

DOI:10.3969/j.issn.1003-5060.2026.04.006

# 基于全局先验和误差补偿的 稀疏表示遥感图像时空融合

方 帅<sup>1,2</sup>, 吴 博<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:** 基于稀疏表示的遥感图像时空融合方法存在 2 个问题: 当低分辨率图像退化严重时, 即使在字典非常理想的前提下, 也无法由低分辨率图像的稀疏表示重建理想的高分辨率图像; 参考日期的高分辨率图像可以帮助细节重建, 但如果预测日期与参考日期场景发生变化, 对局部先验的利用会引入错误。针对上述问题, 文章提出基于全局先验和误差补偿的稀疏表示融合算法。首先, 提出全局跨尺度先验引导的稀疏重建, 利用参考日期高分辨率图像里的相似块对稀疏系数结构进行约束, 构建新的目标函数, 并提出自适应投影策略, 将高、低分辨率图像投影到一个兼顾投影精度和消除二义性的中间尺度上, 进行相似块匹配和相似块权重的确定; 其次, 提出基于稀疏表示的误差估计, 在训练阶段, 利用参考日期高-低分辨率图像对和稀疏重建结果计算高-低分辨率图像误差对, 学习误差字典对, 在预测阶段利用耦合算法估计稀疏系数重建图像误差。实验结果表明: 相较于次优算法, 该算法在 BOREAS 数据集中, 光谱角制图(spectral angle mapper, SAM)提高了 8%, 结构相似性(structural similarity, SSIM)提高了 2%; 在 CIA 数据集中, SAM 提高了 7%, SSIM 提高了 2%; 在 LGC 数据集中, SAM 提高了 8%, SSIM 提高了 4%。文章所提算法在不同的数据集下均有最优的表现, 不仅提升了预测效果, 还具有一定的鲁棒性。

**关键词:** 遥感; 时空融合; 稀疏表示; 全局先验; 误差补偿

**中图分类号:** TP751.1 **文献标志码:** A **文章编号:** 1003-5060(2026)04-0472-10

## Sparse representation for remote sensing image spatiotemporal fusion based on global prior and error compensation

FANG Shuai<sup>1,2</sup>, WU Bo<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 are two problems with spatiotemporal fusion methods for remote sensing images based on sparse representation: one is that when the low-resolution image is severely degraded, it is not possible to reconstruct a desirable high-resolution image from the sparse representation of the low-resolution image, even when the dictionary is highly desirable; the other is that the high-resolution image of the reference date can facilitate detail reconstruction, but if the scene discrepancies occur between the predicted date and the reference date, the utilization of the local prior introduces errors. To address the problem as above, this paper proposes a sparse representation fusion algorithm based on global prior and error compensation. Firstly, the global cross-scale prior guided sparse reconstruction is proposed, the sparse coefficient structure is constrained by using similar blocks in the high-resolution image of the reference date, a new objective function is constructed, and an adaptive projection strategy is proposed to project the high- and low-resolution images onto an intermediate scale that takes into

**收稿日期:** 2023-12-18; **修回日期:** 2024-02-24

**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.

account the projection accuracy and the elimination of the dichotomy, and to carry out the matching of the similar blocks and the determination of the similar block weights. Secondly, sparse representation-based error estimation is proposed to compute high- and low-resolution image error pairs using reference date high- and low-resolution image pairs and sparse reconstruction results in the training stage, learn error dictionary pairs, and estimate sparse coefficients to reconstruct the image error using coupling algorithm in the prediction stage. The experimental results show that compared with the suboptimal algorithm, the algorithm in this paper improves the spectral angle mapper(SAM) by 8% and the structural similarity(SSIM) by 2% on the BOREAS dataset; furthermore, it achieves SAM improvements of 7% and 8%, and SSIM improvements of 2% and 4% on the CIA and LGC datasets, respectively. The proposed algorithm achieves optimal performance across different datasets, which improves the prediction effect and has certain robustness.

**Key words:** remote sensing; spatiotemporal fusion; sparse representation; global prior; error compensation

## 0 引 言

高回访周期和高空间分辨率的卫星遥感数据在实际应用中被广泛需求,尤其在地表信息的动态监测方面<sup>[1]</sup>。由于技术和预算的限制,传感器的空间分辨率与回访周期是相互制约的。因此,单颗卫星无法提供同时具有高空间分辨率和高回访周期(高时间分辨率)的地表信息。为此产生了时空融合技术,该技术将不同卫星源的信息进行融合,即高空间分辨率低时间分辨率图像(简称细图像)与低空间分辨率高时间分辨率图像(简称粗图像)进行融合,生成高空间分辨率高时间分辨率图像。

近年来时空融合方法的研究经历了快速发展,涌现出大量的研究成果。现有的时空融合方法通常可分为基于加权的、基于解混合的、基于稀疏表示的和基于深度学习的4类。

基于加权的方法在滑动窗口根据像素的相关性确定其对目标像素的贡献。最早被提出的时空自适应反射融合模型(spatial and temporal adaptive reflectance fusion model, STARFM)<sup>[2]</sup>依据光谱、空间和时间的相关性确定权重,该方法对同质区域效果不错;接着改进算法反射率变化映射的时空自适应算法(spatial temporal adaptive algorithm for mapping reflectance change, STARARCH)<sup>[3]</sup>和增强型时空自适应反射融合模型(enhanced spatial and temporal adaptive reflectance fusion model, ESTARFM)<sup>[4]</sup>被提出,分别在类型变化区域和异质区域提高了融合精度。这类算法依赖人工设计的权重规则,泛化能力弱且精度不高。

基于解混合的方法<sup>[5]</sup>对参考细图像分类以生成端元并计算丰度,前提假设为整体种类不变、同类光谱相同。但由于场景的复杂性和可变性,类别会发生变化,同类光谱存在很大差异,该类方法的研究主要集中在对“同类光谱相同”假设的突破上。文献[6]实现了局部窗口内同类光谱相同;文献[7]以窗口中心像素为研究对象,实现了每个像素的光谱变化,增加了光谱的动态范围。

基于深度学习的融合模型从大量数据集中提取高质量特征,学习隐含的规则和关系,对粗、细图像之间的复杂非线性关系建模,显著提高了时空融合算法的精度。基于深度卷积神经网络的时空融合(spatiotemporal fusion using deep convolutional neural networks, STFD CNN)<sup>[8]</sup>和增强深度卷积时空融合网络(enhanced deep convolutional spatiotemporal fusion network, EDCST-FN)<sup>[9]</sup>是基于卷积神经网络的方法,较前两类方法提升了预测准确度和图像质量。基于GAN的时空融合模型(GAN-based spatiotemporal fusion model, GANSTFM)<sup>[10]</sup>和文献[11]方法是基于对抗网络的方法,利用判别器提升数据融合网络的精度、收敛速度以及削弱对样本的依赖等。然而,深度学习模型庞大且需要大量的训练样本,时空融合问题需要不同卫星图像在时间上配对,这会受制于回访周期、设备、天气等因素,且大部分模型采用3对粗、细图像训练、2对图像测试,很多情况下无法满足样本需求。

基于稀疏表示的方法首先利用参考日期的粗-细图像对训练低-高分辨率图像耦合字典对,再利用预测日期粗图像的估计稀疏系数重建预测日期细图像。基于稀疏表示的方法虽然也需要训

练,但并不需要目标的真实数据(预测日期细图像)作为样本,只是利用输入数据的一部分(参考日期图像对)进行字典训练。基于稀疏表示的时空融合模型(sparse representation-based spatio-temporal reflectance fusion model, SPSTFM)<sup>[12]</sup>提出了 2 个假设:预测时刻图像字典与先验时刻字典相同;粗图像与细图像的稀疏系数相同。文献[13]即采用类似策略,并使用高通调制进一步提高融合效果。但由于这 2 个假设过于严格,致使该方法融合图像的精度不高。为此,半耦合字典<sup>[14-16]</sup>被提出,将粗-细图像对的稀疏系数相同拓宽为线性一致。文献[14]提出半耦合字典和误差界正则化,允许字典微调稀疏系数线性变化;文献[15]利用系数包含的结构信息,具有单通道图像的聚类一致性和多通道图像的联合一致性,提高了融合结果的鲁棒性。然而,当粗图像与细图像的尺度差异很大时,细图像上的一些细节在粗图像上严重变形或消失,无法通过粗图像重构细图像。快速迭代收缩阈值算法(fast iterative shrinkage-thresholding algorithm, FISTA)<sup>[16]</sup>假设相邻时刻细图像之间具有相似性,利用参考日期细图像提升融合图像细节。但该策略是双刃剑,若相邻时刻场景结构一致,则确实能够丰富重建图像的空间信息;若地物发生了变化,则可能引入错误信息。为此,全局联合字典模型(global joint dictionary model, GJDM)<sup>[17]</sup>提出了局部联合字典和全局联合字典模型,前者重建初步融合结果,后者建立图像块与全局信息之间的关系,构建全局约束模型,降低变化导致的错误。

基于稀疏表示的方法主要从空间维度出发,将时空融合当作是图像超分问题。这类方法具有如下优势:① 基于稀疏表示的方法属于基于学习类方法,在特征级上进行处理,相较于传统算法具

有表征优势和精度优势;② 基于稀疏表示的方法不需要额外的样本训练字典,避免了深度学习面临的样本不足问题;③ 时空融合最大的困难源于场景会随时间发生变化,基于稀疏表示的方法将时空融合转换为图像超分问题,从而将物候变化与土地类型变化区域统一在超分架构下解决。因此,本文采用基于稀疏表示的方法来解决时空融合问题。

## 1 研究问题与动机

基于稀疏表示的时空融合方法存在的问题是:当高、低分辨率图像尺度差异过大时,细图像上的纹理细节在粗图像上严重退化甚至消失,无法通过粗图像的稀疏表示重建细图像精细的细节信息。

基于耦合字典的重建及其误差如图 1 所示。

本文重建部分的实验步骤如下:① 输入粗-细图像对  $I_h$  和  $I_l$ ,通过耦合训练<sup>[12]</sup>得到相同稀疏系数下粗-细图像字典对  $D_h$  和  $D_l$ ;② 再用粗图像  $I_l$  和  $D_l$  作为输入,解得稀疏系数  $\alpha_l$ ;③  $\alpha_l$  与  $D_h$  相乘得到重建细图像  $\hat{I}_h$ 。对比图 1 中真实细图像  $I_h$  与重建细图像  $\hat{I}_h$ , $\hat{I}_h$  非常模糊,因此,即使在字典较理想的情况下(测试图像训练的字典),由于粗、细图像尺度差异过大(本文使用 16 倍差距的 Landsat 和 MODIS 图像),无法重建出高质量的细节。基于稀疏表示的时空融合包含 2 个关键步骤,即字典学习和稀疏重建。由上可知,当粗、细图像尺度差异较大时,稀疏重建的误差更需要关注。

因此,本字典训练采用的是常规方法,工作集中在字典已知情况下的图像重建。主要体现在 2 个方面:① 寻找合适的先验信息引导,提高稀疏系数的求解精度;② 进行误差建模和补偿。

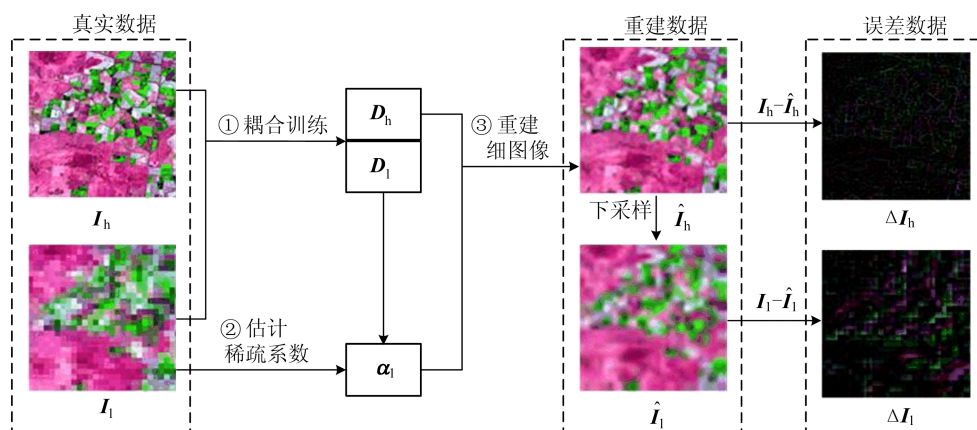


图 1 基于耦合字典的重建及其误差

### 1.1 参考先验的利用及面临的问题

本文在参考日期细图像里,为预测日期粗图像寻找跨尺度相似信息作为约束,提高预测日期细图像质量。因为场景从参考日期到预测日期可能会发生变化,所以不能直接利用对应的局部细图像块,需要在全局寻找跨尺度相似块。尺度带来的二义性对相似块寻找是不能忽视的。

跨尺度相似块二义性的分析如图2所示。从图2可以看出:①单独观察上分支或下分支可知,同一场景图像在不同尺度下呈现的视觉表征不同;②对比观察2个分支可知,在小尺度下具有明显的差异性(如未下采样的原图),随着尺度增大,差异性削弱,在小尺度下表现为明显的圆形和方块,而在大尺度下变得极为相似(如下采样16倍),即若从大尺度图像中找到2个相似的图像块对应到小尺度上可能是完全不同的,表明了




图2 跨尺度相似块二义性的分析

投影满足如下2个条件:①  $(I_h) \downarrow \rightarrow (I_l) \uparrow$ , ②  $((I_h) \downarrow) \uparrow \rightarrow (I_h)$ 。第1个条件表示将2个尺度的图像投影到中间尺度,由于上采样是严重的病态问题,若单纯满足第1个条件,则会倾向于投影到粗图像尺度;第2个条件让下采样的细图像能够被高质量重建,若要达到这个目的,则下采样越少越有利,即会倾向于投影到细图像尺度,这有利于削弱尺度带来的二义性。2个条件互相制衡,让2个图像块尽量投影到小尺度上,有利于二义性削弱,又兼顾可实现性和尺度投影精度。

需要特别说明的是:小尺度指清晰(细)图像;大尺度指模糊(粗)图像;粗、细图像像素个数一样而尺度不一样。

### 1.2 参考日期图像对的附加信息

在基于稀疏表示的时空融合模型中,参考日期粗-细图像对用于训练粗-细图像耦合字典,为重建预测日期细图像做好特征准备。在研究过程中发现,参考日期粗-细图像对还可以用于重建误差建模。

跨尺度相似块具有二义性;③对比观察2个分支的对应中间尺度可知,虽然在大尺度上两者不可区分(如下采样16倍),但在中间尺度上(如下采样4倍)方形和圆形是视觉可分的,下采样16倍后又上采样2倍的图像同样也呈现出视觉可分。通过上述观察,可以将粗、细图像向中间尺度投影,以此削弱尺度带来的二义性。

然而,确定中间尺度是一个重要且困难的任务。首先,由于每个场景和成像条件不同,不存在一个适用于所有粗-细图像对的固定中间尺度;其次,对于具体的粗-细图像对,若中间尺度过小(如逼近细图像),则投影粗图像会变得困难甚至不可能实现,若中间尺度过大(如逼近粗图像),虽然实现容易,但对解决跨尺度相似块的二义性帮助不大。因此,本文提出了尺度自适应的投影策略来解决这个问题。

基于稀疏表示的时空融合认为,在耦合字典下,粗、细图像间的稀疏系数有一致性<sup>[12-13]</sup>、线性一致性<sup>[14-15]</sup>或一定正则项约束下的一致性<sup>[16-17]</sup>。粗、细图像尺度差异越大,依据该假设求解问题带来的误差就越大。而参考日期粗-细图像对尺度差异以及场景的分布与预测日期是基本一致的,可以利用参考日期的重建细图像与参考时刻的真实图像构建误差模型。

基于耦合字典的重建及其误差参见图1。图1中3个虚线框都是粗-细图像对:左边框的粗-细图像对是真实数据;中间框是模型估计出来的细图像及其下采样得到的粗图像,是重建数据;右边框是重建值与真实值之差,是误差数据。本文利用粗-细图像误差对建立误差模型,在预测日期能够测出粗图像的误差,利用误差模型计算细图像误差,进行误差补偿。

### 1.3 本文贡献

1) 为了有效利用先验信息,避免地物发生变化引入错误细节,首先提出全局跨尺度相似块先

验的稀疏重建,利用先验细图像块构建稀疏系数结构损失正则项,以提高稀疏系数的精度;其次提出自适应尺度投影模型,将粗、细图像投影到最合适的中间尺度上,进行全局跨尺度相似块搜寻,以降低尺度带来的二义性。

2) 充分利用参考时刻粗-细图像对,实现基于稀疏表示的误差建模。首先,计算粗-细图像误差对,以此构建误差模型预测重建误差;其次,在误差补偿时引入变化损失一致性约束,关注变化区域的误差,提高融合精度。

## 2 时空融合算法

本文时空融合算法旨在解决当粗、细图像的

空间分辨率差异较大时,缺乏良好局部先验的情况下,无法准确重建细图像的问题。因此,本文选择 Landsat 图像(细图像)和 MODIS 图像(粗图像),两者分辨率相差 16 倍。算法中: $L$  和  $M$  分别表示 Landsat 图像和 MODIS 图像;下标 1 和 2 分别表示  $t_1$  日期(参考日期)和  $t_2$  日期(预测日期);上标  $k$  表示第  $k$  个图像块。

### 2.1 算法整体框架

算法整体框架如图 3 所示。本文算法主要包括 2 个部分:第 1 部分是全局先验引导的稀疏重建;第 2 部分是误差估计与补偿。

图 3 中:虚线下部是字典学习过程;虚线上部是融合过程。

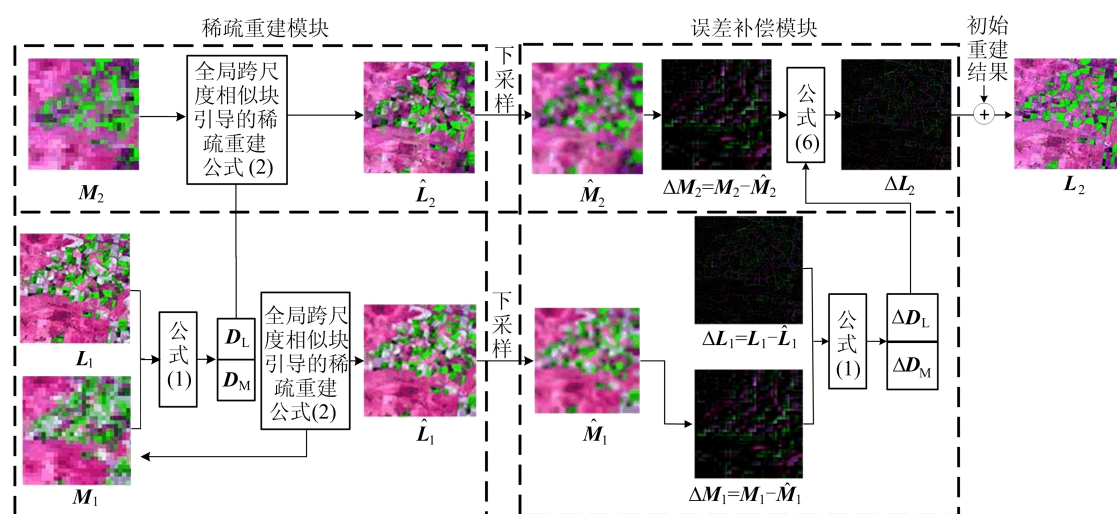


图 3 本文时空融合算法整体框架

### 2.2 字典训练

图像块字典学习采用经典的耦合字典<sup>[12]</sup>。因为图像中存在大量结构相似区域,所以本文采用  $K$ -means 算法对细图像进行聚类,操作都在每一个类中进行。每类的耦合字典训练公式如下:

$$\{D_L, D_M\} = \underset{(D_L, D_M, \alpha)}{\operatorname{argmin}} \left\{ \left\| \begin{bmatrix} L \\ M \end{bmatrix} - \begin{bmatrix} D_L \\ D_M \end{bmatrix} \alpha \right\|_2^2 + \lambda \|\alpha\|_1 \right\} \quad (1)$$

其中: $D_L$ 、 $D_M$  分别为 Landsat、MODIS 的过完备字典; $\alpha$  为共享的稀疏系数。

与此类似,误差补差模型中的字典也使用上述耦合字典方法,训练得到粗-细误差图像字典对  $\Delta D_L$  和  $\Delta D_M$ 。

### 2.3 基于全局先验引导的稀疏重建

从参考日期细图像上寻找跨尺度相似块,作为全局先验构建稀疏系数的结构约束,目标函数如下:

$$\alpha^k = \underset{(\alpha^k)}{\operatorname{argmin}} \left\{ \|M_2^k - D_M \alpha^k\|_2^2 + \|L_{cs}^k - D_L \alpha_{cs}^k\|_2^2 + \lambda_1 \|\operatorname{sgn}(\alpha^k) - \operatorname{sgn}(\alpha_{cs}^k)\|_2^2 + \lambda_2 (\|\alpha^k\|_1 + \|\alpha_{cs}^k\|_1) \right\} \quad (2)$$

其中: $D_L$ 、 $D_M$  为上学习到的耦合字典; $M_2^k$  为  $t_2$  时刻的粗图像块; $L_{cs}^k$  为  $M_2^k$  的跨尺度相似块,其求取在下文详细讲解; $\alpha^k$ 、 $\alpha_{cs}^k$  分别为  $M_2^k$ 、 $L_{cs}^k$  对应的稀疏系数; $\operatorname{sgn}(x)$  为符号函数,当  $x$  为 0 时函数值为 0,大于 0 时为 1,小于 0 时为 -1。式(2)的第 1 项是常规的保真项,第 4 项是全局先验块的稀疏系数约束,第 3 项约束图像块  $M_2^k$  和  $L_{cs}^k$  的稀疏系数结构一致,即系数的零、非零、正和负分布一致。本文通过使用稀疏结构一致性约束,能够重建出更多的图像细节。

全局先验的跨尺度相似块寻找的步骤如下:对于  $t_2$  时刻粗图像块  $M_2^k$ ,将在  $t_1$  时刻粗图像中搜索的  $N$  个相似块  $M_1^i (i=1, 2, \dots, N)$  按坐标投影到  $t_1$  时刻的细图像上,获得  $N$  个跨尺度图像块

$L_i^i (i=1, 2, \dots, N)$ , 这  $N$  个图像块有些并不是  $M_2^k$  的小尺度下的相似块。为了剔除“虚假”相似块, 使用 2 个投影矩阵将粗、细图像投影到中间尺度进行相似判断, 投影矩阵的目标函数表示为:

$$\{P_L, P_M^{-1}\} = \underset{(P_L, P_M^{-1}, Q^{-1})}{\operatorname{argmin}} \{ \|P_L L - P_M^{-1} M\|_2 + \beta \|Q^{-1} P_L L - L\|_2 \} \quad (3)$$

其中:  $L, M$  分别表示细图像块和粗图像块;  $P_L$  为  $L$  的投影矩阵, 令  $L$  向大尺度投影;  $P_M^{-1}, Q^{-1}$  分别为  $M, P_L L$  的反投影矩阵, 将  $M, P_L L$  向小尺度投影。本文使用迭代反投影算法<sup>[18]</sup>求解投影矩阵。式(3)第 1 项保证投影后的粗、细图像特征相似, 第 2 项保证投影后的图像尽量保留更多细节。反投影是严重的病态问题, 因此两项相互制约, 可以自适应地找到一个最优的投影尺度, 既能够保证反投影精度, 又能更好地消除尺度二义性。得到  $P_L$  和  $P_M^{-1}$  后分别将粗、细图像块投影到最优尺度下, 在此尺度求解相似块的权重  $\omega_k$ , 即

$$\omega_k = \arg \min_{\{\omega_k\}} \|P_M^{-1} M_2^k - \sum_{i \in \Omega_k} \omega_{k,i} P_L L_1^i\|_2 \quad (4)$$

其中,  $\Omega_k$  为相似块集合  $L_1^i$  上标索引  $i$  的集合。再构建  $M_2^k$  的小尺度相似块  $L_{cs}^k$ , 公式如下:

$$L_{cs}^k = \sum_{i \in \Omega_k} \omega_{k,i} L_1^i \quad (5)$$

## 2.4 误差补偿

本文利用粗图像和细图像误差对, 训练粗-细误差字典对, 在预测阶段利用耦合算法求解稀疏系数, 估计预测图像误差。为了提高误差补偿的准确性, 防止变化区域引入错误的细节, 增加了变化损失一致性约束, 目标函数如下:

$$\Delta \alpha^k = \arg \min_{\{\Delta \alpha^k\}} \{ \|\Delta M_2^k - \Delta D_M \Delta \alpha^k\|_2 + \eta_1 \|R[(\hat{L}_2^k + \Delta D_L \Delta \alpha^k) - L_1^k] - (M_2^k - M_1^k)\|_2 + \eta_2 \|\Delta \alpha^k\|_1 \} \quad (6)$$

其中:  $\Delta M_2^k$  为  $t_2$  时刻误差粗图像块;  $\Delta \alpha^k$  为其耦合系数;  $M_1^k, M_2^k$  分别为  $t_1, t_2$  时刻的粗图像块;  $L_1^k$  为  $t_1$  时刻的细图像块;  $\hat{L}_2^k$  为上节模型得到的初步重建图像块;  $R$  为下采样矩阵。式(6)中: 第 1 项和第 3 项分别是保真项和系数稀疏正则项; 第 2 项是变化损失一致性约束, 如果预测得正确, 那么相邻细图像差  $L_2 - L_1$  下采样应该趋近于相邻粗图像差  $M_2 - M_1$ , 该约束体现误差补偿对变化区域的关注, 有利于进一步提升重建精度。

## 3 实验与分析

### 3.1 实验数据集

本研究选择了物候变化、异质景观、土地类型

变化 3 种类型的 Landsat-MODIS 数据集场景图像: ① 数据集一 (BOREAS), 该数据集是美国北方生态系统大气研究南部研究区图像, 本文图像选取于 2001 年 5 月 24 日和 8 月 12 日, 该区植被生长季节短, 物候变化明显; ② 数据集二 (CIA), 该数据集采集于澳大利亚新南威尔士州南部灌区, 本文图像选取 2002 年 1 月 11 日和 2 月 12 日, 该区是多种作物灌溉田, 景观具有高度异质性; ③ 数据集三 (LGC), 该数据集采集的区域同样位于澳大利亚新南威尔士州, 本文图像选取于 2004 年 11 月 26 日和 12 月 12 日, 该时间段内发生了洪水, 有土地类型变化。

### 3.2 实验参数设置

本文实验中, 耦合字典的字典原子数为 128, 图像块大小设置为  $5 \times 5$ 。本文算法还设置了一些关键参数: 式(1)中  $\lambda = 0.01$ ; 式(2)中  $\lambda_1 = 0.1, \lambda_2 = 0.01$ ; 式(3)中  $\beta = 0.01$ ; 式(4)和式(5)中在搜索相似块时使用同样大小的图像块, 并以欧式距离为依据, 选前 30 个进行权重的求解; 式(6)中  $\eta_1 = 0.01, \eta_2 = 0.01$ 。

### 3.3 对比算法与评估标准

本文选取 5 种基于一对参考图像的时空融合算法进行对比实验, 分别是 STARFM<sup>[2]</sup>、FISTA<sup>[16]</sup>、柔性时空数据融合算法 (flexible spatio-temporal data fusion, FSDAF)<sup>[19]</sup>、GJDM<sup>[17]</sup> 和 GANSTFM<sup>[10]</sup>。其中, STARFM 是基于加权的方法, FSDAF 是基于解混的方法, FISTA 和 GJDM 是基于稀疏表示的算法, GANSTFM 是基于深度学习的算法。由于 BOREAS 数据集样本过少, 因此在该数据集下未与 GANSTFM 算法进行比较。

为了对各算法融合结果进行评价, 本文选取 6 种评价指标检测融合结果的光谱质量和空间质量, 分别是峰值信噪比 (peak signal to noise ratio, PSNR)、相关系数 (correlation coefficient, CC)、光谱角制图 (spectral angle mapper, SAM)、全局相对误差 (relative dimensionless global error in synthesis, ERGAS)、结构相似性 (structural similarity, SSIM) 和均方根误差 (root mean square error, RMSE)。

### 3.4 对比实验结果与分析

1) 实验 1。为了验证本文全局先验引导稀疏重建模块的有效性, 在 LGC 数据集上与 FISTA 算法进行对比 (未使用误差补偿模块)。FISTA 算法利用参考日期细图像局部先验, 即

对应位置的细图像块作为先验,但是当相邻时刻地物发生变化时可能引入错误信息;而本文利用自适应投影算法在一个中间尺度上进行全局跨尺度相似块搜索,避免了场景变化导致的错误信息引入。因此将本文算法与 FISTA

算法在发生剧烈土地类型变化的 LGC 数据集上进行比较,跨尺度相似块模块的对比实验结果评价指标见表 1 所列。

从表 1 可以看出,本文算法融合结果的各项指标均优于 FISTA 算法。

表 1 跨尺度相似块模块的对比实验结果评价指标

评价指标	PSNR	CC	SAM	ERGAS	SSIM	RMSE
FISTA 算法	15.688 4	0.685 2	10.598 7	0.349 2	0.481 5	0.042 3
本文算法	16.238 6	0.733 6	9.866 2	0.320 7	0.519 0	0.039 9

2) 实验 2。为了验证误差补偿模块的有效性,在其他优化项以及正则化参数一致的情况下,在 CIA 数据集上分析误差补偿模块对融合结果的影响。误差补偿模块的消融实验结果评价指标见表 2 所列。

从表 2 可以看出,进行误差补偿后,各项指标均优于无误差补偿的结果。由于全局跨尺度相似块引导模块的出色效果,该消融实验中误差补偿模块的效果被隐式地削弱了,若在其他算法后面增加误差补偿模块,则可能表现更加出色。

表 2 误差补偿模块的消融实验结果评价指标

评价指标	PSNR	CC	SAM	ERGAS	SSIM	RMSE
误差补偿前	17.707 6	0.818 4	8.362 1	0.318 7	0.690 5	0.035 8
误差补偿后	17.893 8	0.828 1	8.001 5	0.311 7	0.694 5	0.035 1

3) 实验 3。为了验证本文算法的优越性,分别在 3 个具有代表性的数据集上与其他 5 种算法进行对比实验。为了更好地对比各算法的效果差异,在图像左下角添加了局部放大图。

**场景一** BOREAS 数据集实验结果如图 4 所示。从图 4 可以看出,各种算法均能较好地适应物候变化。STARFM 算法采用加权的方式,因此图像比较模糊;FISTA 算法利用局部先验细图像块的稀疏系数作为约束条件,比上述方法更好地保留了先验图像的信息;FSDAF 算法通过解混与加权 2 种方法将时间变化信息加到先验细图像上得到预测结果,因此在光谱预测上表现良好,但细节也接近先验时刻细图像,由此可以看出不精确的先验信息会带来负面影响;GJDM 算法使用相似块全局约束,提升了整体图像的细节;本文算法使用了尺度投影后的跨尺度相似块引导,并进行了误差补偿,从而获得了最佳的整体效果。

**场景二** CIA 数据集实验结果如图 5 所示。从图 5 可以看出;STARFM 算法的加权策略使图像模糊;GANSTFM 算法也使图像呈现模糊,但光谱特征保持较好;FSDAF 算法融合结果由先验图像与预测的变化相加构成;FISTA 算法利用先验细图像为约束,该策略相当于采用了局部先

验约束,因此图像细节上更加锐化;GJDM 算法的全局约束也提升了图像的细节,但如果场景有大的地物变化,那么容易引入错误信息,若尺度差异大,则全局约束相似块精度低;而本文算法可以很好地捕获精确的空间-光谱信息和降低模型误差,从而更有效地处理异构区域。

**场景三** LGC 数据集实验结果如图 6 所示。LGC 数据集 2 个日期的图像发生了剧烈变化,包含土地类型变化和物候变化,整体预测难度变大。由于土地覆盖类型变化很难从输入数据的相似像元中估计出来,STARFM 算法的融合效果较差;由于无法从粗图像中准确地捕捉变化信息,FS-DAF 算法的融合效果也不理想;FISTA 算法在优化过程中使用了参考日期细图像的局部先验信息,导致错误信息被引入;GJDM 算法利用全局相似块约束,融合效果良好,但会受到相似块准确度的影响;GANSTFM 算法的细节表现不佳,但光谱特性表现良好;本文算法通过自适应投影寻找更佳先验图像块引导,并进行了误差补偿。

BOREAS 数据集、CIA 数据集、LGC 数据集的实验结果评价指标分别见表 3、表 4、表 5 所列。从表 3、表 4、表 5 可以看出,本文算法的各项指标均最优。




图 4 BOREAS 数据集实验结果

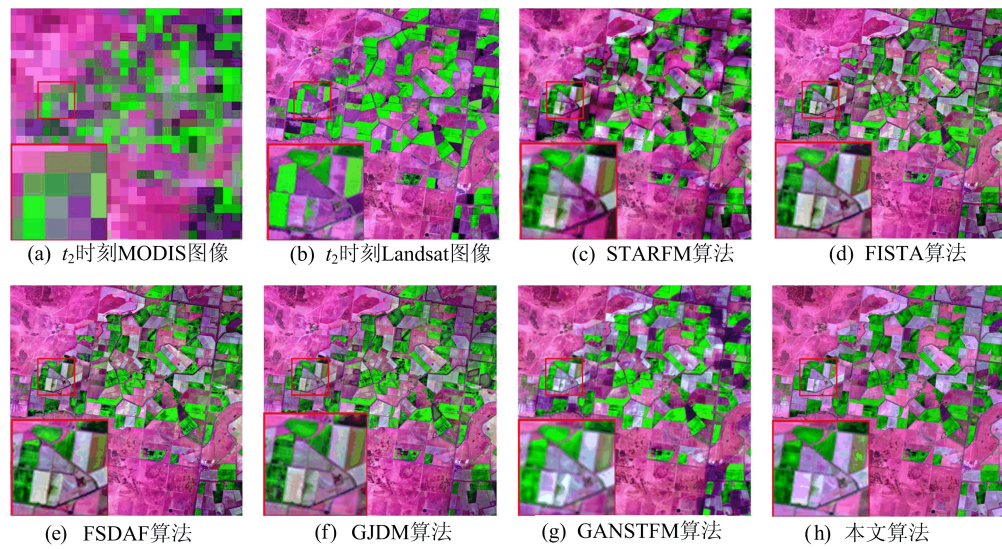


图 5 CIA 数据集实验结果

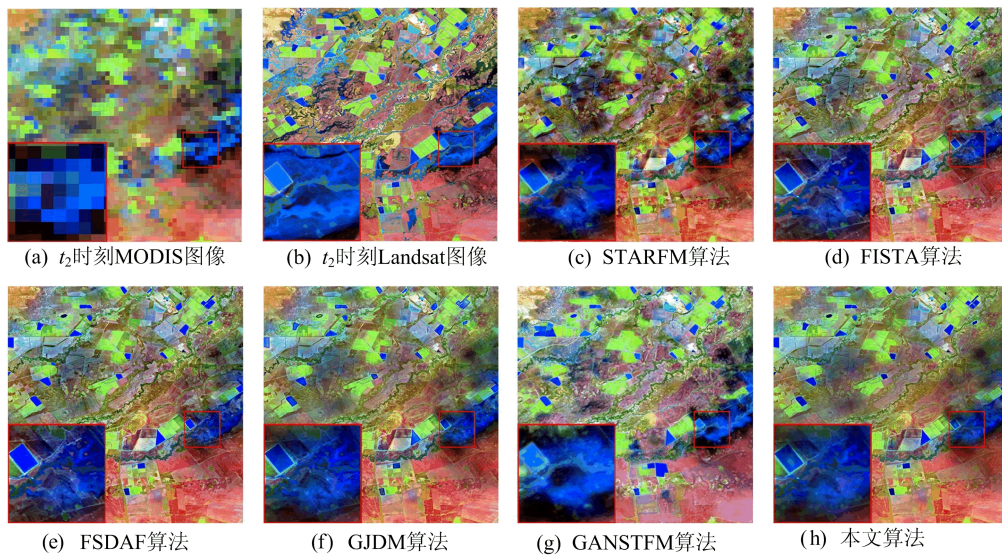


图 6 LGC 数据集实验结果

表 3 BOREAS 数据集实验结果评价指标

算法	PSNR	CC	SAM	ERGAS	SSIM	RMSE
STARFM	17.866 2	0.813 1	9.041 5	0.251 2	0.727 4	0.033 8
FISTA	18.908 1	0.831 2	8.904 2	0.249 9	0.754 7	0.029 9
FSDAF	19.235 6	0.836 1	7.988 7	0.218 5	0.750 3	0.029 1
GJDM	19.429 0	0.844 7	8.321 9	0.216 2	0.766 9	0.028 9
本文	20.004 3	0.862 2	7.693 0	0.209 2	0.783 1	0.027 8

表 4 CIA 数据集实验结果评价指标

算法	PSNR	CC	SAM	ERGAS	SSIM	RMSE
STARFM	16.176 1	0.791 0	9.479 1	0.363 7	0.616 5	0.041 9
FISTA	16.961 3	0.791 0	8.891 2	0.337 9	0.658 7	0.038 6
FSDAF	16.940 4	0.790 0	8.952 1	0.337 8	0.658 4	0.038 7
GJDM	16.982 6	0.791 3	8.769 2	0.332 4	0.664 7	0.037 8
GANSTFM	17.487 8	0.803 2	8.554 1	0.324 8	0.683 7	0.036 7
本文	17.893 8	0.828 1	8.001 5	0.311 7	0.694 5	0.035 1

表 5 LGC 数据集实验结果评价指标

算法	PSNR	CC	SAM	ERGAS	SSIM	RMSE
STARFM	14.716 7	0.687 9	12.634 6	0.390 8	0.458 7	0.047 8
FISTA	15.688 4	0.685 2	10.598 7	0.349 2	0.481 5	0.042 3
FSDAF	15.645 8	0.706 8	10.801 6	0.343 4	0.498 0	0.042 6
GJDM	15.881 8	0.711 4	10.585 1	0.342 1	0.500 5	0.041 6
GANSTFM	15.961 7	0.722 1	10.404 3	0.342 5	0.506 7	0.041 5
本文	16.471 9	0.745 8	9.593 6	0.314 5	0.526 1	0.039 1

## 4 结 论

本文提出了基于稀疏表示框架的遥感图像时空融合算法,该算法包含基于全局跨尺度先验的稀疏重建和重建误差的稀疏估计。全局跨尺度先验有 2 个重要作用:当高低分辨率图像差异过大时,低分辨率图像严重退化,甚至细节丢失,无法通过低分辨率图像的稀疏表示重建高分辨率细节,跨尺度先验对稀疏结构进行约束,有助于细节重建;当参考日期和预测日期场景发生大的变化时,在地物类型发生变化的区域,局部先验会引入错误信息,而全局跨尺度先验在丰富重建细节的同时,能有效避免变化带来的负面影响。跨尺度先验实施的难点在于匹配跨尺度相似块时面临二义性困境,尺度差异越大,二义性越严重,为此本文提出了自适应尺度模型,将大小尺度图像投影到一个兼顾投影精度和消除二义性的中间尺度上。在误差补偿模块中巧妙地构建了误差图像,包括参考日期的误差图像对和预测日期的低分辨率误差图像,参考日期的误差图像对用于生成误差图像字典对,预测日期的低分辨率误差图像用于估计重建误差,进行误差补偿。本文算法在误差估计时引入了变化损失一致性的约束,提高了融合

精度。在 BOREAS、CIA、LGC 这 3 个数据集上的对比实验和消融实验结果证明,本文算法在客观评价指标和主观视觉效果方面都取得了最佳的效果。

## [参 考 文 献]

- [1] LEES K J,QUAIFE T,ARTZ R R E,et al. Potential for using remote sensing to estimate carbon fluxes across northern peatlands; a review[J]. Science of the Total Environment,2018,615:857-874.
- [2] 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.
- [3] 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(8):1613-1627.
- [4] 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(11):2610-2623.
- [5] 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.
- [6] WU M Q, HUANG W J, NIU Z, et al. Generating daily synthetic Landsat imagery by combining Landsat and MODIS data[J]. Sensors, 2015, 15(9): 24002-24025.
- [7] AMORÓS-LÓPEZ J, GÓMEZ-CHOVA L, ALONSO L, et al. Multitemporal fusion of Landsat/TM and ENVISAT/MERIS for crop monitoring [J]. International Journal of Applied Earth Observation and Geoinformation, 2013, 23: 132-141.
- [8] 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.
- [9] TAN Z Y, DI L P, ZHANG M D, et al. An enhanced deep convolutional model for spatiotemporal image fusion[J]. Remote Sensing, 2019, 11(24): 2898.
- [10] 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.
- [11] SONG Y Y, ZHANG H Y, HUANG H, et al. Remote sensing image spatiotemporal fusion via a generative adversarial network with one prior image pair[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-17.
- [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, DENG C W, ZHAO B J. Spatiotemporal reflectance fusion based on location regularized sparse representation [C]//2016 IEEE International Geoscience and Remote Sensing Symposium. [S. l.]: IEEE, 2016: 2562-2565.
- [17] HOU B, ZHOU K, JIAO L C. Adaptive super-resolution for remote sensing images based on sparse representation with global joint dictionary model[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 56(4): 2312-2327.
- [18] IRANI M, PELEG S. Improving resolution by image registration[J]. CVGIP: Graphical Models and Image Processing, 1991, 53(3): 231-239.
- [19] 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.

(责任编辑 胡亚敏)

### (上接第 471 页)

- [16] 张景玲, 冯勤炳, 赵燕伟, 等. 基于强化学习的超启发算法求解有容量车辆路径问题[J]. 计算机集成制造系统, 2020, 26(4): 1118-1129.
- [17] ZHANG F, MEI Y, NGUYEN S, et al. Multitask genetic programming-based generative hyperheuristics: a case study in dynamic scheduling[J]. IEEE Transactions on Cybernetics, 2022, 52(10): 10515-10528.
- [18] 李尚函, 胡蓉, 钱斌, 等. 超启发式遗传算法求解模糊柔性作业车间调度 [J]. 控制理论与应用, 2020, 37(2): 316-330.
- [19] 南丽君, 陈彦如, 张宗成. 改进的自适应大规模邻域搜索算法求解动态需求的混合车辆路径问题[J]. 计算机应用研究, 2021, 38(10): 2926-2934.
- [20] PILLAY N, QU R. Hyper-heuristics: theory and applications[M]. Cham, Switzerland: Springer, 2018.
- [21] CLARKE G, WRIGHT J W. Scheduling of vehicles from a central depot to a number of delivery points[J]. Operations research, 1964, 12(4): 568-581.
- [22] ROBBINS J A, TURNER W C. Cawlip Clark and Wright-Lin interchange program for vehicle routing problems[J]. Computers & Industrial Engineering, 1979, 3(1): 89-100.
- [23] MOLE R H, JAMESON S R. A sequential route-building algorithm employing a generalised savings criterion [J]. Journal of the Operational Research Society, 1976, 27(2): 503-511.
- [24] 胡小建, 杨智. 基于混合遗传算法的多拣货小车路径规划研究[J]. 合肥工业大学学报(自然科学版), 2022, 45(12): 1715-1722.
- [25] UCHOA E, PECIN D, PESSOA A, et al. New benchmark instances for the capacitated vehicle routing problem[J]. European Journal of Operational Research, 2017, 257(3): 845-858.

(责任编辑 胡亚敏)