically calculated for image subgroups of varying complexities, and a pure RSVD low-rank approximation is executed. Ablation experiments and generalization performance comparisons demonstrate that, compared with globally fixed-rank algorithms, un-grouped adaptive algorithms, as well as representative heavy-duty classical methods like Block-Matching 3D filtering (B-M3D) and traditional Weighted Nuclear Norm Minimization (WNNM), the proposed algorithm not only effectively circumvents the shortcomings of traditional methods (e.g., failure under high noise and lack of local adaptability), but also achieves highly competitive denoising fidelity (PSNR/SSIM) with a millisecond-level, extremely low

overhead of only about 0.03 seconds (nearly 1000 times faster than traditional heavy algorithms). This work successfully pioneers a new path that strikes a high degree of balance among robust denoising, detail preservation, and extreme computational throughput, providing an exceptionally efficient numerical algebraic solution for large-scale image restoration.

Keywords

Image Denoising, Randomized SVD (RSVD), Gradient Reordering, Mathematical Cancellation Effect, Non-Stationarity, Grouped Adaptive

Copyright © 2026 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

1.1. 图像去噪与低秩矩阵逼近背景

在计算机视觉与图像处理领域，图像去噪是一项基础且至关重要的预处理任务。在实际获取过程中，图像往往会受到传感器或传输通道的干扰，一幅受加性高斯白噪声污染的图像可被建模为 $Y = X + E$ ，其中 X 为纯净的底层图像信号， E 为随机噪声矩阵。由于自然图像在空间域上具有高度的非局部自相似性(Non-local Self-similarity) [1, 2]，其分块矩阵通常呈现出显著的低秩或近似低秩特性 [3]；而随机噪声则均匀分布于矩阵的全秩空间中。因此，基于奇异值分解(Singular Value Decomposition, SVD)的低秩矩阵逼近方法被广泛应用于去噪领域 [4]。根据Eckart-Young定理 [5]，截断奇异值分解(TSVD)能够通过舍弃对应于高频噪声的微小奇异值，在给定秩约束下实现最优的Frobenius 范数逼近。然而，面对现代高分辨率图像，传统SVD 分解的计算复杂度高达 $O(\min(mn^2, m^2n))$ ，这构成了严峻的算力瓶颈，极大地限制了其在大规模数据处理中的实际部署。

1.2. 现有方法的局限性

为突破SVD 的算力瓶颈，近年来随机化数值线性代数(Randomized Numerical Linear Algebra)的兴起提供了革命性的工具 [6, 7]。随机奇异值分解(RSVD)利用高斯测试矩阵进行降维投影，在极大提升计算效率的同时保证了逼近精度 [8]。在此基础上，Bai 等人(2021) [9] 针对大规模线性离散不适定问题，提出了一种高效的矩阵截断SVD 算法(MTRSVD)。该算法最突出的贡献在于，引入了基于Hutchinson 迹估算 [10] 的随机误差准则，实现了截断秩 k 的自适应最优选取，无需依

赖人工经验调参。尽管MTRSVD 在理论与计算效率上取得了显著成功，但若将其直接应用于图像纯数据域去噪，在理论机制与空间处理上仍暴露出两大局限性：第一，**尾部奇异值填充导致的伪能量注入**。MTRSVD 算法最初是为求解带有显式退化算子 A 的物理逆问题(如图像去模糊)而设计的，其核心机制之一是在截断后，将尾部丢弃的奇异值强行填充为 σ_k ，以防止算子求逆时分母趋于零而发生数值爆炸。然而，在无算子 A 的纯数据去噪(正问题)中，奇异值尾部空间由纯粹的噪声主导。若强行保留该补偿机制，在数学上等同于向噪声子空间重新注入“伪能量”，这将破坏TSVD的最优逼近下界，导致重构误差显著增大。第二，**全局统一截断导致的空间失配**。自然图像在空间域表现出高度的非平稳性。平滑区域(如天空)具有极强的低秩先验，需要极小的 k 来彻底消除噪声；而纹理与边缘区域蕴含丰富的高频结构，需要较大的 k 来防止过度平滑。若将整幅图像或全部分块作为一个整体进行全局SVD投影并赋予单一的截断秩，必然会陷入“平滑区噪声残留”与“边缘区细节模糊”的顾此失彼困境。

1.3. 本文主要贡献

针对上述理论痛点与应用局限，本文摒弃了MTRSVD中不适用于去噪的尾部补偿机制，转而从数据空间重构的角度出发，提出了一种基于分块梯度排序与分组自适应RSVD的图像去噪新架构。本文的主要贡献可归纳为以下三点：

- **引入特征排序，人为诱导奇异值加速衰减**：本文利用提取算子将图像分解为分块矩阵，并计算各列向量的全变分(TV)梯度特征。通过升序重排，将具有相似复杂度的图像块在矩阵空间中强制聚类。该操作将原本无序的数据重构为具有强列连贯性的低秩流形，显著加速了奇异值能量向主成分集中。
- **揭示并证明了全局投影的“数学抵消效应”**：本文从严格的矩阵代数角度指出，若仅执行列排序而不改变全局投影机制，列重排操作等价于右乘一个正交置换矩阵。在全局SVD投影及其逆向还原过程中，该置换矩阵的数学作用将被完全吸收并抵消。这一发现为图像重排算法的设计提供了重要的理论预警。
- **提出分组自适应RSVD截断算法**：为打破上述抵消悖论，本文创新性地将重排后的矩阵依据复杂度划分为平滑、纹理与边缘子组。进一步，我们将Bai等人(2021)提出的随机误差估计准则独立应用于各子组，自适应解算出异质化的最优截断秩，并执行纯粹的RSVD截断。该机制在数学上成功锁定了低秩红利，实现了强力去噪与边缘保真的完美统一。

2. 预备知识

本节将简要给出图像去噪的低秩矩阵逼近模型，并回顾随机奇异值分解(RSVD)的基础代数框架，最后引入用于本文后续自适应算法的随机迹估算准则。

2.1. 低秩矩阵逼近与RSVD 框架

在纯数据域的图像去噪任务中，受高斯白噪声污染的离散观测矩阵 $Y \in \mathbb{R}^{m \times n}$ 可建模为：

$$Y = X + E \quad (1)$$

其中, X 为未知且近似低秩的清晰图像矩阵, E 为随机噪声矩阵。去噪的核心在于寻找 Y 的最优低秩逼近, 从而在滤除高频噪声的同时保留真实的结构信息。根据 Eckart-Young 定理, 给定目标秩 k , 截断奇异值分解(TSVD)能提供理论上的最优逼近 $\hat{Y}_k = U_k \Sigma_k V_k^T$ 。

为了避免对大规模矩阵直接执行全奇异值分解的庞大计算开销, RSVD 利用随机投影技术实现降维加速。其核心代数步骤如下: 首先, 生成一个标准高斯随机测试矩阵 $\Omega \in \mathbb{R}^{n \times (k+p)}$, 其中 p 为防止概率失效的过采样参数。利用 Ω 探测原矩阵的列空间, 计算样本矩阵 Z :

$$Z = Y\Omega \in \mathbb{R}^{m \times (k+p)} \quad (2)$$

随后, 对 Z 进行 QR 分解 ($Z = QR$), 提取出一组近似张成 Y 主列空间的正交基底 $Q \in \mathbb{R}^{m \times (k+p)}$ 。利用投影算子 Q^T , 将高维矩阵 Y 压缩至低维子空间:

$$B = Q^T Y \in \mathbb{R}^{(k+p) \times n} \quad (3)$$

最后, 仅需对尺寸极小的小矩阵 B 执行确定性 SVD 分解 ($B = \tilde{U} \Sigma V^T$), 即可映射回原空间得到秩 k 的近似恢复矩阵:

$$\hat{Y}_k = Q \tilde{U} \Sigma_k V_k^T \quad (4)$$

该随机化框架将传统 SVD 的计算复杂度由 $\mathcal{O}(mn^2)$ 骤降至 $\mathcal{O}(mnk)$, 为大规模图像分块去噪提供了算力保障。

2.2. 基于随机迹估算的自适应截断准则

在上述 RSVD 框架中, 截断秩 k 的选取起着决定性作用。过大的 k 会导致低秩空间中残留噪声, 过小的 k 则会抹除图像边缘细节。由于真实的纯净矩阵 X 无法观测, 直接计算逼近误差 $\|Y - \hat{Y}_k\|_F^2$ 难以实现。为了实现截断秩的自适应寻优, Bai 等人(2021) [9] 结合前沿的随机迹估计理论 [11], 提出了一种基于 Hutchinson 迹估算(Trace Estimator) [10] 原理的后验误差估计准则。设对应截断秩 k 的投影残差算子为 $R_k = (I - Q_k Q_k^T)Y$, 最优截断秩 k_{opt} 的求解可转化为极小化如下离散代价函数 $\mathcal{E}(k)$:

$$k_{opt} = \arg \min_k \mathcal{E}(k) \approx \arg \min_k \{ \|Y\omega - Q_k(Q_k^T Y\omega)\|_2^2 + \mathcal{P}(k) \} \quad (5)$$

公式(5) 中的第一项通过极低成本的矩阵-向量乘法, 巧妙地估算了因截断而丢弃的尾部残差能量; 第二项 $\mathcal{P}(k)$ 则是依据噪声方差标定的惩罚项, 用于防止过拟合。

该准则原本用于确定全局逆问题中的唯一截断参数。在本文的第3 节中, 这一高效准则将作为核心的自适应评估器, 被创新性地独立应用于经特征重排后划分的各个图像子空间中。

3. 本文方法: 分组自适应RSVD 去噪算法

针对传统全局 SVD 图像去噪顾此失彼的缺陷, 以及原版 MTRSVD 尾部补偿机制在去噪任务中的失效, 本文提出了一种基于分块梯度重排与分组自适应 RSVD 的改进框架。本节将详细阐述该算法的数学构造与破局机理。

3.1. 非局部图像分块与TV 梯度排序

自然图像在空间域上蕴含极其丰富的非局部自相似性(Non-local Self-similarity)。为了充分发掘这一数据特性, 本文首先将图像从空间域转换至分块矩阵域。

给定受损的二维观测图像 $Y \in \mathbb{R}^{H \times W}$, 设定分块尺寸为 $b \times b$ 。利用滑动窗口提取算子遍历图像, 提取出 N 个图像小块。将每个二维图像块拉直为长度为 b^2 的一维列向量 p_i , 拼接构造出初始观测矩阵 P :

$$P = [p_1, p_2, \dots, p_N] \in \mathbb{R}^{b^2 \times N} \quad (6)$$

此时, P 的列向量严格按图像原始空间位置排列, 列与列之间缺乏结构连贯性, 导致矩阵呈现较高秩的杂乱状态。为了衡量各列向量的内容复杂度, 本文借鉴ROF 经典模型 [12], 引入全变分(Total Variation, TV)作为梯度特征的度量工具。对于矩阵 P 中的任意列向量 p_i , 将其重塑回 $b \times b$ 的二维图像块 $I^{(i)}$ 后, 其离散TV 特征值 v_i 定义为:

$$v_i = \sum_{x=1}^{b-1} \sum_{y=1}^b |I_{x+1,y}^{(i)} - I_{x,y}^{(i)}| + \sum_{x=1}^b \sum_{y=1}^{b-1} |I_{x,y+1}^{(i)} - I_{x,y}^{(i)}| \quad (7)$$

基于计算得到的特征向量 $\mathbf{v} = [v_1, v_2, \dots, v_N]$ 进行升序排列。在数学代数中, 这一排序操作等价于将原矩阵右乘一个正交置换矩阵(Permutation Matrix) $\Pi \in \mathbb{R}^{N \times N}$, 满足 $\Pi^T \Pi = I$ 。重排后的新矩阵 $\tilde{P}$ 表示为:

$$\tilde{P} = P\Pi = [\tilde{p}_1, \tilde{p}_2, \dots, \tilde{p}_N] \quad (8)$$

正如局部像素分组方法(LPG-PCA) [13] 等研究所揭示的, 经过该置换操作, 具有相似平滑度的图像块(低TV 值)与复杂的纹理块(高TV 值)在矩阵空间中被强制聚类, 人为诱导出了极强的局部列相干性, 极大加速了奇异值能量向低阶主成分的集中。

3.2. 全局投影的数学抵消困境分析

在获得强连贯的重排矩阵 $\tilde{P}$ 后, 直观的思路是直接对其应用RSVD 进行全局低秩去噪。然而, 本文通过严格的矩阵分析指出: 若沿用传统的全局投影机制, 即在严格的全局线性正交投影条件下, 前期的排序操作在最终的逆向重构中将被完全抹除。

注记1 (全局线性正交投影下的数学抵消效应): 定义截断秩为 k 的全局RSVD 线性投影算子为 $\mathcal{P}_k(\cdot)$ 。在全局统一的子空间投影框架下, 该算子等价于将整个矩阵投影至前 k 个左奇异向量张成的主空间中, 即 $\mathcal{P}_k(M) = U_k U_k^T M$ 。

假设对重排矩阵 $\tilde{P}$ 执行全局正交投影, 为重构图像空间, 必须在去噪后右乘置换矩阵的逆矩阵 Π^{-1} (即 Π^T) 以还原列向量。最终输出的恢复矩阵 P_{rec} 满足以下推导:

$$\begin{aligned}
 P_{rec} &= \mathcal{P}_k(\tilde{P})\Pi^{-1} \\
 &= \mathcal{P}_k(P\Pi)\Pi^T \\
 &= (U_k U_k^T P \Pi) \Pi^T \\
 &= U_k U_k^T P (\Pi \Pi^T) \\
 &= U_k U_k^T P = \mathcal{P}_k(P)
 \end{aligned} \tag{9}$$

如公式(9)所示, 该抵消效应成立的严谨前提在于投影算子的全局性与线性正交性: 由于全局共享同一组正交基底 U_k , 且置换算子具备正交性 $\Pi\Pi^T = I$, 置换算子 Π 在全局投影后的逆向还原中被彻底吸收。这意味着, 全局统一截断会使重排序带来的“结构连贯性红利”发生完美的代数抵消。这一发现为数据重排算法的设计敲响了理论警钟。

3.3. 破局策略: 主动适应非平稳性的分组自适应机制

为打破上述抵消悖论, 纯粹依靠数学技巧破坏全局对称性是片面的。本文分组策略的更深层次动机, 源于对自然图像固有的非平稳性(Non-stationarity) [14,15] 的主动适应。如经典文献 [16] 所述, 自然图像的局部结构极其复杂多样, 平滑区域的像素变化极其缓慢(内在维度极低), 而边缘与复杂纹理区域则包含剧烈的高频跳变(内在维度较高)。如果强行使用全局单一的秩 k 进行截断, 本质上是对整幅图像非平稳特征的数学妥协。基于此物理与数学的双重动机, 本文提出将基于梯度排序后的矩阵 $\tilde{P}$ 沿列维度切分为 G 个连续的子组(本文设 $G = 3$, 分别隐式对应平滑组、纹理组与边缘组):

$$\tilde{P} = [\tilde{P}_{smooth}, \tilde{P}_{texture}, \tilde{P}_{edge}] \tag{10}$$

分组后, 本文摒弃全局统一设定截断秩的做法, 独立调用第2节中的随机误差估计准则(公式(5)), 针对各子组分别自适应解算出异质化的最优截断秩 k_1, k_2, k_3 。并在各自的低维子空间内执行纯粹的RSVD截断(不作尾部填充)。

此时, 矩阵的逆向重构过程转变为一种分段非线性投影:

$$P_{final} = [\mathcal{P}_{k_1}(\tilde{P}_{smooth}), \mathcal{P}_{k_2}(\tilde{P}_{texture}), \mathcal{P}_{k_3}(\tilde{P}_{edge})] \Pi^{-1} \tag{11}$$

对比公式(9)与(11)可以清晰地看到, 由于自适应求解使得 $k_1 \neq k_2 \neq k_3$, 各子空间的投影基底 U_{k_i} 的维度与方向截然不同, 无法再从外部提取全局公因子 $U_k U_k^T$ 。此时, 线性正交前提被打破, Π^{-1} 无法再与内部发生代数抵消。

综上所述, 本文的分组自适应机制实现了双重贡献: 在代数层面上, 它成功锁死了排序带来的低秩红利(打破了抵消困境); 在物理层面上, 它主动顺应了图像内容的非平稳性, 实现了“平滑区极致去噪(极小 k)”与“边缘区锐利保真(较大 k)”的智能动态平衡。

3.4. 算法流程

本文提出的基于TV梯度排序与分组自适应RSVD的图像去噪算法完整流程如算法1所示。

算法 1 基于 TV 排序与分组自适应 RSVD 的图像去噪算法**输入:** 观测图像 Y , 分块尺寸 b , 过采样参数 p , 分组数 G **输出:** 去噪图像 $\hat{X}$

- 1: 将 Y 分块并拉直为矩阵 P
- 2: 计算 P 各列的 TV 特征 $\mathbf{v}$
- 3: 根据 $\mathbf{v}$ 升序排列, 获得置换矩阵 Π 和重排矩阵 $\tilde{P} = P\Pi$
- 4: 将 $\tilde{P}$ 沿列切分为 G 个子组: $[\tilde{P}_1, \dots, \tilde{P}_G]$
- 5: **for** $g = 1, \dots, G$ **do**
- 6: 利用公式 (5) 对子组 $\tilde{P}_g$ 计算最优秩 k_g
- 7: 对 $\tilde{P}_g$ 执行纯粹的 RSVD 截断, 得到 $\mathcal{P}_{k_g}(\tilde{P}_g)$
- 8: **end for**
- 9: 拼接各组结果并逆向重排: $P_{final} = [\dots]\Pi^{-1}$
- 10: 将 P_{final} 折叠重构, 通过重叠区域平均化生成最终去噪图像 $\hat{X}$ 。

4. 数值实验与结果分析

为验证本文所提出的基于分块梯度排序与分组自适应RSVD (下文统称TV-Ada RSVD)算法的有效性与工程优越性, 本节设计了由浅入深的机制验证、参数敏感度分析以及多维度的消融对比实验。

4.1. 实验设置与评价指标

运行环境与数据集: 本文所有的数值仿真实验均在一台配备Intel Core i7 处理器与16 GB 内存的个人计算机上运行, 编程环境统一采用MATLAB R2021a。在数据集选取方面, 实验选用图像处理领域公认的标准灰度测试图像(如House、Cameraman、Peppers 等, 图像分辨率均归一化为 256×256 像素)。为模拟实际传感器获取图像时的退化过程, 人为向纯净图像矩阵 X 中注入均值为0、标准差为 σ 的加性高斯白噪声矩阵 E (基准压测环境下设为 $\sigma = 0.05$)。

对比基线设置: 为了全面且严格地验证本文所提TV-Ada RSVD 算法的有效性与先进性, 实验构建了完备的内外对比矩阵:

- **内部消融基线:** 包含1) **Fixed-k RSVD** (全局固定秩, 不对图像进行重排分组); 2) **Global-Ada RSVD** (全局自适应但无分块机制), 用于剥离并验证本文核心机制的必要性。
- **外部标杆基线:** 引入了传统图像去噪领域极具代表性的重量级标杆方法, 包括加权核范数最小化(WNNM) 算法 [17] 与三维块匹配(BM3D) 算法 [18], 重点用于评估本文轻量级随机化架构与传统重型迭代算法在画质与耗时上的多维博弈。

实现细节与超参数: 在矩阵分块提取阶段, 为从根本上抑制传统非重叠分块带来的“网格伪影(Block Artifacts)”, 本文算法引入了重叠滑动窗口(Overlapping Sliding Window) 机制, 并在最终逆向重构阶段, 对空间坐标重叠区域的恢复像素值执行加权平均操作, 以实现平滑过渡。本文算法及内部消融基线的核心超参数均统一依据后续实验的最优结论进行配置: 块大小 $b = 6$, 滑动

步长 $step = 2$ ，容差系数 $\tau = 1.0$ ，自适应分组数 $K = 3$ 。而对于WNNM与BM3D算法，其内部超参数均严格遵照原文献的经典推荐设置，以确保对比实验的绝对公平性。

评价指标： 在去噪性能的定量评估上，本文采用两项核心客观指标：

- **峰值信噪比(Peak Signal-to-Noise Ratio, PSNR):** 以分贝(dB)为单位，衡量去噪后图像 $\hat{X}$ 与纯净原图 X 之间像素级别的绝对误差。PSNR数值越高，表明全局去噪的彻底性越好，噪声残余越少。
- **结构相似性(Structural Similarity, SSIM):** 取值范围为 $[0, 1]$ ，重点从亮度、对比度与结构纹理三个维度衡量图像局部特征的保真度。SSIM取值越接近1，表明算法在去噪的同时，能够越好地防止边缘模糊与细节丢失。

4.2. 奇异值加速衰减机理验证

基于SVD的降维去噪算法，其核心性能高度依赖于观测矩阵的低秩潜能。换言之，矩阵的奇异值(Singular Values)衰减得越迅速，算法便能用越小的截断秩 k 捕获绝大部分有效信号，从而将高频噪声彻底孤立于尾部子空间中。

为从代数底层验证本文所提TV梯度排序机制的物理有效性，图1绘制了观测矩阵 P 重排前后的奇异值能量衰减对数曲线。为保证对比的公平性，实验分别提取了未排序的原始全图矩阵 P ，以及经过TV特征升序排列后截取的前三分之一平滑子矩阵 P_{smooth} ，并对其奇异值进行了归一化处理。




Figure 1. Comparison of matrix singular-value decay curves before and after TV sorting (logarithmic scale)

图 1. TV 排序前后矩阵奇异值衰减对数曲线对比(对数坐标)

如图1所示，代表原始无序矩阵 P 的黑色曲线其奇异值衰减极其平缓。这说明由于自然图像局部结构的高度非平稳性，强行拼接的矩阵呈现出高秩的复杂混合状态，信号与噪声在奇异值谱上严重交叠；若此时直接实施全局低秩截断，必然导致有效细节的不可逆丢失。

形成鲜明对比的是, 经过TV 排序并提取出的平滑子矩阵 P_{smooth} (红色曲线), 其奇异值在第一主成分之后出现了“断崖式”的暴跌, 并在极短的阶数内迅速衰减至零(注意纵轴为对数尺度, 实际能量差异达数个数量级)。这直观且严格地证明了: 本文引入的特征重排序操作, 成功在局部空间内诱导了强烈的列连贯性(Column Coherence)。该机制清除了异质结构的干扰, 极大地释放了后续SVD 的低秩逼近潜能, 为自适应随机误差准则以极小的秩 k 实施精准降维提供了坚实的数学基础。

4.3. 核心超参数敏感度分析

为确保本算法在实际应用中的鲁棒性与最优性, 本节采用严格的控制变量法, 对主导去噪性能与计算效率的四个核心超参数(块大小 b 、滑动步长 $step$ 、分组数量 G 、容差系数 τ)进行深度敏感度分析。

4.3.1. 块大小(b)与滑动步长($Step$)的时空权衡

分块尺度 b 决定了局部感受野与低秩空间的容量, 而滑动步长 $step$ 则控制着图像重构时的重叠冗余度。图 2 与图 3 分别展示了这两项参数对去噪质量(PSNR/SSIM)与运行时间的综合影响。




Figure 2. Effect of block size b on denoising performance and computational time

图 2. 块大小 b 对去噪性能与计算耗时的影响

如图 2 所示, 当 $b = 4$ 时, 由于感受野过小, 图像块内缺乏足够的冗余信息, 导致结构相似性(SSIM)处于低谷; 当 $b \geq 12$ 时, 局部跨越了过多的异质区域, 导致混杂过度进而破坏了低秩性假定, PSNR 呈现急剧下降。因此, 本文确立 $b = 8$ 为最优空间尺度。

此外, 滑动步长消融实验(图 3)指出, $step = 1$ (全重叠)虽能获得理论上的极高画质, 但伴随着指数级增长的算力负担(耗时剧增)。相比之下, 本文选取的 $step = 2$ 在牺牲不到0.35 dB 的前提下, 节省了近4 倍的计算时间。这在工程实现上达到了质量与效率的最佳Trade-off (权衡)。




Figure 3. Effect of sliding step size $step$ on denoising performance and computational time

图 3. 滑动步长 $step$ 对去噪性能与计算耗时的影响

4.3.2. 分组数量(K) 的物理语义对齐与泛化稳定性分析

分组数量 K 决定了打破“数学抵消悖论”的细粒度。为探究该参数在不同图像结构下的普适性与稳定性，我们在异质结构图像上对 $K \in [1, 6]$ 进行了对比测试，其典型性能曲线如图 4 所示。




Figure 4. Comprehensive effect of the number of groups K on denoising quality and overfitting analysis

图 4. 分组数量 K 对去噪质量的综合影响与过拟合分析

观察图 4 可发现清晰的三个阶段特征：第一阶段($K = 1$)：当不进行分组时，算法等同于全局自适应截断，其PSNR与SSIM在所有测试中均处于绝对低谷。这再次在实验层面印证了全局统一截断处理复杂自然图像的固有缺陷。

第二阶段($K \rightarrow 3$)：随着分组数量增至3，PSNR与SSIM均迎来了极其剧烈的攀升，并到达了

一个极为优异的性能平台期。这一数学拐点并非偶然，它完美契合了人类视觉与自然图像底层特征的“平滑、纹理、边缘”三大物理语义区，使得自适应准则得以“因材施教”。

第三阶段($K > 3$ 的过拟合灾难)：值得高度警惕的是，若盲目追求更细的切分(如 $K \geq 4$ 甚至 $K = 6$)，算法表现出了极强的泛化不稳定性。一方面，过度分组导致各子组内的有效图像块数量发生锐减，直接引发了基于大数定律的Hutchinson 随机迹估算准则出现统计偏差，导致结构相似性(SSIM)停止增长甚至出现反噬下降；另一方面，如图4尾端所示，过度的空间割裂破坏了非局部自相似性构建的连续低秩流形，最终导致PSNR 出现回落。

综合考量物理语义的完美对齐、统计估算的样本冗余度保障，以及跨场景的泛化稳定性，本文在避免过拟合的前提下，确立 $K = 3$ 为兼顾理论可解释性与代数性能的绝对最优配置。

4.3.3. 容差系数(τ)的无偏估计印证

容差系数 τ 控制着自适应准则对残差能量的容忍阈值。图5展示了 $\tau \in [0.8, 1.4]$ 区间内的性能波动。




Figure 5. Inverted U-shaped sensitivity analysis of the tolerance coefficient τ

图 5. 容差系数 τ 的倒U 型敏感度分析

实验曲线呈现出极其优美的“倒U 型”分布，且PSNR 与SSIM 的最高点分毫不差地重合于 $\tau = 1.0$ 处。当 $\tau < 1.0$ 时，过低的阈值导致高频噪声残留(欠截断)；当 $\tau > 1.0$ 时，过高的阈值导致纹理细节被抹杀(过平滑)。这一物理极值与高斯白噪声残差能量数学期望的无偏估计理论完全吻合，强有力地证实了该自适应准则在本文分组框架下具有绝佳的数值鲁棒性。

4.4. 策略消融与全面泛化能力验证

在确立了最优超参数架构($b = 6, step = 2, K = 3, \tau = 1.0$) 之后，本节设计了严格的策略消融实验与主流经典算法的对比分析。为全面验证本文提出的“TV 排序诱导低秩”与“分组自适应”两大核心机制的有效性，并客观评估其在去噪领域的相对性能，实验选取了以下四种策略作为Baseline进行深度对比：

- **Fixed-k RSVD (极限固定秩)**: 消融基线一。传统做法, 不对图像进行重排分组, 直接使用全局固定经验秩, 用于验证自适应机制的必要性。
- **Global-Ada RSVD (全局自适应)**: 消融基线二。仅引入随机误差准则, 但不进行TV 特征重构与局部展开, 用于验证TV 排序与局部化处理的不可或缺性。
- **BM3D (三维块匹配)**: 业界经典去噪标杆, 基于非局部自相似性机制。
- **Traditional WNNM (传统加权核范数)**: 传统低秩矩阵优化方法的代表, 用于对比本文随机化轻量架构与传统重型迭代优化算法的特性差异。

为全面验证算法的泛化鲁棒性, 实验在House与Cameraman两幅异质图像上进行了正交交叉测试。测试环境涵盖了轻度噪声($\sigma = 0.02$)、基准噪声($\sigma = 0.05$)以及重度噪声($\sigma = 0.10$)的极限压测。各策略的去噪性能与机制深度对比详见表 1、表 2。

1. 核心机制消融验证(内部对比):

观察表 1与表 2 可知, 本文方法(TV-Ada RSVD) 在所有测试场景下均以绝对优势超越了Fixed-k RSVD 与Global-Ada RSVD。例如, 在House 图像轻度噪声($\sigma = 0.02$) 下, 本文方法的PSNR 达到38.33 dB, 较Global-Ada RSVD 提升了1.55 dB。正如机制缺失分析所示, Fixed-k RSVD 完全“缺乏智能自适应”能力, 而Global-Ada RSVD 在处理整幅复杂图像时极易“陷入全局数学妥协”, 导致细节模糊。本文引入的TV 排序与分组自适应机制, 成功“打破了全局抵消效应”, 使RSVD 能够精准捕获并保留局部最优的低秩结构, 有力证明了这两大核心机制的科学性与必要性。

2. 标杆算法特性对比(外部对比):

在与BM3D 和Traditional WNNM 两种经典重量级算法的横向对比中, 本文方法展现出了不同的机制侧重点。从绝对量化指标来看, BM3D 和WNNM 凭借其极高的计算复杂度与全局迭代搜索特性, 在PSNR 和SSIM 上取得了最高的数值表现。然而, 结合机制分析可以发现传统方法的固有限制:

- **BM3D** 高度依赖图像内部的非局部块相似性, 在极端重度噪声环境下(高噪易失效), 寻找真实相似块的难度剧增, 容易产生伪影;
- **Traditional WNNM** 虽能有效去除噪声, 但采用全局统一的加权核范数求解, 存在“缺乏局部结构自适应”的短板, 且通常伴随着极其高昂的计算代价。

相比之下, 本文提出的**TV-Ada RSVD** 是一种基于随机化降维的创新架构。虽然在极限评价指标上未能超越上述两种依赖密集计算的传统标杆, 但其巧妙地通过TV 特征重组, 赋予了快速RSVD 算法局部最优的自适应能力。在Cameraman 基准噪声($\sigma = 0.05$) 下, 本文方法取得了30.81 dB/0.8818 的优异成绩, 大幅拉开了与普通全局RSVD 的差距, 成功逼近了重型经典算法的处理水平。

总结:

综合多场景与多噪声梯度的交叉压测结果, 本文方法展现出了极强的泛化鲁棒性。实验证明, TV-Ada RSVD 有效规避了全局降维的数学妥协与传统低秩方法的局部适应性缺失, 提供了一种

在“智能自适应”、“局部结构保留”与“快速随机化架构”之间取得高度平衡的去噪新范式。

Table 1. Comparison of smoothness and generalization of different denoising strategies across multiple scenarios (test image: House, PSNR/SSIM)

表 1. 不同去噪策略在多场景下的消融与泛化对比(测试图像: House, PSNR/SSIM)

去噪策略(Strategy)	House			机制缺失分析
	$\sigma = 0.02$	$\sigma = 0.05$	$\sigma = 0.10$	
带噪图像(Noisy)	33.96/0.8272	26.00/0.4996	19.98/0.2653	外部环境劣化
Fixed-k RSVD (极限固定秩)	34.89/0.9120	31.70/0.8065	28.41/0.6902	缺乏智能自适应
Global-Ada RSVD (全局自适应)	36.78/0.9230	31.52/0.8164	28.28/0.7271	陷入全局数学妥协
BM3D (三维块匹配)	39.51/0.9527	35.39/0.8951	32.30/0.8334	依赖自相似, 高噪易失效
Traditional WNNM (传统加权核范数)	39.43/0.9564	34.92/0.9030	31.59/0.8409	缺乏局部结构自适应
TV-Ada RSVD (本文方法)	38.33/0.9479	33.44/0.8733	29.90/0.7854	打破抵消, 局部最优

Table 2. Comparison of smoothness and generalization of different denoising strategies across multiple scenarios (test image: Cameraman, PSNR/SSIM)

表 2. 不同去噪策略在多场景下的消融与泛化对比(测试图像: Cameraman, PSNR/SSIM)

去噪策略(Strategy)	House			机制缺失分析
	$\sigma = 0.02$	$\sigma = 0.05$	$\sigma = 0.10$	
带噪图像(Noisy)	33.96/0.8392	26.00/0.5449	19.98/0.3255	外部环境劣化
Fixed-k RSVD (极限固定秩)	28.32/0.8730	27.29/0.7688	25.22/0.6024	缺乏智能自适应
Global-Ada RSVD (全局自适应)	34.11/0.8856	28.54/0.7344	25.17/0.6091	陷入全局数学妥协
BM3D (三维块匹配)	38.04/0.9596	32.51/0.9015	29.01/0.8183	依赖自相似, 高噪易失效
Traditional WNNM (传统加权核范数)	37.91/0.9595	32.26/0.9101	28.62/0.8436	缺乏局部结构自适应
TV-Ada RSVD (本文方法)	36.58/0.9491	30.81/0.8818	27.11/0.7710	打破抵消, 局部最优

除了去噪质量的静态评估, 算法的运行效率与时间复杂度是衡量其实用价值的另一核心维度。为了凸显本文基于随机化降维架构的轻量化优势, 实验进一步记录了各去噪策略在处理House与Cameraman 图像时的实际运行时间(单位: 秒), 详见表 3 与表 4。

3. 运行效率与时间复杂度分析(极致平衡):

结合表 3 与表 4 的耗时数据, 我们可以清晰地看到本文方法在计算效率上的压倒性优势, 这也解释了为何在极限画质上本文方法与经典重型算法存在特定权衡:

- **重型算法的算力瓶颈:** 尽管BM3D 与Traditional WNNM 在前文的客观评价指标中表现优异, 但其计算代价极其高昂。在处理单张图像时, 两者的耗时普遍高达20 至38 秒。正如表内机制分析所示, BM3D 的“三维块匹配”搜索与WNNM 的“频繁迭代加权核范数优化”产生了巨大的运算开销, 这种严重耗时的特性极大地限制了它们在实时处理或大规模工程中的应用。
- **本文方法的毫秒级响应:** 相比之下, 本文提出的**TV-Ada RSVD** 方法在所有噪声梯度下的运行时间均稳定在**0.03 至0.07 秒**之间, 实现了真正的“**毫秒级实时响应**”。这意味着, 本文方法在运行速度上比BM3D 和传统WNNM 快了**近1000 倍**。
- **极低的附加开销:** 值得关注的是, 与结构最简单的Global-Ada RSVD (耗时约0.01 - 0.03 秒)相比, 本文方法在引入了精细的“TV 排序诱导”与“分块局部自适应”机制后, 仅仅增加了约几十毫秒的微小时间开销。这充分印证了本文设计的特征重排与自适应阈值策略具有极高的计算友好性。

消融与泛化实验总论：综合表 1 至表 4 的全面压测结果，本文所提出的TV-Ada RSVD 算法不仅有效克服了常规全局降维的数学妥协，更在“重型迭代优化算法(耗时长、画质略高)”与“基础快速算法(耗时极短、画质差)”之间，开辟出了一条全新的路径。它以近乎零附加开销的极速执行效率，斩获了高度竞争力的去噪质量，完美诠释了去噪算法在“高性能”与“超高效率”之间的极致平衡。

Table 3. Comparison of runtime of different denoising strategies at different noise levels (test image: House, unit: s)

表 3. 不同去噪策略在不同噪声水平下的运行时间对比(测试图像：House，单位：秒)

去噪策略(Strategy)	测试图像：House (运行时间/s)			时间复杂度评估
	$\sigma = 0.02$	$\sigma = 0.05$	$\sigma = 0.10$	
Fixed-k RSVD (极限固定秩)	1.30	1.50	1.32	基础SVD，常规秒级
Global-Ada RSVD (全局自适应)	0.02	0.02	0.01	全局极简，耗时极低
BM3D (三维块匹配)	29.68	26.71	26.92	三维匹配，开销巨大
Traditional WNNM (传统加权核范数)	24.35	21.94	23.70	频繁迭代，严重耗时
TV-Ada RSVD (本文方法)	0.04	0.03	0.03	极低附加开销，毫秒级实时响应

Table 4. Comparison of runtime of different denoising strategies at different noise levels (test image: House, unit: s)

表 4. 不同去噪策略在不同噪声水平下的运行时间对比(测试图像：Cameraman，单位：秒)

去噪策略(Strategy)	测试图像：Cameraman (运行时间/s)			时间复杂度评估
	$\sigma = 0.02$	$\sigma = 0.05$	$\sigma = 0.10$	
Fixed-k RSVD (极限固定秩)	1.33	1.29	1.34	基础SVD，常规秒级
Global-Ada RSVD (全局自适应)	0.03	0.02	0.01	全局极简，耗时极低
BM3D (三维块匹配)	27.31	27.96	38.55	三维匹配，开销巨大
Traditional WNNM (传统加权核范数)	24.09	23.46	31.68	频繁迭代，严重耗时
TV-Ada RSVD (本文方法)	0.04	0.03	0.07	极低附加开销，毫秒级实时响应

4.5. 综合去噪性能与视觉细节验证

为了直观且深刻地验证不同截断策略对图像局部微观结构的影响，图 6 展示了 *Cameraman* 图像($\sigma = 0.05$) 的去噪视觉对比。本组对比图极其精准地印证了前文对于全局正交投影“顾此失彼”缺陷的数学分析。




Figure 6. Visual comparison of denoising results and local detail visualization for the *Cameraman* image

图 6. *Cameraman* 图像去噪视觉对比与局部细节展示

观察图 6 可发现令人瞩目的现象：首先，采用一刀切截断的Fixed-k 策略，由于无法适应局部平滑度，其背景天空区域残留了致密的“麻点状”高频噪声。其次，Global-Ada 全局自适应策略

暴露了严重的理论妥协：该算法为了强行滤除背景噪声而被迫选取了极小的全局截断秩 k ，这把无情的低秩截断刀直接抹杀了摄影师面部与三脚架的锐利边缘，导致图像出现了极其严重的振铃模糊伪影(Ringing Artifacts)。

形成鲜明对比的是，本文提出的TV-Ada RSVD 算法在视觉观感上实现了无可争议的登顶。得益于排序分组机制的“因材施教”：平滑组(天空)被智能分配了极小的秩以实现极致净化；而边缘组(三脚架)则被分配了极大的秩以实现高频保真。这完美印证了打破“数学抵消困境”对释放低秩红利的决定性意义。

5. 结论

针对传统全局奇异值分解(SVD)在图像去噪中面临的“去噪与保边”妥协困境，以及针对逆问题设计的尾部截断补偿机制在纯数据域中易诱发伪能量注入的固有缺陷，本文提出了一种基于分块梯度排序与分组自适应随机奇异值分解(RSVD)的全新图像去噪架构。

5.1. 研究总结

本文的核心理论贡献可归纳为以下三个方面：

- 理论突破：**通过矩阵代数推导，严格揭示并证明了全局正交投影对数据重排操作存在的“数学抵消效应”，从根本上解释了传统方法在保留局部细节特征时的失效机理。
- 方法创新：**为打破上述理论壁垒，本文巧妙地将一维全变分(TV)特征流形对齐与非线性分组截断相结合，构建了鲁棒的特征映射空间。
- 工程实现：**引入基于Hutchinson 随机迹估算的无偏误差准则，实现了针对各复杂度子组的自适应最优截断秩解算，确保了降维逼近的精确性。

详实的消融实验与参数敏感性分析表明，得益于随机化算子的计算加速，本文算法在兼顾极高运算效率的同时，成功将SVD 的低秩红利锁定在局部子空间中。无论在轻度还是重度噪声压力下，本文算法在客观量化指标(如PSNR、SSIM 等)与主观视觉保真度上，均优于传统的全局固定秩与全局自适应去噪算法。

5.2. 研究意义与后续工作

本文的研究不仅为大规模数据驱动的图像恢复任务提供了一种高效的数值代数求解方案，也为矩阵低秩逼近理论在无算子正问题中的应用拓展了新的思路。

后续研究工作将重点关注以下方向：

- 多维扩展：**探讨将该自适应分组机制推广至彩色图像及高维张量去噪领域的可行性。
- 性能优化：**结合深度学习中的自监督框架，进一步挖掘该架构在复杂非高斯噪声环境下的泛化能力。

参考文献

- [1] Buades, A., Coll, B. and Morel, J.M. (2005) A Non-Local Algorithm for Image Denoising. 2005 *IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*, San Diego, 20-25 June 2005, 60-65. <https://doi.org/10.1109/cvpr.2005.38>
- [2] Elad, M. and Aharon, M. (2006) Image Denoising via Sparse and Redundant Representations over Learned Dictionaries. *IEEE Transactions on Image Processing*, **15**, 3736-3745. <https://doi.org/10.1109/tip.2006.881969>
- [3] Dong, W., Shi, G. and Li, X. (2013) Nonlocal Image Restoration with Bilateral Variance Estimation: A Low-Rank Approach. *IEEE Transactions on Image Processing*, **22**, 700-711. <https://doi.org/10.1109/tip.2012.2221729>
- [4] Cai, J., Candès, E.J. and Shen, Z. (2010) A Singular Value Thresholding Algorithm for Matrix Completion. *SIAM Journal on Optimization*, **20**, 1956-1982. <https://doi.org/10.1137/080738970>
- [5] Eckart, C. and Young, G. (1936) The Approximation of One Matrix by Another of Lower Rank. *Psychometrika*, **1**, 211-218. <https://doi.org/10.1007/bf02288367>
- [6] Halko, N., Martinsson, P.G. and Tropp, J.A. (2011) Finding Structure with Randomness: Probabilistic Algorithms for Constructing Approximate Matrix Decompositions. *SIAM Review*, **53**, 217-288. <https://doi.org/10.1137/090771806>
- [7] Martinsson, P.G. and Tropp, J.A. (2020) Randomized Methods for Matrix Computations. *Annual Review of Computational and Data Science*, **1**, 1-41.
- [8] Halko, N., Martinsson, P., Shkolnisky, Y. and Tygert, M. (2011) An Algorithm for the Principal Component Analysis of Large Data Sets. *SIAM Journal on Scientific Computing*, **33**, 2580-2594. <https://doi.org/10.1137/100804139>
- [9] Bai, X., Huang, G.X., Lei, X.J., Reichel, L. and Yin, F. (2021) A Novel Modified TRSVD Method for Large-Scale Linear Discrete Ill-Posed Problems. *Applied Numerical Mathematics*, **164**, 72-88. <https://doi.org/10.1016/j.apnum.2020.08.019>
- [10] Hutchinson, M.F. (1989) A Stochastic Estimator of the Trace of the Influence Matrix for Laplacian Smoothing Splines. *Communications in Statistics—Simulation and Computation*, **18**, 1059-1076. <https://doi.org/10.1080/03610918908812806>
- [11] Avron, H. and Toledo, S. (2011) Randomized Algorithms for Estimating the Trace of an Implicit Symmetric Positive Semi-Definite Matrix. *Journal of the ACM*, **58**, 1-34. <https://doi.org/10.1145/1944345.1944349>
- [12] Rudin, L.I., Osher, S. and Fatemi, E. (1992) Nonlinear Total Variation Based Noise Removal Algorithms. *Physica D: Nonlinear Phenomena*, **60**, 259-268. [https://doi.org/10.1016/0167-2789\(92\)90242-f](https://doi.org/10.1016/0167-2789(92)90242-f)

-
- [13] Zhang, L., Dong, W., Zhang, D. and Shi, G. (2010) Two-Stage Image Denoising by Principal Component Analysis with Local Pixel Grouping. *Pattern Recognition*, **43**, 1531-1549. <https://doi.org/10.1016/j.patcog.2009.09.023>
- [14] Field, D.J. (1987) Relations between the Statistics of Natural Images and the Response Properties of Cortical Cells. *Journal of the Optical Society of America A*, **4**, 2379-2394. <https://doi.org/10.1364/josaa.4.002379>
- [15] Zoran, D. and Weiss, Y. (2011) From Learning Models of Natural Image Patches to Whole Image Restoration. *2011 International Conference on Computer Vision*, Barcelona, 6-13 November 2011, 479-486. <https://doi.org/10.1109/iccv.2011.6126278>
- [16] Chang, S.G., Bin Yu, and Vetterli, M. (2000) Adaptive Wavelet Thresholding for Image Denoising and Compression. *IEEE Transactions on Image Processing*, **9**, 1532-1546. <https://doi.org/10.1109/83.862633>
- [17] Gu, S., Zhang, L., Zuo, W. and Feng, X. (2014) Weighted Nuclear Norm Minimization with Application to Image Denoising. *2014 IEEE Conference on Computer Vision and Pattern Recognition*, Columbus, 23-28 June 2014, 2862-2869. <https://doi.org/10.1109/cvpr.2014.366>
- [18] Dabov, K., Foi, A., Katkovnik, V. and Egiazarian, K. (2007) Image Denoising by Sparse 3-D Transform-Domain Collaborative Filtering. *IEEE Transactions on Image Processing*, **16**, 2080-2095. <https://doi.org/10.1109/tip.2007.901238>