

基于STFCNN时空融合与VPM模型的农田总初级生产力反演研究

马佳妮¹ 解毅¹ 蔡兴冉¹ 项麦祺¹ 张超² 张茜³

(1. 山西师范大学地理科学学院, 太原 030031; 2. 中国农业大学土地科学与技术学院, 北京 100193;
3. 韩城市农业技术推广中心, 渭南 715400)

摘要: 针对 MODIS GPP 产品空间分辨率较低、难以满足农田尺度生态系统生产力精细化监测需求问题,以山西省寿阳县玉米种植区为研究对象,利用 2014—2015 年生长季 MODIS 和 Landsat 8 遥感数据,构建基于深度卷积神经网络的时空融合模型(Supervised-training fully-connected neural network, STFCNN),实现增强型植被指数(EVI)和地表水分指数(LSWI)的高时空分辨率重建,并以融合后植被指数驱动植被光合作用模型(Vegetation photosynthesis model, VPM)开展 GPP 反演。采用均方根误差(RMSE)、决定系数(R^2)、结构相似性指数(SSIM)、通用图像质量指数(UIQI)、光谱角映射(SAM)和全局相对误差(ERGAS)等指标,比较了 STFCNN 与 STARFM、ESTARFM、FSDAF 和 STNLFM 模型的融合性能,并利用涡度相关观测数据验证模型反演结果。结果表明:在 EVI 和 LSWI 时空融合中,STFCNN 均表现出最佳的融合精度。EVI 融合 RMSE 为 0.02~0.09, R^2 为 0.70~0.95, UIQI 为 0.82~0.98; LSWI 融合 RMSE 为 0.024~0.046, R^2 为 0.54~0.88, 整体优于其他模型。空间细节与散点分析表明,STFCNN 能够有效保持农田边界和纹理结构信息,融合结果与真实 Landsat 影像具有较高一致性,像元级验证获得 R^2 为 0.985、RMSE 为 0.003, 表现出最优的光谱重建能力和空间细节恢复能力。基于融合影像驱动 VPM 模型反演 GPP, 与实测 GPP 相比,反演结果 R^2 由 MODIS GPP 产品的 0.168 2 提高至 0.345 2, 对植被生长旺盛期光合作用变化的响应能力明显增强,更准确地表征农田 GPP 时空变化。寿阳县 2014—2015 年 GPP 总体呈“西北部高、东南部低”的空间分布格局,平均 GPP 为 585~827 gC/m²。研究结果表明,STFCNN 能够充分融合 MODIS 数据的高时间分辨率和 Landsat 数据的高空间分辨率优势,可为区域农业生态系统生产力监测和碳循环研究提供高时空分辨率数据支撑。

关键词: 时空融合; STFCNN; GPP 反演; 寿阳县

中图分类号: S18 文献标识码: A 文章编号: 1000-1298(2026)20-0021-10 OSID: 

Inversion of Total Primary Productivity of Farmland Based on STFCNN Spatiotemporal Fusion and VPM Model

Ma Jiani¹ Xie Yi¹ Cai Xingran¹ Xiang Maiqi¹ Zhang Chao² Zhang Qian³

(1. College of Geographical Sciences, Shanxi Normal University, Taiyuan 030031, China
2. College of Land Science and Technology, China Agricultural University, Beijing 100193, China
3. Hancheng Agricultural Technology Extension Center, Weinan 715400, China)

Abstract: Aiming to address the issue of low spatial resolution in MODIS GPP products, which makes it difficult to meet the needs of refined monitoring of ecosystem productivity at the farmland scale, focusing on a maize-growing area in Shouyang County, Shanxi Province, the MODIS and Landsat 8 remote sensing data from the 2014—2015 growing season was used, a supervised-training fully-connected neural network (STFCNN) was constructed to achieve high spatiotemporal resolution reconstruction of the enhanced vegetation index (EVI) and surface water index (LSWI). The fused vegetation index was then used to drive a vegetation photosynthesis model (VPM) for GPP inversion. The fusion performance of

收稿日期: 2026-07-01 修回日期: 2026-07-18

基金项目: 山西省基础研究计划项目(202303021222181、202303021222184、202203021222226)和山西省回国留学人员科研资助项目(2023-109)

作者简介: 马佳妮(1993—),女,讲师,博士,主要从事土地遥感监测研究,E-mail: mjn@sxnu.edu.cn

通信作者: 张超(1984—),男,教授,博士,主要从事土地信息研究,E-mail: zhangchaobj@cau.edu.cn

STFCNN with STARFM, ESTARFM, FSDAF, and STNLFFM models was compared using indicators such as root mean square error (RMSE), coefficient of determination (R^2), structural similarity index (SSIM), universal image quality index (UIQI), spectral angle mapping (SAM), and global relative error (ERGAS). Eddy covariance observation data were used to verify the model inversion results. The results showed that STFCNN exhibited the best fusion accuracy in both EVI and LSWI spatiotemporal fusion. The RMSE of EVI fusion was 0.02 ~ 0.09, R^2 was 0.70 ~ 0.95, and UIQI was 0.82 ~ 0.98; the RMSE of LSWI fusion was 0.024 ~ 0.046, and R^2 was 0.54 ~ 0.88, which was better than that of other models overall. Spatial detail comparison and scatter analysis showed that STFCNN can effectively preserve farmland boundary and texture structure information. Its fusion results had high consistency with real Landsat images. Pixel-level verification yielded R^2 of 0.985 and RMSE of 0.003, showing the best spectral reconstruction ability and spatial detail recovery ability. Based on the fusion image-driven VPM model, the correlation of the inverted GPP with the measured GPP was increased from 0.168 2 in the MODIS GPP product to 0.345 2, which significantly enhanced the response to changes in photosynthesis during the peak vegetation growth period and more accurately characterized the spatiotemporal changes of farmland GPP. The GPP of Shouyang County in 2014—2015 generally showed a spatial distribution pattern of “high in the northwest and low in the southeast”, with an average GPP range of 585 ~ 827 gC/m². The result showed that STFCNN can fully integrate the high temporal resolution advantage of MODIS data and the high spatial resolution advantage of Landsat data, and can provide high spatiotemporal resolution data support for regional agricultural ecosystem productivity monitoring and carbon cycle research.

Key words: spatiotemporal fusion; STFCNN; GPP inversion; Shouyang County

0 引言

总初级生产力(Gross primary productivity, GPP)能够直接反映作物通过光合作用固定大气二氧化碳的能力,是衡量农田生态系统生产力、碳汇能力和生态功能的重要指标^[1-2]。近年来,随着全球碳循环研究和精准农业监测需求的不断增加,获取高时空分辨率 GPP 产品已成为遥感生态学领域的重要研究方向^[3]。目前广泛应用的 MODIS GPP 产品能够实现连续时间序列监测,但空间分辨率通常为 500 m 甚至 1 km,难以准确表征农田生态系统内部复杂的空间异质性,特别是在地块尺度下容易受到混合像元效应的影响,导致 GPP 估算精度下降。因此,提高 GPP 产品的空间分辨率已成为当前生态遥感研究的重要前沿问题之一^[4]。

针对这一问题,国内外学者主要从 3 个方面开展研究。①利用高空间分辨率遥感数据直接驱动光能利用率模型或机器学习模型进行 GPP 估算。例如利用 Landsat、Sentinel-2 等数据构建高分辨率植被指数并结合 VPM (Vegetation photosynthesis model)、CASA 等模型进行 GPP 反演^[5-6],能够获得较高的空间分辨率,但受限于卫星重访周期和云覆盖影响,难以形成连续时间序列 GPP 产品。②基于 GPP 降尺度技术提高产品空间分辨率^[7-8]。研究人员利用植被指数、土地利用类型、气象因子以及地形因子等辅助变量,通过统计回归、随机森林、支持向量机和深度学习等方法建立 MODIS GPP 与高分辨

率遥感数据之间的关系,实现粗分辨率 GPP 向细尺度空间的转换,然而,往往依赖大量训练样本和区域经验参数,不同地区之间的泛化能力仍然有限。③利用时空融合技术构建高时空分辨率植被指数产品,并进一步驱动 GPP 模型反演高分辨率 GPP^[9]。通过融合 MODIS 的高时间分辨率和 Landsat 或 Sentinel-2 的高空间分辨率优势,能够同时获得连续时间序列和精细空间尺度信息。目前 STARFM^[10]、ESTARFM^[11]、FSDAF^[12] 以及 STNLFFM^[13] 等模型已被广泛应用于植被监测和生态参数反演研究,并在叶面积指数(LAI)、归一化植被指数(NDVI、EVI)以及蒸散发(ET)等生态变量估算中取得较好结果^[14-17]。然而,传统时空融合模型通常建立在线性假设基础上,在复杂地表条件和快速物候变化时期易产生光谱失真和空间模糊现象,从而影响 GPP 反演精度。

近年来,深度学习发展为高分辨率 GPP 制图提供了新的解决方案。卷积神经网络(CNN)、生成对抗网络(GAN)以及 Transformer 等模型能够学习高低分辨率遥感数据之间复杂的非线性映射关系^[18],在时空融合精度和空间细节重建方面表现出明显优势。其中,基于深度卷积神经网络的时空融合模型(Spatiotemporal fusion based on convolutional neural network, STFCNN)能够有效地提高植被指数重建精度^[19],为高时空分辨率 GPP 估算提供更加可靠的输入数据。然而,目前相关研究主要集中融合影像精度评价,对于融合结果驱动 VPM 模型进行农田

GPP 反演的应用研究相对较少,对 GPP 估算精度提升的贡献尚缺乏系统验证。

针对现有 GPP 产品空间分辨率较低、难以满足农田尺度生态系统生产力精细化监测需求,本文以山西省寿阳县农田为研究区,利用 MODIS 与 Landsat 遥感数据构建基于 STFCNN 算法实现归一化植被指数 (EVI) 和地表水分指数 (LSWI) 高时空分辨率影像重建,在此基础上,利用融合后的高时空分辨率植被指数驱动 VPM 模型开展 GPP 反演,通过地面实测数据验证反演结果,探讨时空融合技术在提高农田 GPP 空间分辨率和估算精度方面的应用潜力,以期为区域农业生态系统生产力监测和碳循环研究提供技术支撑。

1 研究区概况与数据来源

1.1 研究区概况

如图 1 所示,研究区寿阳县 (37°32′ ~ 38°5′N, 112°46′ ~ 113°28′E) 位于山西省中东部,晋中市东北部,地处黄土高原东部,是连接晋中盆地与太行山西的重要过渡带。全县总面积 2 110 km²,是山西省重要的粮食生产基地。耕地面积约 6.5 × 10⁴ hm²,玉米种植面积占粮食作物播种面积的 60% 以上,是典型的玉米主产区。地形以丘陵和山地为主,海拔 900 ~ 1 800 m,地势起伏较大。属于暖温带大陆性季风气候,年平均气温 7 ~ 10℃,年平均降水量 450 ~ 550 mm,降水主要集中在 6—9 月,占全年降水量的 70% 以上,具有明显的雨热同期特征。玉米一般于 4 月底至 5 月上旬播种,9 月底至 10 月上旬收获,生长期 140 ~ 160 d。




图 1 研究区概况
Fig. 1 Overview of study area

1.2 数据来源与处理

遥感数据来自 Google Earth Engine (GEE) 的 2014—2015 年 4—10 月期间 Landsat8 地表反射率数据和 MOD09A1 地表反射率产品。Landsat 提供

30 m 空间细节,MOD09A1 提供连续 8 d 时间信息。根据 VPM 模型参数需求,分别计算 EVI 和 LSWI,并基于质量控制波段剔除云、云阴影异常观测。对于缺失数据和噪声较明显的时间序列,采用 Savitzky – Golay 滤波进行时序重构,以增强作物曲线的连续性。

GPP 实测数据来自中科院寿阳野外观测站碳水通量数据,经涡度通量塔观测春玉米的 GPP^[20]。提取 4—10 月 GPP 数据作为 VPM 模型反演的验证数据。光合有效辐射 (Photosynthetically active radiation, PAR) 数据与温度数据均来自国家青藏高原科学数据中心^[21–22],通过重采样到 500 m,整合为每 8 d 的 PAR 与温度栅格数据集。

2 研究方法

2.1 时空融合算法 STFCNN

STFCNN 是一种基于深度卷积神经网络的时空融合方法^[19],如图 2 所示,通过学习 MODIS 与 Landsat 影像之间复杂的非线性映射关系,实现高时间分辨率与高空间分辨率遥感数据的融合。与 STARFM、ESTARFM 等基于相似像元和加权函数的传统时空融合方法不同,STFCNN 利用深度学习自动提取多尺度空间特征和时间变化特征,建立端到端的映射模型,从而提高融合结果的空间细节恢复能力和光谱保持能力。STFCNN 主要包括训练阶段和预测阶段 2 个部分。在训练阶段,通过构建非线性映射网络 (Nonlinear mapping network, NLM) 和超分辨率重建网络 (Super-resolution network, SR) 学习 MODIS 与 Landsat 影像之间的对应关系。在预测阶段,利用训练的网络对目标时相 MODIS 影像进行空间细节重建,并结合参照时相 Landsat 影像信息生成目标时相高空间分辨率影像。

(1) 非线性映射网络

由于 MODIS 与 Landsat 影像在空间分辨率、传感器响应特征以及观测条件等方面存在显著差异,因此需建立两者之间的非线性映射关系。为减小空间尺度差异,将 Landsat 影像重采样至与 MODIS 相近的空间分辨率,并与对应时相的 MODIS 影像构建训练样本。NLM 网络采用卷积神经网络结构,以 MODIS 影像作为输入,以降尺度后 Landsat 影像作为目标输出。通过多层卷积操作逐步提取影像的光谱特征、纹理特征以及空间结构信息,从而学习 2 种传感器数据之间的转换关系。为了提高网络训练效率并增强对细节信息的学习能力,模型采用残差学习策略,将网络学习目标由直接预测影像转换为预测 2 种影像之间的差异信息。这样能够有效降低训




图 2 STFCNN 时空融合算法

Fig. 2 STFCNN spatiotemporal fusion algorithm

练难度,提高模型对地表变化信息的表达能力。网络结构由输入层、多个卷积隐藏层以及输出层组成。其中,在多个卷积层中前几层主要用于提取 MODIS 影像的低层特征和高层语义特征,中间层负责建立复杂的非线性映射关系,最后一层用于重建预测结果。网络训练过程采用均方根误差作为损失函数,通过反向传播算法不断更新网络参数,使预测结果逐渐逼近真实的低分辨率 Landsat 影像。

(2) 超分辨率重建网络

虽然经过 NLM 网络处理后能够获得与 Landsat 具有相似光谱特征的预测结果,但空间分辨率仍然较低,难以恢复真实 Landsat 影像中细节信息。因此,STFCNN 进一步构建超分辨率重建网络,对预测结果进行空间细节增强。SR 网络以低分辨率 Landsat 影像为输入,以原始高分辨率 Landsat 影像为训练目标,通过学习两者之间的空间细节差异,实现影像空间分辨率的提升。网络结构与 NLM 网络类似,同样采用多层卷积结构和残差学习机制,通过提取边缘、纹理以及局部结构等高频信息,实现空间细节重建。在训练过程,SR 网络重点学习低分辨率影像与高分辨率影像之间缺失的空间细节信息,使模型能够有效恢复农田边界、道路、水体边缘等地物特征,从而提高融合结果的空间表达能力。

(3) 时空融合预测

在预测阶段,选取目标时相前后 2 个参照时相的 Landsat - MODIS 配对影像作为输入数据,并获取目标时相的 MODIS 影像。利用训练的 NLM 网络,将目标时相 MODIS 影像转换为对应的低分辨率 Landsat 影像,获得目标时相的过渡影像。随后采用高通调制方法,将参照时相 Landsat 影像中空间细节信息传递至目标时相。通过分析目标时相与参照时相之间的时间变化关系,对 2 景参照 Landsat 影像进行调整,使其能够反映目标时相地表覆盖状况的变化特征。为了充分利用前后 2 个参照时相的信息,STFCNN 根据目标时相与参照时相之间的变化程度构建权重。当某一参照时相与目标时相变化较小时,对应权重较大;反之权重较小。最终通过加权融合方式获得目标时相的低分辨率预测结果。最后,将低分辨率预测结果输入 SR 网络进行超分辨率重建,恢复高频纹理和空间细节信息,得到目标时相的高空间分辨率 Landsat 影像,至此完成整个时空融合过程。通过非线性映射网络、超分辨率重建网络以及高通调制融合策略的协同作用,STFCNN 能够充分利用 MODIS 影像的时间连续性和 Landsat 影像的空间细节信息,有效提高融合结果的空间精度和光谱保真度,为高时空分辨率植被指数和 GPP 产品构建提供可靠的数据支撑。

2.2 评价指标

为评价融合模型精度,将模型融合结果与真实影像对比,精度采用均方根误差 (RMSE)^[23]、全局相对误差 (ERGAS)^[24]、光谱角映射 (Spectral angle mapper, SAM)^[25]、结构相似性指数 (Structural similarity index measure, SSIM)^[26]、通用图像质量指数 (Universal image quality index, UIQI)^[27] 和决定系数 R^2 6 个指标进行评价。

均方根误差是融合影像与真实影像之间的数值偏差,反映与真实值整体误差水平, RMSE 越小越好。计算式为

$$RMSE = \sqrt{\frac{\sum_{i=1}^R \sum_{j=1}^C (L(i,j) - \hat{L}(i,j))^2}{RC}} \quad (1)$$

式中 R, C ——影像行、列数

$L(i,j), \hat{L}(i,j)$ ——真实与融合影像对应 i, j 的像素值

全局相对误差评价融合影像整体光谱失真程度,是综合反映融合质量的重要指标, ERGAS 越小,表明融合结果整体光谱失真越小。计算式为

$$ERGAS = 100 \frac{h}{l} \sqrt{\frac{1}{M} \sum_{i=1}^M \frac{RMSE_{L_i}^2}{\mu_i^2}} \quad (2)$$

式中 h, l ——Landsat 与低分辨率影像空间分辨率

M ——波段数

μ_i ——第 i 个波段真实影像平均值

L_i ——第 i 个波段融合影像与真实影像均方根误差

光谱角映射通过计算真实光谱向量与融合光谱向量之间的夹角评价融合结果的光谱保持能力, SAM 越小,融合影像对真实光谱信息的保持能力越强。计算式为

$$SAM = \frac{1}{N} \sum_{i=1}^N \arccos \frac{\sum_{j=1}^M (L_i^j \hat{L}_i^j)}{\sqrt{\left(\sum_{j=1}^M (L_i^j)^2\right) \left(\sum_{j=1}^M (\hat{L}_i^j)^2\right)}} \quad (3)$$

式中 $L_i^j, \hat{L}_i^j$ ——真实影像和融合影像第 i 个像元在第 j 个波段上数值

N ——像元总数

结构相似性指数从亮度、对比度和结构 3 个方面评价融合影像与真实影像之间的相似程度, SSIM 取 0~1,越接近 1 表示结构相似性越高。计算式为

$$SSIM = \frac{(2\mu_L \mu_{\hat{L}} + C_1)(2\sigma_{L\hat{L}} + C_2)}{(\mu_L^2 + \mu_{\hat{L}}^2 + C_1)(\sigma_L^2 + \sigma_{\hat{L}}^2 + C_2)} \quad (4)$$

式中 $\sigma_L^2, \sigma_{\hat{L}}^2$ ——真实影像与融合影像的方差

$\mu_L, \mu_{\hat{L}}$ ——真实影像与融合影像的像素平均值

$\sigma_{L\hat{L}}$ ——真实与融合影像的协方差

C_1, C_2 ——避免分母为零而设置的常数

通用图像质量指数综合考虑相关性、亮度失真和对比度失真,评价融合影像的整体质量, UIQI 绝对值越接近 1,融合影像质量越高。计算式为

$$UIQI = \frac{\sigma_{L\hat{L}}}{|\sigma_{L\hat{L}}|} \frac{2\sigma_L \sigma_{\hat{L}}}{\sigma_L^2 + \sigma_{\hat{L}}^2} \frac{2\mu_L \mu_{\hat{L}}}{\mu_L^2 + \mu_{\hat{L}}^2} \quad (5)$$

式中 $\sigma_L, \sigma_{\hat{L}}$ ——真实与融合影像的标准差

决定系数 R^2 衡量融合影像与真实影像之间的线性相关程度,反映融合结果对真实影像变化特征的解释能力, R^2 越接近 1 表示融合影像与真实影像之间具有更高的一致性。计算式为

$$R^2 = \frac{\sigma_{L\hat{L}}^2}{\sigma_L^2 \sigma_{\hat{L}}^2} \quad (6)$$

式中 $\sigma_{L\hat{L}}^2$ ——真实影像与融合影像的方差

2.3 GPP 反演模型 VPM

VPM 是基于遥感数据进行 GPP 估算的光能利用率模型^[28],计算式为

$$GPP = \varepsilon_g FPAR_{chl} PAR \quad (7)$$

其中

$$FPAR_{chl} = a EVI \quad (8)$$

$$\varepsilon_g = \varepsilon_0 T_{scalar} W_{scalar} P_{scalar} \quad (9)$$

$$P_{scalar} = \begin{cases} \frac{1 + LSWI}{2} & (t < t_{lswi_{max}}) \\ 1 & (t \geq t_{lswi_{max}}) \end{cases} \quad (10)$$

$$W_{scalar} = \frac{1 + LSWI}{1 + LSWI_{max}} \quad (11)$$

$$T_{scalar} = \frac{(T - T_{min})(T - T_{max})}{(T - T_{min})(T - T_{max}) - (T - T_{opt})^2} \quad (12)$$

式中 $FPAR_{chl}$ ——植被光合的部分吸收光合有效辐射比例

ε_g ——光能利用率,受温度、叶龄与水分影响

ε_0 ——作物最大光能利用率^[29],玉米取 3.65 g/MJ^[30]

$T_{scalar}, W_{scalar}, P_{scalar}$ ——温度影响因子、水分胁迫因子与叶龄影响因子

$t_{lswi_{max}}$ ——叶面完全伸展时期

t ——时间

T ——温度

$T_{min}, T_{max}, T_{opt}$ ——作物三基温,取 0、45、23℃

P_{scalar} 受叶片寿命的影响,对于生长期内叶片经历出芽、伸展、凋落的植物,叶面伸展前期 $t < t_{lswi_{max}}$ 、叶面伸展后期 $t \geq t_{lswi_{max}}$ 。

3 结果与分析

3.1 不同时空融合精度

为了定量评估 STFCNN 融合鲁棒性,STFCNN、STARFM、ESTARFM、FSDAF 和 STNLFFM 对 VPM 关键指数(EVI 与 LSWI)的融合结果如图 3、4 所示。由图 3 可知,STFCNN 在多数时点及指标上均显著优于其他模型。在误差与光谱保真度方面,STFCNN 的 RMSE 为 0.02~0.09,ERGAS 始终处于时序最低水平,显著低于其他模型的 RMSE(0.04~0.14);尤其在 2015 年 6—8 月物候剧烈变化期,其他模型误

差陡增, RMSE 大于 0.12, ERGAS 大于 14, 而 STFCNN 表现出更强的动态捕捉力, RMSE 小于 0.09, ERGAS 小于 12;同时,图 3e 中 STFCNN 多数时点 SAM 处于 0.15~0.42,证实了光谱保真度。在空间结构重构与统计相关性方面,图 3b、3d 中 STFCNN 决定系数 R^2 为 0.70~0.95, UIQI 为 0.82~0.98,全时序保持高位,避免了其他模型在特定时点,如 2015 年 6 月 18 日和 10 月 8 日的指标剧烈退化。此外,图 3c 中 STFCNN 的 SSIM 指标展现出更优的波动下限,证明对地表空间异质性结构重构具有极强的鲁棒性。




图3 不同时间不同模型融合 EVI 指数的精度

Fig. 3 Accuracy of EVI index of different models fused at different times

图 4 为不同融合模型 LSWI 时序融合精度。由于 LSWI 极易受到降雨、灌溉以及土壤含水率突变的影响,时空融合难度高于 EVI,但相较其他模型,STFCNN 表现出更强的融合精度。从误差控制与光谱保真度来看,如图 4a 所示,在 2014 年 5 月 29 日—9 月 18 日,各模型 RMSE 整体处于较高水平,为 0.04~0.075,STFCNN 在 2014 年 6 月 27 日的 RMSE 最低为 0.024。在 2015 年 10 月 8 日其他模型 RMSE 接近 0.11,STFCNN 的 RMSE 最高为 0.046。如图 4e 所示,STFCNN 的 SAM 为 0.25~0.72。在 2015 年 10 月 8 日,其他模型 SAM 为 1.25~1.40,STFCNN 为 0.72,体现了对水分敏感波段的高效解译能力。同时,如图 4f 所示,STFCNN 的

ERGAS 表现出稳步上升但在同类中最低的趋势,为 2.7~9.8。如图 4b 所示,STFCNN 在绝大多数时点 R^2 稳定 0.54~0.88。其他模型表现差的 2015 年 6 月 19 日 R^2 低于 0.20,而 STFCNN 的 R^2 为 0.61。如图 4d 所示,2015 年 6 月 2 日受到地表剧烈扰动导致各模型的 UIQI 出现低值,STFCNN 在其余时点 UIQI 均稳定 0.70~0.93,显著高于 STNLFFM 等模型的表现。如图 4c 所示,尽管地表动态复杂,本文模型在时序中后段 SSIM 仍维持 0.58~0.84,有效保留了地表水分异质性的边界和纹理信息。

3.2 时空融合模型空间细节

图 5 为不同时空融合模型生成的 EVI 与 LSWI 空间分布结果,各模型均能较好地重建研究区植被




图 4 不同时间不同模型融合 LSWI 指数的精度

Fig. 4 Accuracy of LSWI index of different models fused at different times




图 5 不同融合模型生成 EVI 与 LSWI 的空间细节

Fig. 5 Spatial detail images generated by different fusion models for EVI and LSWI

覆盖的总体空间格局,但在地物边界、纹理细节及高低值区域的保持能力方面存在明显差异。与真实影像相比,FSDAF 和 STARFM 生成的结果存在一定程度的空间平滑现象,局部高值区出现扩散,导致农田边界和地形纹理细节有所模糊。ESTARFM 虽然在空间结构上较 STARFM 有所改善,但仍存在局部块状效应,部分区域高、低植被覆盖区的过渡不够自然。相比之下,STFCNN 能够较好地恢复真实影像中细节纹理特征,尤其在山地沟谷、农田边界及植被斑块分布区域,空间分布与真实影像更为接近。其中,STFCNN 对高频空间信息的保持能力最强,纹理

结构与真实影像高度一致,在局部区域表现出较好的空间连续性和边界清晰度。从整体视觉效果看,STFCNN 在空间细节重建方面明显优于其他融合模型(STARFM、ESTARFM 和 FSDAF),能够更准确地反映研究区植被空间异质性特征。

不同模型融合影像的散点图如图 6 所示,所有模型的散点均沿 1:1 线分布,表明融合结果能较好地保持 EVI 的整体变化趋势。然而,不同模型的散点聚集程度存在明显差异。STFCNN 的散点最为集中,几乎完全分布在 1:1 线附近,决定系数 R^2 为 0.985, RMSE 为 0.003,表现出最高的光谱重建精




图6 不同模型融合影像与真实 Landsat 影像散点图

Fig. 6 Scatter plots of fused images from different models and real Landsat images

度。ESTARFM 同样表现出较高的一致性, R^2 为 0.915 和 RMSE 为 0.006, 散点分布紧凑, 仅次于 STFCNN。STARFM 的精度略低于上述 2 种模型, R^2 为 0.863, RMSE 为 0.008, 在高值区域出现少量离散点。相比之下, STNLFFM 和 FSDAF 的散点离散程度明显增加, 其中 STNLFFM 的 R^2 为 0.541, RMSE 为 0.014, FSDAF 的 R^2 为 0.606, RMSE 为 0.013, 说明 2 种模型在高、低 EVI 区域均存在一定程度偏差。综合散点分布特征及统计指标可以发现, 深度学习模型 STFCNN 能更准确地恢复真实影像的光谱信息, 在像元级定量重建方面表现最佳。

3.3 GPP 模拟结果验证

为了验证融合后影像估计 GPP 值的精度, MODIS GPP 产品、融合影像 VPM 模型计算的站点 GPP 值与实测 GPP 值, 如图 7 所示。散点图结果如图 7a、7b 所示, 2 种模拟结果均能较好地反映 GPP 变化趋势, 但整体上存在一定程度的低估现象, 尤其在高 GPP 时期更为明显, 图 7a 显示, MODIS GPP 与实测 GPP 之间呈显著正相关关系, R^2 为 0.168 2, RMSE 为 0.036 9 gC/m^2 。散点主要分布于 1:1 线下方, 表明模型对高生产力时期的 GPP 存在低估, 但模型仍能够较好地捕捉观测值的总体变化趋势。相比之下, 图 7b 所示拟合效果有所提升, R^2 达到 0.345 2, RMSE 增至 0.032 8 gC/m^2 。回归线斜率增大, 散点分布更加接近 1:1 参考线, 说明改进后的结果能够解释更多的 GPP 变异性, 对植被光合作用强度的响应能力有所增强。

时间序列变化特征如图 7c 所示, 实测 GPP 呈明显的单峰型季节变化规律。4—5 月期间植被生长缓慢, GPP 维持较低水平 (0.005 ~ 0.01 gC/m^2); 进入 6 月后迅速增长, 7—8 月达到全年峰值, 最高




图7 MODIS GPP、融合 VPM 模型与实测 GPP 结果

Fig. 7 Results of MODIS GPP, fused VPM model and measured GPP

接近 0.12 gC/m^2 ; 随着植被进入衰退期, GPP 逐渐下降, 并于 10 月底恢复至较低水平。2 种结果较好地呈现了实测 GPP 的季节变化趋势。然而, 与实测值相比, 2 种结果在生长旺盛期均表现出不同程度的低估, 特别是在 7—8 月高值阶段, 峰值幅度明显偏低。其中 MODIS GPP 峰值约为 0.06 gC/m^2 , 仅达到实测峰值 50% 左右; 改进结果在峰值阶段有所提高, 为 0.075 gC/m^2 , 但仍未完全反映实测 GPP 的高值特征。这种低估现象可能与混合像元、植被指数饱和效应以及环境胁迫因子参数化误差有关。总体而言, 2 种模型均能有效捕捉研究区 GPP 的季节动态变化特征, 但在高生产力时期仍存在一定低估。其中融合 VPM 在相关性和趋势拟合方面均优于 MODIS GPP, 表明对植被生长过程的表征能力有所增强, 具有更高的 GPP 估算精度。

STFCNN 融合后 EVI 与真实影像具有极高的一致性,说明该方法能够准确重建植被指数的时空分布特征。然而,图 7 中基于融合 EVI 驱动 VPM 模型反演的 GPP 与实测值相关性较低。GPP 不仅受 EVI 影响,还受到温度、水分、光能利用效率等多种因素的共同控制,EVI 中微小误差在 VPM 非线性计算过程可能被放大。此外,遥感像元与地面样点之间存在尺度差异,也会降低验证精度。尽管如此,从图 7c、7d 可以看出,融合数据反演的 GPP 仍较好地反映了作物生长季动态变化趋势和峰值出现时间,说明 STFCNN 提高了 GPP 时空连续性,但 GPP 反演精度仍受模型结构和参数不确定性的限制。

图 8 为 2014 年和 2015 年寿阳县 GPP 空间分布图,研究区 2 年的 GPP 为 585 ~ 827 gC/m²。2014 年 GPP 高值区域主要分布在西北部及中部连片耕地区域,GPP 达到 600 gC/m² 以上,局部区域接近最大值 760 gC/m²。这些区域作物生长状况良好,光合作用能力较强,具有较高的碳固定能力。中等 GPP 区域广泛分布于研究区大部分耕地,形成连续的带状和斑块状分布格局。低值区域则主要出现在东南部及部分山区边缘地带,反映受地形条件、土壤含水率及植被覆盖状况等因素影响,植被生产力相对较低。与 2014 年相比,2015 年 GPP 整体水平有所上升,高值区域面积明显增加,空间分布趋于集中。西北部是主要的高值集聚区;中低值区域范围扩大,尤其是在研究区中部和东南部地区表现更为明显。整体来




图 8 融合后影像基于 VPM 模型反演的农田 GPP 空间分布图

Fig. 8 Spatial distribution maps of farmland GPP retrieved from fused images based on VPM model

看,2015 年寿阳县植被碳同化能力强于 2014 年,表明当年植作物生长状况和生产力水平有所降低。从空间格局上看,2 年 GPP 均呈现“西北部较高、东南部较低”的分布特征,说明寿阳县植被生产力受区域自然条件控制明显。总体而言,融合影像结合 VPM 模型能够较好地揭示寿阳县农田生长季 GPP 的空间分异特征,为区域碳循环研究及农业生态系统生产力评估提供可靠的数据支撑。

4 结论

(1)以寿阳县为研究区,构建了基于 STFCNN 的时空融合模型,实现了 Landsat 与 MODIS 数据的时空融合,并结合 VPM 模型开展了农田 GPP 估算。在 EVI 和 LSWI 的时空融合中,STFCNN 的融合精度最高。对于 EVI 的融合,STFCNN 的 RMSE 稳定在 0.02 ~ 0.09, R² 维持在 0.70 ~ 0.95, UIQI 保持 0.82 ~ 0.98,在多个关键时相均取得最佳结果;在 LSWI 融合中,STFCNN 同样表现出较强的稳定性和鲁棒性,RMSE 为 0.024 ~ 0.046, R² 达 0.54 ~ 0.88,显著优于其他模型,表明该模型可以刻画复杂地形的异质性。

(2)空间细节结果表明,STFCNN 能够较好地保持地物边界、纹理结构和空间异质性特征。相比 STARFM、ESTARFM 和 FSDAF 等传统模型存在的空间平滑和局部模糊现象,STFCNN 生成的融合影像与真实 Landsat 影像在空间分布上具有更高的一致性。散点分析进一步表明,STFCNN 获得最高的像元级重建精度, R² 达 0.985, RMSE 为 0.003,说明能更准确地恢复地表植被信息并保持较高的光谱保真度。

(3)基于融合影像驱动 VPM 模型进行 GPP 估算后,结果能够较好地反映研究区植被生长过程及季节变化规律。与 MODIS GPP 产品相比,融合影像反演结果与实测 GPP 的相关性由 0.168 2 提高至 0.345 2,对高生产力时期植被光合作用变化的响应能力明显增强,能够解释更多的 GPP 变异性。尽管在生长旺盛期仍存在一定程度的低估现象,但整体上显著提高了 GPP 估算精度。

参 考 文 献

[1] 竞霞,张二妮,段维纳,等. 基于红光波段 SIF 的高寒草甸 GPP 遥感监测方法[J]. 农业机械学报,2026,57(3):284-293.
Jing Xia, Zhang Erni, Duan Weina, et al. Remote sensing monitoring of GPP in alpine meadows based on red SIF[J]. Transactions of the Chinese Society for Agricultural Machinery, 2026, 57(3): 284-293. (in Chinese)

[2] 王宗明,国志兴,宋开山,等. 2000—2005 年三江平原土地利用/覆被变化对植被净初级生产力的影响研究[J]. 自然资源学报,2009,24(1):136-146.
Wang Zongming, Guo Zhixing, Song Kaishan, et al. Effects of land use/cover change on net primary productivity of Sanjiang Plain, during 2000—2005[J]. Journal of Natural Resources, 2009, 24(1): 136-146. (in Chinese)

- [3] 洪长桥, 金晓斌, 陈昌春, 等. 集成遥感数据的陆地净初级生产力估算模型研究综述[J]. 地理科学进展, 2017, 36(8): 924–939.
Hong Changqiao, Jin Xiaobin, Chen Changchun, et al. Overview on estimation models of land net primary productivity integrating remote sensing data[J]. Progress in Geography, 2017, 36(8): 924–939. (in Chinese)
- [4] 罗亮, 闫慧敏, 牛忠恩. 农田生产力监测中3种多源遥感数据融合方法的对比分析[J]. 地球信息科学学报, 2018, 20(2): 268–279.
Luo Liang, Yan Huimin, Niu Zhong'en. Comparative analysis on three multi-source remote sensing data fusion models in monitoring farmland productivity[J]. Journal of Geo-information Science, 2018, 20(2): 268–279. (in Chinese)
- [5] 牛忠恩, 闫慧敏, 陈静清, 等. 基于VPM与MOD17产品的中国农田生态系统总初级生产力估算比较[J]. 农业工程学报, 2016, 32(4): 191–198.
Niu Zhong'en, Yan Huimin, Chen Jingqing, et al. Comparison of crop gross primary productivity estimated with VPM model and MOD17 product in field ecosystem of China[J]. Transactions of the CSAE, 2016, 32(4): 191–198. (in Chinese)
- [6] 马佳妮, 张超, 吕雅慧, 等. 基于长时间序列遥感数据反演NPP的耕地质量评价[J]. 农业机械学报, 2019, 50(1): 202–208.
Ma Jiani, Zhang Chao, Lü Yahui, et al. Cultivated land quality evaluation based on inversion of NPP based on long-term sequence remote sensing data[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(1): 202–208. (in Chinese)
- [7] Hu J, Jia J, Ma Z, et al. A spatially downscaled TROPOMI SIF product at 0.005° resolution with bias correction[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2024, 17: 13413–13425.
- [8] 张云, 汪伊源, 杨树瑚, 等. CYGNSS超分辨率土壤湿度反演模型研究[J]. 地球信息科学学报, 2026, 28(6): 1719–1731.
Zhang Yun, Wang Yiyuan, Yang Shuhu, et al. Research on CYGNSS super-resolution soil moisture retrieval model[J]. Journal of Geo-information Science, 2026, 28(6): 1719–1731. (in Chinese)
- [9] 黄海. 基于MDD融合数据集的GPP估算比较研究[D]. 北京: 中国地质大学, 2019.
Huang Hai. Comparative study of GPP estimation based on MDD fusion data set[D]. Beijing: China University of Geosciences, 2019. (in Chinese)
- [10] Zhang M, Ma X, Chen A, et al. A spatio-temporal fusion strategy for improving the estimation accuracy of the aboveground biomass in grassland based on GF-1 and MODIS[J]. Ecological Indicators, 2023, 157: 111276.
- [11] Zhu X, 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.
- [12] Cui D, Chen Z, Wang S. A novel spatio-temporal fusion approach combining deep learning downscaling and FSDAF method[J]. Remote Sensing Letters, 2023, 14(12): 1271–1282.
- [13] Cheng Q, Liu H, Shen H, 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.
- [14] Houborg R, McCabe M F, Gao F. Downscaling of coarse resolution LAI products to achieve both high spatial and temporal resolution for regions of interest[C]//2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS). IEEE, 2015: 3317–3320.
- [15] 管琪卉, 丁明军, 张华, 等. ESTARFM算法在长江中下游平原地区的适用性研究[J]. 地球信息科学学报, 2021, 23(6): 1118–1130.
Guan Qihui, Ding Mingjun, Zhang Hua, et al. Analysis of applicability about ESTARFM in the Middle-Lower Yangtze Plain[J]. Journal of Geo-information Science, 2021, 23(6): 1118–1130. (in Chinese)
- [16] 刘建波, 马勇, 武易天, 等. 遥感高时空融合方法的研究进展及应用现状[J]. 遥感学报, 2016, 20(5): 1038–1049.
Liu Jianbo, Ma Yong, Wu Yitian, et al. Review of methods and applications of high spatiotemporal fusion of remote sensing data[J]. Journal of Remote Sensing, 2016, 20(5): 1038–1049. (in Chinese)
- [17] Zhang G, Sun G, Yin G, et al. TALESF: a novel terrain-adjusted local-enhanced spatiotemporal fusion method for generating spatiotemporally seamless, high resolution NDVI[J]. IEEE Transactions on Geoscience and Remote Sensing, 2025, 64: 1–18.
- [18] 张立福, 彭明媛, 孙雪剑, 等. 遥感数据融合研究进展与文献定量分析(1992—2018)[J]. 遥感学报, 2019, 23(4): 603–619.
Zhang Lifu, Peng Mingyuan, Sun Xuejian, et al. Progress and bibliometric analysis of remote sensing data fusion methods (1992—2018)[J]. Journal of Remote Sensing, 2019, 23(4): 603–619. (in Chinese)
- [19] Song H, Liu Q, Wang G, 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.
- [20] 顾峰雪. 寿阳站2011—2024年碳水通量观测数据集[DS/OL]. 国家生态科学数据中心. (2024-11-01)[2026-06-16]. <https://doi.org/10.12199/nesdc.ecodb.2021YFF0703900.sha>. 2025. 1.
- [21] 唐文君. 全球长序列高分辨率光合有效辐射(PAR)(1984—2018)[DS/OL]. 国家青藏高原科学数据中心. (2022-04-29)[2026-06-16]. <https://doi.org/10.11888/RemoteSen.tpd.271909>.
- [22] 彭守. 中国1km分辨率逐月平均气温数据集(1901—2025)[DS/OL]. 国家青藏高原科学数据中心. (2026-07-01)[2026-07-01]. <https://doi.org/10.11888/Meteoro.tpd.270961>.

226 – 235.

Li Le, Zhou Xiaoming, Zhang Mei. Monitoring method for abandoned farmland on the Loess Plateau based on feature optimization of remote sensing images with high spatial resolution[J]. Transactions of the CSAE, 2023, 39(22): 226 – 235. (in Chinese)

[18] Wu X, Zhao N, Wang Y, et al. The potential role of abandoned cropland for food security in China[J]. Resources, Conservation and Recycling, 2025, 212: 108004.

[19] Guo A, Yue W, Yang J, et al. Cropland abandonment in China: patterns, drivers, and implications for food security[J]. Journal of Cleaner Production, 2023, 418: 138154.

[20] 牛继强, 林昊, 牛樱楠, 等. 经济欠发达地区撂荒耕地空间格局与驱动因素分析[J]. 农业机械学报, 2017, 48(2): 141 – 149.

Niu Jiqiang, Lin Hao, Niu Yingnan, et al. Analysis of spatial pattern and driving factors for abandoned arable lands in underdevelopment region[J]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(2): 141 – 149. (in Chinese)

[21] Richter R, Wang X, Bachmann M, et al. Correction of cirrus effects in Sentinel-2 type of imagery[J]. International Journal of Remote Sensing, 2011, 32(10): 2931 – 2941.

[22] Malila W A. Change vector analysis: an approach for detecting forest changes with Landsat[C]//LARS Symposia, 1980: 385.

[23] Chen J, Zhao W, Chen X. Cropland change detection with harmonic function and generative adversarial network[J]. IEEE Geoscience and Remote Sensing Letters, 2020, 19: 1 – 5.

[24] Ge Y, Hu S, Ren Z, et al. Mapping annual land use changes in China's poverty-stricken areas from 2013 to 2018[J]. Remote Sensing of Environment, 2019, 232: 111285.

[25] Zhang T, Yang J, Zhou H, et al. Abandoned cropland mapping with phenology-enhanced change vector analysis and semi-supervised learning in different cropping intensity areas[J]. IEEE Transactions on Geoscience and Remote Sensing, 2024, 62: 1 – 15.

[26] 张秀霞, 邓灵芝, 李旺平, 等. 基于农作物物候特征的干旱区撂荒耕地识别: 以甘肃省凉州区为例[J]. 农业资源与环境学报, 2025, 42(3): 568 – 579.

Zhang Xiuxia, Deng Lingzhi, Li Wangping, et al. Identification of abandoned farmland in arid areas based on crop phenological characteristics: a case study of Liangzhou District, Gansu Province[J]. Journal of Agriculture Resources and Environment, 2025, 42(3): 568 – 579. (in Chinese)

[27] Zhang T, Du Z, Yang J, et al. Land cover mapping and ecological risk assessment in the context of recent ecological migration[J]. Remote Sensing, 2021, 13(7): 1381.

[28] Breiman L. Random forests[J]. Machine Learning, 2001, 45(1): 5 – 32.

~~~~~

(上接第 30 页)

[23] 陈欣远, 余楚楚, 王猛猛, 等. 地表温度时空融合模型性能对比: 地表环境、空间尺度差异及数据相关性的影响分析[J]. 遥感学报, 2025, 29(12): 3575 – 3594.

Chen Xinyuan, She Chuchu, Wang Mengmeng, et al. Performance comparison of spatiotemporal fusion models for land surface temperature: analysis of the effect of surface environment, spatial scale differences, and data correlation[J]. National Remote Sensing Bulletin, 2025, 29(12): 3575 – 3594. (in Chinese)

[24] 唐以洁, 王群明. 耦合空域重建的植被指数时空融合方法[J]. 遥感学报, 2025, 29(8): 2602 – 2615.

Tang Yijie, Wang Qunming. Spatial reconstruction-aided spatio-temporal fusion of NDVI images[J]. Journal of Remote Sensing, 2025, 29(8): 2602 – 2615. (in Chinese)

[25] 陈友慧, 王磊, 赵光俊, 等. 一种基于面向对象策略的增强型光学遥感影像时空融合方法[J]. 武汉大学学报(信息科学版), 2025, 50(11): 2285 – 2294.

Chen Youhui, Wang Lei, Zhao Guangjun, et al. An enhanced spatiotemporal fusion method for optical remote sensing imagery based on object-oriented strategy[J]. Geomatics and Information Science of Wuhan University, 2025, 50(11): 2285 – 2294. (in Chinese)

[26] 张圣微, 方科迪, 周莹, 等. 基于 UBiaSTF 时空融合模型的时序 NDVI 重建方法研究[J]. 农业机械学报, 2026, 57(3): 294 – 305.

Zhang Shengwei, Fang Kedi, Zhou Ying, et al. Temporal NDVI reconstruction method based on UBiaSTF spatiotemporal fusion model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2026, 57(3): 294 – 305. (in Chinese)

[27] 安娜, 赵莹莹, 孙娅琴, 等. 基于奇异谱分析的改进遥感时空融合模型[J]. 自然资源遥感, 2023, 35(2): 89 – 96.

An Na, Zhao Yingying, Sun Yaqin, et al. An improved spatio-temporal fusion model for remote sensing images based on singular spectrum analysis[J]. Remote Sensing for Natural Resources, 2023, 35(2): 89 – 96. (in Chinese)

[28] Wu C, Munger J W, Niu Z, et al. Comparison of multiple models for estimating gross primary production using MODIS and eddy covariance data in Harvard Forest[J]. Remote Sensing of Environment, 2010, 114(12): 2925 – 2939.

[29] Xiao X, Boles S, Frolking S, et al. Mapping paddy rice agriculture in South and Southeast Asia using multi-temporal MODIS images[J]. Remote Sensing of Environment, 2006, 100(1): 95 – 113.

[30] Yan H, Fu Y, Xiao X, et al. Modeling gross primary productivity for winter wheat-maize double cropping system using MODIS time series and CO<sub>2</sub>, eddy flux tower data[J]. Agriculture Ecosystems & Environment, 2009, 129(4): 391 – 400.