

# 基于低秩矩阵恢复的高光谱图像去噪

徐 辉, 杨 敏

(南京邮电大学 自动化学院、人工智能学院, 江苏 南京 210023)

**摘 要:**高光谱图像在采集中通常受到各类噪声的污染,存在多种不同程度的退化,传统的高光谱图像去噪仅考虑图像的低秩性而忽略了高光谱图像的相邻波段之间的相似性,缺乏空间信息。基于低秩矩阵模型和空间光谱全变分正则化,该文提出一种将不同噪声统一去除的框架,从而对退化的高光谱数据进行复原。算法基于低秩矩阵恢复抑制分离稀疏噪声,并保证图像的局部低秩性;采用空间光谱全变分正则化模型,增强全局空间光谱的平滑性,减少伪影。由此,建立两者相结合的正则化模型,并用增广拉格朗日乘子法优化求解。仿真实验结果表明:与其他高光谱复原方法相比,在峰值信噪比和结构相似性方面,所提算法数值指标较高,提高了去噪性能。

**关键词:**高光谱图像;图像去噪;低秩矩阵;全变分正则化;稀疏噪声

中图分类号:TP39

文献标识码:A

文章编号:1673-629X(2022)10-0046-05

doi:10.3969/j.issn.1673-629X.2022.10.008

## Hyperspectral Image Denoising Based on Low Rank Matrix Restoration

XU Hui, YANG Min

(School of Automation & School of Artificial Intelligence, Nanjing University of  
Posts and Telecommunications, Nanjing 210023, China)

**Abstract:** Hyperspectral images are usually contaminated by various types of noise during the acquisition, and there are many different degrees of degradation. The traditional hyperspectral image denoising only considers the low rank of the image and ignores the similarity between adjacent bands of the hyperspectral image, lacking spatial information. Based on the low-rank matrix model and the full variational regularization of the spatial spectrum, we propose a unified removal framework for different noises, so as to restore the degraded hyperspectral data. The algorithm is based on low-rank matrix restoration to suppress and separate sparse noise, and to ensure the local low-rank of the image. The spatial spectrum full variation regularization model is used to enhance the smoothness of the global spatial spectrum and reduce artifacts. Therefore, a regularized model combining the two is established, and the augmented Lagrangian multiplier method is used to optimize the solution. The simulation experiment results show that compared with other hyperspectral restoration methods, in terms of peak signal-to-noise ratio and structural similarity, the proposed algorithm has a higher numerical index, which improves the denoising performance.

**Key words:** hyperspectral image; image denoising; low-rank matrix; total variation regularization; sparse noise

## 0 引 言

高光谱图像因其拥有丰富的空间和光谱结构信息,被成功地应用于军事、城市、航天等多个领域<sup>[1]</sup>。但图像在采集过程中会受到各类噪声的污染,如高斯、椒盐、条带噪声等,使得高光谱图像质量严重退化。因此,有必要对高光谱图像进行去噪,从退化图像中恢复出接近原始清晰的图像。

高光谱图像拥有很多光谱通道,且图像是低秩的,相邻的图像像素存在相似性。从高光谱图像的低秩结

构出发,主成分分析法(PCA)、低秩近似和低秩矩阵分解的方法已被成功地用于高光谱图像去噪。从空间角度出发,利用全变分正则化(TV)方法<sup>[2]</sup>实现空间分段光滑,对图像的边缘信息进行处理,减少伪影。这种方法被广泛应用于高光谱图像去噪,其中将全变分的方法和基于低秩先验的方法联合使用<sup>[3-6]</sup>,取得了高质量的复原结果。此外采用了块的非局部相似性和基于子空间的方法来进一步提高高光谱图像去噪的性能<sup>[7-8]</sup>。对高光谱图像进行局部建模,分块处理可以

收稿日期:2021-10-27

修回日期:2022-02-27

基金项目:国家自然科学基金(61971237)

作者简介:徐 辉(1996-),男,硕士研究生,研究方向为图像处理与模式识别;通讯作者:杨 敏(1969-),男,博士,副教授,研究方向为图像处理与计算机视觉。

有效地增强低秩属性,文献[9]采用 PCA(主成分分析)模型依次处理每个分块,有效地对相似像素进行分组。这些方法不能去除结构化稀疏噪声,需要用空间约束来去除结构化稀疏噪声。该文将空间光谱正则化和光谱低秩特性联合用于图像去噪。先采用基于秩约束的局部低秩方法从每个噪声块中分离出低秩分量,然后使用空间光谱重建这些图像的低秩分量,进一步去除噪声。

## 1 高光谱模型

### 1.1 观测模型

原始的高光谱图像的数据表示形式为  $\hat{X} \in R^{m \times n \times b}$ ,  $m \times n$  表示高光谱图像的空间尺寸,  $b$  表示波段数。数据  $\hat{X}$  可以表示成 2 维矩阵的形式如  $X = [X_1, X_2, \dots, X_b] \in R^{m \times n \times b}$ , 用 2 维矩阵形式表示退化模型:

$$Y = X + S + N \quad (1)$$

式中,  $Y$  表示观测到的高光谱图像;  $S$  表示稀疏噪声, 如条带噪声、脉冲噪声等;  $N$  表示高斯噪声。

原始的高光谱图像在不同波段之间存在着很强的相关性,这种相关性在  $X$  中体现为列空间具有低秩结构,提出秩约束下的鲁棒主分量分析(RPCA)模型,即:

$$\begin{aligned} \argmin_{X,S} \quad & \|X\|_* + \lambda \|S\|_1 \\ \text{s. t.} \quad & \|Y - X - S\|_F^2 \leq \varepsilon, \text{rank}(X) \leq r \end{aligned} \quad (2)$$

式(2)模型能够有效去除稀疏噪声,同时还约束数据的秩不能超过终端单元的个数,这可以在一定程度上抑制高斯噪声。

基于秩约束的局部低秩方法模型可以定义为:

$$\begin{aligned} \min_{X,S} \quad & \sum_{(i,j) \in [1, M-m+1] \times [1, N-n+1]} (\|X_{i,j}\|_* + \lambda \|S_{i,j}\|_1) \\ \text{s. t.} \quad & \|Y_{i,j} - X_{i,j} - S_{i,j}\|_F^2 \leq \varepsilon, \text{rank}(X_{i,j}) \leq r \end{aligned} \quad (3)$$

其中,  $X_{i,j}$  表示在高光谱图像位置  $(i,j)$  的  $m \times n \times b$  块立方体中提取  $m \times n$  行相应的矩阵。式(3)将逐块 RPCA 模型应用于高光谱图像去噪。

### 1.2 空间光谱全变分正则化

全变分 TV 模型的应用,对于高光谱图像去噪效果有很大的改善。各向同性模型很容易引入明显伪影<sup>[10]</sup>,而各向异性模型<sup>[11]</sup>效果好。选用各向异性模型加强图像的平滑度。大小为  $M \times N$  的灰度图像  $u$ , 各向异性 TV 范数定义为:

$$\|u\|_{TV} = \|D_x u\|_1 + \|D_y u\|_1 \quad (4)$$

其中,  $D_x, D_y$  分别对应于水平和垂直一阶离散差线性算子。不同方向上的梯度强度可能不相同,可以将高

光谱图像  $X$  的各向异性空间光谱全变分定义为:

$$\|X\|_{SSTV} = \|D_x X\|_1 + \|D_y X\|_1 + \tau_z \|D_z X\|_1 \quad (5)$$

其中,  $D_x, D_y, D_z$  可定义为:

$$\begin{cases} D_x = X(x+1, y, z) - X(x, y, z) \\ D_y = X(x, y+1, z) - X(x, y, z) \\ D_z = X(x, y, z+1) - X(x, y, z) \end{cases} \quad (6)$$

其中,  $D_z$  是沿光谱方向的前向有限差分算子,也是表示高光谱图像中光谱维的差异信息。 $\tau_z$  是正则化参数,表示对光谱的梯度贡献的权重。根据文献[12],将两个空间维度对空间光谱 TV 正则化的贡献看作是相同的且都为 1。

## 2 基于增广拉格朗日乘子法的模型求解

将高光谱图像的基于局部块的低秩约束 RPCA 模型(3)代入到空间光谱正则化(4)中,即:

$$\begin{aligned} \min_{X,S} \quad & \sum_{i,j} (\|X_{i,j}\|_* + \lambda \|S_{i,j}\|_1) + \tau \|X\|_{SSTV} \\ \text{s. t.} \quad & \|Y_{i,j} - X_{i,j} - S_{i,j}\|_F^2 \leq \varepsilon, \text{rank}(X_{i,j}) \leq r \end{aligned} \quad (7)$$

其中,  $\lambda$  和  $\tau$  是正则化参数。首先引入三个辅助变量  $J, L, U$ , 得到以下的表达式:

$$\begin{aligned} \min_{X,S,J,L,U} \quad & \sum_{i,j} (\|X_{i,j}\|_* + \lambda \|S_{i,j}\|_1) + \tau \|U\|_1 \\ \text{s. t.} \quad & \|Y - X - S\|_F^2 \leq \varepsilon, X_{i,j} = J_{i,j}, \\ & J = L, U = DL, \text{rank}(X_{i,j}) \leq r \end{aligned} \quad (8)$$

$D = [\tau_x D_x, \tau_y D_y, \tau_z D_z]$  代表 SSTV 算子。用增广拉格朗日乘子方法将式(8)变为无约束优化问题,即:

$$\begin{aligned} \argmin_{X,L,S,J,U} E(X, L, S, J, U) = \\ \argmin_{X,L,S,J,U} \sum_{i,j} (\|X_{i,j}\|_* + \lambda \|S_{i,j}\|_1 + \langle \Lambda_1, Y_{i,j} - X_{i,j} - S_{i,j} \rangle + \frac{\mu}{2} \|Y_{i,j} - X_{i,j} - S_{i,j}\|_F^2 + \\ \langle \Lambda_2, X_{i,j} - J_{i,j} \rangle + \frac{\mu}{2} \|X_{i,j} - J_{i,j}\|_F^2) + \tau \|U\|_1 + \\ \langle \Lambda_3, U - DL \rangle + \langle \Lambda_4, J - L \rangle + \frac{\mu}{2} (\|U - DL\|_2^2 + \\ \|J - L\|_2^2) \end{aligned} \quad (9)$$

式中,  $\mu$  是惩罚参数;  $\Lambda_1, \Lambda_2, \Lambda_3, \Lambda_4$  是拉格朗日乘数。在一个变量上迭代优化增广拉格朗日函数(9),同时保持其他变量不变。迭代优化增广拉格朗日函数将第  $k+1$  次迭代中的更新分为两个子问题:

低秩和稀疏矩阵分解问题:

$$(X^{k+1}, S^{k+1}) = \argmin_{X,S} E(X, S, J^k) \quad (10)$$

低秩块的空间光谱正则化图像重建问题:

$$(J^{k+1}, L^{k+1}, U^{k+1}) = \underset{J, L, U}{\operatorname{argmin}} E(X_{i,j}^{k+1}, J, L, U) \quad (11)$$

拉格朗日乘子更新:

$$\begin{cases} \Lambda_1 = \Lambda_1 + \mu(Y_{i,j} - X_{i,j} - S_{i,j}) \\ \Lambda_2 = \Lambda_2 + \mu(X_{i,j} - J_{i,j}) \\ \Lambda_3 = \Lambda_3 + \mu(U - DL) \\ \Lambda_4 = \Lambda_4 + \mu(J - L) \end{cases} \quad (12)$$

算法 1: 高光谱图像去噪。

输入: 高光谱图像  $X$ , 终止迭代条件  $\varepsilon$ , 正则化参数  $\lambda$ ,  $\tau$  和

$\tau_z$

输出: 去噪图像  $X$

初始化:  $L = X = S = J = 0, U = 0, \mu = 10^{-2}, \mu_{\max} = 10^6$ ,

$\rho = 1.5$

迭代更新:

通过公式(10)更新所有  $(X_{i,j}, S_{i,j})$ , 通过公式(11)更新  $(J, L, U)$  进行空间光谱正则化图像重建, 分别更新拉格朗日乘子以及惩罚参数更新  $\mu: = \min(\rho\mu, \mu_{\max})$

检查收敛条件:

$$\max \{ \|Y_{i,j} - X_{i,j}^{k+1} - S_{i,j}^{k+1}\|_{\infty}, \|J^{k+1} - L^{k+1}\|_{\infty}, \|U^{k+1} - DL^{k+1}\|_{\infty} \} \leq \varepsilon$$

其中,  $\lambda$  是低秩干净图像和稀疏噪声的比重,  $\tau$  是正则化参数,  $\rho$  是 ADMM 中引入的参数为常数值。停止迭代规则设置  $\varepsilon = 1e^{-6}$ 。初始化并且所有的拉格朗日乘数都为 0。对于增广拉格朗日函数, 将其初始化为  $\mu = 10^{-2}$ , 并在迭代中更新参数, 以保持算法的收敛性。最后, 算法 1 的输出是去噪图像  $X \in R^{M \times N \times b}$ 。

### 3 仿真实验与分析

#### 3.1 评价指标

使用峰值信噪比 (PSNR) 和结构相似性 (SSIM) 作为相应评价指标, 用来评价复原效果。PSNR 是基于误差敏感的图像质量评价指标。给定一个大小的干净图像  $X$  和噪声图像  $Y$ , PSNR 定义为:

$$\begin{aligned} \text{PSNR} &= 10 * \log_{10} \frac{MN}{\sum_{x=1}^M \sum_{y=1}^N [X(i,j) - Y(i,j)]^2} \\ \text{MPSNR} &= \frac{1}{B} \sum_{i=1}^B \text{PSNR} \end{aligned} \quad (13)$$

当 PSNR 的值越大, 说明图像的失真越小, 恢复的图像越接近真实图像。

SSIM 定义为:

$$\text{SSIM} = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\mu_x^2 + \mu_y^2 + C_2)} \quad (14)$$

$$\text{MSSIM} = \frac{1}{B} \sum_{i=1}^B \text{SSIM}$$

SSIM 的取值范围为  $[0, 1]$ , 其值越大表示图像失真越小, 图像的恢复效果好。

#### 3.2 数据集及参数设置

仿真实验在 Lenovo N50-80 笔记本电脑上进行, 处理器为 Inter (R) Core (TM) i5-5200U CPU @ 2.2 GHz 和 8 GB 内存, 操作系统为 64 位 Windows10, 同时仿真软件为 Matlab (2020)。

实验中, 将正则化参数设置为  $\tau = 0.005, \lambda = 0.2$ 。高光谱数据选取的是 Pavia 数据集 ([http://www.ehu.es/ccwintco/index.php/Hyperspectral\\_Remote\\_Sensing\\_Scenes](http://www.ehu.es/ccwintco/index.php/Hyperspectral_Remote_Sensing_Scenes)) 和 Indian Pines 数据集 (<https://engineering.purdue.edu/biehl/MultiSpec/hyperspectral.html>)。Pavia 数据集由光学系统成像光谱仪 (ROSIS-03) 收集。选择其某一子集进行实验, 其空间图像的尺寸为  $200 \times 200 \times 80$ ; Indian Pines 数据集由真实地物类别 Indian Pines 数据集和美国数字光谱实验室提供的光谱数据库 splib06a 通过人工合成得到, 其空间图像的尺寸为  $145 \times 145 \times 224$ 。首先对两个数据集的各个波段数据进行归一化处理, 然后添加不同种类的模拟噪声。

与文中复原方法作对比的有 FastHyDe 方法<sup>[13]</sup>、LRMR 方法<sup>[6]</sup>、LRTV 方法<sup>[3]</sup>。在高光谱数据上进行模拟实验。在两个数据集的所有波段中添加了高斯噪声、椒盐脉冲噪声:

实验 1: 高斯噪声和椒盐脉冲噪声都被添加到所有波段。高斯噪声 ( $G$ ) 的方差分别为 0.02、0.04、0.06、0.08 和 0.1。同时, 椒盐脉冲噪声也被添加到所有的频带, 以模拟稀疏噪声。脉冲噪声 ( $P$ ) 的百分比分别为 0.04、0.08、0.12、0.16 和 0.2。

实验 2: 不同强度的噪声被添加到每个波段, 高斯噪声 ( $G$ ) 的方差从 0 到 0.1 随机选择。

用文中方法和对比方法对 4 种不同的模拟观测数据进行复原。将复原结果的 SSIM 和 PSNR 分别取均值, 记为 MSSIM 和 MPSNR, 并用这两个均值作为最终复原效果的评价标准。

#### 3.3 实验结果

图 1 分别表示当高斯噪声  $G=0.1$ , 椒盐脉冲噪声  $P=0.2$  时测试的 Pavia 数据集高光谱图像的原始图像, 加入高斯噪声和椒盐脉冲噪声后的噪声图像, 不同方法最终恢复得到的图像。

图 2 展示了当高斯噪声  $G=0.1$ , 椒盐脉冲噪声  $P=0.2$  时, 测试的 Indian Pines 数据集高光谱图像的原始图像、噪声图像, 以及不同方法最终恢复得到的图像。

表 1 和表 2 分别汇总了 4 种方法在 Pavia 数据集和 Indian Pines 数据集下的复原结果。对取得最优评价指标的方法进行了加粗, 第二顺位的方法也利用下划线进行表示。




图 1 模拟 Pavia 数据集第 30 波段的实验结果




图 2 模拟 Indian Pines 数据集第 60 波段的实验结果

表 1 高光谱图像 Pavia 数据集的复原结果

噪声强度	评判标准	FastHyDe	LRMR	LRTV	文中方法
$G = 0.02$	MSSI M	<b>0.994 9</b>	0.990 2	0.989 0	<u>0.993 8</u>
$P = 0.04$	MPSNR (dB)	<b>45.251 4</b>	42.103 6	41.548 1	<u>44.392 4</u>
$G = 0.04$	MSSIM	<u>0.979 5</u>	0.975 9	0.973 3	<b>0.983 5</b>
$P = 0.08$	MPSNR (dB)	37.438 0	<u>37.945 7</u>	37.765 8	<b>40.252 7</b>
$G = 0.06$	MSSIM	<u>0.958 2</u>	0.955 7	0.954 4	<b>0.968 1</b>
$P = 0.12$	MPSNR (dB)	33.539 5	35.023 2	<u>35.348 8</u>	<b>37.237 6</b>
$G = 0.08$	MSSIM	0.854 8	<u>0.931 2</u>	0.930 8	<b>0.947 6</b>
$P = 0.16$	MPSNR (dB)	25.529 3	32.867 4	<u>33.440 6</u>	<b>34.821 5</b>
$G = 0.1$	MSSIM	0.770 2	0.902 7	<u>0.904 8</u>	<b>0.923 6</b>
$P = 0.2$	MPSNR (dB)	22.311 4	31.172 2	<u>31.804 1</u>	<b>32.775 7</b>
$G$ (随机取值)	MSSIM	<b>0.994 5</b>	0.972 0	0.970 3	<u>0.989 5</u>
	MPSNR (dB)	<b>45.179 3</b>	37.280 6	38.210 5	<u>41.233 0</u>

表 2 高光谱图像 Indian Pines 数据集的复原结果

噪声强度	评判标准	FastHyDe	LRMR	LRTV	文中方法
$G = 0.02$	MSSIM	<b>0.990 0</b>	0.989 4	0.989 6	<u>0.989 9</u>
$P = 0.04$	MPSNR (dB)	38.196 5	<b>40.007 6</b>	36.512 9	<u>38.989 4</u>
$G = 0.04$	MSSIM	0.980 8	0.978 9	<b>0.988 4</b>	<u>0.985 3</u>
$P = 0.08$	MPSNR (dB)	33.521 6	<u>38.049 5</u>	36.340 9	<b>38.479 7</b>
$G = 0.06$	MSSIM	0.970 2	0.961 2	<b>0.986 0</b>	<u>0.976 7</u>
$P = 0.12$	MPSNR (dB)	30.581 2	35.657 0	<u>36.012 2</u>	<b>37.698 7</b>
$G = 0.08$	MSSIM	0.958 2	0.938 1	<b>0.982 1</b>	<u>0.962 9</u>
$P = 0.16$	MPSNR (dB)	28.425 7	34.088 0	<u>35.496 1</u>	<b>36.695 2</b>
$G = 0.1$	MSSIM	0.944 8	0.908 8	<b>0.976 1</b>	<u>0.944 9</u>
$P = 0.2$	MPSNR (dB)	26.517 6	32.427 0	<u>34.789 0</u>	<b>35.506 2</b>
$G$ (随机取值)	MSSIM	<b>0.997 9</b>	0.977 0	0.989 1	<u>0.989 5</u>
	MPSNR (dB)	<b>46.240 0</b>	37.701 5	36.297 3	<u>38.478 2</u>

相比之下,可以看出文中方法将所有的块一起处理,并使用空间光谱正则化对于图像的重建效果有明显的提高。在实验 1 中:当稀疏噪声增强时, FastHyDe 方法的性能降低; LRMR 方法可以去除稀疏噪声,但仍

会存在少量噪声; LRTV 对高光谱图像的低秩特性全局建模并结合 TV 范数正则化,没有与文中方法一样将所有块一起全局处理,细节的平滑度效果不如文中方法,但恢复的效果优于其他方法且仅次于文中方法;



在实验 2 中:当高斯噪声的方差从 0 到 0.1 随机选择时,文中方法优于 LRMR 和 LRTV,仅次于 FastHyDe 方法,由于随机选择的数值具有不确定性,可能在 0 ~ 0.1 之间取得小,从而 FastHyDe 方法更优一点,但当取值增大时,FastHyDe 方法的效果会就明显变差,而与之相比文中方法不会有太大的差异,因此文中方法实现了最佳的 MPSNR 和 MSSIM 值,提高了图像边缘细节的效果,对于高光谱图像的去噪性能有了很大的改善。

表 3 汇总了 4 种方法在 Pavia 数据集和 Indian Pines 数据集的运行时间。

表 3 高光谱图像噪声复原运行时间 s

数据集	FastHyDe	LRMR	LRTV	文中方法
实验 1,2 (Pavia 数据)	15	95	29	132
实验 1,2 (Indian 数据)	30	140	50	200

可以看出加入空间光谱全变分框架后,模型计算复杂度有所增加,运算时间明显增加了,而 FastHyDe 是基于子空间表示来进行去噪的,运行时间明显变快,但图像的复原精度比不上文中方法。因此降低运算复杂度,提高恢复效率还有待提高。

#### 4 结束语

将高光谱图像低秩结构和空间谱全变分相结合,提出一种高光谱图像噪声去除方法。该方法可以去除混合噪声,能够单独处理所有的块,从噪声中分离出低秩干净块。仿真实验表明了该方法的有效性和优越性。该模型较复杂,采用矩阵奇异值分解来探索每个块的低秩结构迭代时间长,未来可以考虑基于子空间投影的方法来完成干净块和噪声块的分解,从而降低去噪的复杂度。

#### 参考文献:

- [1] 童庆禧,张 兵,郑兰芬. 高光谱遥感的多学科应用[M]. 北京:电子工业出版社,2006.
- [2] RUDIN L I, OSHER S, FATEMI E. Nonlinear total variation based noise removal algorithms[J]. Physica D: Nonlinear Phenomena, 1992, 60(1-4): 259-268.
- [3] HE W, ZHANG H, ZHANG L, et al. Total-variation-regularized low-rank matrix factorization for hyperspectral image restoration[J]. IEEE Transactions on Geoscience & Remote Sensing, 2015, 54(1): 178-188.
- [4] WU Z, QIANG W, WU Z, et al. Total variation-regularized weighted nuclear norm minimization for hyperspectral image mixed denoising[J]. Journal of Electronic Imaging, 2016, 25(1): 013037.
- [5] 贺 威. 高光谱影像多类型噪声分析的低秩与稀疏方法研究[D]. 武汉:武汉大学, 2017.
- [6] ZHANG H, WEI H, ZHANG L, et al. Hyperspectral image restoration using low-rank matrix recovery[J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(8): 4729-4743.
- [7] CHANG Y, YAN L, ZHAO X L, et al. Weighted low-rank tensor recovery for hyperspectral image restoration[J]. IEEE Transactions on Cybernetics, 2020, 50(11): 4558-4572.
- [8] ZENG H, XIE X, KONG W, et al. Hyperspectral image denoising via combined non-local self-similarity and local low-rank regularization[J]. IEEE Access, 2020, 8: 50190-50208.
- [9] ZHUANG L, NG M K. Hyperspectral mixed noise removal by l1-norm based subspace representation[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2020, 13: 1143-1157.
- [10] CHANG Y, YAN L, FANG H, 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] HE W, ZHANG H, ZHANG L. Total variation regularized re-weighted sparse nonnegative matrix factorization for hyperspectral unmixing[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(7): 3909-3921.
- [12] CHAN S H, KHOSHABEH R, GIBSON K B, et al. An augmented Lagrangian method for total variation video restoration[J]. IEEE Translation Image Process, 2011, 20(11): 3097-3111.
- [13] ZHUANG L, BIOUCAS-DIAS J M. Fast hyperspectral image denoising and inpainting based on low-rank and sparse representations[J]. IEEE Journal of Selected Topics in Applied Earth Observations & Remote Sensing, 2018, 11(99): 730-742.