

DOI:10.3969/j.issn.1003-5060.2024.01.008

基于全变分加权差正则的高光谱图像去噪算法

钱妍, 张莉

(合肥工业大学 数学学院, 安徽 合肥 230601)

摘要:针对现有全变分模型在高光谱图像中出现的伪影、边缘结构消失等问题,文章提出一种增强型三维全变分加权差正则模型。首先,该模型并非直接将稀疏性强加于梯度映射本身,而是对梯度映射的基矩阵添加稀疏性约束。此外,与一般稀疏约束方法不同的是,为避免由 l_1 范数自身局限性带来的去噪不良影响,利用 l_1 范数与 l_2 范数的全变分加权差(简记为 l_{1-2})分别对高光谱图像的空间域与光谱域施加稀疏约束。实验结果表明,该文提出的算法有效避免了伪影的产生以及图像细节丢失的问题,具有更优的去噪效果。

关键词:高光谱图像;混合噪声;全变分模型;稀疏性;梯度映射

中图分类号:TP391.41

文献标志码:A

文章编号:1003-5060(2024)01-0047-08

Hyperspectral image denoising algorithm based on total variation weighted difference regularization

QIAN Yan, ZHANG Li

(School of Mathematics, Hefei University of Technology, Hefei 230601, China)

Abstract: Aiming at the problems of artifacts and edge structure disappearance in hyperspectral images of existing total variation models, an enhanced three-dimensional total variation weighted difference regularization model is proposed in this paper. Firstly, this model does not directly impose sparsity on the gradient map itself, but adds a sparsity constraint to the base matrix of the gradient map. In addition, different from the general sparsity constraint approaches, to avoid the undesirable effects of denoising caused by the limitations of the l_1 norm, a sparse constraint is applied to the spatial domain and spectral domain of the hyperspectral image using the total variation weighted difference of l_1 norm and l_2 norm (l_{1-2}), respectively. Experimental results show that the proposed method effectively avoids artifacts and image details loss, and has a better denoising effect.

Key words: hyperspectral image; mixed noise; total variation model; sparsity; gradient map

0 引言

随着遥感工作的不断深入,高光谱图像应用成为遥感领域研究热点之一。然而,受各种现实因素的影响,高光谱图像往往会受到各种噪声的污染^[1],这不仅降低了图像的视觉效果,同时对后续应用,如目标检测、图像分类和场景识别等产生不良影响。因此高光谱图像去噪问题受到了众多

学者的关注和研究。

近年来,针对含噪声的高光谱图像,学者们提出了很多高光谱图像去噪算法,并取得了较好的研究效果^[2-15]。文献[2-3]使用传统的二维去噪方法对高光谱图像进行去噪,然而这种逐波段去噪方式往往会忽略相邻波段之间的相关性和一致性,导致去噪结果不理想。

为充分表征图像内部结构信息,适应更复杂

收稿日期:2022-05-20;修回日期:2022-06-02

基金项目:国家重点研发计划资助项目(2018YFB2100301);国家自然科学基金资助项目(61972131)

作者简介:钱妍(1997—),女,安徽合肥人,合肥工业大学硕士生;

张莉(1976—),女,安徽合肥人,博士,合肥工业大学教授,博士生导师,通信作者,E-mail:lizhang@hfut.edu.cn

的噪声环境,基于 l_1 范数的全变分正则化 (l_1 -spatial-spectral total variation, l_1 -SSTV) 模型在去噪任务中受到广泛应用。文献[4]利用 l_1 范数对图像梯度映射的基矩阵添加稀疏性约束,提出了增强型三维全变分(enhanced 3-D total variation, E-3DTV)模型;文献[5]将 l_1 -SSTV 模型与低秩先验相结合,提出低秩全变分(low-rank total variation, LRTV)模型;文献[6]利用 l_1 -SSTV 正则项模型恢复去噪的低秩图片块,形成低秩空谱全变分(spatial-spectral total variation regularized local low-rank matrix recovery, LLRSSTV)模型。然而,文献[7]发现 l_1 -SSTV 模型在去噪过程中会受到 l_1 范数自身局限性的影响,在实际去噪过程中往往会产生伪影现象。

上述去噪算法主要存在以下 3 个缺陷:① 在复杂噪声环境下去噪效果不佳;② 恢复后的图像会产生一定的伪影;③ 优化低秩模型涉及奇异值分解,计算量大。本文针对上述去噪算法存在问题,提出了一种基于增强型三维全变分加权差(enhanced 3-D- l_{1-2} total variation, E-3D l_{1-2} TV)正则模型的去噪算法。首先,利用 l_1 范数与 l_2 范数的全变分加权差(简记为 l_{1-2})模型代替 l_1 范数对图像稀疏性加以约束,避免由 l_1 范数产生的伪影现象;同时,直接对梯度映射的基矩阵添加稀疏性约束,使得图像内部结构得到充分表征,适应复杂噪声环境。此外,本文算法在保证去噪效果较好的同时,在运算时间比上述方法具有明显优势。

1 预备知识

对于一个给定的高光谱图像 $\chi \in \mathbf{R}^{h \times w \times s}$,其中, h, w, s 分别表示高光谱图像空间高度、宽度以及光谱数量的大小。将 χ 沿着光谱方向展开得到矩阵形式的高光谱图像 $\mathbf{X} \in \mathbf{R}^{hw \times s}$ 。进一步地,将高光谱图像 χ 上沿第 n 个模方向计算的差分算子表示为 $D_n (n=1, 2, 3)$, 分别对应于空间高度、宽度和光谱模方向。于是有:

$$\mathbf{g}_n = D_n(\chi) \quad (1)$$

其中: $\mathbf{g}_n \in \mathbf{R}^{h \times w \times s}$ 是沿 3 个张量模计算得到的梯度映射张量。将这些梯度映射张量沿着光谱模展开为矩阵形式:

$$\mathbf{G}_n = \text{unfold}(\mathbf{g}_n), \quad \forall n = 1, 2, 3 \quad (2)$$

易知 χ 上的差分算子 D_1 和 D_2 等价于 \mathbf{X} 中行之间的减法运算, χ 上的差分算子 D_3 等价于在 \mathbf{X} 中列之间的减法运算。上述 3 个线性运算可表示为:

$$\begin{aligned} \nabla_n \mathbf{X} &= \text{unfold}(D_n(\text{fold}(\mathbf{X}))) = \mathbf{G}_n, \\ \forall n &= 1, 2, 3 \end{aligned} \quad (3)$$

其中, ∇_n 表示在矩阵上的差分算子。

式(3)将高光谱图像 \mathbf{X} 与其梯度映射 \mathbf{G}_n 之间的关系进行编码,构建了关于梯度映射先验模型的高光谱图像处理方法。 l_1 范数稀疏度量是最常用于计算梯度映射稀疏度的度量之一,即

$$S(\mathbf{G}_n) = \|\mathbf{G}_n\|_1 \quad (4)$$

在高光谱图像处理任务中,采用 l_1 范数约束梯度稀疏性的三维全变分(3DTV)正则化模型通常表示为:

$$f_{3DTV}(\mathbf{X}) = \sum_{n=1}^3 S(\nabla_n \mathbf{X}) = \sum_{n=1}^3 S(\mathbf{G}_n) \quad (5)$$

2 本文算法

2.1 增强型全变分正则模型

对于给定的高光谱图像 $\mathbf{X} \in \mathbf{R}^{hw \times s}$, 沿着其梯度映射施加稀疏度量可表示为 $S_{TV}(\mathbf{G}_n)$, 其中, $\mathbf{G}_n = \nabla_n \mathbf{X}, \forall n = 1, 2, 3$ 。基于展开的高光谱图像具有低秩性质这一前提, \mathbf{G}_n 可表示为:

$$\mathbf{G}_n = \mathbf{U}_n \mathbf{W}_n^T, \quad \forall n = 1, 2, 3 \quad (6)$$

其中: $\mathbf{U}_n \in \mathbf{R}^{hw \times r}; \mathbf{W}_n \in \mathbf{R}^{s \times r}; r$ 为高光谱图像矩阵的秩。 \mathbf{U}_n 中的列构成梯度映射 \mathbf{G}_n 的一组基。同样,式(6)中 \mathbf{U}_n 也可以看作为 \mathbf{G}_n 经过变换得到的结果,即

$$\mathbf{U}_n = \mathbf{G}_n \mathbf{W}_n (\mathbf{W}_n^T \mathbf{W}_n)^{-1} \quad (7)$$

与沿图像梯度映射施加稀疏约束不同,本文对 \mathbf{G}_n 的线性变换结果,即 $\mathbf{G}_n \mathbf{V}_n$, 采用 l_1 范数稀疏度量约束,构建增强型全变分模型,表示为:

$$\begin{aligned} S_{E-TV}(\mathbf{G}_n) &= \min_{\mathbf{V}_n \in \mathbf{R}^{s \times r}} \|\mathbf{G}_n \mathbf{V}_n\|_1, \\ \text{s. t.} \quad &\|\mathbf{G}_n \mathbf{V}_n\|_F = \|\mathbf{G}_n\|_F, \quad \mathbf{V}_n^T \mathbf{V}_n = \mathbf{I} \end{aligned} \quad (8)$$

式(8)对 \mathbf{V}_n 采用 2 个必要的约束:① 对变换结果 $\mathbf{G}_n \mathbf{V}_n$ 施加 Frobenius 范数约束,避免变换引起的信息丢失;② 对 \mathbf{V}_n 施加正交约束,保证变换结果 $\mathbf{G}_n \mathbf{V}_n$ 更充分地保留其原始梯度映射 \mathbf{G}_n 的内部结构信息并且获得封闭解。直接求解式(8)并不容易,因此将其改写为:

$$\begin{aligned} S_{E-TV}(\mathbf{G}_n) &= \min_{\mathbf{U}_n} \|\mathbf{U}_n\|_1, \\ \text{s. t.} \quad &\mathbf{G}_n = \mathbf{U}_n \mathbf{V}_n^T, \quad \mathbf{V}_n^T \mathbf{V}_n = \mathbf{I} \end{aligned} \quad (9)$$

2.2 增强型三维全变分加权差正则模型

与式(5)中 3DTV 正则化模型类似,本文通过沿不同模的梯度映射稀疏度量值求和,对增强型三维全变分正则化进行建模:

$$f_{\text{E-3DTV}}(\mathbf{X}) = \sum_{n=1}^3 S_{\text{E-TV}}(\nabla_n \mathbf{X}) = \sum_{n=1}^3 S_{\text{E-TV}}(\mathbf{G}_n) \quad (10)$$

式(10)等价于:

$$\begin{aligned} f_{\text{E-3DTV}}(\mathbf{X}) &= \sum_{n=1}^3 \min_{\mathbf{V}_n, \mathbf{U}_n} \|\mathbf{U}_n\|_1, \\ \text{s. t. } \nabla_n \mathbf{X} &= \mathbf{U}_n \mathbf{V}_n^T, \mathbf{V}_n^T \mathbf{V}_n = \mathbf{I} \end{aligned} \quad (11)$$

由于 l_1 范数自身的局限性,基于 3DTV 正则模型的去噪算法往往会产生伪影。考虑到全变分加权差正则化(l_{1-2} TV)模型在自然图像去噪中的优越表现,将式(11)中 $\|\mathbf{U}_n\|_1$ 替换为 $f_{1-2}(\mathbf{U}_n)$,其中 $f_{1-2}(\mathbf{U}_n) = \|\mathbf{U}_n\|_1 - \alpha \|\mathbf{U}_n\|_2$ 。于是增强型全变分加权差(E-3D l_{1-2} TV)正则模型可表示为:

$$\begin{aligned} f_{\text{E-3DTV}}(\mathbf{X}) &= \sum_{n=1}^3 \min_{\mathbf{V}_n, \mathbf{U}_n} f_{1-2}(\mathbf{U}_n) \\ \text{s. t. } \nabla_n \mathbf{X} &= \mathbf{U}_n \mathbf{V}_n^T, \mathbf{V}_n^T \mathbf{V}_n = \mathbf{I} \end{aligned} \quad (12)$$

2.3 基于 E-3D l_{1-2} TV 正则模型去噪算法

基于 E-3D l_{1-2} TV 正则模型的高光谱图像算法表示为:

$$\begin{aligned} \min_{\mathbf{X}, \mathbf{E}} \tau f_{\text{E-3D}l_{1-2}\text{TV}}(\mathbf{X}) + \|\mathbf{E}\|_1, \\ \text{s. t. } \mathbf{Y} = \mathbf{X} + \mathbf{E} \end{aligned} \quad (13)$$

其中: $\mathbf{Y}, \mathbf{X}, \mathbf{E} \in \mathbf{R}^{l \times o \times r}$ 分别为输入的噪声图像、待恢复的图像以及稀疏噪声; τ 为正则项与噪声稀疏项之间的平衡系数。由式(12)可得,目标函数式(13)的等价形式可写为:

$$\begin{aligned} \min_{\mathbf{X}, \mathbf{U}_n, \mathbf{V}_n, \mathbf{E}} \sum_{n=1}^3 \tau (f_{\text{SSTV}}^{\text{ani}}(\mathbf{U}_n) - \alpha f_{\text{SSTV}}^{\text{iso}}(\mathbf{U}_n)) + \|\mathbf{E}\|_1 \\ \text{s. t. } \mathbf{Y} = \mathbf{X} + \mathbf{E}, \nabla_n \mathbf{X} = \mathbf{U}_n \mathbf{V}_n^T, \mathbf{V}_n^T \mathbf{V}_n = \mathbf{I} \end{aligned} \quad (14)$$

其中: $\mathbf{V}_n \in \mathbf{R}^{s \times r}$; $\mathbf{U}_n \in \mathbf{R}^{l \times o \times r}$; $n=1, 2, 3$ 。

3 模型求解

模型式(14)利用交替方向乘子(alternating direction method of multipliers, ADMM)算法^[16]求解。引入拉格朗日乘子 \mathbf{M}_n ($n=1, 2, 3$)、 \mathbf{F} 以及参数 μ , 对应的增广拉格朗日方程为:

$$\begin{aligned} \mathcal{L}(\mathbf{X}, \mathbf{E}, \mathbf{U}_n, \mathbf{V}_n, \mathbf{M}_n, \mathbf{F}) = \\ \sum_{n=1}^3 \tau (f_{\text{SSTV}}^{\text{ani}}(\mathbf{U}_n) - \alpha f_{\text{SSTV}}^{\text{iso}}(\mathbf{U}_n)) + \|\mathbf{E}\|_1 + \\ \sum_{n=1}^3 \langle \mathbf{M}_n, \nabla_n \mathbf{X} - \mathbf{U}_n \mathbf{V}_n^T \rangle + \frac{\mu}{2} \|\nabla_n \mathbf{X} - \mathbf{U}_n \mathbf{V}_n^T\|_{\text{F}}^2 + \\ \langle \mathbf{F}, \mathbf{Y} - \mathbf{X} - \mathbf{E} \rangle + \frac{\mu}{2} \|\mathbf{Y} - \mathbf{X} - \mathbf{E}\|_{\text{F}}^2 \end{aligned} \quad (15)$$

保持其他变量固定不变,交替优化式(15)中

每个变量,下面讨论解决相关变量的子问题。

3.1 更新变量 \mathbf{X}

关于式(15)中的 \mathbf{X} 变量,可得到如下线性等式:

$$\begin{aligned} (\mu \mathbf{I} + \mu \sum_{n=1}^3 \nabla_n^T \nabla_n) \mathbf{X} &= \mu (\mathbf{Y} - \mathbf{E}) + \mathbf{F} + \\ &\mu \sum_{n=1}^3 \nabla_n^T (\mathbf{U}_n \mathbf{V}_n^T) - \nabla_n^T (\mathbf{M}_n) \end{aligned} \quad (16)$$

其中, $\nabla_n^T(\cdot)$ 表示 $\nabla_n(\cdot)$ 的转置运算符。

采用快速傅里叶变换求解方程,得到 \mathbf{X} 的闭式解如下:

$$\begin{cases} \mathbf{H} = \mu \sum_{n=1}^3 \mathcal{F}(\mathbf{D}_n)^* \odot \mathcal{F}(\text{fold}(\mathbf{U}_n \mathbf{V}_n^T) - \mathbf{M}_n), \\ \mathbf{T}_x = |\mathcal{F}(\mathbf{D}_1)|^2 + |\mathcal{F}(\mathbf{D}_2)|^2 + |\mathcal{F}(\mathbf{D}_3)|^2, \\ \mathbf{X} = \mathcal{F}^{-1} \left[\frac{\mathcal{F}(\text{fold}(\mu \mathbf{Y} - \mu + [\mathbf{F}]) + \mathbf{H})}{\mu \mathbf{1} + \mu \mathbf{T}_x} \right] \end{cases} \quad (17)$$

其中: $\mathbf{1}$ 表示元素全为 1 的张量; \odot 为逐元素相乘运算; $\mathcal{F}(\cdot)$ 表示傅里叶变换; $|\cdot|^2$ 表示逐元素平方运算。

3.2 更新变量 \mathbf{U}_n

从式(15)中提取所有含 \mathbf{U}_n 的项可得:

$$\begin{aligned} \mathbf{U}_n = \operatorname{argmin}_{\mathbf{U}_n} \tau (f_{\text{SSTV}}^{\text{ani}}(\mathbf{U}_n) - \alpha f_{\text{SSTV}}^{\text{iso}}(\mathbf{U}_n)) + \\ \frac{\mu}{2} \|\mathbf{U}_n - (\nabla_n \mathbf{X} + \mathbf{M}_n / \mu) \mathbf{V}_n\|_{\text{F}}^2 \end{aligned} \quad (18)$$

求解式(18)前需要利用 DCA 算法^[17]对其线性化处理,令

$$\mathbf{E}(\mathbf{U}_n) = \mathbf{G}(\mathbf{U}_n) - \mathbf{H}(\mathbf{U}_n) \quad (19)$$

其中

$$\mathbf{G}(\mathbf{U}_n) = \|\mathbf{U}_n\|_1 +$$

$$\frac{\mu}{2\tau} \|\mathbf{U}_n - (\nabla_n \mathbf{X} + \mathbf{M}_n / \mu) \mathbf{V}_n\|_{\text{F}}^2 \quad (20)$$

$$\mathbf{H}(\mathbf{U}_n) = \alpha \|\mathbf{U}_n\|_2 \quad (21)$$

于是,式(18)可重写为:

$$\begin{aligned} \mathbf{U}_n^{(i+1)} = \operatorname{argmin}_{\mathbf{U}_n} \frac{\mu}{2\tau} \|\mathbf{U}_n - (\nabla_n \mathbf{X} + \\ \mathbf{M}_n / \mu) \mathbf{V}_n\|_{\text{F}}^2 + \|\mathbf{U}_n\|_1 - \\ \alpha \|\mathbf{U}_n^{(i)}\|_2 - \langle \mathbf{U}_n - \mathbf{U}_n^{(i)}, \alpha \frac{\mathbf{U}_n^{(i)}}{\|\mathbf{U}_n^{(i)}\|_2} \rangle \end{aligned} \quad (22)$$

由软阈值算法^[18]求解得:

$$\mathbf{U}_n^{(i+1)} = S_{\frac{\mu}{\tau}} \left((\nabla_n \mathbf{X} + \mathbf{M}_n / \mu) \mathbf{V}_n - \frac{\tau \alpha}{\mu} \frac{\mathbf{U}_n^{(i)}}{\|\mathbf{U}_n^{(i)}\|_2} \right) \quad (23)$$

3.3 更新变量 \mathbf{V}_n

从式(15)中提取所有含有 \mathbf{V}_n 的项可得:

$$\mathbf{V}_n^{i+1} = \underset{\mathbf{V}_n}{\operatorname{argmin}} \frac{\mu}{2} \left\| \mathbf{U}_n \mathbf{V}_n^T - \left(\nabla_n \mathbf{X} + \frac{\mathbf{M}_n}{\mu} \right) \right\|_F^2 = \underset{\mathbf{V}_n}{\operatorname{argmin}} \langle \left(\nabla_n \mathbf{X} + \frac{\mathbf{M}_n}{\mu} \right)^T \mathbf{U}_n, \mathbf{V}_n \rangle \quad (24)$$

计算出封闭解:

$$\begin{cases} [\mathbf{B}, \mathbf{D}, \mathbf{C}] = \operatorname{svd}((\nabla_n \mathbf{X} + \mathbf{M}_n/\mu)^T \mathbf{U}_n), \\ \mathbf{V}_n = \mathbf{BC} \end{cases} \quad (25)$$

3.4 更新变量 \mathbf{E}

从式(15)中提取所有含有 \mathbf{E} 的项可得:

$$\mathbf{E} = \underset{\mathbf{E}}{\operatorname{argmin}} \|\mathbf{E}\|_1 + \frac{\mu}{2} \left\| \mathbf{E} - \left(\mathbf{Y} - \mathbf{X} + \frac{\mathbf{I}}{\mu} \right) \right\|_F^2 \quad (26)$$

软阈值算法求解:

$$\mathbf{E} = \mathbf{S}_{\frac{1}{\mu}} \left(\mathbf{Y} - \mathbf{X} + \frac{\mathbf{I}}{\mu} \right) \quad (27)$$

基于一般的 ADMM 算法原理,拉格朗日乘子更新可得:

$$\begin{cases} \mathbf{M}_n = \mathbf{M}_n + \mu(\nabla_n \mathbf{X} - \mathbf{U}_n \mathbf{V}_n^T), n = 1, 2, 3; \\ \mathbf{I} = \mathbf{I} + \mu(\mathbf{Y} - \mathbf{X} - \mathbf{E}) \end{cases} \quad (28)$$

综上,基于 E-3D l_{1-2} TV 的去噪模型优化过程全部完成。

4 实验结果与分析

为验证 E-3D l_{1-2} TV 算法的去噪性能,设计了仿真实验和模拟实验 2 类实验。选取现有 4 种去

噪算法(文献[4]、文献[5]、文献[8]、文献[9])作比较。仿真实验中 Indian-s 数据集的大小为 $145 \times 145 \times 175$,真实实验中 HYDICE Urban 数据集大小为 $207 \times 207 \times 210$ 。

在仿真实验过程中,本文设计 4 种加噪方案模拟噪声环境,具体如下:

方案 1 高斯噪声($S_{NR} = 10 \sim 20$ dB)被添加到每个波段。

方案 2 在方案 1 基础上,在每个波段添加 10% 的脉冲噪声,并在 4 个随机波段中分别添加 4 条水平和垂直的死线噪声,宽度在 1~3 个单位宽度中生成。

方案 3 方差范围在 0.1~0.2 随机选择的零均值高斯噪声添加到每个波段。

方案 4 在方案 2 基础上,在每个波段添加 10% 的脉冲噪声,在波段 61~71 中分别随机添加 1~10 条死线噪声,宽度在 1~3 个单位中随机生成。

Indian-s 数据集中所有算法的客观评价结果见表 1 所列。表 1 中: MPSNR (mean peak signal-to-noise ratio) 为平均峰值信噪比; MSSIM (mean structural similarity) 为平均结构相似性; ERGAS (erreur relative globale adimensionnelle de synthèse) 为相对维度综合误差; MSA (mean spectral angle) 为平均光谱角度。从表 1 可以看出,本文算法 E-3D l_{1-2} TV 的定量结果均优于其他去噪算法。

表 1 Indian-s 数据集的定量对比结果

加噪方案	评价指标	噪声图像	文献[4]	文献[5]	文献[8]	文献[9]	本文算法
方案 1	MPSNR	21.080	43.176	37.307	37.935	41.351	44.240
	MSSIM	42.458	0.995	0.986	0.945	0.985	0.996
	ERGAS	42.262	21.031	48.227	31.553	24.672	18.997
	MSA	4 856.637	0.794	1.589	1.538	0.988	0.725
方案 2	MPSNR	11.561	40.733	24.353	35.428	37.921	42.379
	MSSIM	453.395	0.993	0.903	0.921	0.971	0.994
	ERGAS	87.334	26.714	158.942	42.026	32.720	23.147
	MSA	67.232	0.998	5.546	1.988	1.395	0.852
方案 3	MPSNR	16.582	39.681	36.620	33.943	37.535	40.896
	MSSIM	8.634	0.989	0.979	0.892	0.972	0.991
	ERGAS	77.742	33.170	50.352	49.154	34.862	29.517
	MSA	67.589	1.231	1.781	2.476	1.564	1.069
方案 4	MPSNR	14.675	38.502	29.516	33.101	36.536	40.487
	MSSIM	78.366	0.987	0.957	0.887	0.968	0.990
	ERGAS	543.147	38.541	99.900	54.125	39.884	31.112
	MSA	555.293	1.358	3.302	2.651	1.755	1.126

方案 1 与方案 2 下每个波段对应的 PSNR 值

如图 1 所示。从图 1 可以看出,与 E-3DTV 相比,

E-3D l_{1-2} TV 指标分数更高,表明了全变分加权差模型在图像恢复中的有效性,这也是本文所提出算法的核心思想。

加噪方案 2 下 Indian-s 数据集第 70 波段在 5 种去噪算法下的去噪结果如图 2 所示。由图 2 可知,通过局部放大细节可以看出,E-3D l_{1-2} TV 获得最佳视觉效果,有效去除了噪声并完全保留了原本图像中的边缘结构,而其他算法均有不同程度的丢失。

为了更加直观地验证 E-3D l_{1-2} TV 混合噪声消除的能力,第 70 波段的噪声图像去噪前后的垂

直平均轮廓曲线如图 3 所示。从图 3 可以看出,E-3D l_{1-2} TV 的轮廓曲线最接近干净图像曲线,与图 2 所示的视觉对比度一致。总体而言,与其他算法相比,E-3D l_{1-2} TV 不仅有效去除了混合噪声,还完整保留了图像结构。

在真实数据集实验中,一方面通过对比真实数据集 Urban 恢复图像的视觉效果评价各方法的去噪性能;另一方面对真实数据集 Indian-Pines 的恢复图像进一步施加分类实验,通过分类视觉效果和量化指标结果进一步对比恢复图像的质量。

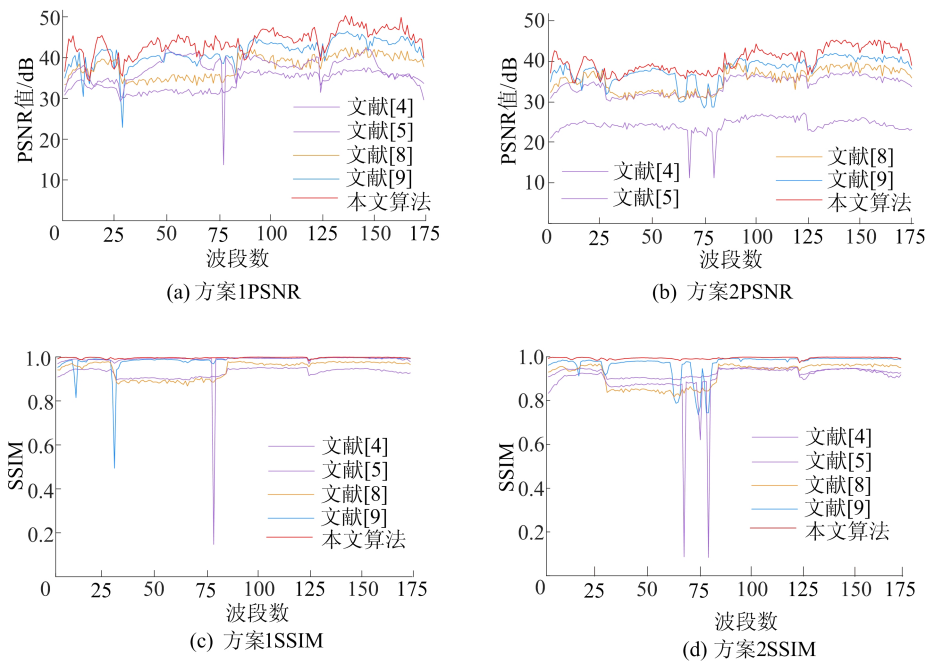


图 1 加噪方案 1 和方案 2 下 5 种算法去噪各波段 PSNR 与 SSIM 结果

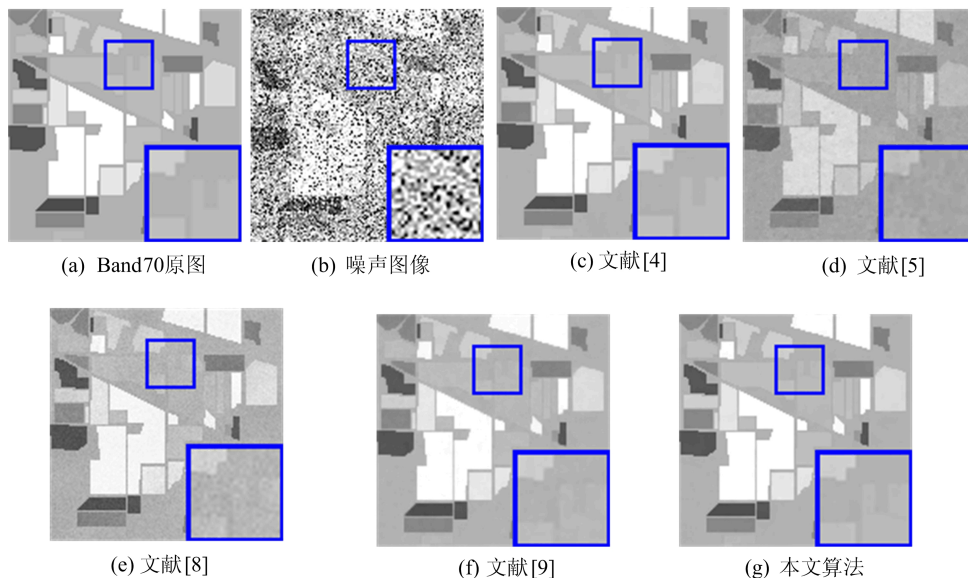


图 2 加噪方案 2 下第 70 波段对应的 5 种算法的恢复结果




图 3 加噪方案 2 下第 70 波段对应的 5 种去噪算法的垂直平均轮廓曲线

Urban 数据集第 139 波段的原始噪声图像和不同算法的去噪结果如图 4 所示。观察局部放大部分, E-3D l_{1-2} TV 得到的恢复图像具有更加清晰的边缘, 条纹噪声的去除更加彻底, 保留了更多空

间细节。其他算法的恢复结果要么显得过于平滑, 要么条纹噪声仍然存在。第 139 波段的原始图像及其不同去噪图像的垂直平均轮廓曲线如图 5 所示。




图 4 Urban 数据集第 139 波段在 5 种去噪算法下的恢复结果

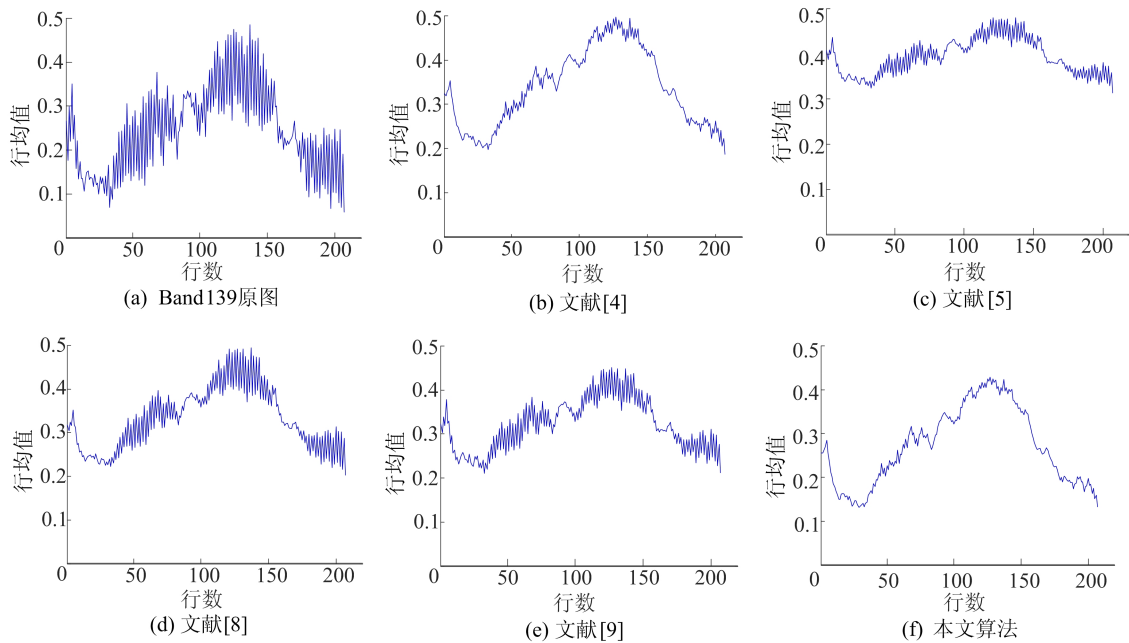


图 5 Urban 数据集第 139 波段在 5 种去噪算法下的垂直平均剖面

尽管均值曲线在恢复后出现不同程度平滑,但 BM4D、LRTDTV 和 TLR- l_{1-2} SSTV 算法对应的曲线仍存在较大的波动,表明噪声未完全消除。相反, E-3D l_{1-2} TV 获得更平滑的曲线,表明其降噪能力优于其他算法。

对 Indian Pines 采用不同方法进行去噪,并将所得的恢复图像进一步施加分类实验,分类结果如图 6 所示。实验结果表明,去噪算法对图像

后续应用具有一定提升效果,并且 E-3D l_{1-2} TV 得到最清晰的分类结果。各算法分类实验的客观评价结果见表 2 所列。表 2 中:OA (overall accuracy) 指标代表整体精度;kappa 系数用来衡量 2 个变量一致性。

对比结果表明, E-3D l_{1-2} TV 取得了最高指标分数,进一步说明了 E-3D l_{1-2} TV 在去噪性能上的优越性。




图 6 IndianPines 数据集在五种方法去噪后的分类实验结果

表 2 Indian-Pines 数据集分类实验评价指标

指标	原始图像	文献[4]	文献[5]	文献[8]	文献[9]	本文算法
OA/%	62.86	80.57	81.97	74.89	62.92	89.77
Kappa	0.550 2	0.765 2	0.781 3	0.805 8	0.551 3	0.897 7

5 结 论

针对现有基于全变分正则模型的高光谱图像去噪算法中出现的伪影、边缘细节丢失等问题,本文改变了传统全变分模型约束对象,并使用一种新的约束度量,提出增强型的三维全变分加权差正则化(E-3D l_{1-2} TV)模型。该模型对梯度映射的基矩阵添加稀疏性约束,并使用加权差模型作为稀疏性度量,有效抑制了去噪过程中伪影的产生。实验结果表明,相比一些主流的去噪算法,本文算法所得到的图像能保留更多的图像细节。

[参 考 文 献]

[1] VEGANZONES M A, TOCHON G, DALLA-MURA M, et al. Hyperspectral image segmentation using a new spectral unmixing-based binary partition tree representation [J]. IEEE Transactions on Image Processing, 2014, 23(8): 3574-3589.

[2] ELAD M, AHARON M. Image denoising via sparse and redundant representations over learned dictionaries[J]. IEEE Transactions on Image Processing, 2006, 15(12): 3736-3745.

[3] DABOV K, FOI A, KATKOVNIK V, et al. Image denoising by sparse 3-D transform-domain collaborative filtering[J]. IEEE Transactions on Image Processing, 2007, 16(8): 2080-2095.

[4] PENG J J, XIE Q, ZHAO Q, et al. Enhanced 3DTV regularization and its applications on HSI denoising and compressed sensing[J]. IEEE Transactions on Image Processing, 2020, 29: 7889-7903.

[5] HE W, ZHANG H Y, ZHANG L P, et al. Total-variation-regularized low-rank matrix factorization for hyperspectral image restoration[J]. IEEE Transactions on Geoscience and Remote Sensing, 2015, 54(1): 178-188.

[6] HE W, ZHANG H Y, SHEN H F, et al. Hyperspectral image denoising using local low-rank matrix recovery and global spatial-spectral total variation[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2018, 11(3): 713-729.

[7] 檀结庆, 蔡蒙琪, 朱星辰, 等. 基于局部结构相似与稀疏表示的超分辨率图像重建[J]. 合肥工业大学学报(自然科学版), 2021, 44(8): 1045-1050.

[8] ZHANG H Y, WEI H, ZHANG L P, et al. Hyperspectral image restoration using low-rank matrix recovery[J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(8): 4729-4743.

[9] WANG Y, PENG J J, ZHAO Q, et al. Hyperspectral image restoration via total variation regularized low-rank tensor decomposition[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2017, 11(4): 1227-1243.

[10] CHANG Y, YAN L X, FANG H Z, et al. Anisotropic spectral-spatial total variation model for multispectral remote sensing image destriping[J]. IEEE Transactions on Image Processing, 2015, 24(6): 1852-1866.

[11] LIU H Y, SUN P P, DU Q, et al. Hyperspectral image restoration based on low-rank recovery with a local neighborhood weighted spectral-spatial total variation model[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 57(3): 1409-1422.

(下转第 76 页)

桥墩端部形状对桥墩局部冲刷的影响较明显,根据河道不同流速合理选择墩型,能够更好地预防冲刷破坏。

[参 考 文 献]

- [1] 易仁彦,周瑞峰,黄茜. 近 15 年国内桥梁坍塌事故的原因和风险分析[J]. 交通科技, 2015(5):61-64.
- [2] 齐梅兰,郅艳荣. 河床溯源冲刷影响下的桥墩冲刷[J]. 水利学报, 2017, 48(7):791-798.
- [3] 高冬光,田伟平,张义青,等. 桥台的冲刷机理和冲刷深度[J]. 中国公路学报, 1998, 11(1):56-64.
- [4] 张曙光,尹进步,张根广. 基于 Flow-3D 的圆柱形桥墩局部冲刷大涡模拟[J]. 泥沙研究, 2020, 45(1):67-73.
- [5] 高鹏程. 基于 FLOW-3D 的圆端形桥墩防护措施数值模拟研究[D]. 呼和浩特:内蒙古农业大学, 2020.
- [6] 河北省交通规划设计院. 公路工程水文勘测设计规范:JTGC30—2015[S]. 北京:人民交通出版社股份有限公司, 2015:33-34.
- [7] MELVILLE B W. Pier and abutment scour; integrated approach[J]. Journal of Hydraul Engineering, 1997, 123(2):125-136.
- [8] KESHAVARZ A, VAGHEFI M, AHMADI G. Effect of the shape and position of the bridge pier on the bed changes in the sharp 180-degree bend[J]. Iranian Journal of Science and Technology: Transactions of Civil Engineering, 2022, 46:2449-2467.
- [9] FAROOQ R, GHUMMAN A R. Impact assessment of pier shape and modifications on scouring around bridge pier[J]. Water, 2019, 11(9):1761.
- [10] VIJAYASREE B A, ELDHO T I, MAZUMDER B S, et al. Influence of bridge pier shape on flow field and scour geometry[J]. International Journal of River Basin Management, 2019, 17(1):109-129.
- [11] JALAL H K, HASSAN W H. Effect of bridge pier shape on depth of scour[J]. IOP Conference Series: Materials Science and Engineering, 2020, 671:012001.
- [12] 王飞,姚磊华,张彬,等. 桥墩局部冲刷动态模拟及不同截面的冲刷特性[J]. 水利水电科技进展, 2018, 38(3):81-87.
- [13] SANADGOL E, HEIDARPOUR M, MOHAMMADPOUR R. Reduction of local scouring at round-nosed rectangular piers using a downstream bed sill[J]. Journal of the South African Institution of Civil Engineering, 2021, 63(3):62-70.
- [14] QIN Y F, TAO Z R, TAO X X, et al. A numerical case study on pier shape coefficient of seismic hydrodynamic pressure in design codes[J]. IOP Conference Series: Earth and Environmental Science, 2021, 638:012052.
- [15] DEHGHAN D, VAGHEFI M, GHODSIAN M. Experimental study of the effect of the length-to-width ratio and skewness angles of the pier installed at the bend on scour pattern[J]. Journal of the Brazilian Society of Mechanical Sciences and Engineering, 2021, 43:150.
- [16] DANESHFARAZ R, ABAM M, HEIDARPOUR M, et al. The impact of cables on local scouring of bridge piers using experimental study and ANN, ANFIS algorithms[J]. Water Supply, 2022, 22(1):1075-1093.
- [17] JUSTESEN P. A note on turbulence calculations in the wave boundary layer[J]. Journal of Hydraulic Research, 1991, 29(5):699-711.

(责任编辑 张淑艳)

(上接第 53 页)

- [12] XUE H Y, ZHANG S M, CAI D. Depth image inpainting: Improving low rank matrix completion with low gradient regularization[J]. IEEE Transactions on Image Processing, 2017, 26(9):4311-4320.
- [13] WANG M H, WANG Q, CHANUSSOT J, et al. l0-l1 Hybrid total variation regularization and its applications on hyperspectral image mixed noise removal and compressed sensing[J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 59(9):7695-7710.
- [14] XIE J, CHOU C C, FERIS R, et al. Single depth image super resolution and denoising via coupled dictionary learning with local constraints and shock filtering[C]//2014 IEEE International Conference on Multimedia and Expo. [S. l.]: IEEE, 2014:1-6.
- [15] ZHANG H Y, LIU L, HE W, et al. Hyperspectral image denoising with total variation regularization and nonlocal low-rank tensor decomposition[J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 58(5):3071-3084.
- [16] WAHLBERG B, BOYD S, ANNERGREN M, et al. An ADMM algorithm for a class of total variation regularized estimation problems [J]. IFAC Proceedings Volumes, 2012, 45(16):83-88.
- [17] PHAM D T, LE T H A. Recent advances in DC programming and DCA[J]. Transactions on Computational Intelligence XIII, 2013, 8342:1-37.
- [18] DONOHO D L. Denoising by soft-thresholding[J]. IEEE Transactions on Information Theory, 1995, 41(3):613-627.

(责任编辑 李 凯)