

DOI:10.3969/j.issn.1003-5060.2026.06.007

# 基于超图的多波段联合稀疏表示遥感图像时空融合

方 帅<sup>1,2</sup>, 沈 丽<sup>1</sup>

(1. 合肥工业大学 计算机与信息学院, 安徽 合肥 230601; 2. 工业安全与应急技术安徽省重点实验室, 安徽 合肥 230601)

**摘 要:**对于给定的卫星传感器,其在空间分辨率与时间分辨率之间总是存在权衡,现有的基于稀疏表示的融合算法大多在单波段上进行,忽略了多波段间的相关性,并且稀疏表示算法应用于分辨率差距过大的场景下,融合效果较差。针对以上问题,文章提出一种基于超图的多波段联合稀疏表示算法。该算法将超图约束引入稀疏表示模型,保持多波段之间的关联性,并通过细节增强模型对初步预测结果进行细节增强,从而提高融合精度。实验结果表明:在 BOREAS 数据集上,相比于次优算法,文章所提算法的结构相似度(structural similarity, SSIM)提高了 3.0%,光谱角匹配(spectral angle match, SAM)提高了 5.4%;在 CIA 数据集上,相比于次优算法,文章所提算法的 SSIM 提高了 2.0%,SAM 提高了 4.0%;在 LGC 数据集上,相比于次优算法,文章所提算法的 SSIM 提高了 2.4%,SAM 提高了 4.5%。表明文中所提出的算法在光谱的保持和空间信息的预测上都表现出一定的优势。

**关键词:**遥感;时空融合;稀疏表示;超图;细节增强

**中图分类号:**TP751.1

**文献标志码:**A

**文章编号:**1003-5060(2026)06-0764-09

## Hypergraph-based multi-band joint sparse representation for remote sensing image spatiotemporal fusion

FANG Shuai<sup>1,2</sup>, SHEN Li<sup>1</sup>

(1. School of Computer Science and Information Engineering, Hefei University of Technology, Hefei 230601, China; 2. Anhui Province Key Laboratory of Industry Safety and Emergency Technology, Hefei 230601, China)

**Abstract:** There is always a trade-off between spatial resolution and temporal resolution for a given satellite sensor. Most of the existing sparse representation based fusion algorithms are carried out on a single band, ignoring the correlation between multiple bands, and the sparse representation algorithm has poor fusion effect when applied to the scene with a large resolution gap. To solve the above problems, this paper proposes a multi-band joint sparse representation algorithm based on hypergraph. The hypergraph constraint is introduced into the sparse representation model to maintain the correlation between multi-bands, and the detail enhancement model is used to enhance the details of the preliminary prediction results, so as to improve the fusion accuracy. The experimental results show that the structural similarity(SSIM) of the proposed algorithm is improved by 3.0% and the spectral angle match(SAM) is improved by 5.4% on BOREAS dataset compared with the suboptimal algorithm. On the CIA dataset, compared with the suboptimal algorithm, the SSIM of the proposed algorithm is improved by 2.0% and the SAM is improved by 4.0%. On the LGC dataset, compared with the suboptimal algorithm, the SSIM of the proposed algorithm is increased by 2.4% and the SAM is increased by 4.5%. The algorithm in this paper shows advantages in spectrum preservation and spatial information prediction.

**Key words:** remote sensing; spatiotemporal fusion; sparse representation; hypergraph; detail enhancement

**收稿日期:**2023-12-18; **修回日期:**2024-02-26

**基金项目:**国家自然科学基金资助项目(61872327)

**作者简介:**方 帅(1978—),女,安徽寿县人,博士,合肥工业大学教授,博士生导师,通信作者, E-mail:fangshuai@hfut.edu.cn.

## 0 引 言

随着遥感技术的不断发展,高时空分辨率的遥感图像可以快速、准确地提供地形变化信息,在农业监测、城市规划建设等多个领域具有广泛的应用和需求。然而,由于技术和预算的限制,单个遥感卫星的传感器往往很难同时具有高时间和高空间分辨率,从而限制了遥感图像的潜在应用。时空图像融合是解决该“时空矛盾”问题的一种方法。时空数据融合将来自多源卫星传感器的低空间分辨率高时间分辨率图像与高空间分辨率低时间分辨率图像进行有效融合,以获得具有高时间和高空间分辨率的图像。目前,现有的时空融合算法可以分为两大类,即基于传统的方法和基于学习的方法。

基于传统的方法包括基于加权的方法和基于解混的方法。基于加权的方法<sup>[1-5]</sup>假设一类或相邻位置的像素共享相似的像素值,通过加权函数结合所有输入图像的信息来估计精细像素值,其关键步骤是计算权重。时空自适应反射率融合模型(spatial and temporal adaptive reflectance fusion model, STARFM)<sup>[1]</sup>是首次被提出的基于加权的时空融合方法,该方法提出混合权重由时间差、光谱差和空间距离共同决定,将相邻的相似像素和混合权重相结合生成高分辨率图像。但是,STARFM存在2个主要的问题:①假设在异质性景观中是无效的;②权重函数是经验的。基于以上问题出现了一些基于STARFM的改进算法,如映射反射率变化的时空自适应算法<sup>[2]</sup>。这类方法在预测有物候变化的像素时具有良好的性能,在处理异质景观和经历土地覆盖类型变化的景观方面表现不佳,融合精度较低。基于解混的方法是基于线性光谱混合理论,通过分解粗像素来估计细像素的值。多传感器多分辨率技术(multi-sensor multiresolution technique, MMT)<sup>[6]</sup>是一种基于解混的融合方法,由于MMT方法存在光谱分解中的较大误差和粗像素内的精细像素缺乏类内可变性问题,出现了一些改进的基于解混的方法<sup>[7-9]</sup>,大多数基于解混的方法在保存空间细节和捕获物候变化方面具有良好的性能。然而,这些方法也会受到对端元数的错误估计、多时观测中端成员的光谱变异性以及光谱混合的非线性的影响。

基于学习的方法可分为基于稀疏表示的方法和基于深度学习的方法。基于深度学习的方法

法<sup>[10-11]</sup>通过网络结构和损失函数的设计,可以提高对时空融合的适应性。然而,基于深度学习的方法需要大量的数据集进行模型训练,为了获得高的融合精度,大多数方法会选择多对图像进行训练,这样的数据需求在实际中很难满足。

基于稀疏表示的方法<sup>[12-20]</sup>通过训练粗细图像字典对,建立了精细空间分辨率图像与粗糙空间分辨率图像之间的映射关系,进而求解高分辨率图像。在遥感图像中,Landsat-MODIS图像之间的分辨率相差过大,超出稀疏表示算法的能力,融合效果较差。针对这一问题,文献<sup>[13]</sup>提出基于一对图像学习的时空遥感卫星图像融合方法,该方法采用联合字典学习方式学习高低空间分辨率图像对之间的关系,预测出过渡的预测日期目标图像,考虑到重建图像缺少高频细节,采用高通调制方法提高重建图像的空间分辨率,并结合两层融合框架模型进一步提高融合精度。文献<sup>[14]</sup>提出误差有界的半耦合字典学习模型,通过采用误差有界正则化方法来适应字典扰动,同时采用半耦合字典学习来放宽对稀疏系数的约束,提高稀疏表达的能力。文献<sup>[20]</sup>提出基于非局部张量稀疏表示的半耦合字典学习方法,通过基于张量-张量乘积的张量稀疏表示,同时利用了非局部相似立方体的光谱相关性和空间相似性。

此外,将稀疏系数在高和低空间分辨率图像空间上的半耦合映射先验知识与耦合字典相结合,约束稀疏系数的相似性,以提高预测性能。从遥感图像中使用更多的光谱波段可以提高回归模型的性能,来自空间光谱融合的研究也鼓励输入更多的波段。

对于时空融合问题而言,当粗图像和细图像分辨率差距过大时,如何利用先验信息更好地重建预测图像是大多数方法旨在解决的问题。但现有的方法大多数只考虑单波段的空间信息,很少关注遥感图像的光谱相关性。

基于以上问题,本文提出了基于超图的多波段联合稀疏表示,在遥感图像超分辨率的稀疏表示中引入超图学习作为正则项,超图正则项不仅可以探索单波段的信息,还可以跨波段寻找更多的先验信息;同时可以捕获每个像素与其他任何像素之间的复杂关系,并增强了同一超边缘中多波段之间像素的一致性,使得稀疏系数的求解更加稳定。本文还提出了细节增强模型,通过对空间细节的增强,弥补稀疏表示算法在分辨率差距过大的情况下,对空间细节预测的不足,从而进一步

步提高融合性能。

## 1 融合算法

本文的整体思路是在稀疏表示的基础上建立多波段联合字典,并引入超图正则项,利用超图构建 3 个波段之间像素的复杂关系,保持多波段之间的关联性,并通过细节增强模型,进一步提高融合质量。

### 1.1 超图

超图是泛化的图结构,图中的边只能连接 2 个顶点,而超图中的边可以连接多个顶点,这意味着超图可以对多个对象的特征关系进行建模。

超图  $G$  可以表示为  $G=(Y, E)$ , 其中  $Y=\{y_1, y_2, \dots, y_n\}$  是  $n$  个顶点的集合,  $E=\{e_1, e_2, \dots, e_m\}$  是  $m$  条超边的集合。超图的关联矩阵表示超边与顶点的关系,公式如下:

$$\mathbf{H}(y, e) = \begin{cases} 1, & y \in e; \\ 0, & \text{其他} \end{cases} \quad (1)$$

带权重的超图可以用三元组  $G=(Y, E, W)$  表示,其中  $W$  代表超边权重集合,权重与超边上顶点相似度成正比,即超边内部顶点越凝聚,权重越大,每条超边的权重记为  $w(e)$ 。

### 1.2 图像块超图

图像块大小为  $m \times m \times n$ , 其中  $m$  为长、宽,  $n$  为波段数,将每个波段拉伸为一个  $m^2 \times 1$  的列向量,将  $n$  个向量进行叠加,则一个图像块可以表示为一个  $N \times 1 (N=m^2 \times n)$  的列向量  $\mathbf{Y}$ , 共  $N$  个像素,每个像素是一个顶点,对  $\mathbf{Y}$  建立超图。计算像素  $y_k$  和其他像素  $y_j$  之间的距离关系,具体公式如下:

$$d_j^k = \exp\left[\frac{-(y_j - y_k)^2}{r^2}\right] \quad (2)$$

其中,  $r = \frac{2}{N(N-1)} \sum_{j=1}^N \sum_{k=1, k \neq j}^N |y_j - y_k|$ ,  $j=1, 2, \dots, N, j \neq k$ ,  $r$  为所有顶点两两之间欧式距离的均值。 $d_j^k$  反映两像素相似程度,相似程度越相近  $d_j^k$  越逼近 1, 相差越大  $d_j^k$  越逼近 0, 这也是超边权重计算的依据,即

$$d_j^k = \begin{cases} d_j^k, & d_j^k \geq \sum_{j=1}^N d_j^k / N; \\ 0, & \text{其他} \end{cases} \quad (3)$$

式(3)保留与顶点  $y_k$  之间的相似程度大于平均相似程度的顶点,形成一条超边  $e$ , 根据此方法建立图像块的超图。超边权重  $w(e) = \sum_{y_j \in e} d_j^k$ 、超

边度  $\delta(e) = \sum_{y \in e} \mathbf{H}(y, e)$ 、顶点度  $d(y) = \sum_{e \in E | y \in e} w(e)$ , 顶点度、超边度和超边权重构成的对角矩阵分别记作  $\mathbf{D}_y = \text{diag}(d(y))$ 、 $\mathbf{D}_e = \text{diag}(\delta(e))$ 、 $\mathbf{W}_e = \text{diag}(w(e))$ 。超图的邻接矩阵  $\mathbf{A} = \mathbf{H}\mathbf{W}_e\mathbf{D}_e^{-1}\mathbf{H}^T$ ; 超图的拉普拉斯矩阵  $\mathbf{L} = \mathbf{D}_y - \mathbf{A}$ , 表示每个顶点之间的相邻关系。

对于一个图像块  $\mathbf{Y}$ , 同一超边的像素距离可以表示为  $\sum_{e \in E} \sum_{j, k \in e} (y_j - y_k)^2$ , 由前面超边建立的方法可知, 属于同一超边的像素是非常相似的, 因此满足  $\min\left\{\sum_{e \in E} \sum_{j, k \in e} (y_j - y_k)^2\right\}$ 。利用超图拉普拉斯矩阵, 可等价于:

$$\min\left\{\sum_{e \in E} \sum_{j, k \in e} (y_j - y_k)^2\right\} = \min\{\mathbf{Y}^T \mathbf{L} \mathbf{Y}\}。$$

本文利用超图表达多个像素之间关系的能力, 约束字典和稀疏系数的求解。在超图的约束下, 图像块内原本相似的像素, 稀疏表示后仍然保持相似(属于同一条超边的像素); 原本有差异的像素, 其差异性能很好地保持(属于不同超边的像素); 原本具有微弱差异像素, 其差异性不会丢失(同一像素可以属于不同超边)。

### 1.3 基于超图的多波段联合字典

基于超图的多波段联合字典是在传统的稀疏表示基础上, 采用多波段联合字典学习的方式, 建立高低分辨率图像之间的关系, 并将超图约束引入稀疏表示模型进行字典学习, 目标函数表示如下:

$$\underset{\mathbf{D}_h, \mathbf{D}_l, \boldsymbol{\alpha}^i}{\text{argmin}} \left\{ \frac{1}{N_1} \sum_{i=1}^{N_1} \left[ \|\mathbf{X}^i - \mathbf{D}_l \boldsymbol{\alpha}^i\|_2^2 + \|\mathbf{Y}^i - \mathbf{F}_h \boldsymbol{\alpha}^i\|_2^2 + \lambda_1 \|\boldsymbol{\alpha}^i\|_1 + \lambda_2 (\mathbf{Y}^i)^T \mathbf{L}_{\text{hg}}^i (\mathbf{Y}^i) \right] \right\} \quad (4)$$

其中:  $\mathbf{Y}^i$ 、 $\mathbf{X}^i$  分别为第  $i$  个高、低分辨率图像块;  $\mathbf{L}_{\text{hg}}^i$  为  $\mathbf{Y}^i$  的超图;  $\mathbf{D}_h$ 、 $\mathbf{D}_l$  分别为高、低分辨率图像字典;  $\mathbf{Y}_n^i$ 、 $\mathbf{X}_n^i$  分别为第  $i$  个高、低分辨率图像块的第  $n$  个波段;  $\boldsymbol{\alpha}^i$  为  $\mathbf{Y}^i$ 、 $\mathbf{X}^i$  的联合稀疏系数;  $\boldsymbol{\alpha}_n^i$  为第  $n$  个波段的系数。其表达式分别如下:

$$\mathbf{D}_h = \begin{bmatrix} \mathbf{D}_{h,1} & \mathbf{0} & \cdots & \mathbf{0} \\ \mathbf{0} & \mathbf{D}_{h,2} & \cdots & \mathbf{0} \\ \vdots & \vdots & & \vdots \\ \mathbf{0} & \mathbf{0} & \cdots & \mathbf{D}_{h,n} \end{bmatrix}, \quad \mathbf{D}_l = \begin{bmatrix} \mathbf{D}_{l,1} & \mathbf{0} & \cdots & \mathbf{0} \\ \mathbf{0} & \mathbf{D}_{l,2} & \cdots & \mathbf{0} \\ \vdots & \vdots & & \vdots \\ \mathbf{0} & \mathbf{0} & \cdots & \mathbf{D}_{l,n} \end{bmatrix} \quad (5)$$

$$\mathbf{Y}^i = \begin{bmatrix} \mathbf{Y}_1^i \\ \mathbf{Y}_2^i \\ \vdots \\ \mathbf{Y}_n^i \end{bmatrix}, \mathbf{X}^i = \begin{bmatrix} \mathbf{X}_1^i \\ \mathbf{X}_2^i \\ \vdots \\ \mathbf{X}_n^i \end{bmatrix}, \mathbf{Y}_1^i = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_{m^2} \end{bmatrix}, \boldsymbol{\alpha}^i = \begin{bmatrix} \alpha_1^i \\ \alpha_2^i \\ \vdots \\ \alpha_n^i \end{bmatrix} \quad (6)$$

根据  $\mathbf{Y} = \mathbf{D}_h \boldsymbol{\alpha}$  可将损失函数变形为:

$$\operatorname{argmin}_{\mathbf{D}_h, \mathbf{D}_l, \boldsymbol{\alpha}^i} \left\{ \frac{1}{N_1} \sum_{i=1}^{N_1} \left[ \|\mathbf{X}^i - \mathbf{D}_l \boldsymbol{\alpha}^i\|_2^2 + \|\mathbf{Y}^i - \mathbf{D}_h \boldsymbol{\alpha}^i\|_2^2 + \lambda_1 \|\boldsymbol{\alpha}^i\|_1 + \lambda_2 (\mathbf{D}_h \boldsymbol{\alpha}^i)^T \mathbf{L}_{hg} (\mathbf{D}_h \boldsymbol{\alpha}^i) \right] \right\} \quad (7)$$

#### 1.4 基于超图的多波段联合重建

根据字典学习阶段获得的高、低分辨率空间字典  $\mathbf{D}_h$  和  $\mathbf{D}_l$ , 对预测日期的低分辨率图像  $\mathbf{M}_2$ , 利用式(8)求解低分辨率稀疏系数, 再通过式(9)得到预测日期高分辨率图像的初步预测结果  $\mathbf{L}_2'$ 。

$$\boldsymbol{\alpha}^i = \operatorname{argmin}_{\boldsymbol{\alpha}^i} \left\{ \frac{1}{N_1} \sum_{i=1}^{N_1} \left( \|\mathbf{X}^i - \mathbf{D}_l \boldsymbol{\alpha}^i\|_2^2 + \lambda_1 \|\boldsymbol{\alpha}^i\|_1 \right) \right\} \quad (8)$$

$$\mathbf{Y}^i = \operatorname{argmin}_{\mathbf{Y}^i} \left\{ \frac{1}{N_1} \sum_{i=1}^{N_1} \left[ \|\mathbf{Y}^i - \mathbf{D}_h \boldsymbol{\alpha}^i\|_2^2 + \lambda_2 (\mathbf{Y}^i)^T \mathbf{L}_{hg} (\mathbf{Y}^i) \right] \right\} \quad (9)$$

#### 1.5 图像细节增强

由于遥感图像 Landsat 和 MODIS 图像的分辨率差距过大, 超出了稀疏表示算法的能力, 空间

细节预测不理想。因此本文提出细节增强模型对于初步预测结果  $\mathbf{L}_2'$  进行细节增强, 进一步提高预测精度。细节增强模型如图 1 所示, 主要包括细节提取和细节增强。

细节提取的步骤如下:

1) 变化区域检测。变化区域检测是按波段执行的, 首先将低分辨率图像  $\mathbf{M}_1$  和  $\mathbf{M}_2$  进行分块, 分别计算 2 个时刻对应块的结构相似度 (structural similarity, SSIM), 判断是否发生形状变化, 得到变化区域的模, 变化区域的模是一种逻辑图像, 图像中只包含 0 或 1 值。非形状变化区域的模取值为 0, 表现为图 1 中的黑色; 形状变化区域的模取值为 1, 表现为图 1 中的白色。

2) 细节提取。对于非形状变化区域, 使用式(10)提取先验时刻的高分辨率图像的细节, 对于形状变化区域, 使用式(11)提取预测时刻低分辨率图像的细节。

$$\mathbf{S}_1(x, y, b) = \frac{\mathbf{F}_{k-1}(x, y, b)}{\sum_{i=-a}^a \mathbf{F}_{k-1}(x+i, y+i, b)} \quad (10)$$

$$\mathbf{S}_2(x, y, b) = \frac{\mathbf{M}_k(x, y, b)}{\sum_{i=-a}^a \mathbf{M}_k(x+i, y+i, b)} \quad (11)$$

其中:  $\mathbf{F}_{k-1}$  为先验时刻的高分辨率图像;  $\mathbf{M}_k$  为预测时刻的低分辨率图像;  $\mathbf{S}_1$  为从  $\mathbf{F}_{k-1}$  上提取的空间细节;  $\mathbf{S}_2$  为从  $\mathbf{M}_k$  上提取的空间细节;  $x, y$  分别为水平轴和垂直轴坐标;  $b$  为波段;  $a$  为局部范围的大小。




图 1 细节增强模型

细节增强是细节提取的逆过程, 在基于超图学习的多波段联合稀疏表示预测结果的基础上, 通过式(12)对初步预测结果进行细节增强, 进一步提高融合结果。

$$\mathbf{F}_k(x, y, b) = [(1 - \mathbf{M}_{\text{mask}}) \mathbf{S}_1(x, y, b) +$$

$$\mathbf{M}_{\text{mask}} \mathbf{S}_2(x, y, b)] \sum_{i=-s}^s \mathbf{F}_k'(x+i, y+i, b) \quad (12)$$

其中:  $\mathbf{M}_{\text{mask}}$  为区域变化的模;  $\mathbf{F}_k$  为初步预测结果。

### 1.6 算法总体框架

本文算法主要有字典训练和图像重建 2 个阶段,算法流程如图 2 所示。

在字典训练阶段,建立多波段联合字典训练模型,并引入超图约束,利用超图“超边可以连接 2 个及以上的顶点”的特性,关联图像的多个波

段,探索了图像像素之间的复杂关系。

在图像重建阶段,首先利用基于超图的联合稀疏表示模型,预测一个初步结果  $L_2'$ ,再利用细节增强模型获取图像的空间信息,最后将获取的细节信息嵌入到初步预测的结果  $L_2'$  中进行细节增强,获得最终的预测图像  $L_2$ 。




图 2 本文算法流程图

## 2 实验与分析

### 2.1 实验数据和参数设置

为了验证算法的可靠性,本文选择 3 种代表不同场景变化的 Landsat-MODIS 图像数据集,具体如下。

数据集一(BOREAS):该数据集是北方生态系统大气研究南部研究区( $54^{\circ}\text{N}$ ,  $104^{\circ}\text{W}$ )的数据,选取 2001 年 5 月 24 日和 2001 年 8 月 12 日的图像作为研究数据,该研究区植被生长季节短,有着显著的物候变化。

数据集二(CIA):本文选取澳大利亚新南威尔士州地区 2002 年 1 月 11 日和 2 月 12 日的图像作为研究数据,该研究区属于异质性区域,涵盖了许多不同类型作物,兼具物候变化特征。

数据集三(LGC):该数据集同样是澳大利亚新南威尔士州数据,选取 2004 年 11 月 26 日和 12 月 12 日的图像作为研究数据,记录了该时间段内 LGC 洪水泛滥的土地覆盖类型变化。

在本实验中,相关的实验参数设置如下:图像块的大小设为  $5 \times 5$ ;高低分辨率字典大小设置为 128,稀疏重建的效果会随着字典原子数的增大而有一定的提升,但同时也会增加计算的负担; $\lambda_1$  设置为 0.01; $\lambda_2$  设置为 0.01。同时,对比算法的

相关参数按照原文设置。

### 2.2 对比算法

本文选取了 5 种基于一对图像的时空融合算法进行对比实验,分别是 STARFM<sup>[1]</sup>、灵活时空融合(flexible spatiotemporal data fusion, FS-DAF)<sup>[7]</sup>、基于一对图像学习的时空遥感卫星图像融合算法(spatiotemporal satellite image fusion through one-pair image learning, One-pair)<sup>[13]</sup>、快速迭代收缩阈值算法(fast iterative shrinkage thresholding algorithm, FISTA)<sup>[16]</sup>、基于 GAN 的时空融合模型(GAN-based spatiotemporal fusion model, GANSTFM)<sup>[11]</sup>。STARFM 算法是典型的基于加权的算法,该方法提出混合权重由时间差、光谱差和空间距离共同决定,在有效的分辨率下能准确地预测表面反射率,对于物候变化有较好的预测;FS-DAF 算法基于解混和加权的思想,对于地物变化有较好的预测;One-pair 时空融合算法采用高通调制和两层时空融合框架,提高了图像重建的质量,对物候变化和土地覆盖类型变化有较好的预测;FISTA 算法通过利用相邻的精细分辨率图像之间的空间位置相关性来缓解稀疏表示的不稳定性;GANSTFM 算法是首个只需要两幅图像作为模型输入的时空融合模型,相对于其他深度学习算法,减少了模型输入的

数量,并且不限制参考图像的获取时间。

因为 BOREAS 数据集样本过少,无法保证 GANSTFM 算法在该数据集下的正常训练,所以 GANSTFM 算法仅用于 CIA 数据集和 LGC 数据集进行对比实验。

### 2.3 实验结果和分析

为了对各算法融合结果进行评价,本文选取了 6 种评价指标,分别为峰值信噪比(peak signal-to-noise ratio, PSNR)、相关系数(correlation coefficient, CC)、光谱角匹配(spectral angle match, SAM)、相对全局精度误差(error relative global accuracy, ERGAS)、SSIM 和均方根误差(root mean square error, RMSE)。实验结果与分析如下。

1) 实验 1。为了验证本文的超图正则项的有效性,使用 BOREAS 数据集进行实验,对基于稀疏表示的方法分为 2 种情况:① 仅对图像进行稀疏表示重建;② 对图像进行稀疏表示重建时增加超图正则项约束。2 种情况下分别进行图像融合实验,结果见表 1 所列。由表 1 可知,加超图的融合结果较低,其中光谱指标 SAM 得到改善。

由于关联矩阵可以表示超图,并且可以表示像素之间的关系,本文以关联矩阵作为衡量标准,对实验结果进行进一步验证。通过对上述实验得到的重建图像分别构建超图,并使用关联矩阵表示,分别记作  $H_1$ 、 $H_2$ ,记 Landsat 图像的关联矩阵为  $H$ 。分别比较  $H_1$ 、 $H_2$  与  $H$  的相似度,结果如图 3 所示。

表 1 超图消融实验结果

| 方法   | PSNR     | CC      | SAM     | ERGAS   | SSIM    | RMSE    |
|------|----------|---------|---------|---------|---------|---------|
| 不加超图 | 18.391 1 | 0.804 9 | 8.281 0 | 0.231 5 | 0.666 8 | 0.031 3 |
| 加超图  | 18.521 1 | 0.830 2 | 7.921 2 | 0.220 4 | 0.696 3 | 0.029 8 |




图 3 关联矩阵的相似度

在相似度较大的区间中,若图像块数越多,则相似度越大。从图 3 可以看出,增加超图正则项约束预测结果的超图与 Landsat 图像的超图相似性较大,表明超图正则项约束在图像重建时保持

了 Landsat 图像像素之间的关系。

2) 实验 2。为了验证本文细节增强模块的有效性,分别对初步融合结果和加入图像细节增强之后的融合结果进行对比,结果见表 2 所列。

表 2 细节增强消融实验结果

| 方法   | PSNR     | CC      | SAM     | ERGAS   | SSIM    | RMSE    |
|------|----------|---------|---------|---------|---------|---------|
| 初步融合 | 18.521 1 | 0.830 2 | 7.921 2 | 0.220 4 | 0.696 3 | 0.029 8 |
| 最终融合 | 20.196 3 | 0.869 9 | 7.837 2 | 0.208 2 | 0.779 2 | 0.027 6 |

从表 2 可以看出,细节增强后的模块在指标上有了提升,其中光谱指标 SAM 改善幅度较小,而结构指标 SSIM 大幅提升。

3) 实验 3。为了验证本文算法的有效性,分别在 3 个具有代表性的数据集上进行验证,并与

其他算法进行对比实验,实验结果如图 4~图 6 所示,为了更好地对比各实验差异,在左下角添加了局部放大图。

不同数据集下各算法融合结果评价指标见表 3~表 5 所列。




图 4 BOREAS 数据集实验结果




图 5 CIA 数据集实验结果




图 6 LGC 数据集实验结果

表 3 BOREAS 数据集融合结果评价指标

| 算法      | PSNR     | CC      | SAM     | ERGAS   | SSIM    | RMSE    |
|---------|----------|---------|---------|---------|---------|---------|
| STARFM  | 17.802 0 | 0.812 3 | 9.361 1 | 0.252 8 | 0.725 5 | 0.034 0 |
| Onepair | 18.819 1 | 0.832 7 | 8.624 4 | 0.247 5 | 0.735 4 | 0.030 4 |
| FSDAF   | 19.191 8 | 0.846 0 | 8.285 7 | 0.219 1 | 0.756 3 | 0.029 3 |
| FISTA   | 19.199 4 | 0.839 1 | 8.432 4 | 0.215 4 | 0.748 7 | 0.028 9 |
| 本文算法    | 20.196 3 | 0.869 9 | 7.837 2 | 0.208 2 | 0.779 2 | 0.027 6 |

表 4 CIA 数据集融合结果评价指标

| 算法      | PSNR     | CC      | SAM     | ERGAS   | SSIM    | RMSE    |
|---------|----------|---------|---------|---------|---------|---------|
| STARFM  | 16.154 9 | 0.798 3 | 9.449 3 | 0.352 8 | 0.614 2 | 0.041 2 |
| Onepair | 16.805 2 | 0.792 0 | 8.909 3 | 0.337 3 | 0.646 9 | 0.038 9 |
| FSDAF   | 17.105 5 | 0.806 2 | 8.725 0 | 0.329 6 | 0.666 2 | 0.037 8 |
| FISTA   | 17.352 7 | 0.812 8 | 8.511 0 | 0.326 1 | 0.667 1 | 0.036 8 |
| GANSTFM | 17.487 8 | 0.813 2 | 8.554 1 | 0.324 8 | 0.683 7 | 0.033 7 |
| 本文算法    | 18.484 0 | 0.841 6 | 8.171 1 | 0.298 5 | 0.696 9 | 0.033 5 |

表 5 LGC 数据集融合结果评价指标

| 算法      | PSNR     | CC      | SAM      | ERGAS   | SSIM    | RMSE    |
|---------|----------|---------|----------|---------|---------|---------|
| STARFM  | 15.051 5 | 0.690 8 | 12.005 8 | 0.375 9 | 0.464 9 | 0.046 1 |
| Onepair | 15.843 4 | 0.715 9 | 10.321 0 | 0.368 0 | 0.487 2 | 0.041 7 |
| FSDAF   | 15.642 3 | 0.707 0 | 10.803 7 | 0.343 6 | 0.498 4 | 0.042 6 |
| FISTA   | 16.007 6 | 0.719 2 | 10.314 8 | 0.363 8 | 0.498 9 | 0.041 2 |
| GANSTFM | 15.961 7 | 0.722 1 | 10.404 3 | 0.342 5 | 0.506 7 | 0.041 5 |
| 本文算法    | 16.305 7 | 0.741 6 | 9.844 2  | 0.318 7 | 0.518 9 | 0.039 6 |

本文采用 BOREAS 数据集、CIA 数据集和 LGC 数据集分别用来研究物候变化、异质区域变化和类型变化。STARFM 算法采用的是加权的方式,从图 4c 可以看出细节相对其他算法较模糊;Onepair 采用了高通调制与两层融合模型相结合,提高了对空间细节的预测;FSDAF 算法在先验时刻的高分辨率图像中增加预测的变化图像,在数据集中表现良好;FISTA 算法采用了位置正则化引导稀疏系数来缓解系数的不稳定,在数据集的类型变化不剧烈的情况下,细节重建效果较好;GANSTFM 算法利用生成式对抗网络的思想 and 可切换归一化技术,缓解了对参考图像的强时间依赖性,由于输入的减少,也带来了精度的降低;本文算法引入了超图正则化约束波段之间的相关性,并通过细节增强模块对细节进行嵌入,在指标上有一定的提升。

### 3 结 论

基于稀疏表示的时空融合算法通过训练字典对和稀疏编码表示建立粗、细图像之间的关系,为遥感图像的“时空矛盾”提供了一种解决方案。现有的基于稀疏表示的时空融合算法大多是分波段

进行的,导致光谱信息损失较大,并且在遥感图像分辨率差距过大的情况下,稀疏表示算法超出算法的最佳适用范围,导致预测效果不佳。本文从光谱保持的角度出发,将超图引入时空融合,利用“超图可以表达多个像素之间的关系”的特性来约束字典和稀疏系数的求解,从而保持波段之间的相关性。对于算法超出最佳适用范围带来的误差问题,本文通过细节增强模型对预测结果进行增强,从而提高融合精度。本文分别使用 3 组不同场景的实验数据集进行实验,并与其他算法进行对比。实验结果表明,本文算法在光谱信息的保持和空间信息的预测上都表现出一定的优势。

### [参 考 文 献]

- [1] GAO F, MASEK J, SCHWALLER M, et al. On the blending of the Landsat and MODIS surface reflectance: predicting daily Landsat surface reflectance[J]. IEEE Transactions on Geoscience and Remote Sensing, 2006, 44(8): 2207-2218.
- [2] HILKER T, WULDER M A, COOPS N C, et al. A new data fusion model for high spatial and temporal resolution mapping of forest disturbance based on Landsat and MODIS[J]. Remote Sensing of Environment, 2009, 113: 1613-1627.

(下转第 820 页)

## [参 考 文 献]

- [1] 李磊. 基于 ANSYS 的桥梁桩土接触分析[J]. 国防交通工程与技术, 2022, 20(5): 21-23.
  - [2] 胡启军, 蒋晶, 徐亚辉, 等. 红层泥岩桩岩接触面本构模型试验及数值模拟[J]. 土木建筑与环境工程, 2017, 39(3): 122-128.
  - [3] 高晋明. 基于 FLCA3D 的大直径桩竖向承载特性分析[D]. 成都: 西南交通大学, 2018.
  - [4] 中华人民共和国交通运输部. 公路桥涵地基与基础设计规范: JTG 3363—2019[S]. 北京: 人民交通出版社, 2019: 42-43.
  - [5] 国家铁路局. 铁路桥涵地基和基础设计规范: TB 10093—2017[S]. 北京: 中国铁道出版社, 2017: 30-31.
  - [6] 吴顺川. 岩石力学[M]. 北京: 高等教育出版社, 2021: 118-122.
  - [7] 张丹. 重载作用下复杂地层深嵌岩桩桩-岩界面力学特性及竖向承载机理研究[D]. 合肥: 合肥工业大学, 2023.
  - [8] 陈育民, 徐鼎平. FLAC/FLAC3D 基础与工程实例[M]. 北京: 中国水利水电出版社, 2013: 143-144.
  - [9] 莫海鸿. 基础工程实例[M]. 北京: 中国建筑工业出版社, 2020: 111-113.
- (责任编辑 吴 亮)
- 
- (上接第 771 页)
- [3] ZHU X L, CHEN J, GAO F, et al. An enhanced spatial and temporal adaptive reflectance fusion model for complex heterogeneous regions[J]. Remote Sensing of Environment, 2010, 114: 2610-2623.
  - [4] WENG Q H, FU P, GAO F. Generating daily land surface temperature at Landsat resolution by fusing Landsat and MODIS data[J]. Remote Sensing of Environment, 2014, 145: 55-67.
  - [5] WU P H, SHEN H F, ZHANG L P, et al. Integrated fusion of multi-scale polar-orbiting and geostationary satellite observations for the mapping of high spatial and temporal resolution land surface temperature[J]. Remote Sensing of Environment, 2015, 156: 169-181.
  - [6] ZHUKOV B, OERTEL D, LANZL F, et al. Unmixing-based multisensor multiresolution image fusion[J]. IEEE Transactions on Geoscience and Remote Sensing, 1999, 37(3): 1212-1226.
  - [7] ZHU X L, HELMER E H, GAO F, et al. A flexible spatiotemporal method for fusing satellite images with different resolutions[J]. Remote Sensing of Environment, 2016, 172: 165-177.
  - [8] ZURITA-MILLA R, CLEVERS J G P W, SCHAEPMAN M E. Unmixing-based landsat TM and MERIS FR data fusion[J]. IEEE Geoscience and Remote Sensing Letters, 2008, 5(3): 453-457.
  - [9] WU M G, NIU Z. Use of MODIS and Landsat time series data to generate high-resolution temporal synthetic Landsat data using a spatial and temporal reflectance fusion model[J]. Journal of Applied Remote Sensing, 2012, 6(1): 063507.
  - [10] SONG H H, LIU Q S, WANG G J, et al. Spatiotemporal satellite image fusion using deep convolutional neural networks[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2018, 11(3): 821-829.
  - [11] TAN Z Y, GAO M L, LI X H, et al. A flexible reference-insensitive spatiotemporal fusion model for remote sensing images using conditional generative adversarial network[J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 60: 1-13.
  - [12] HUANG B, SONG H H. Spatiotemporal reflectance fusion via sparse representation[J]. IEEE Transactions on Geoscience and Remote Sensing, 2012, 50(10): 3707-3716.
  - [13] SONG H H, HUANG B. Spatiotemporal satellite image fusion through one-pair image learning[J]. IEEE Transactions on Geoscience and Remote Sensing, 2012, 51(4): 1883-1896.
  - [14] WU B, HUANG B, ZHANG L P. An error-bound-regularized sparse coding for spatiotemporal reflectance fusion[J]. IEEE Transactions on Geoscience and Remote Sensing, 2015, 53(12): 6791-6803.
  - [15] WEI J B, WANG L Z, LIU P, et al. Spatiotemporal fusion of remote sensing images with structural sparsity and semi-coupled dictionary learning[J]. Remote Sensing, 2016, 9(1): 21.
  - [16] LIU X, DEN C W, ZHAO B J. Spatiotemporal reflectance fusion based on location regularized sparse representation[C]// 2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS). [S. l.]: IEEE, 2016: 2562-2565.
  - [17] WEI J B, WANG L Z, LIU P, et al. Spatiotemporal fusion of MODIS and Landsat-7 reflectance images via compressed sensing[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(12): 7126-7139.
  - [18] ZHAO C Y, GAO X B, EMERY W J, et al. An integrated spatio-spectral-temporal sparse representation method for fusing remote-sensing images with different resolutions[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(6): 3358-3370.
  - [19] ASEFFPOUR VAKILIAN A, SARADJIAN M R. An object-based sparse representation model for spatiotemporal image fusion[J]. Scientific Reports, 2022, 12(1): 1-14.
  - [20] PENG Y D, LI W S, LUO X B, et al. Spatiotemporal reflectance fusion via tensor sparse representation[J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 60: 5608318.
- (责任编辑 闫杏丽)