

引用格式: 平博, 孟云闪, 苏奋振. 面向 GF-1 WFV 数据和 MODIS 数据的时空融合算法对比分析[J]. 地球信息科学学报, 2019, 21(2): 157-167.  
[ Ping B, Meng Y S, Su F Z. Comparisons of spatio-temporal fusion methods for GF-1 WFV and MODIS data[J]. Journal of Geo-information Science, 2019, 21(2): 157-167. ] DOI:10.12082/dqxxkx.2019.180314

# 面向 GF-1 WFV 数据和 MODIS 数据的时空融合算法对比分析

平 博<sup>1</sup>, 孟云闪<sup>2\*</sup>, 苏奋振<sup>3</sup>

1. 天津大学表层地球系统科学研究院, 天津 300072; 2. 国家海洋信息中心, 天津 300171;  
3. 中国科学院地理科学与资源研究所 资源与环境信息系统国家重点实验室, 北京 100101

## Comparisons of Spatio-temporal Fusion Methods for GF-1 WFV and MODIS Data

PING Bo<sup>1</sup>, MENG Yunshan<sup>2\*</sup>, SU Fenzhen<sup>3</sup>

1. Institute of Surface-Earth System Science, Tianjin University, Tianjin 300072, China; 2. National Marine Data and Information Service, Tianjin 300171, China; 3. State Key Laboratory of Resources and Environmental Information system, Institute of Geographic Sciences and Natural Resources Research, Chinese Academy of Sciences, Beijing 100101, China

**Abstract:** Observations with high spatial resolution and frequency can better monitor land surface dynamics, such as urban heat island effect monitoring, normalized difference vegetation index, leaf area index assimilation. However, it is still difficult to acquire satellite data with high spatial and temporal resolution from one single satellite sensor. For example, Landsat TM/ETM+/OLI data at 30 m spatial resolution have been widely applied for various applications, however, their 16-day revisit-cycles limit their usage in dynamics monitoring; on the other hand, MODIS data can be widely used in land process monitoring at global or large-scale because of their daily revisit period, but the coarser spatial resolution of MODIS data cannot meet the fine-scale environment applications. The spatio-temporal fusion is an effective way to solve this trade-off problem. The spatio-temporal fusion methods can be grouped into linear model methods (STARFM, ESTARFM), unmixing methods (FSDAF, STDFA) and so on. These methods have been used to support various applications such as leaf area index assimilation, urban heat island effect monitoring, land surface temperature generating, crop types and dynamics mapping, land cover classification, and land surface water mapping. The GF-1 satellite was launched from China's Jiuquan Satellite Launch Center in April 2013. It carries two panchromatic cameras with pixel resolution of 2 m and two multi-spectral cameras with pixel resolutions of 8 m, and four wide-field view (WFV) cameras with 16 m pixel resolution. The WFV sensors capture ground features with four bands that cover the visible and near-infrared wavelength range and the swath width reaches 800 km when the four sensors are combined. The spatio-temporal fusion researches on GF-1 WFV are still insufficient, hence, in this study, we used four spatio-temporal fusion methods including STARFM, FSDAF, STDFA and Fit\_FC to blend GF-1 WFV and MODIS data, and then the fusion validation and accuracies were analyzed for further researches.

**Key words:** spatio-temporal fusion method; GF-1 WFV; MODIS; STARFM; FSDAF; STDFA

**\*Corresponding author:** MENG Yunshan, E-mail: mengys@lreis.ac.cn

收稿日期: 2018-07-04; 修回日期: 2018-12-10.

基金项目: 天津市自然科学基金项目(18JCQNJC08900); 资源与环境信息系统国家重点实验室开放基金项目。[ **Foundation items:** Natural Science Foundation of Tianjin, No.18JCQNJC08900; State Key Laboratory of Resources and Environmental Information System. ]

作者简介: 平 博(1986-), 男, 天津人, 博士生, 主要从事遥感数据恢复与融合研究。E-mail: pingbo@tju.edu.cn

\*通讯作者: 孟云闪(1986-), 女, 河北石家庄人, 博士, 主要从事海洋数据分析与恢复研究。E-mail: mengys@lreis.ac.cn

**摘要:**对城市热岛效应、植物覆盖指数、叶面积指数等地表参数的高频次高精度反演,能更好地实现基于遥感手段的地表特征动态监测。然而,目前单一数据源的遥感影像还很难实现高时空分辨率数据的同步获取,时空融合技术是解决这个时空分辨率矛盾的有效方法。根据原理不同,时空融合算法可以分为基于线性模型的融合算法、基于光谱解混的融合算法等。高分卫星产品是近几年中国高分辨率对地观测系统重大专项天基系统中的首发星,对于该类数据的时空融合研究仍然较少。因此,本文拟采用4种常见的时空融合算法(STARFM、FSDAF、STDFA、Fit\_FC)实现GF-1 WFV数据与MODIS数据的时空融合,分析这几种方法对GF-1 WFV数据时空融合的有效性和精度,从而为后续的研究提供一定依据。

**关键词:**时空融合算法;高分卫星;MODIS;STARFM;FSDAF;STDFA

## 1 引言

高精度、多时相的获取地表参数,如归一化植被指数(NDVI)等,能够更好实现地表特征的动态监测。然而,目前单一数据源的遥感影像还很难实现高精度、高频次的同步观测。例如,Landsat TM/ETM+/OLI系列卫星数据的空间分辨率为30 m,然而其16 d的重访周期很难监测地表特征的动态变化,而且受到云、传感器性能等因素的限制,获取同一地区连续无云影像的周期可能会更长;MODIS数据能够实现每天1~2次的重访观测,但其较低的空间分辨率(250~1000 m)很难对中小尺度地物进行检测。时空融合算法能够有效解决这个时空分辨率矛盾问题,其是基于已知时期的高频低分数据(如MODIS数据)与高分低频数据(如Landsat数据)以及预测时期的高频低分数据来模拟预测时期的高分低频数据。

基于线性模型的时空融合是重要的时空融合方法。Gao等<sup>[1]</sup>首先提出STARFM(the Spatial and Temporal Adaptive Reflectance Fusion Model),其基本原理是通过已知时期和预测时期的高频低分数据得到反射率值的变化,然后将该变化值加到已知时期的高分低频像元,从而得到相应的预测时期高分低频像元值。为了消除混合像元问题,该方法采用邻域相似像元的加权求和的方式模拟中心像元的反射值,其权重通过光谱差异、时间差异、距离差异的乘积得到。此后,Hilker等<sup>[2]</sup>基于STARFM提出STAARCH算法,以此提高土地覆盖变化区域的模拟精度;Zhu等<sup>[3]</sup>通过加入反转系数,提高了STARFM算法在异质区域的模拟精度。线性模型时空融合算法已经广泛应用于叶面积指数模拟<sup>[4]</sup>、城市热岛效应监测<sup>[5]</sup>、地表温度反演<sup>[6]</sup>、植被类型和长势监测<sup>[7-9]</sup>、地表分类<sup>[10]</sup>、水域监测<sup>[11]</sup>等。近几年,一些新的线性时空融合方法认为在短时期内两景高频低分数据是线性变化的,其系数可以直接应用于相应的高分低频数据,从而实现预测时期高分低

频数据的模拟。2017年,Cheng等<sup>[12]</sup>提出STNLFFM(the Spatial and Temporal Nonlocal Filter-based Fusion Model),其通过已知时期和预测时期的高频低分数据进行线性模型系数的拟合,然后将系数应用于已知时期高分低频数据,并采用邻域相似像元提高融合算法的精度。Wang和Atkinson<sup>[13]</sup>提出Fit\_FC方法,其主要包括3个步骤:①基于高频低分数据模拟线性模型系数;②空间滤波;③残差补偿。

此外,基于光谱解混的时空融合算法也能够有效实现高分低频数据的模拟。Zurita-Milla等<sup>[14]</sup>基于光谱解混方法实现TM和MERIS数据的融合,光谱解混方法首先通过土地覆盖分类数据或图像分类结果计算每一个高频低分数据像元中每一个类别的丰富度,然后基于每一个高频低分数据像元及其邻域的像元,采用最小二乘法模拟中心像元中每一个类别的反射率,即高分数据像元的反射率。Gevaert和Garcia-Haro<sup>[15]</sup>直接对高频低分数据的变化值进行光谱解混,得到每一个类别的变化,继而实现高分数据的模拟。Xie等<sup>[16]</sup>首先采用光谱解混方法对已知时期和预测时期的高频低分数据进行降尺度,然后基于STARFM算法进行高分低频数据模拟。Wu等<sup>[17]</sup>提出STDFA(the Spatial Temporal Data Fusion Approach)方法,其基础是相同类别像元的变化是相同的,随后其提出改进的STDFA算法,将空间变化调整和传感器差异调整加入STDFA算法<sup>[18]</sup>。Zhu等<sup>[19]</sup>提出FSDAF方法使用光谱解混方法计算每一个类别的变化,并将同质与异质区域的误差分别进行计算,通过同质指数将2个误差进行合并,对变化值进行修正,并采用邻域相似像元的处理方式消除“块效应”。光谱解混方法同样广泛应用于NDVI序列模拟<sup>[20-21]</sup>、植被监测<sup>[22]</sup>。

目前,时空融合算法多采用Landsat数据与MODIS、MERIS等数据进行融合,然而对GF-1数据的研究仍然较少。中国于2013年发射了第一颗民用高分辨率卫星高分一号(GF-1),其搭载了2台2 m分辨率全色/8 m分辨率的多光谱相机,4台16 m分

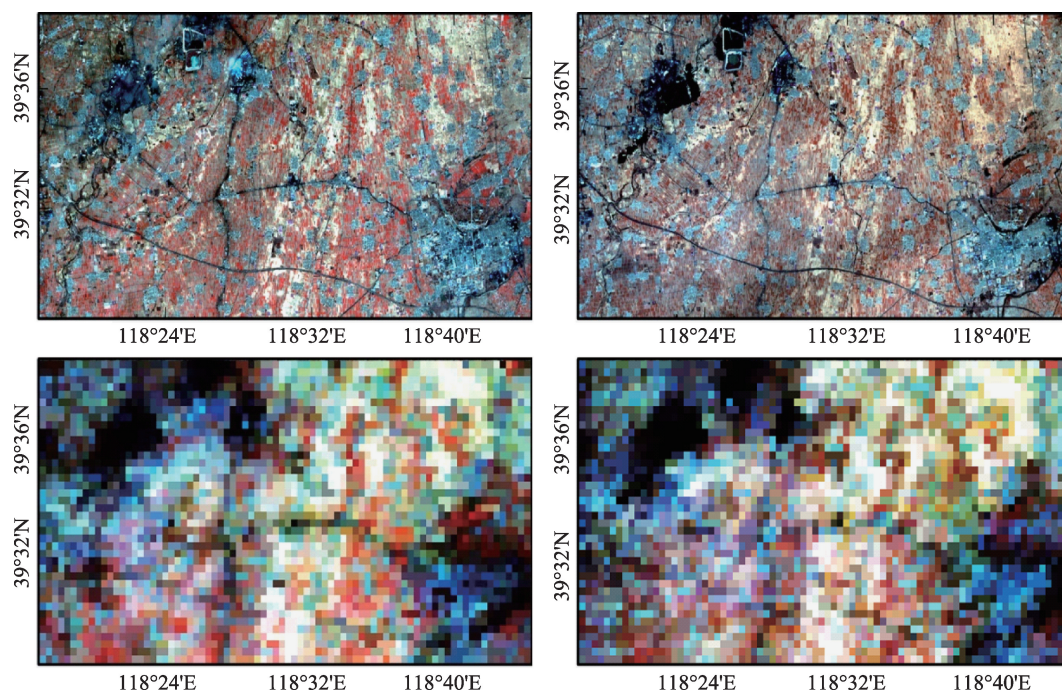
分辨率宽视场多光谱相机(WFV),其中 WFV 传感器的幅宽为 800 km。理论上,GF-1 宽视场相机可实现 4 d 的重复观测,然而受到云的影响,获取连续 2 景无云影像的周期会增大。相比于 Landsat 数据,GF-1 数据与 MODIS 数据的分辨率差异更大,因此时空融合算法对于 GF-1 数据的融合精度有待探讨。本文采用主流的线性模型时空融合方法(STARFM 和 Fit\_FC)和光谱解混时空融合方法(FSDAF 和 STDFA)对 GF-1 数据和 MODIS 数据进行时空融合,分析各算法的融合精度,为后续基于时序 GF-1 数据的应用研究提供科学依据。

## 2 数据源

本文选择 2 个试验区用于算法的对比。① 第 1 个试验区位于中国河北省唐山市南部( $39.46^{\circ}\text{N}$ – $39.64^{\circ}\text{N}$ ,  $118.29^{\circ}\text{E}$ – $118.73^{\circ}\text{E}$ )大约  $19.2\text{ km}\times 38.4\text{ km}$ ( $1200\times 2400$  个 GF-1 像元)的区域,试验区的地貌类型主要是植被,建筑用地,河流湖泊和道路,在 MODIS 尺度下,可以找到相对同质的像元,因此该试验区可以被认为是同质区域(图 1)。2 景 GF-1 WFV 数据分别成像于 2016 年 1 月 6 日和 2016 年 3 月 23 日,相应的 8 d 合成 MODIS 数据(MOD09A1)获

取时间为 2016 年 1 月 1 日和 2016 年 3 月 21 日,其中 1 月 6 日的 GF-1 数据和 1 月 1 日的 MODIS 数据分别作为输入的已知高分低频数据以及高频低分数数据,3 月 21 日的 MODIS 数据作为预测时期的高频低分数数据用来模拟相应时期的高分数据,并将 3 月 23 日的 GF-1 数据作为标准数据,验证时空融合算法的精度。② 第 2 个试验区位于中国天津滨海新区( $38.97^{\circ}\text{N}$ – $39.15^{\circ}\text{N}$ ,  $117.27^{\circ}\text{E}$ – $117.71^{\circ}\text{E}$ )大约为  $19.2\text{ km}\times 38.4\text{ km}$ ( $1200\times 2400$  个 GF-1 像元)的区域,该区域地貌类型复杂,可认为是异质区域(图 2)。2 景 GF-1 WFV 数据分别成像于 2016 年 1 月 6 日和 2016 年 4 月 9 日,相应 8 d 合成 MODIS 数据(MOD09A1)获取时间为 2016 年 1 月 1 日和 2016 年 4 月 6 日,其中 1 月 6 日的 GF-1 数据和 1 月 1 日的 MODIS 数据分别作为输入的已知高分低频数据以及高频低分数数据,4 月 6 日的 MODIS 数据作为预测时期的高频低分数数据来模拟相应时期的高分数据,并将 4 月 9 日的 GF-1 数据作为标准数据,验证时空融合算法精度。

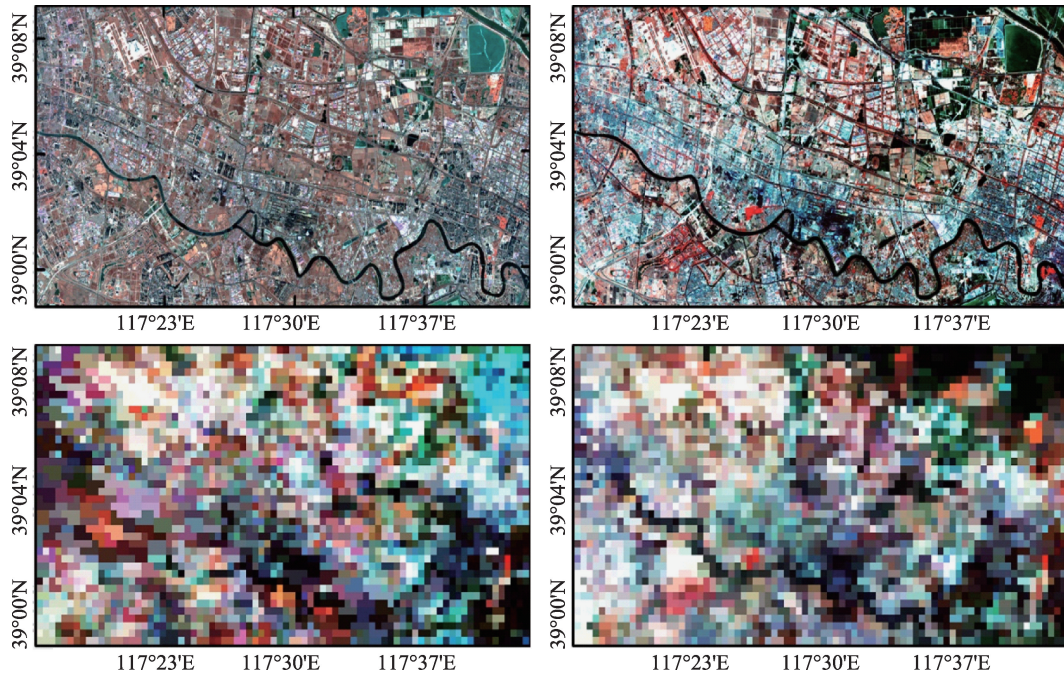
GF-1 数据和 MODIS 数据可以从中国资源卫星应用中心(<http://www.cresda.com/CN/>)和 the NASA EOSDIS Land Processes DAAC, USGS Earth Resources Observation and Science (EROS) Center, Sioux Falls, South Dakota (<https://lpdaac.usgs.gov>)下载。在进行



注:上面 2 景影像分别为 2016 年 1 月 6 日和 2016 年 3 月 23 日的 GF-1WFV 影像,下面为与其成像时期对应的 480 m 分辨率 MODIS 影像。

图 1 试验区 1 的 GF-1WFV 影像和 MODIS 影像(河北省唐山市南部)

Fig. 1 GF-1WFV and MODIS images of experimental site 1 ( Southern Tangshan City, Hebei Province )



注:上面2景影像分别为2016年1月6日和2016年4月9日的GF-1 WFV影像,下面为与其成像时期对应的480 m分辨率MODIS影像。

图2 试验区2的GF-1 WFV影像和MODIS影像(天津滨海新区)

Fig. 2 GF-1 WFV and MODIS images of experimental site 1 (Binhai New Area in Tianjin)

数据融合之前,需要对数据进行预处理。首先使用ENVI 5.1中的辐射校正,大气纠正模块将GF-1数据转换为反射率;使用MODIS Reprojection Tool (MRT)将MODIS数据转换为UTM 50N/WGS84投影和坐标系,并采用最邻近法重采样为480 m和16 m分辨率,最后裁剪到与GF-1数据相同的试验区域。选择GF-1数据的4个多光谱波段和相应的MODIS波段作为实验波段,具体的波段范围如表1所示。

表1 GF-1 WFV和MODIS波段范围

Tab. 1 The band widths of GF-1 WFV and MODIS

	GF-1 WFV 波段范围/ $\mu\text{m}$	MODIS 波段范围/ $\mu\text{m}$
蓝波段	0.450~0.520	0.459~0.479
绿波段	0.520~0.590	0.545~0.565
红波段	0.630~0.690	0.620~0.670
近红波段	0.770~0.890	0.841~0.876

### 3 研究方法

#### 3.1 STARFM算法

STARFM算法认为某一位置的同质像元在高、低分辨率图像上是线性相关的,即:

$$\begin{cases} L(x_i, y_j, t_0) = M(x_i, y_j, t_0) + \varepsilon \\ L(x_i, y_j, t_k) = M(x_i, y_j, t_k) + \varepsilon \end{cases} \quad (1)$$

式中: $x_i, y_j$ 表示某一个同质像元; $t_0$ 和 $t_k$ 分别为预测

时期和已知时期; $L, M$ 分别表示高分低频影像和高频低分影像; $\varepsilon$ 为误差。因此,预测时期高分率像元可以由式(2)求得。

$$L(x_i, y_j, t_0) = M(x_i, y_j, t_0) + L(x_i, y_j, t_k) - M(x_i, y_j, t_k) \quad (2)$$

然而,由于MODIS数据较低的分辨率,很难满足STARFM算法中同质像元的要求。因此,STARFM算法融入邻域相似像元来提高融合算法的精度,即针对预测时期某一个高分率像元,STARFM算法通过式(3)进行模拟。

$$L(x_{\omega/2}, y_{\omega/2}, t_0) = \sum_{i=1}^{\omega} \sum_{j=1}^{\omega} \sum_{k=1}^n W_{ijk} \times (M(x_i, y_j, t_0) + L(x_i, y_j, t_k) - M(x_i, y_j, t_k)) \quad (3)$$

式中: $\omega$ 表示局部窗口的大小,本文中选择与文献[1]相同的策略,即3个MODIS像元为窗口的大小,对应90个GF-1 WFV像元; $(x_{\omega/2}, y_{\omega/2})$ 表示窗口的中心像元,即要模拟的像元位置; $W_{ijk}$ 为相似像元权重; $n$ 表示参与模拟的影像数。

相似像元通过式(4)进行判定:

$$|L(x_i, y_j, t_k) - L(x_{\omega/2}, y_{\omega/2}, t_k)| \leq \sigma / nc \quad (4)$$

式中: $\sigma$ 为影像的标准差; $nc$ 为影像的分类数,本文设定为3类。权重 $W_{ijk}$ 分别通过已知时期高、低分辨率像元的反射率差异(式(5)),已知时期和预测时期低分辨率像元的反射率差异(式(6))以及相似像元与中心像元的距离(式(7))求得。通过式(8)将

3个指标进行合并,得到最终的权重值。

$$S_{ijk} = |L(x_i, y_j, t_k) - M(x_i, y_j, t_k)| \quad (5)$$

$$T_{ijk} = |M(x_i, y_j, t_k) - M(x_i, y_j, t_0)| \quad (6)$$

$$D_{ijk} = 1 + d_{ijk}/A \quad (7)$$

$$W_{ijk} = S_{ijk} \times T_{ijk} \times D_{ijk} \quad (8)$$

式中: $A$ 为一个常量<sup>[1]</sup>;  $d_{ijk} = \sqrt{(x_{\omega/2} - x_i)^2 + (y_{\omega/2} - y_j)^2}$ 。

### 3.2 FSDAF 算法

FSDAF 算法能够较好地对地物类型变化的区域进行预测,其首先基于非监督分类方法对已知时期的高分低频数据进行分类。本文采用 K-means 非监督分类方法并设定分类数为 3 类,然后基于式(9)计算每一个高频低分像元中各个类别的丰富度。

$$f(X, c) = N(X, c)/m \quad (9)$$

式中: $f(X, c)$ 为已知时期高频低分像元  $X$  中类别  $c$  的丰富度; $N(X, c)$ 为像元  $X$  中属于类别  $c$  的高分低频像元的个数; $m$ 为高频低分像元  $X$  中包含高分低频像元的个数。选择各类别中丰富度最高的  $D$  个高频低分像元,本文  $D$  为 30,求出这些高频低分像元在已知时期和预测时期的差异,继而通过最小二乘法拟合出各个类别高分低频像元反射率的变化值。

由于上述算法能够得到主要类别反射率的变化值,但当地物类型在已知时期与预测时期发生变化时,其无法得到准确预测。因此, FSDAF 算法将预测时期的高分低频数据进行三次样条插值,并分析得到同质区域与异质区域的误差,通过同质系数将 2 种误差合并,以此来修正变化值。

最后,为了消除高低分辨率图像融合产生的“块效应”,算法选择邻域相似像元,根据距离赋予相应的权重值,并基于加权求和的方式得到中心点最终的变化值。将变化值加到已知时期的高分低频数据相应像元,得到最终的结果。具体参见文献[19]。

### 3.3 STDFA 算法

STDFA 算法是一类光谱解混方法。该算法首先基于 K-means 对已知时期的高分低频影像进行分类,本文设定为 3 类,并采用式(9)计算每一个高频低分像元中各个类别的丰富度。以某一个高频低分像元为中心确定相应子区域,本文中子区域的大小为 11 个高频低分像元,通过式(10)计算子区域各个类别的平均反射率值,并将该值赋给中心像元内相应类别的高分低频像元。

$$X(t) = \sum_{c=0}^k f(X, c) \times \bar{x}(c, t) \quad (10)$$

$$\text{限制条件: } \sum_{c=0}^k f(X, c) = 1, f(X, c) \geq 0$$

式中: $t$ 表示预测时期与已知时期  $t_0$  和  $t_k$ ;  $\bar{x}(c, t)$ 表示高频低分像元  $X$  中类别  $c$  的反射率平均值; $k$ 为总的类别数。分别计算已知时期和预测时期类别  $c$  的反射率平均值,通过 SRCM (Surface Reflectance Calculation Model), 基于式(11)<sup>[17]</sup>可以得到最终预测时期的高分低频数据。

$$x(c, t_0) = \bar{x}(c, t_0) - \bar{x}(c, t_k) + x(c, t_k) \quad (11)$$

式中: $x(c, t_0)$ 和  $x(c, t_k)$ 分别表示预测时期与已知时期属于类别  $c$  的高分低频像元反射率。

### 3.4 Fit\_FC 算法

Fit\_FC 算法基于线性模型进行数据时空融合,其采用已知时期与预测时期低分高频数据拟合线性系数,然后将该系数应用到已知时期相应的高分低频数据,为了消除分辨率差异较大造成的“块效应”,其基于邻域相似像元分别进行拟合值和误差值的空间平滑。以高频低分像元  $X$  为中心,确定邻域子区域,子区域大小为 5 个高频低分像元,并基于已知时期和预测时期的高分低频数据拟合式(12)中的系数  $a$  和  $b$ 。

$$X(t_0) = a \times X(t_k) + b \quad (12)$$

将系数  $a$  和  $b$  应用于已知时期中心像元  $X$  对应的高分低频像元,即可得到预测的初始高分低频数据。另外,残差值  $R$  能够通过式(13)得到。

$$R = X(t_0) - (a \times X(t_k) + b) \quad (13)$$

为了消除高低分辨率数据融合产生的“块效应”,采用式(14)<sup>[13]</sup>确定以某一个高分低频像元为中心的邻域相似像元。

$$D = \sqrt{\sum_{b=1}^{nb} (x(t_k) - x_{neigh}(t_k))^2 / nb} \quad (14)$$

式中: $nb$ 表示参与计算的波段数; $x(t_k)$ 和  $x_{neigh}(t_k)$ 表示已知时期高分低频中心像元以及其邻域像元。选择最小的  $D$  个高分低频像元作为相似像元,本文  $D$  为 30,根据与中心像元的归一化距离赋予相应的权重。对初始预测的高分低频数据,首先基于相似像元和其权重值,通过加权求和的方式得到中心高分低频像元的初始修正;然后将残差  $R$  进行线性插值,使其分辨率与高分低频数据相同,并基于得到的相似像元和权重再次修正中心高分低频像元的反射率值,从而得到最终的结果。

3.5 精度评定

本文采用相关系数( $r$ )、均方根误差(RMSE)、平均绝对误差(AAD)、结构相似指数(SSIM)和综合性整体误差(ERGAS)5个指标分析4种时空融合算法的精度。

4 实验结果分析

4.1 试验区1结果分析

对实验区1采用4种时空融合方法进行时空融合,其统计结果如表2所示,其中4种方法得到的ERGAS分别为1.6777、1.6772、1.6955和1.3734。从统计分析结果可看出:①对于4个波段,基于STARFM算法得到的融合结果具有最好的相关系数和SSIM,而Fit\_FC算法能够得到较低的RMSE和AAD值;相对而言,对于红波段和近红波段的预测精度要高于对蓝波段和绿波段的预测;②对于4个波段,相比于FSDAF,STDFA和Fit\_FC3种方法,基于STARFM方法得到的结果的相关系数平均提高0.0353、0.0259、0.0826;对于蓝波段和近红波段,SSIM平均提高0.0253、0.0104、0.0381;③对于4个波段,相比于STARFM、FSDAF和STDFA3种方法,基于Fit\_FC方法得到的结果的RMSE和AAD值平均降低0.0078、0.0079、0.0083和0.0087、0.0081、0.0089;对于绿波段和红波段,SSIM平均提高0.0163、0.0342、0.0294。

图3所示为针对试验区1采用4种方法得到的

表2 试验区1统计比较结果

Tab. 2 Statistical Results for site 1

波段	方法	$r$	RMSE	AAD	SSIM
蓝波段	STARFM	0.7238	0.0165	0.0130	0.9040
	FSDAF	0.6980	0.0174	0.0137	0.8912
	STDFA	0.6865	0.0172	0.0135	0.8941
	Fit_FC	0.4758	0.0163	0.0122	0.8321
绿波段	STARFM	0.7841	0.0461	0.0438	0.8194
	FSDAF	0.7434	0.0457	0.0430	0.8022
	STDFA	0.7532	0.0465	0.0440	0.8056
	Fit_FC	0.7474	0.0365	0.0336	0.8428
红波段	STARFM	0.8457	0.0490	0.0460	0.8481
	FSDAF	0.8193	0.0489	0.0453	0.8295
	STDFA	0.8290	0.0494	0.0462	0.8356
	Fit_FC	0.8250	0.0413	0.0376	0.8572
近红波段	STARFM	0.8539	0.0553	0.0511	0.8600
	FSDAF	0.8055	0.0550	0.0496	0.8223
	STDFA	0.8354	0.0555	0.0512	0.8492
	Fit_FC	0.8288	0.0415	0.0358	0.8557

融合结果。从整体上看,4种融合方法都能够较好地得到相应的细节信息,由于Fit\_FC方法是将已知时期与预测时期低分辨率数据拟合的线性系数直接应用于已知时期的高分辨率数据,因此当高、低分辨率的差异较大时,会出现明显的“块效应”(图3(e)),从而可能会失去一些细节信息,另外用于拟合系数的窗口大小对结果也有一定的影响。

图4为图3(a)中黄色框选出的区域放大图,以

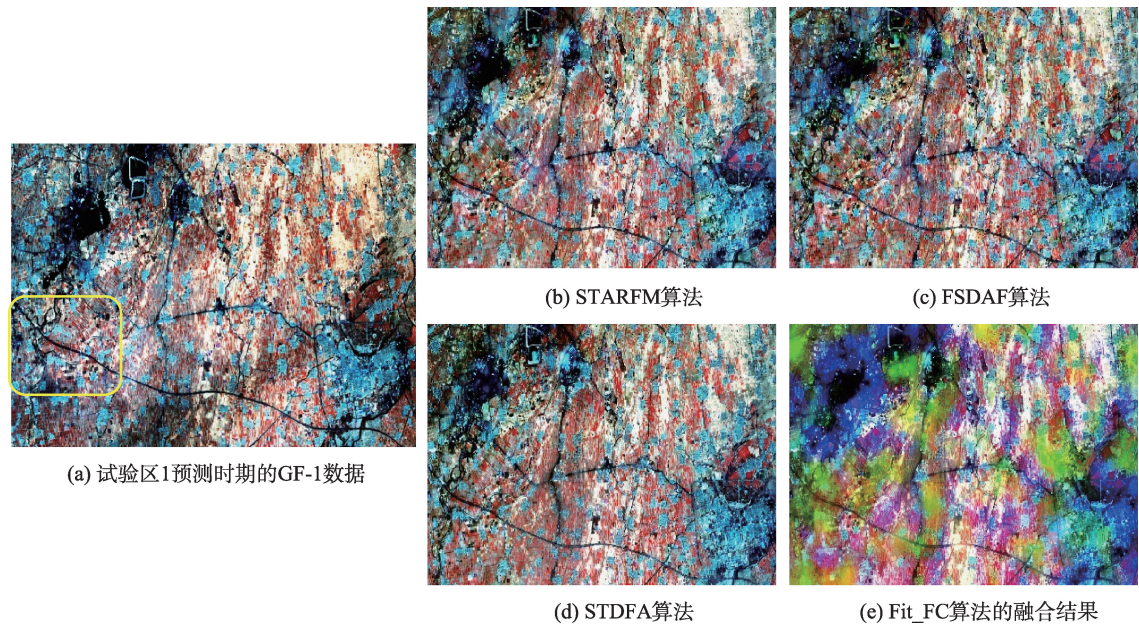


图3 试验区1融合结果

Fig.3 The results for experiment site 1

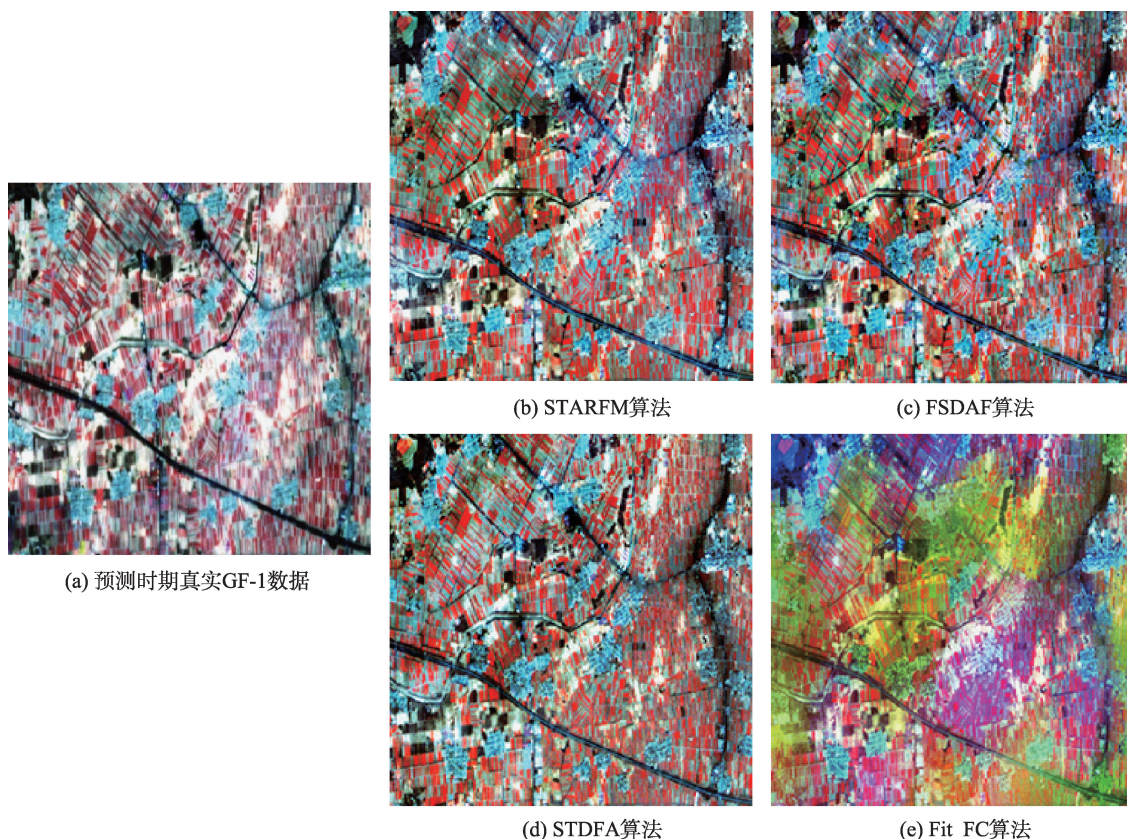


图4 试验区1黄框区域放大对比  
Fig. 4 The area marked by yellow square

及该区域基于4种算法的融合结果。从结果上看,4种融合算法都能够较好的保留空间细节信息,农田、河流、居民地等主要地物的形状和范围都得到较好的反映。

从统计分析和融合图像的视觉比较上可以看到:对于同质区域,基于线性模型和光谱解混的方法都能够得到较为理想的融合结果;对于各个波段,融合图像和真实图像的相关系数在0.7以上,且地物的空间信息能够较好的体现。

由基于4种方法得到的融合结果各个波段预测值与真实值的点分布(图5)可知,4种方法得到的各个波段点分布基本相似。总体而言,对于蓝波段,4种方法得到的融合值与真实值基本沿1:1线分布,而对于其他3个波段,预测值往往要低于真实值,尤其在低反射率值区域,预测值会明显低于真实值。

#### 4.2 试验区2结果分析

对试验区2采用4种时空融合方法进行时空融合,其统计结果如表3所示,其中4种方法得到的ERGAS分别为2.1011、2.2312、2.0764和1.7364。从表3可看出:① STARFM算法能够得到较好的相关

系数,对于蓝波段,STDFA算法能够得到较好的RMSE、AAD和SSIM值,而对于其他3个波段,Fit\_FC算法能够得到比较好的RMSE、AAD和SSIM值;② 对于4个波段,相比于FSDAF,STDFA和Fit\_FC方法,基于STARFM方法得到的融合结果的相关系数平均提高0.0553、0.0278、0.0909;③ 对于绿、红和近红波段,相比于STARFM,FSDAF和STDFA方法,基于Fit\_FC方法得到的融合结果能够平均降低RMSE和AAD值0.0128、0.0165、0.0126和0.0143、0.0141、0.0138。

图6(见第165页)为基于4种时空融合方法对试验区2进行时空融合的结果。从图6可看出,4种融合方法都能对不同地物的空间细节进行融合。但由于分辨率差异和邻域相似像元的选择,造成STARFM算法、FSDAF算法和Fit\_FC算法得到的结果出现了“块效应”,而Fit\_FC算法是将低分高频数据拟合的线性系数直接应用于已知时期的高分低频数据,其“块效应”更加明显。STDFA是针对不同类别进行融合,其“块效应”不明显。

图7(见第165页)为图6(a)黄色框选区域的放

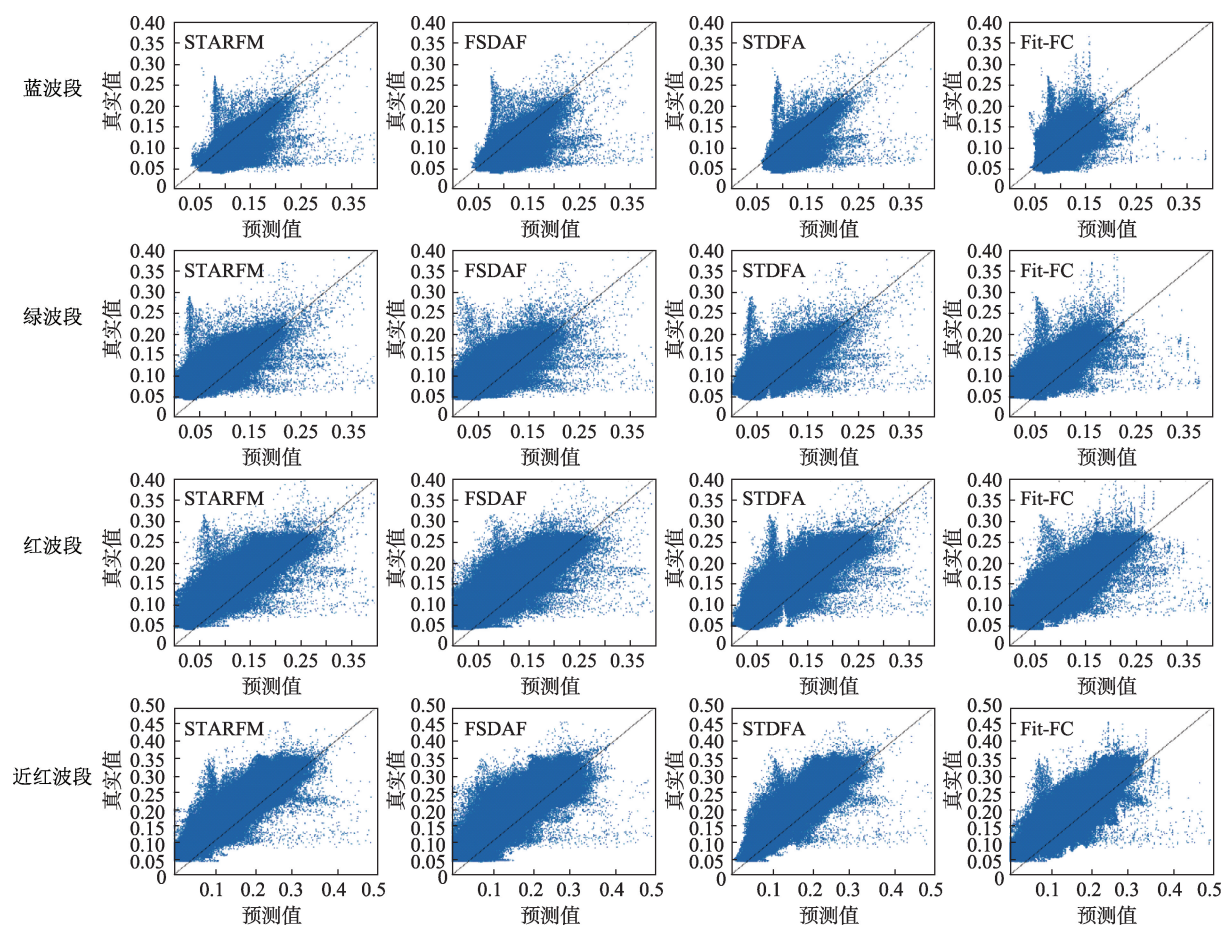


图5 基于4种时空融合算法的各波段预测值与真实值点分布(试验区1)

Fig. 5 Scatter plots of actual and predicted values for the four experimental bands of site 1

表3 试验区2统计比较结果

Tab. 3 Statistical results for site 2

波段	方法	<i>r</i>	<i>RMSE</i>	<i>AAD</i>	<i>SSIM</i>
蓝波段	STARFM	0.8075	0.0214	0.0160	0.8387
	FSDAF	0.7424	0.0230	0.0169	0.8094
	STDFA	0.7985	0.0199	0.0149	0.8468
	Fit_FC	0.6553	0.0324	0.0272	0.7855
绿波段	STARFM	0.8028	0.0586	0.0542	0.7222
	FSDAF	0.7695	0.0597	0.0539	0.6925
	STDFA	0.7791	0.0578	0.0534	0.7158
	Fit_FC	0.7222	0.0416	0.0363	0.7812
红波段	STARFM	0.8133	0.0545	0.0493	0.7698
	FSDAF	0.7423	0.0598	0.0494	0.6840
	STDFA	0.7813	0.0539	0.0485	0.7572
	Fit_FC	0.7451	0.0422	0.0354	0.7833
近红波段	STARFM	0.8298	0.0459	0.0394	0.8210
	FSDAF	0.7780	0.0505	0.0388	0.7563
	STDFA	0.7832	0.0465	0.0394	0.7940
	Fit_FC	0.7671	0.0367	0.0282	0.8002

大图,以及相应区域4种算法的融合结果。从图7可看出,4种方法都能够得到较好的细节信息,但STARFM算法,FSDAF算法以及Fit\_FC算法都会出现一定的平滑现象,这可能是由于这3种方法都需要基于邻域像元进行局部加权运算。另外,对于异质区域的融合,其平滑现象要比对同质区域的融合更加明显。STDFA方法只是针对类别进行计算,因此,其平滑现象不明显。相比于Landsat 30 m数据,GF-1 WFV数据与MODIS数据的分辨率差异更大,因此这种局部平滑现象可能会对GF-1 WFV数据与MODIS数据的融合影响更大。

图8(见第166页)为基于4种方法得到的融合结果各个波段预测值与真实值的点分布。如图8所示,4种方法得到的各个波段点分布基本相似。总体而言,虽然预测值与真实值大致均匀分布在1:1线的两侧,但相比于试验区1的融合结果,试验区2的精度较低,具体表现在中低反射率值区域,预测值要低于真实值,而在高反射率值区域,预测值往

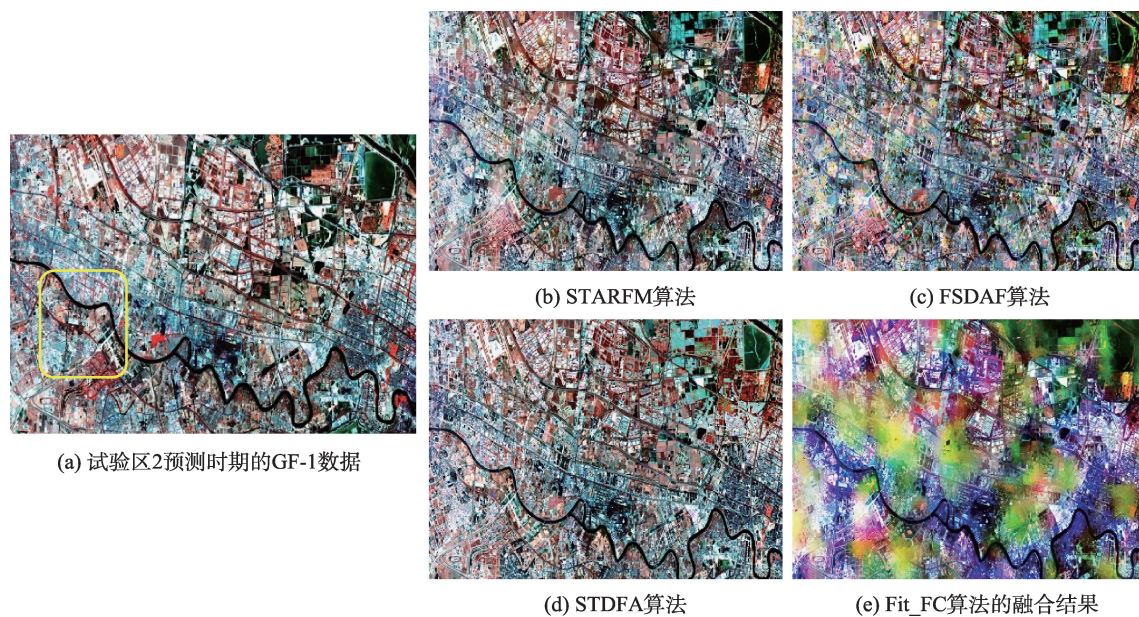


图6 试验区2融合结果

Fig. 6 The results for experiment site 2

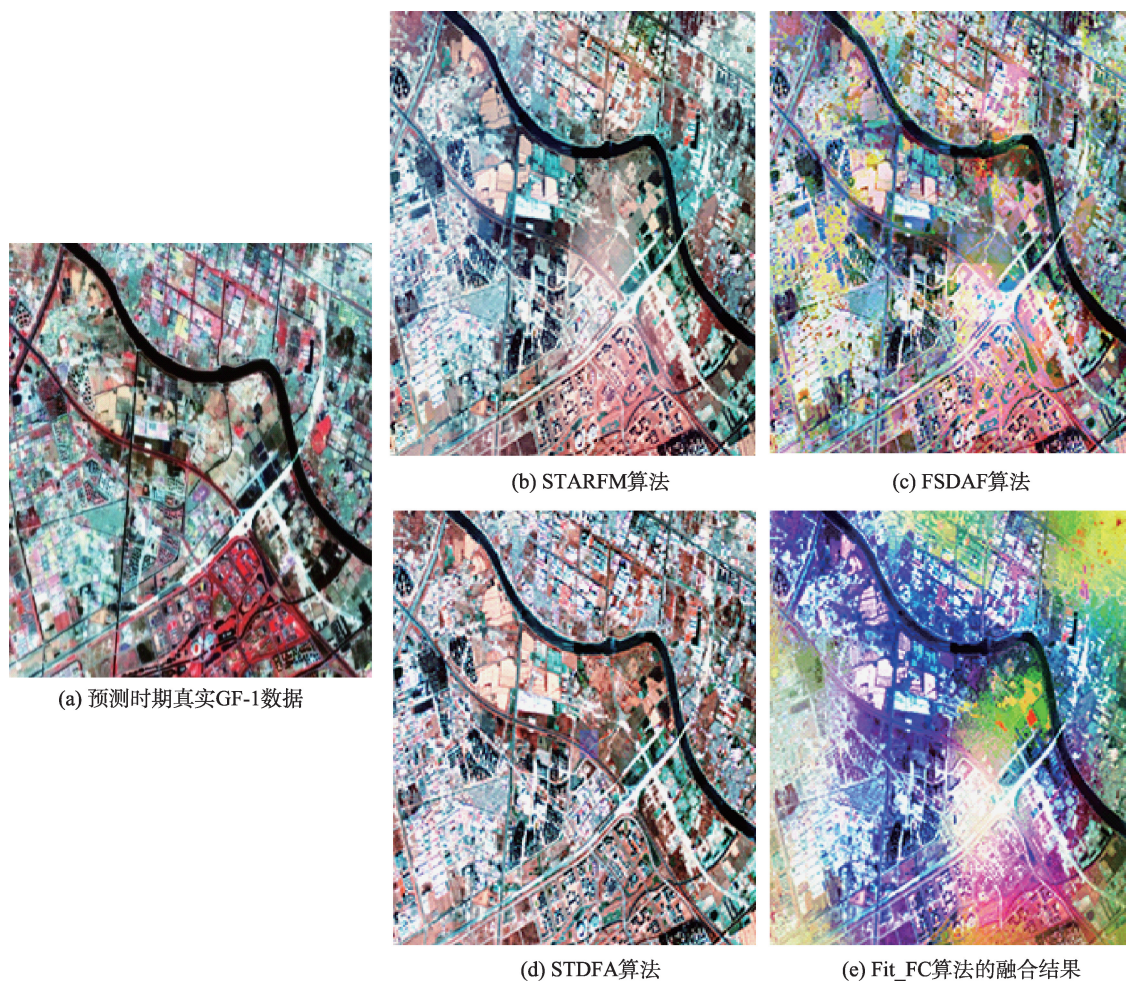


图7 试验区2黄框区域放大对比

Fig. 7 The area marked by yellow square

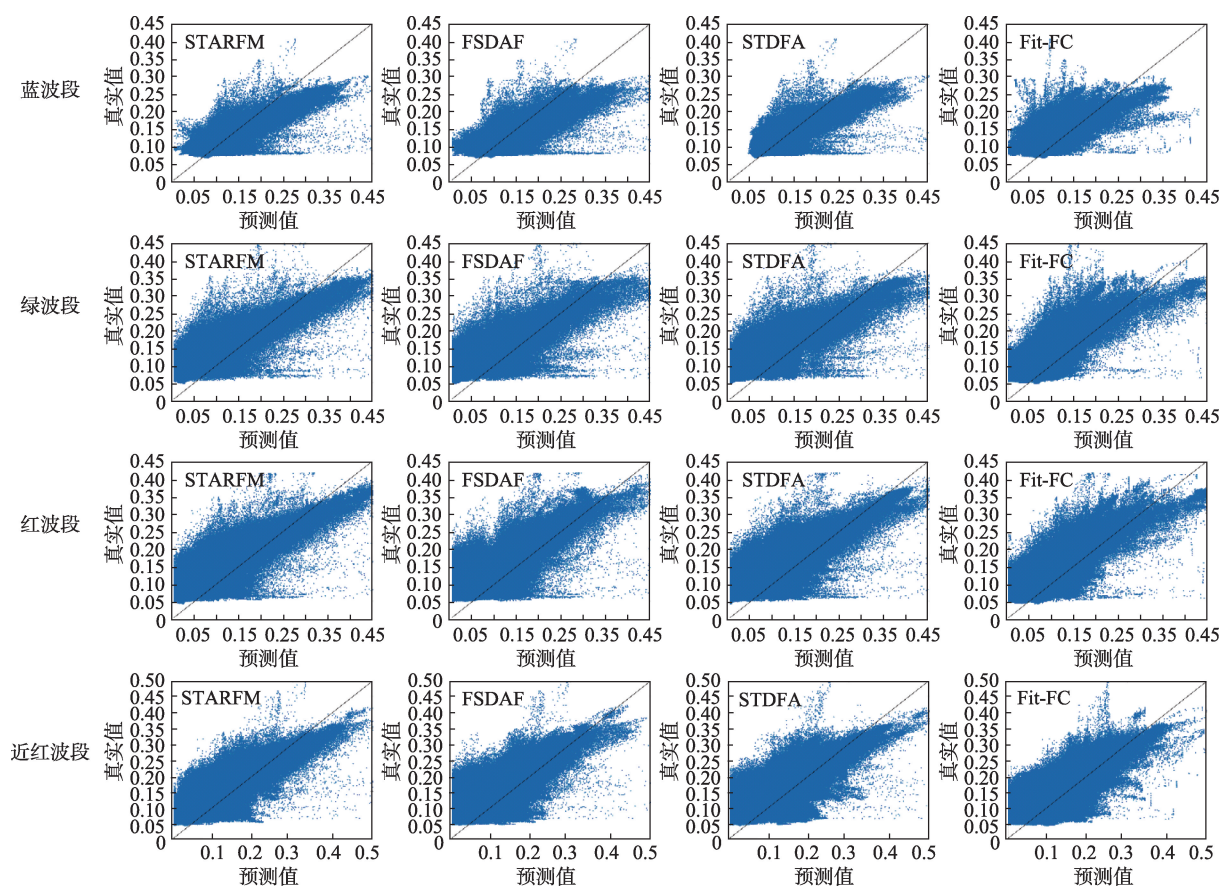


图8 基于4种时空融合算法的各波段预测值与真实值点分布(试验区2)

Fig. 8 Scatter plots of actual and predicted values for the four experimental bands of site 2

往又要高于真实值。由于试验区2可看作是异质区域,因此与以往研究类似,其融合精度要低于同质区域的融合。

## 5 讨论

通过对2个试验区的融合可以看到,基于解混方法(FSDAF和STDFA)的时空融合算法的精度较低,这主要由2个方面造成:①其都需要首先对已知时期的高分低频数据进行分类,而非监督分类方法(如K-means方法)的分类精度会对这2种算法造成一定影响;②当高分低频数据与高频低分数数据的分辨率差异较大时,每一个端元(即高分低频像元)所代表的区域会更加精细,当分类数较少时,会造成融合的平滑,而当分类数较多时,也会造成拟合精度的降低(如在高频低分像元中,如某一个类别的丰富度很低,会增大拟合误差)。

STARFM和Fit\_FC方法都是在像元尺度进行时空融合,STARFM算法需要将已知时期和预测时

期的高频低分数数据进行重采样。而Fit\_FC方法将已知时期和预测时期的高频低分数数据进行拟合,并将拟合系数应用于高分低频数据,因此,GF-1 WFV和MODIS数据较大的分辨率差异会造成Fit\_FC算法的结果出现明显的“块效应”。

从2个试验区预测值与真实值点分布图可看出,4种方法对于异质区域的融合效果要低于对同质区域的融合,这与以往的研究结果类似。在低反射率区域,预测值往往要低于真实值,而对于同质区域,其高反射率区域的融合值与真实值基本沿1:1线均匀分布,对于异质区域,其高反射率区域的融合值要高于真实值。

## 6 结论

本论文基于4种主流的时空融合算法(STARFM,FSDAF,STDFA和Fit\_FC)对GF-1数据和MODIS数据进行时空融合,分析4种算法对GF-1数据时空融合的有效性,为后续基于国产卫星数据

进行时序研究提供数据支持。从统计结果看, STARFM算法在4个波段能够取得较好的相关系数值,而大部分情况下Fit\_FC方法能够取得较好的RMSE和AAD值。图像分析表明4种方法都能较好地实现GF-1数据的预测,但受到拟合窗口,分类数,高低分辨率影像分辨率差异较大等因素的影响,Fit\_FC方法有一些过平滑现象。

下一步将主要集中于对不同地形,已知时期与预测时期间隔较大等情况时,时空融合算法对GF-1数据的融合有效性进行研究。

#### 参考文献(References):

- [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(8):1613-1627.
- [2] 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.
- [4] Dong T F, Liu J G, Qian B D, et al. Estimating winter wheat biomass by assimilating leaf area index derived from fusion of Landsat-8 and MODIS data[J]. International Journal of Applied Earth Observation and Geoinformation, 2016,49:63-74.
- [5] Shen H F, Huang L W, Zhang L P, et al. Long-term and fine-scale satellite monitoring of the urban heat island effect by the fusion of multi-temporal and multi-sensor remote sensed data: A 26-year case study of the city of Wuhan in China[J]. Remote Sensing of Environment, 2016,172:109-125.
- [6] 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.
- [7] Zhu L K, Radeloff V C, Ives A R. Improving the mapping of crop types in the Midwestern US by fusing Landsat and MODIS satellite data[J]. International Journal of Applied Earth Observation and Geoinformation, 2017,58:1-11.
- [8] Gao F, Hilker T, Zhu X, et al. Fusing Landsat and MODIS data for vegetation monitoring[J]. IEEE Geoscience and Remote Sensing Magazine, 2015,3(3):47-60.
- [9] Gao F, Anderson M C, Zhang X Y, et al. Toward mapping crop progress at field scales through fusion of Landsat and MODIS imagery[J]. Remote Sensing of Environment, 2017,188:9-25.
- [10] Kong F J, Li X B, Wang H, et al. Land cover classification based on fused data from GF-1 and MODIS NDVI time series[J]. Remote Sensing, 2016,8(9):741.
- [11] Huang C, Chen Y, Zhang S Q, et al. Surface water mapping from Suomi NPP-VIIRS imagery at 30m resolution via blending with Landsat data[J]. Remote Sensing, 2016,8:631.
- [12] Cheng Q, Liu H Q, Shen H F, et al. A spatial and temporal nonlocal filter-based data fusion method[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017,55(8):4476-4488.
- [13] Wang Q M, Atkinson P M. Spatio-temporal fusion for daily Sentinel-2 images[J]. Remote Sensing of Environment, 2018,204:31-42.
- [14] Zurita-Milla R, Kaiser G, Clevers J G P W, et al. Downscaling time series of MERIS full resolution data to monitor vegetation seasonal dynamics[J]. Remote Sensing of Environment, 2009,113(9):1874-1885.
- [15] Gevaert C M, Garcia-Haro F J. A comparison of STARFM and an unmixing-based algorithm for Landsat and MODIS data fusion[J]. Remote Sensing of Environment, 2015,156:34-44.
- [16] Xie D F, Zhang J S, Zhu X F, et al. An improved STARFM with help of an unmixing-based method to generate high spatial and temporal resolution remote sensing data in complex heterogeneous regions[J]. Sensors, 2016,16(207):1-19.
- [17] Wu M Q, Niu Z, Wang C Y, et al. 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, 2012,6:063507(1-13).
- [18] Wu M Q, Wu C Y, Huang W J, et al. An improved high spatial and temporal data fusion approach for combining Landsat and MODIS data to generate daily synthetic Landsat imagery[J]. Information Fusion, 2016,31:14-25.
- [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.
- [20] Rao Y H, Zhu X L, Chen J, et al. An improved method for producing high spatial-resolution NDVI time series datasets with multi-temporal MODIS NDVI data and Landsat TM/ETM plus images[J]. Remote Sensing, 2015, 7(6):7865-7891.
- [21] Wu M Q, Huang W J, Niu Z, et al. Validation of synthetic daily Landsat NDVI time series data generated by the improved spatial and temporal data fusion approach[J]. Information Fusion, 2018,40:34-44.
- [22] Amoros-Lopez J, Gomez-Chova L, Alonso L, et al. Multi-temporal fusion of Landsat/TM and ENVISAT/MERIS for crop monitoring[J]. International Journal of Applied Earth Observation and Geo-information, 2013,23:132-141.