基于组稀疏混合模型的遥感图像去噪方法

张瑜舟1*,成丽波1.2

1长春理工大学数学与统计学院,吉林 长春 2长春理工大学中山研究院遥感技术与大数据分析实验室,广东 中山

收稿日期: 2025年1月13日; 录用日期: 2025年2月7日; 发布日期: 2025年2月17日

摘要

在遥感图像的拍摄和传输过程中,会产生大量的噪声,高斯噪声和椒盐噪声是较为常见的两种噪声,目前的去噪算法对于这类混合噪声的去除普遍存在边缘模糊等问题。针对此问题,文章提出了一种新的基于组稀疏混合模型的遥感图像混合噪声的去除方法,首先通过双边矩阵乘法提高块组的稀疏性,然后通过块组独立这一假设提出了基于块组的混合噪声去噪框架,接着对辅助变量、估计的图像、椒盐噪声分别进行最小化问题的优化求解,最后通过聚合块组得到去噪后的图像。实验结果表明,本文的算法能够有效地去除遥感图像中的高斯噪声和椒盐噪声,相对于其他传统方法具有更高的PSNR、SSIM以及FSIM数值。

关键词

遥感图像去噪,混合噪声,组稀疏混合模型,双边矩阵乘法,块组

Remote Sensing Image Denoising Method Based on Group Sparse Mixture Model

Yuzhou Zhang^{1*}, Libo Cheng^{1,2}

¹School of Mathematics and Statistics, Changchun University of Science and Technology, Changchun Jilin ²Laboratory of Remote Sensing Technology and Big Data Analysis, Zhongshan Institute of Changchun University of Science and Technology, Zhongshan Guangdong

Received: Jan. 13th, 2025; accepted: Feb. 7th, 2025; published: Feb. 17th, 2025

Abstract

In the process of capturing and transmitting remote-sensing images, a large amount of noise is generated. Gaussian noise and salt-and-pepper noise are two common types of noise. Current denoising

*通讯作者。

algorithms generally have problems with edge blurring when removing such mixed noise. To address this problem, we propose a new method based on a group sparse mixed model to remove mixed noise in remote sensing images. Firstly, the sparsity of patch groups is improved through bilateral matrix multiplication. Then, a patch group-based mixed noise denoising framework is proposed based on the assumption of patch group independence. Then, the auxiliary variables, estimated images, and salt and pepper noise are optimized and solved separately. Finally, the denoised image is obtained by aggregating patch groups. Experimental results show that the algorithm in this paper can effectively remove Gaussian noise and salt-and-pepper noise in remote sensing images and has higher values of PSNR, SSIM, and FSIM compared with several popular algorithms.

Keywords

Remote Sensing Image Denoising, Mixed Noise, Group Sparse Mixed Model, Bilateral Matrix Multiplication, Patch Group

Copyright © 2025 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/

1. 引言

遥感是指在不接触研究目标的情况下,利用飞行器对目标物体的信息进行提取和处理的一门观测技术[1]。然而,由于成像环境和设备的限制,遥感图像会被噪声污染,严重降低了图像的视觉质量,无法满足人们对质量的需求[2]。

目前,图像去嗓算法[3]大致分为传统的空间域法[4]和变换域法[5]、基于偏微分方程的方法[6]、基于 非局部自相似性的方法[7]、基于稀疏表示的方法[8] [9]。其中,组稀疏模型(Group Sparsity Model, GSM) 在图像去噪取得了巨大成功,基于稀疏表示的图像去噪方法是采用冗余字典对图像进行稀疏分解,将图 像的有用信息看作是稀疏分量,将噪声看作图像稀疏表示后的残差[10]。根据字典学习算法,Xu等人[11] 提出了基于非局部块的稀疏表示图像去噪算法,通过训练大量字典集进行图像去噪。针对去噪算法容易 忽略退化图像的噪声,从而干扰相似图像块的选择这个问题,Zha等人[12]利用组稀疏残差和外部非局部 自相似先验,对原始图像和噪声图像的组稀疏系数进行了近似。为了同时利用稀疏表示和图像的非局部 自相似性的优点,Lee等人[13]提出了基于字典学习的非局部稀疏表示去噪算法,对图像的局部信息和非 局部信息进行了充分利用。针对不重复图像块恢复后出现伪影这一问题,Ou等人[14]提出了一种新的多 尺度加权组稀疏编码图像去噪模型,利用多尺度非局部自相似先验构造相似块,利用交替极小化方法求 解模型,但不能够对块组进行建模。为了有效学习图像块组,Liu等人[15]提出了组稀疏混合模型(Group Sparsity Mixture Model, GSMM),通过双边矩阵乘法表述单个块的局部特征和非局部相似块之间的关系,将强稀 疏性体现在图像块组中。然而,上述基于稀疏表示的图像去噪算法对于非局部相似块的容量相对有限。

现有的大部分图像去噪方法是对高斯噪声进行复原,然而,遥感图像容易同时受到高斯噪声和椒盐 噪声的影响。早期的混合噪声去噪方法往往采用检测的方法,Liu 等人[16]提出了一种基于图像局部统计 信息的椒盐噪声检测方法,但是随着图像统计信息被噪声污染程度的增加,对椒盐噪声检测的准确度也 受到了影响。为了进一步提高去噪效果,Xiao 等人[17]提出了一种*l*₀-*l*₁最小化方法,*l*₁用于去除椒盐噪 声,*l*₀用于对某个未知的稀疏表示图像块字典。由于图像中含有不规则的数据,Wang 等人[18]通过最小 化加权保真度项和稀疏正则化项的和去除图像的混合噪声,但对于图像块的先验特征研究较少。由于图 像中含有大量的冗余信息,朱文生等人[19]采用加权稀疏表示模型刻画图像的全局特性,同时利用范数描述稀疏噪声,但没有充分利用混合噪声的统计特征,对于混合噪声的滤波性能较弱。

基于组稀疏去噪方法大多只能去除单一类型的图像噪声,为了避免遥感图像中混合噪声产生的影响, 并充分学习图像非局部相似块组的先验知识,本文提出了一种新的组稀疏混合模型去除图像混合噪声的 方法,首先通过双边矩阵乘法提高块组的稀疏性,接着通过块组独立这一假设提出了基于块组的混合噪 声去噪框架,最后通过聚合块组得到去噪后的图像。实验结果表明,本文相对于其他传统算法具有更好 的去噪效果。

2. 相关工作

2.1. 去噪模型

在数学中,图像去噪问题本质上是不适定的逆问题,遥感图像在成像过程中会受到高斯噪声和椒盐 噪声的影响,图像去噪的退化模型可以表示为

$$y = x + N + S \tag{1}$$

其中, x表示原始图像, N表示加性高斯白噪声(Additive White Gaussian Noise, AWGN), S表示椒盐噪声(Impulse Noise, IN), 图像去噪的目的是从一幅干净图像的噪声观测值 g 中得到它的精确观测值 f_0 , 通过最大后验概率(Maximum A Posteriori, MAP)框架获得图像去噪模型

$$\hat{f} = \arg\min_{f} -\ln\left(p(g, S|f) - \ln(p(f))\right)$$
(2)

其中, \hat{f} 是估计图像, p(g|f)表示噪声分布, p(f)表示图像先验。 该去噪模型还可以写为

$$\hat{f} = \arg\min D(f,g;S) + R(f)$$
(3)

其中, D(f,g;S)为数据保真度项, R(f)为正则化项。

2.2. 稀疏表示模型

本文是对图像块组的先验进行建模,块组 $M \in R^{l \times J}$ 是通过图像f的前J个最相似块分组为局部块 $x \in R'$ 来确定的,对于第n个图像块 x_n ,其对应的块组 M_n 为

$$M_{n} = \left[x_{n,1}, x_{n,2}, \cdots, x_{n,J} \right]$$
(4)

其中, $x_{n,i}$ 表示与 x_n 最相似的第j个块, 从图像f中提取 x_n 和 M_n 的算子, 分别由 P_n 和 P_{M_n} 表示:

$$P_n f = x_n, P_{M_n} f = vect(M_n)$$
⁽⁵⁾

其中, vect(·)是将矩阵转换为列向量的运算符。

稀疏表示方法只能利用单个图像块内的局部特征,为了对图像的内在非局部自相似性进行建模,将 稀疏表示的各种非局部扩展写成统一的形式[17]:

$$R(M) = \left\| U^{\mathrm{T}} \cdot M \cdot V \right\|_{X} \tag{6}$$

其中,矩阵范数 $\|\cdot\|_v$ 被施加在双边矩阵乘法 $U^{\mathrm{T}}MV$ 上。

从数学上讲, 左乘矩阵 U 和右乘矩阵 V 分别在 M 的行和列之间进行, 由于 M 的每一列都是图像块, U 可以捕获单个图像块内的局部特征并将图像块变换为稀疏系数, V 可以捕获块组不同块之间的非局部 特征并进一步增强系数的稀疏性,具体表现形式如图1所示。



Figure 1. The influence of U and V on M in bilateral matrix multiplication 图 1. 双边矩阵乘法中 U 和 V 对 M 的影响

U和V在块组变换中的大多数系数具有最小方差,表明双边矩阵乘法具有强稀疏性,适用于块组的先验建模。

2.3. 组稀疏混合模型

通过双边矩阵乘法来表示组稀疏混合模型的数学形式[15]:

$$p(M) = \sum_{k=1}^{K} \pi_k \cdot q(M; \theta_k)$$
⁽⁷⁾

其中, 混合系数 π_k 满足 $\sum_k \pi_k = 1$, 且 $0 \le \pi_k \le 1$, 分量分布 $q(M; \theta)$ 是

$$q(M;\theta) = \frac{1}{Z(\theta)} \exp\left(-\frac{1}{2} \left\| U^{\mathrm{T}} M V \right\|_{F,W^{-1}}^{2}\right)$$
(8)

其中, θ={U,V,W}, W 是正对角矩阵, ||·||_F 是加权 F 范数。 根据文献[15], 归一化因子 Z(θ)的计算可表示为

$$Z(\theta) = \frac{1}{(2\pi)^{(IJ)/2}} \frac{1}{|W|^{1/2}}$$
(9)

其中, |. |表示矩阵行列式。

3. 算法模型

本文的去噪算法流程如图 2 所示,可以分为以下几个阶段:



Figure 2. Flow chart of Group Sparse Mixture Model for removing mixed noise 图 2. 组稀疏混合模型去除混合噪声流程图

3.1. 基于块组的混合噪声去除框架

本文提出的基于块组的去噪框架是基于块组独立这一假设,在这个假设下,将一般形式的 MAP 修改为基于块组的形式,用 $p(f|g;S) = p(P_{M_n}f|P_{M_n}g;S)$ 相乘,即

$$\hat{f} = \arg\max_{f} \prod_{n=1}^{N} p\left(P_{M_{n}}f \left| P_{M_{n}}g;S\right)\right)$$

$$= \arg\min_{f} \sum_{n=1}^{N} \left(-\ln\left(p\left(P_{M_{n}}g;S \left| P_{M_{n}}f\right)\right) - \ln\left(p\left(P_{M_{n}}f\right)\right)\right)\right)$$
(10)

假设噪声为高斯噪声与椒盐噪声混合,该框架可进一步写为:

$$\hat{f} = \arg\min_{f} \frac{1}{2\sigma^{2}} \|g - f - S\|_{2,W_{NL}}^{2} + \lambda \|S\|_{1} + \sum_{n=1}^{N} R(P_{M_{n}}f)$$
(11)

其中, σ 是高斯噪声水平,S是椒盐噪声。

$$R(P_{M_n}f) = -\ln(p(P_{M_n}f))$$
(12)

$$W_{NL} = \sum_{n=1}^{N} P_{M_n}^{\rm T} P_{M_n}$$
(13)

其中, W_{NL}是对角矩阵, 其对角元素是每个图像像素的被采样次数。

本文通过半二次分裂(Half Quadratic Splitting, HQS)的方法优化本文框架,将原始问题转化为最小化问题。

$$\min \frac{1}{2\sigma^2} \|g - f - S\|_{2,W_{NL}} + \lambda \|S\|_1 + \sum_{n=1}^{N} \left[\frac{\beta}{2} \|P_{M_n} f - z^n\|_2^2 + R(z^n)\right]$$
(14)

将每个块组 P_{M_n} 引入辅助变量 z^n , 有 $z^n = P_{M_n}f$, β 是可调参数, 当 $\beta \to \infty$ 时, 此问题等价于原问题, 因此本文通过反复优化 f, z^n , S, 使 β 逐渐增加, 得到原问题的近似解, 对于固定的 β , 引入f, z^n , S 的优化求解。

3.2. 优化求解

子问题 1: 优化 zⁿ

将每个 z"相关的子问题可以看成一个块组去噪问题

$$z^{n} = \min_{z^{n}} \frac{\beta}{2} \left\| P_{M_{n}} f - z^{n} \right\|_{2}^{2} + R(z^{n})$$
(15)

其中, $R(z^n)$ 为正则化项, $P_{M_n}f$ 是待处理的块组, z^n 的最佳值是去噪结果。

将学习到的 GSMM 模型替换成式(12),有

$$R(z^{n}) = -\ln p(Z^{n}) = -\ln \sum_{k=1}^{K} \pi_{k} \cdot q(Z^{n}; \theta_{k})$$
(16)

其中, Z^n 是满足 $z^n = vect(Z^n)$ 的矩阵, 式(16)中的正则化项 $R(z^n)$ 的计算过程如下:

参考文献[11], 第二变体用修改的拉普拉斯分布替换 GSMM 为:

$$\frac{1}{2^{(l\cdot J)}} \left| \tilde{W}_{\hat{k}_n} \right| \exp \left(- \left\| \hat{W}_{\hat{k}_n} \cdot \left(V_{\hat{k}_n} \otimes U_{\hat{k}_n} \right)^{\mathrm{T}} \cdot z^n \right\|_{1} \right)$$
(17)

其中, k 表示第k 个分量分布, \hat{k}_n 为Z"的分类, \otimes 表示克罗内克积, 相应的正则化项是

$$\boldsymbol{R}_{l_1} = \left\| \tilde{W}_{\hat{k}_n} \cdot \left(\boldsymbol{V}_{\hat{k}_n} \otimes \boldsymbol{U}_{\hat{k}_n} \right)^{\mathrm{T}} \cdot \boldsymbol{z}^n \right\|_{1}$$
(18)

其中, $\tilde{W}_{\hat{k}}$ 为

$$\tilde{W}_{\hat{k}_n} = c \cdot W_{\hat{k}_n}^{-1/2} \tag{19}$$

其中, c是正可调参数, 最小化问题的求解可参考文献[15]。

z"的最小化优化问题为

$$z^{n} = \min_{z^{n}} \frac{\beta}{2} \left\| P_{M_{n}} f - z^{n} \right\|_{2}^{2} + \left\| c \cdot W_{\hat{k}_{n}}^{-1/2} \cdot \left(V_{\hat{k}_{n}} \otimes U_{\hat{k}_{n}} \right)^{\mathrm{T}} \cdot z^{n} \right\|_{1}$$
(20)

子问题 2: 优化 f

与 f 相关的子问题是

$$f = \min_{f} \frac{1}{2\sigma^{2}} \left\| g - f - S \right\|_{2,W_{NL}}^{2} + \frac{\beta}{2} \sum_{n=1}^{N} \left\| P_{M_{n}} f - z^{n} \right\|_{2}^{2}$$
(21)

$$f = \tilde{f} + \frac{1/\sigma^2}{1/\sigma^2 + \beta} \cdot \left(g - \tilde{f} - S\right)$$
(22)

其中,

$$\tilde{f} = W_{NL}^{-1} \sum_{n=1}^{N} P_{M_n}^{\rm T} z_n$$
(23)

f的优化首先聚集去噪后的块组 z_n 以获得原始图像 f_0 的估计值 \tilde{f} ,然后通过迭代正则化的方法将 滤波后的残差 $\left(g-\tilde{f}-S\right)$ 加回到估计的图像中去。

子问题 3: 优化 S

与 S 相关的子问题是

$$S = \min_{S} \frac{1}{2\sigma^2} \|g - f - S\|_{2, W_{NL}}^2 + \gamma \|S\|_1$$
(24)

式(24)可通过软阈值算子获得

$$S = \operatorname{shrink}\left(g - f, \frac{\gamma}{\lambda}\right)$$
(25)

其中, shrink (\cdot, ξ) 是具有阈值 ξ 的软阈值算子, 有

shrink
$$(f,\xi) = \operatorname{sign}(f) \cdot \max(|f| - \xi, 0)$$
 (26)

本文的算法如算法1所示,该算法表示为图2中的块组去噪过程:

算法 1. 基于组稀疏混合模型去噪算法

输入:噪声图像 g
输出:去噪后的图像 f
1.用 g 初始化 f

续表

2. for iter = 1 to iter_max

3. 更新β

4. 提取块组 M_n

- 5. 通过(20)式更新 z", 求解每个块组的噪声
- 6. 求解正则化项 R(zⁿ)
- 7. 通过式(23)聚集去噪块组
- 8. 通过式(24)更新稀疏噪声 S
- 9. 将过滤后的残差加回到式(22)

end

4. 实验

4.1. 参数设置

在算法 1 的去噪方法中,超参数包括迭代次数 T,每次迭代时的辅助变量 β ,本文实验设置最大迭代次数 T 为 10,每次迭代的 β 设置为

$$\beta = \frac{1}{\sigma^2} [1, 4, 8, 16, 32, 64, 128, 256, 512, 1024]$$
(27)

本文选取图像峰值信噪比(Peak Signal-to-Noise Ratio, PSNR)的平均值、图像结构相似度(Structural Similarity, SSIM)的平均值、图像的特征相似指数(Feature Similarity Index Measure, FSIM)的平均值作为评价指标。

为了确定块组 *p* 和正可调参数 *c* 最佳参数配置,本文以 church 场景的图片在高斯噪声为σ=40、椒 盐噪声 *S* =10% 为例,使用变量分析法展示参数的调节过程,分别对块的大小 *p* 选取 6、7、9,正可调参 数 *c* 选取 0.9、1.0、1.1、1、2 进行分析,图 3 分别展示了不同参数对于评价指标的影响。

根据图 3 所示,对于块的大小 p,本文所使用的 p=9 对于 SSIM 和 FSIM 值均取到最大值;而对于 正可调参数 c=1, PSNR 与 FSIM 数值均为最大值。同样的,在噪声水平 $\sigma < 40$ 时,分别采取控制变量 法,综合比较三个评价指标的变化情况,使三个评价指标尽可能达到最优,本文的最佳参数配置如下:





Figure 3. The influence of parameter size on evaluation indicators 图 3. 参数大小对评价指标的影响

在本文的算法中, $\gamma = 20$, 当 $\sigma < 40$ 时, 块的大小 p = 7, 正可调参数 c = 1.1; 当 $\sigma \ge 40$ 时, 块的大 小 p = 9, 正可调参数 c = 1。

本文所有的实验均在 Matlab2019b, 操作系统 Linux-x84-64bit, 环境 Intel Xeon(R) CPU E5-2620 以及 2.10GHz 16 和 32.0 GB 内存下运行。

4.2. 对比实验

为了验证本文算法的有效性,使用 AID 数据集不同场景下的 6 张图片,如图 4 所示。

本文分别添加三种水平的高斯噪声(σ = 30,40,50)以及三种水平的椒盐噪声(S = 10%,15%,20%),本 文选取主流的四种混合噪声去噪方法进行比较,包括:

Two-Phase [16]: 基于检测的两阶段方法;

MBM3D [21]: 中值滤波预处理后再使用经典的 BM3D 算法;

WESNR [22]: 基于加权稀疏编码和非局部相似性的方法;

MGSMM [15]: 中值滤波预处理后再使用组稀疏混合模型去噪算法。

所有算法的源代码均从作者主页下载,使用默认的参数设置。



图 4. 实验所使用的清晰图像

4.3. 实验结果

表1列出了图4中的6张图片在不同噪声水平下的平均PSNR、SSIM和FSIM数值,可以看出,本 文在处理较高水平的高斯噪声和椒盐噪声的时候,PSNR、SSIM以及FSIM数值有了显著提升,相对于 MGSMM方法,六个场景下不同噪声水平的平均PSNR提升0.0804~0.3577dB,平均SSIM提升 0.0067~0.0201dB,平均FSIM最高提升0.01dB;相对于WESNR方法,平均PSNR数值最高提升5.7255 dB,平均SSIM最高提升0.2031dB,平均FSIM最高提升0.0863dB;跟MBM3D方法比较,平均PSNR 数值提升1.3301~1.7241dB,平均SSIM提升0.0197~0.0484dB,平均FSIM数值提升0.0326~0.0432dB; 跟Two-phase方法相比,平均PSNR数值提升7.6592~11.0148dB,平均SSIM数值提升0.4715~0.5539 dB,平均FSIM数值提升0.0843~0.1477dB,因此本文相对于其他传统算法具有更好的去噪效果。

噪声水平		远位长行	T 1	N		WEAND		+++++
高斯噪声	椒盐噪声	评价指标	Initial	Two-Phase	MBM3D	WESNR	MGSMM	平 义 力 法
		PSNR	13.7861	19.0326	25.9214	28.2155	27.5651	27.6455
	S = 10%	SSIM	0.1411	0.2715	0.7252	0.7852	0.7669	0.7736
		FSIM	0.7041	0.8282	0.8712	0.9118	0.9103	0.9125
$\sigma = 30$	S = 15%	PSNR	12.4774	19.0941	25.5669	28.0216	27.1713	27.2734
		SSIM	0.1112	0.2727	0.7193	0.7808	0.7551	0.7623
		FSIM	0.6611	0.8238	0.8665	0.9108	0.9050	0.9056
	S = 20%	PSNR	11.5025	19.1314	25.2011	27.7671	26.6328	26.7906
		SSIM	0.0894	0.2732	0.7104	0.7761	0.7365	0.7447
		FSIM	0.6262	0.8172	0.8616	0.9091	0.8955	0.8961
		PSNR	13.0009	16.6900	25.0422	25.9512	26.4804	26.7479
$\sigma = 40$	S = 10%	SSIM	0.1191	0.2002	0.6937	0.7175	0.7293	0.7393
		FSIM	0.6785	0.7726	0.8514	0.8903	0.8897	0.8946
	S = 15%	PSNR	11.9134	16.7511	24.7526	25.4454	26.1057	26.3581
		SSIM	0.0962	0.2010	0.6859	0.6997	0.7132	0.7245
		FSIM	0.6420	0.7656	0.8463	0.8846	0.8813	0.8856

Table 1. Average PSNR, SSIM, FSIM values under different noise levels 表 1. 不同噪声水平下的平均 PSNR, SSIM, FSIM 数值

		PSNR	11.0709	16.7967	24.4515	24.9506	25.5897	25.8393
	S = 20%	SSIM	0.0800	0.2014	0.6765	0.6822	0.6895	0.7008
		FSIM	0.6116	0.6644	0.8408	0.8777	0.8688	0.8734
		PSNR	12.2316	14.9357	24.2706	21.5022	25.6400	25.9505
	S = 10%	SSIM	0.1013	0.1551	0.6663	0.5449	0.6943	0.7090
		FSIM	0.6536	0.7254	0.8334	0.8168	0.8693	0.8765
		PSNR	11.3337	14.9788	24.0117	20.3671	25.2201	25.5573
σ = 50	S = 15%	SSIM	0.0868	0.1559	0.6575	0.5022	0.6743	0.6918
		FSIM	0.6280	0.7193	0.8280	0.7936	0.8588	0.8669
	S = 20%	PSNR	10.6144	15.0127	23.7252	19.3327	24.6975	25.0552
		SSIM	0.0713	0.1554	0.6468	0.4635	0.6465	0.6666
		FSIM	0.5960	0.7103	0.8200	0.7677	0.8441	0.8540

图 5 列出了六种场景下不同方法不同噪声水平的细节对比图,其中,Image A 选取 σ =50的高斯噪声以及S=10%的椒盐噪声;Image B 选取 σ =40的高斯噪声以及S=20%的椒盐噪声;Image C 选取 σ =40的高斯噪声以及S=15%的椒盐噪声;Image D 选取 σ =40的高斯噪声以及S=10%的椒盐噪声;Image E 选取 σ =50的高斯噪声以及S=20%的椒盐噪声;Image F 选取 σ =50的高斯噪声以及S=20%的椒盐噪声。



Figure 5. Comparison image of different noise levels in different scenes 图 5. 不同场景下不同噪声水平的对比图

张瑜舟,成丽波

从主观视觉上看,two-phase 对于混合噪声的去除仍有残余的混合噪声,使得边缘细节不清晰; MBM3D 在处理混合噪声的时候,使得图像过于平滑,导致图像的细节丢失;WESNR 在处理混合噪声的 时候,产生了大量的黑色伪影,使得图像的边缘模糊,不能够很好地展现图像的细节信息;在使用 MGSMM 处理混合噪声的时候,产生了过多的伪影。使用 two-phase、MBM3D、WESNR、MGSMM 在处理混合高 斯和椒盐噪声的时候,不能有效地保留图像的边缘信息,而本文算法在去除高斯和椒盐噪声的同时更好 地保留了图像的目标边缘和细节纹理信息,具有更清晰的视觉效果。

5. 结论

为了去除遥感图像中的混合噪声,本文提出了一种新的组稀疏混合模型去除遥感图像中的高斯噪声和椒盐噪声。首先通过双边矩阵乘法提高块组的稀疏性,然后通过块组独立这一假设提出了基于块组的 混合噪声去噪框架,接着对去噪后的块组 z"、估计的图像 f 、椒盐噪声 S 分别进行优化求解,最后通过 聚合块组得到去噪后的图像,同时实验结果表明:本文相对于其他传统算法,PSNR、SSIM 与 FSIM 值 有了显著提升。主观视觉方面,在去除图像噪声的同时更好地保留了边缘信息,相对于其他传统算法具 有更好的去噪性能。

本文仅使用传统方法进行图像去噪,在未来的工作中,可将研究的重心转向如何将深度学习与数学 优化模型巧妙融合起来。

基金项目

吉林省教育厅科学技术研究项目(JJKH20230788KJ);国家自然科学基金(12171054)。

参考文献

- [1] 卢廷玉. 基于深度学习的遥感影像作物精细分类方法研究[D]: [博士学位论文]. 哈尔滨: 哈尔滨师范大学, 2023.
- [2] 任超, 张胜国, 李现广, 等. 一种新的遥感影像组合滤波去噪方法[J]. 桂林理工大学学报, 2023, 43(3): 442-449.
- [3] 徐华. 基于稀疏表示的图像去噪算法研究[D]: [硕士学位论文]. 重庆: 重庆邮电大学, 2020.
- [4] Tan, X., Sun, C. and Pham, T.D. (2016) Edge-Aware Filtering with Local Polynomial Approximation and Rectangle-Based Weighting. *IEEE Transactions on Cybernetics*, 46, 2693-2705. <u>https://doi.org/10.1109/tcyb.2015.2485203</u>
- [5] Chen, X., Liu, L., Zhang, J. and Shao, W. (2021) Infrared Image Denoising Based on the Variance-Stabilizing Transform and the Dual-Domain Filter. *Digital Signal Processing*, **113**, Article 103012. <u>https://doi.org/10.1016/j.dsp.2021.103012</u>
- [6] Guillemot, C. and Le Meur, O. (2014) Image Inpainting: Overview and Recent Advances. *IEEE Signal Processing Magazine*, 31, 127-144. <u>https://doi.org/10.1109/msp.2013.2273004</u>
- [7] Zhong, H., Ma, K. and Zhou, Y. (2015) Modified BM3D Algorithm for Image Denoising Using Nonlocal Centralization Prior. Signal Processing, 106, 342-347. <u>https://doi.org/10.1016/j.sigpro.2014.08.014</u>
- [8] Wu, Y.W., Jia, Y.D., Li, P.H., Zhang, J. and Yuan, J.S. (2015) Manifold Kernel Sparse Representation of Symmetric Positive-Definite Matrices and Its Applications. *IEEE Transactions on Image Processing*, 24, 3729-3741. <u>https://doi.org/10.1109/tip.2015.2451953</u>
- Gai, S., Wang, L., Yang, G. and Yang, P. (2016) Sparse Representation Based on Vector Extension of Reduced Quaternion Matrix for Multiscale Image Denoising. *IET Image Processing*, 10, 598-607. <u>https://doi.org/10.1049/iet-ipr.2015.0611</u>
- [10] 王忠美,杨晓梅,顾行发.张量组稀疏表示的高光谱图像去噪算法[J]. 测绘学报, 2017, 46(5): 614-622.
- [11] Xu, J., Zhang, L., Zuo, W., Zhang, D. and Feng, X. (2015) Patch Group Based Nonlocal Self-Similarity Prior Learning for Image Denoising. 2015 *IEEE International Conference on Computer Vision (ICCV)*, Santiago, 7-13 December 2015, 244-252. <u>https://doi.org/10.1109/iccv.2015.36</u>
- [12] Zha, Z., Zhang, X., Wang, Q., Bai, Y. and Tang, L. (2017) Image Denoising Using Group Sparsity Residual and External Nonlocal Self-Similarity Prior. 2017 IEEE International Conference on Image Processing (ICIP), Beijing, 17-20 September 2017, 2956-2960. <u>https://doi.org/10.1109/icip.2017.8296824</u>
- [13] Lee, X. and Wu, J. (2019) Image Denoising Algorithm Based on Improved NCSR Model. Journal of Physics: Conference

Series, 1314, Article 012209. https://doi.org/10.1088/1742-6596/1314/1/012209

- [14] Ou, Y., Swamy, M.N.S., Luo, J. and Li, B. (2022) Single Image Denoising via Multi-Scale Weighted Group Sparse Coding. Signal Processing, 200, Article 108650. <u>https://doi.org/10.1016/j.sigpro.2022.108650</u>
- [15] Liu, H., Li, L., Lu, J. and Tan, S. (2022) Group Sparsity Mixture Model and Its Application on Image Denoising. *IEEE Transactions on Image Processing*, **31**, 5677-5690. <u>https://doi.org/10.1109/tip.2022.3193754</u>
- [16] Cai, J., H. Chan, R. and Nikolova, M. (2008) Two-Phase Approach for Deblurring Images Corrupted by Impulse Plus Gaussian Noise. *Inverse Problems & Imaging*, 2, 187-204. <u>https://doi.org/10.3934/ipi.2008.2.187</u>
- [17] Xiao, Y., Zeng, T., Yu, J. and Ng, M.K. (2011) Restoration of Images Corrupted by Mixed Gaussian-Impulse Noise via L1-10 Minimization. *Pattern Recognition*, 44, 1708-1720. <u>https://doi.org/10.1016/j.patcog.2011.02.002</u>
- [18] Wang, C., Yan, Z., Pedrycz, W., Zhou, M. and Li, Z. (2020) A Weighted Fidelity and Regularization-Based Method for Mixed or Unknown Noise Removal from Images on Graphs. *IEEE Transactions on Image Processing*, 29, 5229-5243. <u>https://doi.org/10.1109/tip.2020.2969076</u>
- [19] 朱文生,何显文.结合加权低秩表示和 L1 范数的图像混合去噪[J]. 赣南师范大学学报, 2022, 43(3): 116-120.
- [20] Mairal, J., Bach, F., Ponce, J., Sapiro, G. and Zisserman, A. (2009) Non-Local Sparse Models for Image Restoration. 2009 IEEE 12th International Conference on Computer Vision, Kyoto, 27 September-4 October 2009, 2272-2279. https://doi.org/10.1109/iccv.2009.5459452
- [21] 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. <u>https://doi.org/10.1109/TIP.2007.901238</u>
- [22] Jiang, J.L., Zhang, L. and Yang, J. (2014) Mixed Noise Removal by Weighted Encoding with Sparse Nonlocal Regularization. *IEEE Transactions on Image Processing*, 23, 2651-2662. <u>https://doi.org/10.1109/tip.2014.2317985</u>