doi:10.6041/j.issn.1000-1298.2022.08.018

基于 Sentinel 的时间序列田块尺度 LAI 重建与冬小麦估产

周西嘉[1,2]　张　悦[1]　王鹏新[1]　张树誉[3]　李红梅[3]　田惠仁[1]
(1. 中国农业大学信息与电气工程学院, 北京 100083; 2. 国家卫星气象中心, 北京 100081;
3. 陕西省气象局, 西安 710014)

摘要: 为了进行田块尺度的冬小麦单产估测,以陕西省关中平原为研究区域,基于 Sentinel-1、Sentinel-2 和 Sentinel-3 卫星数据反演叶面积指数(LAI),并利用增强的深度卷积神经网络融合模型(EDCSTFN)和增强的时空自适应反射率融合模型(ESTARFM)对 Sentinel-1、Sentinel-2 和 Sentinel-3 LAI 进行时空融合,进而重建尺度 12 d 的空间分辨率 20 m LAI 并用于冬小麦单产估测。结果表明,基于 Sentinel-1 后向散射系数和相干性能够准确地反演关中平原冬小麦种植区的 20 m 空间分辨率 LAI,决定系数(R^2)在冬小麦主要生育期可达 0.70 以上;相比于基于 Sentinel-2 和 Sentinel-3 的 ESTARFM 模型和 EDCSTFN 模型(EDCSTFN_S3),基于 Sentinel-1 和 Sentinel-2 的 EDCSTFN 模型(EDCSTFN_S1)可以明显提高距离参考影像获取日期较远的日期的 LAI 时空融合精度,ESTARFM、EDCSTFN_S3 和 EDCSTFN_S1 3 个模型在 5 月下旬的融合结果对应的 R^2 分别为 0.53、0.71 和 0.76;基于时空融合 LAI 的冬小麦估产结果与冬小麦单产数据具有良好的相关性($R^2=0.52$, $P<0.01$),估产结果的均方根误差为 358.25 kg/hm^2,归一化均方根误差为 19%,平均相对误差为 7.34%,并显示了丰富的田块尺度冬小麦单产分布细节特征,展现了进行田块尺度冬小麦精确估产的潜力。

关键词: 冬小麦; 估产; 叶面积指数; 时空数据融合; 田块尺度; 时间序列重建
中图分类号: TP79　　**文献标识码**: A　　**文章编号**: 1000-1298(2022)08-0173-13　　**OSID**:

Reconstruction of Time Series LAI and Winter Wheat Yield Estimation at Field Scales Based on Sentinel Satellites

ZHOU Xijia[1,2]　ZHANG Yue[1]　WANG Pengxin[1]　ZHANG Shuyu[3]　LI Hongmei[3]　TIAN Huiren[1]
(1. *College of Information and Electrical Engineering*, *China Agricultural University*, *Beijing* 100083, *China*
2. *National Satellite Meteorological Center*, *Beijing* 100081, *China*
3. *Shaanxi Provincial Meteorological Bureau*, *Xi'an* 710014, *China*)

Abstract: Time-series crop growth monitoring at field scales is very important for crop management and yield estimation. However, the spatial resolutions (250 ~ 1000 m) of current satellite sensors with high temporal resolutions are too coarse for areas with complex and diverse land-use types, such as the Guanzhong Plain of Shaanxi Province, which causes great uncertainties in crop yield estimation results. To estimate the winter wheat yield at field scales, a study was carried out on the Guanzhong Plain. The enhanced deep convolutional spatiotemporal fusion network (EDCSTFN) model and enhanced spatial and temporal adaptive reflectance fusion model (ESTARFM) were used to fuse the leaf area index (LAI) retrieved from Sentinel-1, Sentinel-2 and Sentinel-3 imagery, thereby reconstructing the LAI imagery with a 20 m spatial resolution at 12-day interval. Finally, the reconstructed LAI imagery were used for the winter wheat yield estimation at field scales. The results showed that the LAI imagery with a 20 m spatial resolution in the winter wheat planting area of Guanzhong Plain can be accurately retrieved based on the backscatter coefficient and coherence derived from Sentinel-1 data, and the coefficient of determination (R^2) in March and April were larger than 0.70. Compared with the ESTARFM and EDCSTFN models based on Sentinel-2 and Sentinel-3 (EDCSTFN_S3), the EDCSTFN model based on Sentinel-1 and Sentinel-2 (EDCSTFN_S1) can significantly improve the accuracy of LAI spatio-temporal fusion results

收稿日期: 2021-09-01　修回日期: 2021-10-08
基金项目: 国家自然科学基金项目(42171332、41871336)
作者简介: 周西嘉(1992—),男,博士生,国家卫星气象中心工程师,主要从事定量遥感及其在农业中的应用研究,E-mail: zxj1992@139.com
通信作者: 王鹏新(1965—),男,教授,博士生导师,主要从事定量遥感及其在农业中的应用研究,E-mail: wangpx@cau.edu.cn

on the dates far from the reference dates (R^2 values for ESTARFM, EDCSTFN_S3 and EDCSTFN_S1 model in late May were 0.53, 0.71 and 0.76, respectively). The winter wheat yield estimation results based on the spatio-temporal fused LAI had a good correlation with the winter wheat yield data (R^2 = 0.52, $P < 0.01$), the root mean square error of the yield estimation results was 358.25 kg/hm^2, the normalized root mean square error was 19% and the average relative error was 7.34%. In addition, the yield estimation results showed more spatial distribution details of winter wheat yield at field scales, thereby indicating the potential for accurate winter wheat yield estimation at field scales.

Key words: winter wheat; yield estimation; leaf area index; spatio-temporal data fusion; field scale; time series reconstruction

0 引言

连续时间序列遥感数据是作物长势监测和产量估测的重要数据来源。在反映作物长势的参数当中,叶面积指数(Leaf area index,LAI)是重要的参数之一,是植物群落光合作用能力的重要指标。冬小麦是我国北方的主要粮食作物之一,其不同生育时期的长势指标与最终产量具有不同程度的相关性,因此在冬小麦主要生育期进行连续时间序列作物长势监测对产量估测十分重要[1-4]。

在田块较小的区域,通常需要中、高空间分辨率遥感数据实现田块尺度的作物长势监测和产量估测。然而由于成本和技术的原因,目前尚没有单颗卫星同时具备高空间分辨率和高时间分辨率。因此在同时具备高空间分辨率和高时间分辨率的遥感卫星传感器出现之前,时空数据融合技术为连续时间序列田块尺度作物长势监测提供了一种解决方案,该技术通过输入 1 ~ 2 个日期的高空间分辨率影像和时间序列高时间分辨率影像,融合得到高时间分辨率的田块尺度遥感影像。在已有的时空数据融合方法中,时空自适应反射率融合模型(Spatial and temporal adaptive reflectance fusion model, STARFM)[5]是目前广泛应用的时空数据融合方法之一。为了提高 STARFM 在异构景观区域的时空融合精度,ZHU 等[6]进一步提出了增强的时空自适应反射率融合模型(Enhanced STARFM, ESTARFM)。此外,随着深度学习的发展,尤其是卷积神经网络模型在图像领域的应用,目前已出现了一些基于卷积神经网络的时空数据融合模型,例如基于卷积神经网络自编码器的深度卷积时空融合网络(Deep convolutional spatiotemporal fusion network, DCSTFN)[7]。此后,TAN 等[8]进一步开发了 DCSTFN 的改进模型 Enhanced DCSTFN(EDCSTFN)。研究结果表明,EDCSTFN 模型的融合精度明显高于传统的基于权重和混合像元分解的时空数据融合模型。目前,时空数据融合已应用于作物种类识别[9-10]、物候监测[11-12]、干旱监测[13-14]、产量估测[15-16]等方面,显示了时空数据融合在以上方面的巨大应用潜力。

目前大部分已有的时空数据融合研究是基于光学遥感数据,然而受到云的影响,光学遥感数据往往无法均匀覆盖整个作物生育期。合成孔径雷达(Synthetic aperture radar,SAR)传感器受云层的影响较小并能够获得连续时间序列的遥感数据。Sentinel-1 卫星是近几年发射的 C-波段 SAR 卫星,可提供约 20 m 的空间分辨率以及单颗卫星 12 d 的时间分辨率。目前许多研究表明,Sentinel-1 的后向散射系数和相干性与 LAI 具有较好的相关性[17-19],因此 Sentinel-1 影像非常适合反演 LAI 并与 Sentinel-2 等中高空间分辨率卫星影像的 LAI 反演结果进行时空融合,进而获得连续时间序列的田块尺度 LAI 影像。

本文以陕西省关中平原为研究区域,以 Sentinel-2 LAI 影像为训练样本数据,建立基于 Sentinel-1 数据的反向传播(Back propagation, BP)神经网络 LAI 反演模型;利用 EDCSTFN 模型对 Sentinel-1 和 Sentinel-2 的 LAI 影像进行时空融合,并与基于 Sentinel-2 和 Sentinel-3 LAI 的 ESTARFM 模型和 EDCSTFN 模型的融合结果进行对比,进而重建冬小麦主要生育期的时间序列田块尺度 LAI 影像;构建时空融合 LAI 与冬小麦单产之间的回归模型,进而实现田块尺度的冬小麦单产估测。

1 数据与方法

1.1 研究区域概况

研究区域为关中平原,位于陕西省中部(106°22′ ~ 110°24′E,33°57′ ~ 35°39′N)(图 1),西起大散关,东到潼关,北起陕北黄土高原,南到秦岭,东西长约 360 km,南北宽约 80 km,平均海拔约 500 m[20-21]。气候为大陆性季风气候,四季分明,冬季寒冷干燥,夏季温暖多雨。年平均降水量 500 ~ 700 mm,年平均气温 6 ~ 13℃[22-23]。关中平原的土地利用类型包括耕地、林地、水体、建设用地及裸地。区域内约 70% 的土地为耕地,主要包括谷物地、果

园和蔬菜地。夏季之前，谷物地种植的主要作物为冬小麦。通常，关中平原的冬小麦在 10 月播种，次年 6 月上旬收获。在此期间，冬小麦的返青期在 3 月上旬—3 月中旬，拔节期在 3 月下旬—4 月中旬，抽穗-灌浆期在 4 月下旬—5 月上旬，乳熟期在 5 月中旬—5 月下旬。关中平原降水量和灌溉条件在空间上差异较大。西部的水资源条件较好，冬小麦单产相对较高，而北部和东北部降水量较少，并且受到地形、地貌等因素的影响，干旱发生频率较高。目前，干旱已成为关中平原地区农业增产增收的主要制约因素，因此在冬小麦主要生育期进行长势监测对该地区的农业管理非常重要。

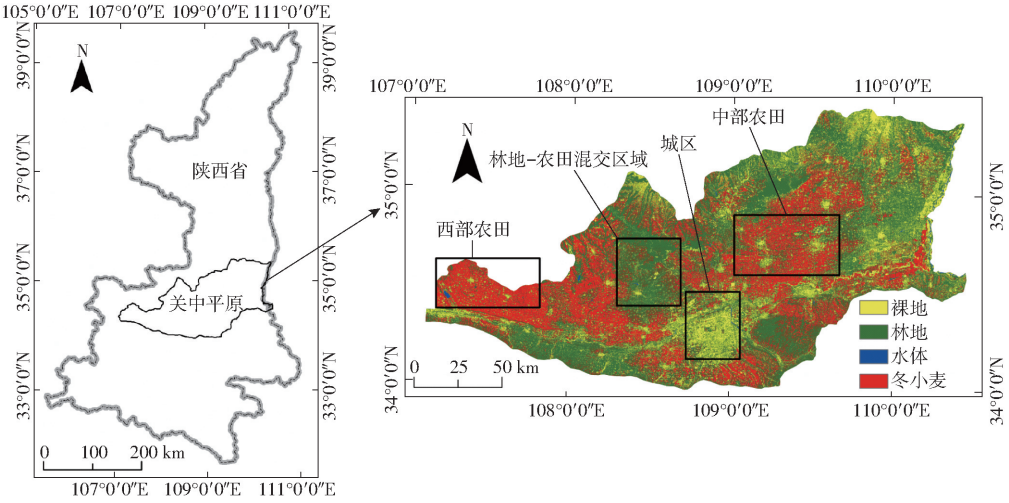

图 1　关中平原的位置与土地利用类型

Fig. 1　Location and land-use types of Guanzhong Plain

按照 ZHOU 等[14]的方法，根据不同时期冬小麦种植区域的光谱变化特征，选择 2018 年 3 月中旬—6 月下旬的 Sentinel－2 数据并采用决策树方法对关中平原的土地利用类型进行分类，分类结果见图 1。可以看出，冬小麦种植区主要分布在关中平原的中部和西部，并且被大量道路和建筑物分割。除了关中平原的西部和中部地区，其余地区的冬小麦种植区较少。根据关中平原研究区的土地利用类型，在研究区域内确定了 4 个重点区域，其中包括西部农田区域、林地-农田混交区域、城区以及中部农田区域。西部农田区域以冬小麦为主，且有少量建设用地。中部农田区域类似于西部农田区域，然而区域内建设用地面积明显大于西部农田区域的建设用地面积。林地-农田混交区域以林地为主，冬小麦种植区面积较少。城区以建设用地为主，冬小麦种植区和林地相对较少。

1.2　数据获取与处理

使用的遥感数据包括 2018 年和 2020 年 3 月上旬—5 月下旬的 Sentinel－1 单视复数影像（Single look complex，SLC）数据、Sentinel－2 多光谱仪器（Multispectral instrument，MSI）数据和 Sentinel－3 数据，其中 Sentinel－3 数据包括空间分辨率 300 m 的 Level－1 海洋和陆地彩色成像仪（Ocean and land colour instrument，OLCI）反射率产品（OL_1_EFR）、空间分辨率 500～1 000 m 的 Level－1 海陆表面温度辐射计（Sea and land surface temperature radiometer，SLSTR）辐射亮度和亮度温度（Radiance and brightness temperature，RBT）产品以及空间分辨率 300 m 的 Level－2 SYN 地表反射率产品。受到云的影响，2019 年 3 月上旬—5 月下旬的可用 Sentinel－2 数据较少，因此本文未进行 2019 年的时间序列田块尺度 LAI 重建。

使用欧洲航天局（European Space Agency，ESA）提供的 SEN2COR v2.5.5 工具对 2018 年 Sentinel－2 MSI Level－1C 产品进行大气校正，进而获得大气校正后的反射率产品，并使用 ENVI flash 对 2018 年 Sentinel－3 OLCI Level－1 EFR 数据和 SLSTR Level－1 RBT 产品进行大气校正。经过大气校正的 2020 年 Sentinel－2 和 Sentinel－3 产品直接从 Sentinels Scientific Data Hub 获取。基于大气校正后的 Sentinel－2 数据，使用 Sentinel 应用程序平台（Sentinel application platform，SNAP）的生物物理参数反演模型反演 20 m 空间分辨率的 LAI 影像。此外，由于 Sentinel－2 数据的主要波段在 Sentinel－3 数据中均可以找到与其相似的波段并且各波段反射率数据之间的相关性较高[16]，因此同样使用 SNAP 生物物理参数反演模型反演空间分辨率为 300 m 的 Sentinel－3 LAI 影像。对于 Sentinel－1 数据，使用 SNAP 软件计算 20 m 空间分辨率的后向散射系数数据以及相邻获取日期的相干性数据。为了减少 Sentinel－1 数据的噪声，分别使用 Lee 滤波和 Savitzky－Golay 滤波[24]对后向散射系数和相干性数

据进行处理。目前,过境关中平原的 Sentinel-1 数据全部为 Sentinel-1A 卫星获取,暂无 Sentinel-1B 数据,因此重访周期为 12 d。由于关中平原冬小麦的返青-乳熟期为 3 月上旬—5 月下旬,因此仅使用这段时期的数据用于时空数据融合。表 1 为 Sentinel-1、Sentinel-2 和 Sentinel-3 数据的获取日期,其中,Sentinel-2 和 Sentinel-3 数据全部是在上午天空晴朗少云的情况下获取的。由于 2020 年可用的 Sentinel-2 数据较多,因此使用 2020 年的数据对 Sentinel-1 LAI 反演模型和时空数据融合模型进行训练,然后将训练的模型应用于 2018 年的数据。

表 1 Sentinel-1 和无云条件下 Sentinel-2、Sentinel-3 数据的获取日期

Tab. 1 Acquisition dates of Sentinel-1, Sentinel-2 and Sentinel-3 data under clear sky conditions

时期	Sentinel-1		Sentinel-2		Sentinel-3	
	2018 年	2020 年	2018 年	2020 年	2018 年	2020 年
3 月上旬		1		4		4
3 月中旬	12	13	15	14、19	13	14
3 月下旬	24	25		24		23
4 月上旬	5	6	9	8	9	8
4 月中旬	17	18	19		17	
4 月下旬	29	30	29	28	29	27
5 月上旬				3		
5 月中旬	11	12		18		
5 月下旬	23	24		23		23

此外,在关中平原各县中选择冬小麦种植区域面积较大并且分布连续的 24 个县(区)的 2018 年统计年鉴冬小麦单产数据,用于检验基于时空融合 LAI 影像的冬小麦单产估测精度。由于关中平原北部、西南部以及城区的冬小麦种植区域面积较小并且分散,而且位于关中平原与周围地区的交接处,因此这些区域对应的县产量数据不在本研究中使用。

1.3 研究方法

时间序列田块尺度 LAI 的重建框架包括 3 部分(图 2):基于 Sentinel-1 数据的 LAI 反演、LAI 时空融合以及田块尺度冬小麦单产估测。在基于 Sentinel-1 数据的 LAI 反演过程中,使用 VV 和 VH 极化的后向散射系数、相干性和局部入射角作为特征数据,Sentinel-2 LAI 影像作为目标样本建立 BP 神经网络模型反演 20 m 空间分辨率的 LAI 影像。在 LAI 时空融合过程中,使用 EDCSTFN 模型对 Sentinel-1 和 Sentinel-2 的 LAI 影像进行融合,生成 12 d 尺度的 20 m 空间分辨率 LAI 影像,并与基于 Sentinel-2 和 Sentinel-3 的 ESTARFM 和 EDCSTFN 模型融合结果进行对比。最后基于时空融合的 LAI 影像估算 20 m 空间分辨率的关中平原冬小麦单产。

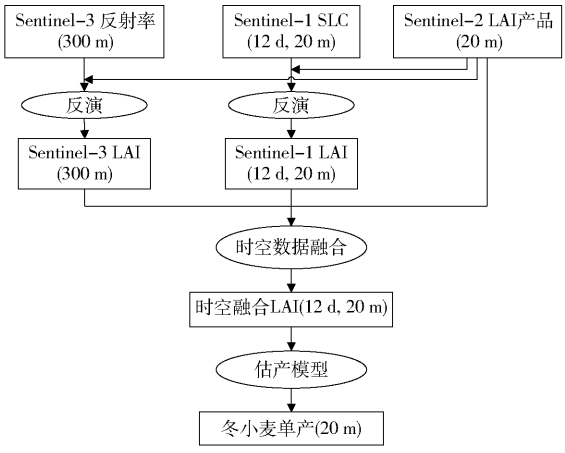

图 2 基于时间序列田块尺度 LAI 重建的冬小麦估产技术流程图

Fig. 2 Flow chart of winter wheat yield estimation based on time series LAI reconstruction at field scales

1.3.1 Sentinel-1 LAI 反演

参考已有基于 Sentinel-1 数据反演 LAI 的方法,使用关中平原冬小麦种植区的 Sentinel-1 后向散射系数(VV、VH)、相干性(VV、VH)和局部入射角作为特征变量,并使用 BP 神经网络模型建立这些特征数据与 Sentinel-2 LAI 之间的非线性映射关系。

BP 神经网络[25]是监督学习的重要方法之一,已广泛应用于定量遥感反演。BP 神经网络通过构建 1 个或多个隐藏层对具有复杂非线性函数关系的数据进行拟合。为了拟合 Sentinel-1 特征数据与 Sentinel-2 LAI 之间的非线性映射关系,设计了一个包含 2 个隐藏层的神经网络模型,模型的结构参数如表 2 所示。考虑训练数据的数量,以及反演精度随网络层数和神经元个数的变化,经过测试,设置神经网络模型的隐藏层数为 2,每层包含 10 个神经元。使用 Levenberg-Marquardt 优化算法[26-27]进行神经元权重的更新。

表 2 Sentinel-1 LAI 反演神经网络模型结构参数

Tab. 2 Structure parameters of Sentinel-1 LAI retrieval neural network

模型参数	输入层	隐藏层 1	隐藏层 2	输出层
神经元数	5	10	10	1
激活函数		双曲正切函数	双曲正切函数	线性函数

基于 Sentinel-1 数据反演 LAI 的具体步骤为:①为了减少 Sentinel-1 数据中噪声对模型训练精度的影响,将 Sentinel-1 的后向散射系数、相干性、局部入射角数据以及 Sentinel-2 LAI 影像聚集升尺度到 300 m 空间分辨率。②在 300 m 空间分辨率的冬小麦种植区进行 BP 神经网络模型的训练,并将 20 m 空间分辨率的 Sentinel-1 特征数据输入训练

的模型反演 20 m 空间分辨率的 LAI 影像。在模型训练与测试过程中，选取 2020 年不同冬小麦生育时期的 Sentinel－1 和 Sentinel－2 数据用于模型的训练与验证（分别占全部数据的 90% 和 10%），然后使用训练的模型反演 2018 年和 2020 年的 LAI 影像。参与模型训练和验证的数据包括 2020 年 3 月 13 日、4 月 6 日和 4 月 30 日的 Sentinel－1 数据，以及 2020 年 3 月 14 日、4 月 8 日和 4 月 28 日的 Sentinel－2 数据。③参考 BISQUERT 等[28]的方法，在 300 m 空间分辨率上利用 Sentinel－3 LAI 数据与 Sentinel－1 LAI 反演结果之间的差值对 Sentinel－1 LAI 反演结果进行残差校正。

1.3.2　基于 Sentinel－1 和 Sentinel－2 的 LAI 时空融合

TAN 等[8]详细描述了 EDCSTFN 模型的原理和使用方法，在此基础上描述基于 Sentinel－1 和 Sentinel－2 数据利用 EDCSTFN 模型重建冬小麦主要生育期 12 d 尺度田块尺度 LAI 的方法（称为 EDCSTFN_S1 模型），并在结果分析中与基于 Sentinel－2 和 Sentinel－3 数据的 ESTARFM 模型和 EDCSTFN 模型（称为 EDCSTFN_S3 模型）的融合结果进行对比。

EDCSTFN 模型基于深度学习模型，学习输入影像（包括高空间分辨率和高时间分辨率的参考影像，以及预测日期的高时间分辨率影像）和预测日期高空间分辨率影像之间的映射关系，进而在高时间分辨率影像获取日期上实现高空间分辨率影像的预测。模型采用编码器–特征融合–解码器的架构对该映射关系进行学习，其中包括 2 个编码器：高空间分辨率影像编码器和残差编码器。高空间分辨率影像编码器学习高空间分辨率参考影像的特征，残差编码器基于输入的高空间分辨率影像和高时间分辨率影像学习参考影像日期和预测日期之间高空间分辨率影像的特征变化。融合过程在特征空间进行，对高空间分辨率参考影像的特征数据和残差编码器输出的特征数据进行相加，最后使用解码器将融合特征数据还原到原始像素空间。该过程可以表示为

$$H_{t_1}=f(g(H_{t_k})+h(H_{t_k},L_{t_1},L_{t_k}))\quad(k\neq1)\quad(1)$$

式中　H_{t_1}、H_{t_k}——日期 t_1 和 t_k 获取的高空间分辨率影像

L_{t_1}、L_{t_k}——日期 t_1 和 t_k 获取的高时间分辨率影像

g——高空间分辨率影像编码器，对输入的高空间分辨率影像进行特征提取

h——残差编码器

f——解码器

模型的损失函数包括内容损失、特征损失和视觉损失，其中内容损失通过均方误差（Mean square error，MSE）进行表示，视觉损失通过多尺度结构相似性（Multi－scale structural similarity，MS－SSIM）指数进行评估。特征损失的评估通过在融合模型之外构建一个沙漏结构自编码器，从而进行融合结果和验证数据的特征提取。使用 2020 年 4 月 28 日的 Sentinel－2 LAI 影像训练评估 LAI 特征损失的自编码器。

相比于 TAN 等[8]描述的原始 EDCSTFN 模型，由于 Sentinel－1 和 Sentinel－2 LAI 影像的空间分辨率均为 20 m，因此无需在 EDCSTFN_S1 模型中对 Sentinel－1 数据进行重采样，而 EDCSTFN_S3 模型中保留将 Sentinel－3 数据重采样为 20 m 空间分辨率的步骤。EDCSTFN 模型的重要参数包括 Adam 优化算法的初始学习率、训练周期、批次尺寸、波段数、训练影像尺寸和预测影像尺寸。设置初始学习率为 0.001，训练周期为 100。当学习率下降为 1×10^{-5} 时，停止训练。根据硬件配置设置训练批次尺寸为 4。

在 EDCSTFN_S1 和 EDCSTFN_S3 模型训练过程中，分别从关中平原西部农田和中部农田选择 2 块 1 500 像素 ×1 500 像素的区域，随机选择其中 2 块作为训练影像，另外 2 块作为验证影像。在模型训练和验证数据日期的选择上，选择 2020 年 3 月中旬、4 月上旬、4 月下旬和 5 月下旬的数据进行组合，在关中平原冬小麦主要生育期总共划分了 6 组数据用于模型的训练（表 3）。EDCSTFN 模型需要 1 或 2 对相近日期获取的高空间分辨率影像和高时间

表 3　EDCSTFN_S1 和 EDCSTFN_S3 模型训练和验证数据获取日期（2020 年）

Tab. 3　Acquisition dates of train data and validation data for EDCSTFN_S1 and EDCSTFN_S3 model in 2020

数据分组	参考影像日期	预测影像日期
第 1 组	3 月 14 日（3 月 13 日/3 月 14 日）	4 月 8 日（4 月 6 日/4 月 8 日）
第 2 组	4 月 8 日（4 月 6 日/4 月 8 日）	3 月 14 日（3 月 13 日/3 月 14 日）
第 3 组	4 月 8 日（4 月 6 日/4 月 8 日）	4 月 28 日（4 月 30 日/4 月 27 日）
第 4 组	4 月 28 日（4 月 30 日/4 月 27 日）	4 月 8 日（4 月 6 日/4 月 8 日）
第 5 组	4 月 28 日（4 月 30 日/4 月 27 日）	5 月 23 日（5 月 24 日/5 月 23 日）
第 6 组	5 月 23 日（5 月 24 日/5 月 23 日）	4 月 28 日（4 月 30 日/4 月 27 日）

注：括号外为 Sentinel－2 数据的获取日期，括号内分别为 Sentinel－1 和 Sentinel－3 数据的获取日期。

分辨率影像作为参考影像。在本研究的训练过程中只使用 1 对参考影像,并使用基于 2020 年数据训练的 EDCSTFN_S1 和 EDCSTFN_S3 模型对 2018 年和 2020 年的时间序列田块尺度 LAI 影像进行预测。

在融合模型的预测阶段,根据关中平原 2018 年和 2020 年冬小麦各生育时期内 Sentinel-2 数据的可用情况,选择 3 月中旬和 4 月下旬获取的 Sentinel-1 和 Sentinel-2 作为融合模型的参考影像。冬小麦主要生育期的具体融合方案为:①选择 1 对 3 月中旬获取的 Sentinel-1 和 Sentinel-2 影像作为融合模型的参考影像,并使用表 3 中第 1 组和第 2 组数据训练的融合模型对 3 月上旬到 3 月下旬的空间分辨率 20 m LAI 影像进行预测。②选择 1 对 4 月下旬获取的 Sentinel-1 和 Sentinel-2 影像作为融合模型的参考影像,并使用表 3 中第 3 组和第 4 组数据训练的融合模型对 4 月中旬和 4 月下旬的空间分辨率 20 m LAI 影像进行预测。③选择 3 月中旬和 4 月下旬获取的 2 对 Sentinel-1 和 Sentinel-2 影像作为融合模型的参考影像,并使用表 3 中前 4 组数据训练的融合模型对 4 月上旬的 20 m 空间分辨率 LAI 影像进行预测。④选择 1 对 4 月下旬获取的 Sentinel-1 和 Sentinel-2 影像作为融合模型的参考影像,并使用表 3 中第 5 组和第 6 组数据训练的融合模型对 5 月上旬到 5 月下旬的空间分辨率 20 m LAI 影像进行预测。按照以上模型参数设置方案和日期方案融合预测 2018 年和 2020 年冬小麦主要生育期的尺度 12 d 空间分辨率 20 m LAI 影像。

1.3.3 基于时空融合 LAI 的冬小麦单产估测

构建冬小麦多生育时期的时空融合 LAI 与冬小麦单产之间的线性回归模型,估测 2018 年和 2020 年关中平原的田块尺度冬小麦单产。对尺度 12 d 的时空融合 LAI 影像按照冬小麦生育时期的日期范围进行平均值合成,得到冬小麦在返青期、拔节期、抽穗-灌浆期和乳熟期的平均 LAI 影像。基于 4 个生育时期的平均 LAI 影像,使用 TIAN 等[3]提出的基于冬小麦主要生育期 LAI 的冬小麦单产估测模型估算冬小麦单产 Y,该估产模型可以表示为

$$Y = 950.61 L_{\text{weighted}} + 3\,011.6 \tag{2}$$

式中 L_{weighted}——冬小麦 4 个生育时期的加权 LAI

4 个生育时期 LAI 对应的权重分别为 0.25、0.21、0.26 和 0.28。本文的研究区域和作物与 TIAN 等[3]的研究相同,并且研究年份接近,因此可将该估产模型及对应的权重参数应用于本研究的冬小麦估产。利用 2018 年关中平原各县的冬小麦单产数据对基于时空融合 LAI 的冬小麦单产估测精度进行检验。

1.3.4 精度评估方法

使用决定系数(Coefficient of determination,R^2)、均方根误差(Root mean square error, RMSE)、拟合 RMSE、归一化 RMSE(Normalized RMSE, NRMSE)和平均相对误差(Mean relative error, MRE)对时空数据融合模型的融合结果和冬小麦估产结果进行定量精度评估。其中,RMSE、NRMSE 和 MRE 均是评估模型估算结果与验证数据之间差异的重要指数,用于评价时空数据融合模型和冬小麦估产模型估算结果的随机偏差和系统偏差。NRMSE 为利用验证数据最大值和最小值的差对 RMSE 进行归一化的结果,其代表 RMSE 占验证数据变化范围的百分比。MRE 反映模型估算误差的绝对值占验证数据的平均百分比。此外,通过对模型估算结果与验证数据进行线性回归,计算二者之间的拟合 RMSE 和 R^2。其中,拟合 RMSE 为线性回归拟合值与验证数据之间的 RMSE,反映了模型估算结果与验证数据之间线性回归的拟合残差,而 R^2 反映了模型估算结果与验证数据之间的线性拟合优度。在本文中,R^2 和拟合 RMSE 用于评价模型估算结果的随机偏差。

2 结果分析

2.1 Sentinel-1 LAI 反演结果

2.1.1 BP 神经网络反演模型训练结果

按照 1.3.1 节基于 Sentinel-1 数据的 LAI 反演方法建立 VV 和 VH 极化的 Sentinel-1 后向散射系数、相干性和局部入射角与 Sentinel-2 LAI 之间的 BP 神经网络模型,并利用 2020 年冬小麦主要生育期的冬小麦种植区数据在空间分辨率 300 m 上对该模型进行训练。模型的训练损失与验证损失曲线见图 3,可以看出,当 LAI 反演模型训练 100 次后,模型的训练精度和验证精度对应的 MSE 均为 0.27,对应的 RMSE 为 0.52,R^2 达到 0.83,并且训练精度与验证精度非常接近,表明在空间分辨率 300 m 上,Sentinel-1 LAI 反演模型具有较高的训练精度。

2.1.2 Sentinel-1 LAI 反演精度评估

将空间分辨率 20 m 的 Sentinel-1 后向散射系数、相干性和局部入射角数据输入训练的 BP 神经网络 LAI 反演模型,进而反演空间分辨率 20 m 的关中平原 Sentinel-1 LAI 影像,并利用 Sentinel-2 LAI 影像对反演结果进行精度评估。图 4 为 2018 年和 2020 年空间分辨率 20 m 的 Sentinel-1 LAI 反演结果与用于验证的 Sentinel-2 LAI 之间的 R^2,以及分别将 Sentinel-1 和 Sentinel-2 LAI 影像升尺度到空间分辨率 300 m 后二者之间的 R^2(图中 R^2 对应的假

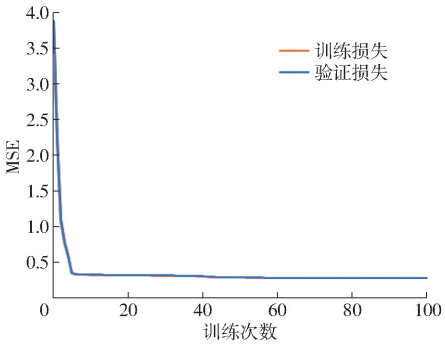

图 3　Sentinel－1 LAI 反演模型的学习曲线

Fig. 3　Learning curves of Sentinel－1 LAI retrieval model

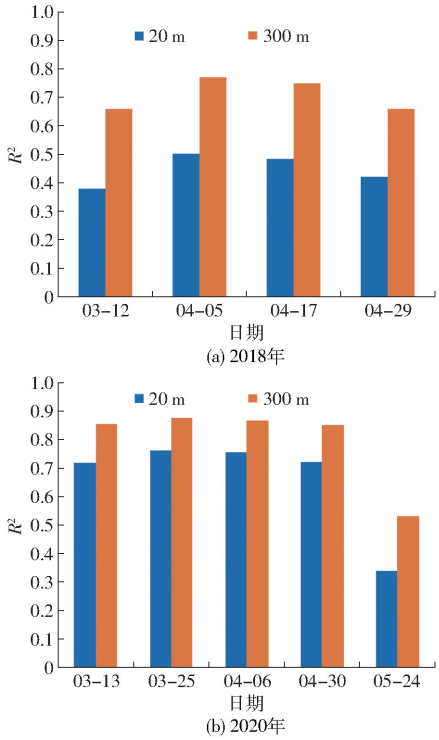

图 4　Sentinel－1 LAI 反演结果的精度评估

Fig. 4　Accuracy evaluation of Sentinel－1 LAI retrieval results

设检验 P 值均小于 0.01，呈极显著水平）。可以看出，在 2020 年 3—4 月之间，空间分辨率 300 m 的 Sentinel－1 LAI 反演结果和 Sentinel－2 数据之间的 R^2 基本不变，在 0.8～0.9 之间，与模型的训练精度比较接近。5 月下旬对应的 R^2 低于 3 月和 4 月，在 0.5～0.6 之间。空间分辨率 20 m 的 Sentinel－1 LAI 反演结果和 Sentinel－2 数据之间的 R^2 在 2020 年 3—4 月整体低于空间分辨率 300 m 的 LAI 反演结果，在 0.7～0.8 之间。5 月下旬的 Sentinel－1 LAI 反演结果与 Sentinel－2 数据之间的 R^2 在 0.4 左右，同样显著低于 3—4 月的 LAI 反演结果对应的 R^2。这些结果表明在 3 月和 4 月，空间分辨率 300 m 下训练的 Sentinel－1 LAI 反演模型在空间分辨率 20 m 下仍具有较高并且稳定的反演精度，而在 5 月下旬的反演精度较低，这可能与冬小麦抽穗–灌浆期后冠层绿色叶片和冠层生物量的不同变化以及反演模型中缺少足够数量的 5 月训练数据有关。2018 年的 Sentinel－1 LAI 反演结果与 Sentinel－2 LAI 之间的 R^2 略低于 2020 年，表明基于单年数据训练的 Sentinel－1 LAI 反演模型可以应用于邻近年份，然而反演精度略低于模型训练数据所在的年份。

2.2　LAI 时空融合结果

2.2.1　EDCSTFN 模型训练结果

利用 EDCSTFN 模型将 Sentinel－2 LAI 分别与 Sentinel－1 和 Sentinel－3 数据进行融合。按照 1.3.2 节中的数据分组方案分别对 EDCSTFN_S1 和 EDCSTFN_S3 模型进行训练。图 5 为利用 2020 年 3—5 月的 LAI 影像对 EDCSTFN_S1 模型进行训练的训练损失和验证损失变化曲线。大约训练 50 次后，模型达到收敛并且训练损失和验证损失非常接近，对应的 MSE 收敛在 0.20 左右（RMSE 在 0.45 左右），表明训练的 EDCSTFN_S1 模型对 Sentinel－1 和 Sentinel－2 的 LAI 影像具有较高的时空融合精度。表 4 为分别使用不同数据分组方案对 EDCSTFN_S1 模型和 EDCSTFN_S3 模型进行训练的最终训练损失和验证损失 MSE。其中，使用 4 月 6 日和 4 月 28 日训练数据组得到的训练损失和验证损失 MSE 在所有分组中最小，其次是 3 月 14 日和 4 月 6 日的训练数据组，4 月 28 日和 5 月 23 日的训练数据组对应的训练损失和验证损失 MSE 最大，使用 3—5 月全部数据得到的训练损失和验证损失 MSE

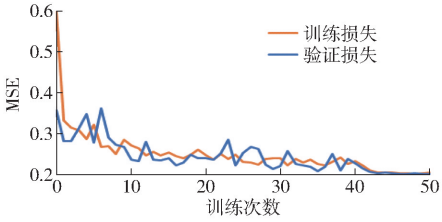

图 5　2020 年 3—5 月 EDCSTFN_S1 模型对 LAI 时空融合的学习曲线

Fig. 5　Learning curves of EDCSTFN_S1 model for LAI spatio-temporal fusion from March to May in 2020

表 4　EDCSTFN_S1 和 EDCSTFN_S3 模型的训练损失和验证损失 MSE

Tab. 4　MSE for training loss of EDCSTFN_S1 and EDCSTFN_S3 models

训练数据日期	EDCSTFN_S1		EDCSTFN_S3	
	训练损失 MSE	验证损失 MSE	训练损失 MSE	验证损失 MSE
3 月 14 日,4 月 6 日	0.20	0.20	0.22	0.21
4 月 6 日,4 月 28 日	0.08	0.06	0.10	0.06
4 月 28 日,5 月 23 日	0.25	0.22	0.40	0.32
3 月 14 日—5 月 23 日	0.20	0.20	0.30	0.24

在所有分组中居中。这些结果表明,EDCSTFN 模型在 3 月和 4 月具有较高的时空融合精度,而在 5 月的时空融合精度较低。在实际应用中,使用 3—5 月全部数据训练的模型在冬小麦主要生育期的整体精度较高,然而使用部分生育时期数据训练的模型在对应的生育时期可能具有更高的精度,因此本研究分别训练不同生育时期的 EDCSTFN 模型,并应用于不同生育时期的 LAI 时空融合。此外,在不同日期组合下,EDCSTFN_S1 模型的训练损失和验证损失 MSE 都小于 EDCSTFN_S3 模型,表明 Sentinel-1 数据的使用可以进一步改善 EDCSTFN 模型对 LAI 影像的时空融合精度。

2.2.2 EDCSTFN_S1 模型预测结果与分析

使用 1.3.2 节的日期融合方案预测冬小麦主要生育期的时间序列田块尺度 LAI 影像,保持预测日期与参考影像日期的间距小于 30 d,并对比 EDCSTFN_S1、EDCSTFN_S3 以及基于 Sentinel-2 和 Sentinel-3 的 ESTARFM 模型在冬小麦主要生育期不同日期的 LAI 预测精度。3 种融合模型均采用 3 月中旬和 4 月下旬的数据作为参考数据。表 5 显示 3 种融合模型在 2020 年不同日期的预测精度评估结果。3 种时空融合模型在 3—4 月的预测结果对应的 R^2 都在 0.9 以上,拟合 RMSE 不超过 0.36,并且预测结果与验证数据之间的平均偏差也非常接近 0,表明在 3 月和 4 月,3 种融合模型都能获得较高的预测精度。而 5 月 23 日的预测结果显示,3 种时空融合模型的预测结果对应的 R^2 明显降低,这与冬小麦 LAI 在抽穗-灌浆期后的复杂非线性变化有关,表明在只使用 1 景 4 月下旬的 Sentinel-2 LAI 影像作为参考影像的情况下,3 种时空融合模型对 5 月下旬的田块尺度 LAI 预测都具有较大的不确定性。因此,获取可用的 5 月下旬 Sentinel-2 LAI 影像作为参考影像对于 5 月下旬的 LAI 时空融合非常重要。然而,相比于 ESTARFM 模型,EDCSTFN_S1 和 EDCSTFN_S3 模型在 5 月 23 日的预测结果对应的 R^2 更高,RMSE 和拟合 RMSE 更低,并且平均偏差更接近 0,表明相比于 ESTARFM 模型,EDCSTFN 模型能够更好地处理 5 月下旬冬小麦种植区 LAI 的非线性变化。此外与 EDCSTFN_S3 模型相比,EDCSTFN_S1 模型在 5 月下旬的预测结果对应的 R^2 更高,RMSE 和拟合 RMSE 更低,并且平均偏差更接近 0,表明基于 Sentinel-1 后向散射系数和相干性等数据反演的 LAI 能够在一定程度上模拟田块尺度 LAI 在 5 月的变化,进而提高 5 月下旬田块尺度 LAI 的时空融合精度。

表 5 EDCSTFN_S1、EDCSTFN_S3 和 ESTARFM 模型的融合精度评估(2020 年)

Tab.5 Accuracy evaluation of EDCSTFN_S1, EDCSTFN_S3 and ESTARFM models in 2020

融合模型	预测日期	R^2	平均偏差	RMSE	拟合 RMSE
EDCSTFN_S1	3 月 4 日	0.95	0.01	0.17	0.16
	3 月 24 日	0.96	0.09	0.24	0.22
	4 月 8 日	0.93	-0.18	0.32	0.25
	5 月 23 日	0.76	0.01	0.27	0.26
EDCSTFN_S3	3 月 4 日	0.96	0.03	0.16	0.15
	3 月 24 日	0.95	-0.06	0.24	0.23
	4 月 8 日	0.96	-0.17	0.32	0.23
	5 月 23 日	0.71	0.07	0.34	0.28
ESTARFM	3 月 4 日	0.95	0.15	0.28	0.17
	3 月 24 日	0.94	0.01	0.23	0.23
	4 月 8 日	0.92	-0.14	0.41	0.36
	5 月 23 日	0.53	0.11	0.53	0.36

注:表中 R^2 对应的假设检验 P 值均小于 0.01,呈极显著水平。

图 6 为 2020 年 5 月 23 日 EDCSTFN_S1、EDCSTFN_S3 和 ESTARFM 模型在关中平原西部农田区域的 LAI 时空融合结果以及用于验证的 Sentinel-2 LAI 影像。从目视效果看,相比于 ESTARFM 模型,EDCSTFN_S1 和 EDCSTFN_S3 模型的 LAI 时空融合结果更接近于用于验证的 Sentinel-2 LAI 影像,二者之间的 R^2 均达到 0.75。而 ESTARFM 模型预测的田块尺度 LAI 在冬小麦种植区域明显高于验证的 Sentinel-2 LAI,二者之间的 R^2 仅为 0.50,这些结果与冬小麦种植区 LAI 在抽穗-灌浆期和乳熟期的非线性变化有关。由于 ESTARFM 模型中假设反射率在研究时段内的变化为线性变化,因此在冬小麦乳熟期,ESTARFM 模型在冬小麦种植区的时空融合精度相对较低。由于 EDCSTFN 模型可以基于冬小麦抽穗-灌浆期和乳熟期的训练数据学习冬小麦种植区 LAI 在这一时段的田块尺度变化特征,以及高空间分辨率数据和高时间分辨率数据之间的关系,因此 EDCSTFN 模型有潜力获得更高的时空融合精度。

EDCSTFN_S1 和 EDCSTFN_S3 模型在关中平原西部区域的融合结果非常接近,然而表 4 和表 5 中整个关中平原的训练结果和预测结果表明,在 EDCSTFN 模型的基础上引入 Sentinel-1 数据可以在一定程度上弥补低空间分辨率的 Sentinel-3 数据在空间细节方面的不足,进而在冬小麦种植区 LAI 变化较快的时期具有获得更高融合精度的潜力。尽管相比于光学影像,Sentinel-1 数据具有较多噪声,然而 EDCSTFN 模型中的卷积神经网络可

以在一定程度上减少原始数据上噪声对融合结果的影响。图 6 表明，EDCSTFN_S1 模型的 LAI 时空融合结果的噪声较少，影像上的空间细节分布与用于验证的 Sentinel－2 影像非常接近，进一步表明了 EDCSTFN 模型融合 Sentinel－1 和 Sentinel－2 LAI 影像的可行性。

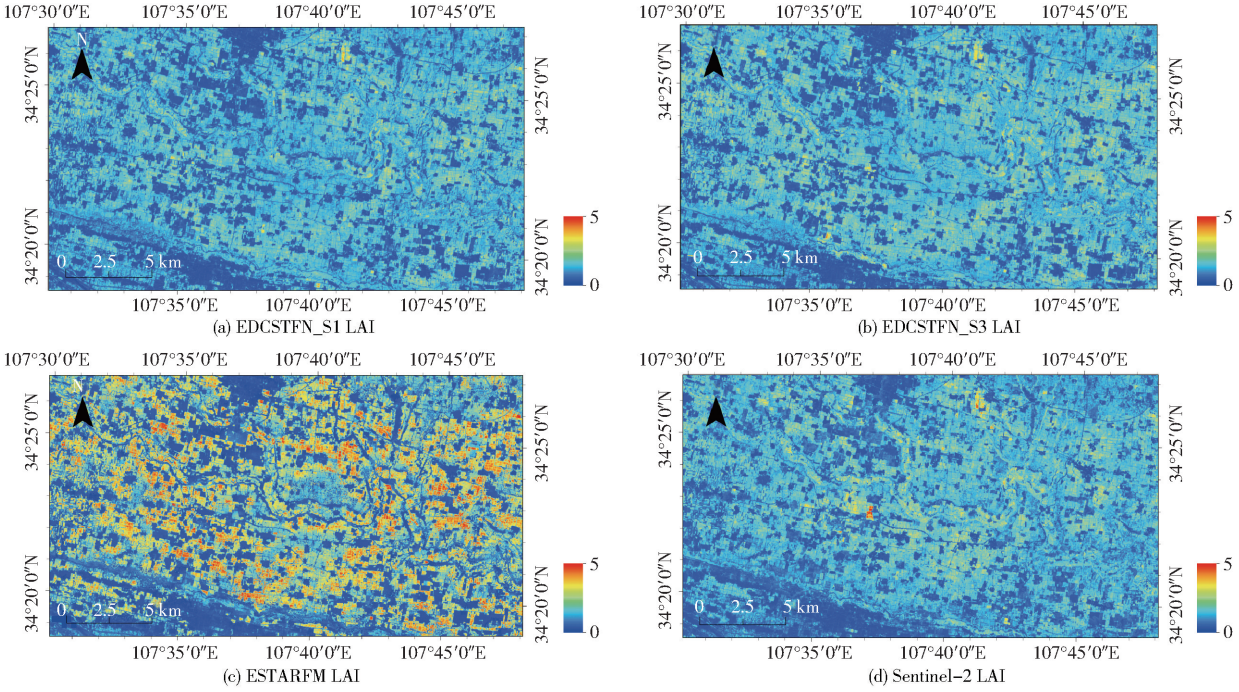

图 6　2020 年 5 月 23 日基于不同时空数据融合模型的田块尺度关中平原西部农田 LAI 影像

Fig. 6　Field-scale LAI imagery fused by different spatio-temporal data fusion model in western cropland on May 23, 2020

为了进一步评估训练的 EDCSTFN 模型在邻近年份的时空融合精度，使用基于 2020 年数据训练的 EDCSTFN 模型对 2018 年冬小麦主要生育期的空间分辨率 20 m LAI 影像进行预测，并与 ESTARFM 模型的 LAI 预测精度进行对比。在 EDCSTFN 模型中，使用 2018 年 4 月 29 日的 Sentinel－2 LAI 影像作为参考影像对 2018 年 4 月 19 日的空间分辨率 20 m LAI 影像进行预测，使用 2018 年 3 月 15 日和 4 月 29 日的 Sentinel－2 LAI 影像作为参考影像对 2018 年 4 月 9 日的空间分辨率 20 m LAI 影像进行预测。在 ESTARFM 模型中，使用 2018 年 3 月 15 日和 4 月 29 日的 Sentinel－2 LAI 影像作为参考影像，对 2018 年 4 月 9 日和 4 月 19 日的空间分辨率 20 m LAI 影像进行预测。表 6 为 EDCSTFN_S1、EDCSTFN_S3 和 ESTARFM 模型在 2018 年 4 月 9 日和 19 日的预测精度评估结果。2018 年融合结果的整体精度略低于 2020 年的融合结果，其中 R^2 在 0.9 左右，拟合 RMSE 在 0.29～0.40 之间。EDCSTFN_S1 模型和 EDCSTFN_S3 模型的 LAI 时空融合结果对应的 R^2 高于 ESTARFM 模型，RMSE 和拟合 RMSE 低于 ESTARFM 模型，表明 EDCSTFN 模型在邻近年份仍具有较高的 LAI 时空融合精度，并且精度高于 ESTARFM 模型。此外，在距离参考影像日期较远的

表 6　EDCSTFN_S1、EDCSTFN_S3 和 ESTARFM 模型的融合精度评估（2018 年）

Tab. 6　Accuracy evaluation of EDCSTFN_S1, EDCSTFN_S3 and ESTARFM models in 2018

融合模型	日期	R^2	平均偏差	RMSE	拟合 RMSE
EDCSTFN_S1	4 月 9 日	0.90	－0.10	0.31	0.29
	4 月 19 日	0.91	－0.01	0.30	0.30
EDCSTFN_S3	4 月 9 日	0.88	－0.12	0.35	0.33
	4 月 19 日	0.92	0.03	0.29	0.29
ESTARFM	4 月 9 日	0.85	0.03	0.39	0.37
	4 月 19 日	0.85	－0.01	0.40	0.40

注：R^2 对应的假设检验 P 值均小于 0.01，呈极显著水平。

日期，EDCSTFN_S1 模型的融合结果对应的 R^2 略高于 EDCSTFN_S3，平均偏差也更接近 0，例如在 4 月 9 日，表明对于邻近年份的田块尺度 LAI 预测，Sentinel－1 数据仍具有改善 EDCSTFN 模型融合精度的潜力。

2.2.3　时间序列田块尺度 LAI 的重建结果与分析

基于 Sentinel－1 和 Sentinel－2 LAI 影像，利用 EDCSTFN 模型重建 2018 年和 2020 年每年 3—5 月的 12 d 尺度 20 m 空间分辨率 LAI 影像。在关中平原的西部农田、中部农田和农田–林地混交区域，对每景时空融合 LAI 影像的冬小麦种植区和林地区域

进行平均处理,计算 3 个区域内冬小麦种植区和林地区域的尺度 12 d 时间序列 LAI(图 7)。可以看出,2018 年关中平原西部农田区域的冬小麦种植区 LAI 整体高于中部农田和农田-林地混交区域,表明 2018 年西部农田的冬小麦长势好于其他区域。2020 年关中平原西部农田的冬小麦种植区 LAI 与中部农田非常接近,表明 2020 年西部农田和中部农田的冬小麦长势比较接近。然而在 2020 年 3 月,西部农田的冬小麦种植区 LAI 明显高于中部农田,并且西部农田的冬小麦种植区 LAI 在 3 月上旬—4 月中旬之间的变化小于中部农田,在 2018 年的冬小麦种植区时间序列 LAI 中也可以看出类似的情况。此外,在西部农田、中部农田和农田-林地混交区域 3 个区域中,冬小麦种植区 LAI 的峰值在 4 月中旬附近,其中西部农田的冬小麦种植区 LAI 的峰值略早于中部农田和农田-林地混交区域,而中部农田和农田-林地混交区域的冬小麦种植区 LAI 峰值比较接近。这些结果表明,西部农田和中部农田的冬小麦生长状况略有不同,造成这种差异可能与关中平原西部农田和中部农田的水资源分布状况、田间管理方式等因素有关。相比于冬小麦种植区 LAI 在 3—5 月的变化,关中平原林地区域的 LAI 在这期间的变化相对较小,并且 LAI 的平均值始终小于 1。从 3 月上旬—4 月中旬,关中平原 3 个不同区域的冬小麦种植区 LAI 都明显高于林地 LAI,并且二者的偏差随日期逐渐增大。从 4 月下旬—5 月下旬,3 个区域的冬小麦种植区 LAI 逐渐减小,而林地 LAI 的变化较小或仍然逐渐增大。到 5 月下旬,冬小麦种植区 LAI 与林地 LAI 非常接近。由于农田-林地混交区域主要以林地为主,冬小麦种植区较少,因此区域内林地的时间序列 LAI 变化受冬小麦种植区的影响较小。可以看出,农田-林地混交区域内林地的 LAI 在 3 月上旬—5 月下旬之间始终逐渐增大,而西部农田和中部农田区域内林地时间序列 LAI 的变化则在一定程度上受到冬小麦种植区的影响,导致林地 LAI 在 5 月中旬以后略有降低。

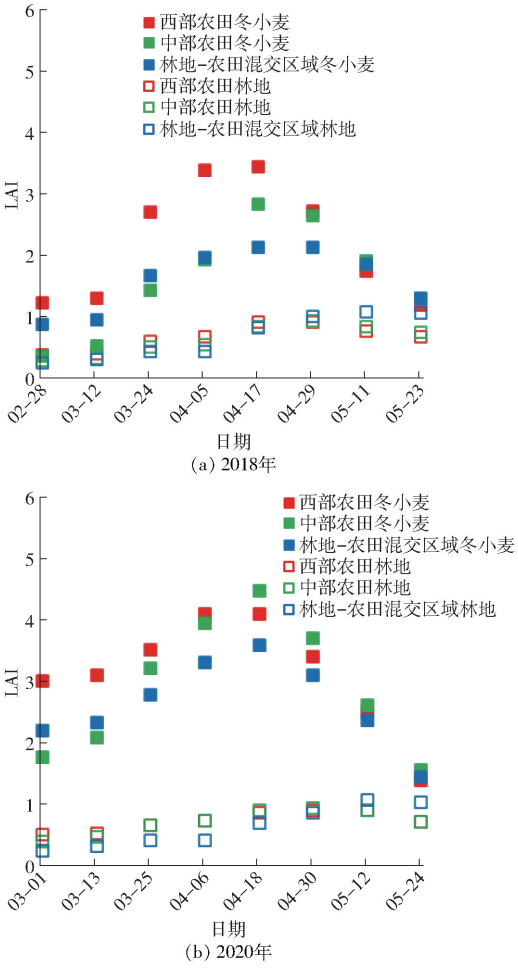

图 7 关中平原不同区域冬小麦和林地的尺度 12 d 时间序列融合 LAI

Fig. 7 Time series data of fused LAI at 12-day interval in winter wheat planting area and woodland area of different parts of Guanzhong Plain

2.3 田块尺度冬小麦单产估测

对 EDCSTFN_S1 模型重建的尺度 12 d 空间分辨率 20 m LAI 影像按照冬小麦生育时期的日期范围进行平均值合成,进而得到在冬小麦返青期、拔节期、抽穗-灌浆期和乳熟期的平均 LAI 影像。利用 TIAN 等[3]基于 LAI 的冬小麦估产模型对 4 个生育时期的 LAI 影像进行加权,并估测 2018 年和 2020 年的关中平原冬小麦单产。图 8 为 2018 年冬小麦单产估测结果与实测单产数据之间的线性回归分析结果,样本容量(n)为 24。基于时空融合 LAI 的冬小麦单产估测结果与实测单产数据之间的 R^2 为 0.52($P < 0.01$,呈极显著水平),RMSE 为 358.25 kg/hm^2,NRMSE 为 19%,MRE 为 7.34%,该结果与 TIAN 等[3]的分析结果接近,表明基于多生育时期的时空融合 LAI 影像,利用 TIAN 等[3]基于

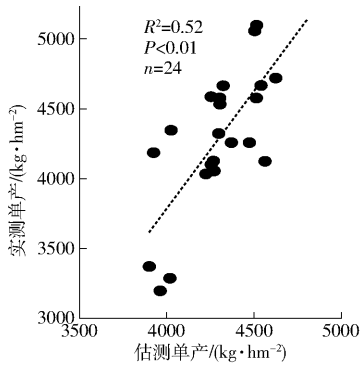

图 8 冬小麦单产估测结果与实测数据的线性回归分析(2018 年)

Fig. 8 Linear regression between winter wheat yield estimation result and actual measurement yield data in 2018

LAI 的冬小麦估产模型可以准确地估测关中平原的冬小麦单产。

图 9 为基于 4 个生育时期时空融合 LAI 影像的 2018 年和 2020 年关中平原冬小麦单产估测结果。可以看出，关中平原的冬小麦单产主要在 2 500 ~ 7 000 kg/hm^{2}之间，种植区主要分布在关中平原的西部和中部地区，其中西部宝鸡市的冬小麦密集种植区的单产最高，其次是关中平原中部的冬小麦密集种植区，位于西安市和渭南市交界部分。此外，在关中平原其他区域也有一些稀疏分布的冬小麦种植区，然而单产较低。这些结果与 TIAN 等[3] 基于 MODIS 数据的冬小麦单产估测结果类似。在 2018 年，关中平原西部冬小麦种植区的冬小麦单产主要在 4 000 ~ 6 000 kg/hm^{2}之间，关中平原中部冬小麦种植区的冬小麦单产主要在 4 000 ~ 5 500 kg/hm^{2}之间。在 2020 年，关中平原西部和中部冬小麦种植区的冬小麦单产明显高于 2018 年，然而周围稀疏分布的冬小麦种植区的单产较低。由图 9c ~ 9f 并结合 TIAN 等[3] 的研究结果可以看出，相比于基于 MODIS 数据的冬小麦单产估测结果，基于时空融合 LAI 估测的冬小麦单产数据具有更丰富的空间细节特征。冬小麦种植区可以更准确地与附近其他植被和建筑物进行区分，从而减少其他土地利用类型对冬小麦单产估测精度的影响。

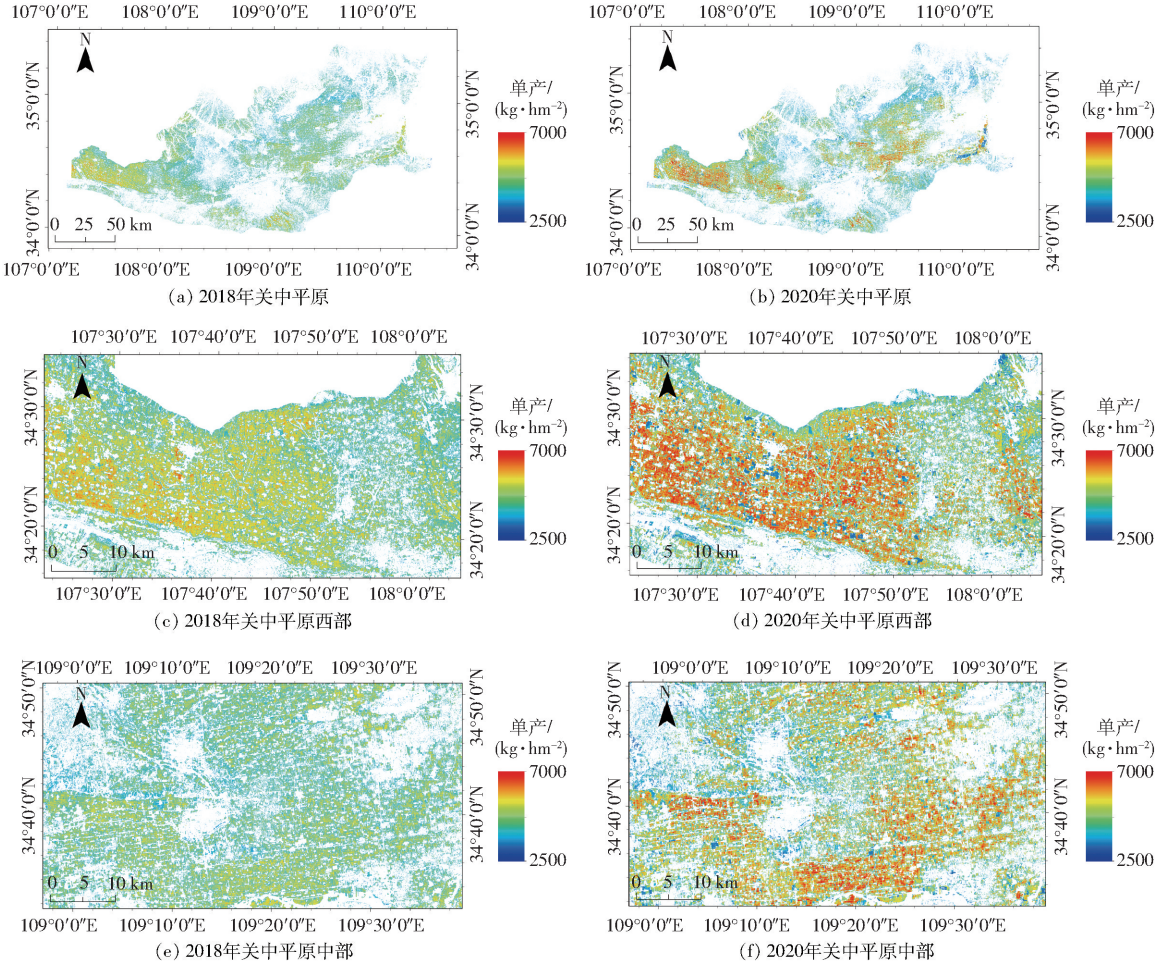

图 9　基于时空融合 LAI 的冬小麦估测单产

Fig. 9　Winter wheat yield estimation results based on spatio-temporal fused LAI

3　讨论

受到云的影响，常用的光学卫星遥感数据难以连续覆盖冬小麦主要生育期，进而导致时空数据融合模型的融合结果在缺少数据的时期具有较大的不确定性。本研究尝试将 Sentinel－1 SAR 数据引入 LAI 的时空融合模型，利用 EDCSTFN 模型对空间分辨率 20 m 的 Sentinel－2 LAI 和尺度 12 d 空间分辨率 20 m 的 Sentinel－1 LAI 进行融合。结果表明，基于 Sentinel－1 和 Sentinel－2 数据的 EDCSTFN 融合模型在冬小麦种植区 LAI 发生快速变化的抽穗–灌浆期和乳熟期的时空融合精度高于基于 Sentinel－2 和 Sentinel－3 数据的 EDCSTFN 和 ESTARFM 模型，因此 EDCSTFN_S1 模型更适用于地表特征在田块尺度发生明显变化以及受云影响可用的光学影像较少的情况。基于 EDCSTFN_S1 模型重建的冬小麦主

要生育期时间序列田块尺度 LAI 影像可用于田块尺度的冬小麦精确估产。

除了结合 Sentinel－1 数据能够进一步提高 EDCSTFN 模型对于冬小麦主要生育期 LAI 的时空融合精度,EDCSTFN 模型的融合精度还可以通过增加训练数据、调整时空数据融合模型的结构和参数等方式得到进一步提高。EDCSTFN_S1 模型在 5 月的预测精度较低可能与 Sentinel－1 LAI 反演模型和 EDCSTFN_S1 模型在 5 月的训练数据较少有关,因此未来将尝试扩大研究区域以及在更多年内选择训练数据,从而进一步增大训练数据的数量并探究增加训练数据对 EDCSTFN_S1 模型在 5 月的预测精度的提高潜力。调整 EDCSTFN 模型的结构和参数也有望进一步提高模型的融合精度。相比于基于相似像元和滑动窗口的 STARFM 系列时空融合模型,EDCSTFN 模型对整个研究区域和所有土地利用类型使用同一套模型参数,因此在预测阶段的计算速度上具有明显优势。然而在地物类型复杂的区域以及面积较大的区域,使用一套模型参数可能无法准确学习所有土地利用类型和区域的变化。未来将尝试根据地物类型的分布情况对整个研究区域进行分块并分别训练 EDCSTFN 模型。此外,未来将通过修改模型的网络参数探究进一步提高融合精度的潜力。当前模型采用 3 × 3 卷积核的 CNN,不同大小的卷积核可以提取不同尺度的特征,更大的卷积核具有更好消除原始影像噪声的能力。由于 Sentinel－1 数据本身的噪声较多,因此较大的卷积核可以更有效地提取噪声之外的重要特征。然而过大的卷积核可能导致融合结果的空间细节损失,因此在未来进一步探究卷积核的大小及其组合方案。

4 结论

(1)基于 Sentinel－1 VV 和 VH 极化的后向散射系数和相干性数据可以准确地反演 20 m 空间分辨率的关中平原冬小麦种植区 LAI,其中 3 月和 4 月的 LAI 反演结果与用于验证的 Sentinel－2 LAI 具有较高的相关性(R^2可达 0.7 以上),5 月的 LAI 反演结果对应的相关性较低。

(2)结合 Sentinel－1 数据的 EDCSTFN 模型(EDCSTFN_S1)可以更精确地重建尺度 12 d 的空间分辨率 20 m LAI 影像,其中 5 月的 LAI 时空融合精度(R^2 = 0.76)高于基于 Sentinel－3 数据的 EDCSTFN_S3 模型(R^2 = 0.71)和 ESTARFM 模型(R^2 = 0.53)。

(3)基于时空融合 LAI 影像的冬小麦单产估测结果与实测冬小麦单产数据具有良好的相关性(R^2 = 0.52),估产结果的均方根误差为 358.25 kg/hm^2,归一化均方根误差为 19%,平均相对误差为 7.34%,并且相比于基于 MODIS 影像的冬小麦单产估测结果,基于时空融合 LAI 影像的冬小麦单产估测结果显示了更丰富的空间细节特征。

参 考 文 献

[1] 王鹏新,田惠仁,张悦,等. 基于深度学习的作物长势监测和产量估测研究综述[J]. 农业机械学报,2022,53(2):1－14.
WANG Pengxin, TIAN Huiren, ZHANG Yue, et al. Crop growth monitoring and yield estimation based on deep learning: state of the art and beyond[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(2): 1－14. (in Chinese)

[2] 刘峻明,周舟,和晓彤,等. 基于 NDWI 和卷积神经网络的冬小麦产量估测方法[J]. 农业机械学报, 2021, 52(12): 273－280.
LIU Junming, ZHOU Zhou, HE Xiaotong, et al. Winter wheat yield estimation method based on NDWI and convolutional neural network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(12): 273－280. (in Chinese)

[3] TIAN H R, WANG P X, TANSEY K, et al. An IPSO－BP neural network for estimating wheat yield using two remotely sensed variables in the Guanzhong Plain, PR China[J]. Computers and Electronics in Agriculture, 2020, 169: 105180.

[4] 解毅, 王鹏新, 王蕾, 等. 基于作物及遥感同化模型的小麦产量估测[J]. 农业工程学报, 2016, 32(20): 179－186.
XIE Yi, WANG Pengxin, WANG Lei, et al. Estimation of wheat yield based on crop and remote sensing assimilation models [J]. Transactions of the CSAE, 2016, 32(20): 179－186. (in Chinese)

[5] 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.

[6] 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.

[7] TAN Z Y, YUE P, DI L, et al. Deriving high spatiotemporal remote sensing images using deep convolutional network[J]. Remote Sensing, 2018, 10(7): 1066.

[8] TAN Z Y, DI L, ZHANG M D, et al. An enhanced deep convolutional model for spatiotemporal image fusion[J]. Remote Sensing, 2019, 11(24): 2898.

[9] 牛海鹏,王占奇,肖东洋. 基于时空数据融合的县域水稻种植面积提取[J]. 农业机械学报, 2020, 51(4): 156－163.
LIU Haipeng, WANG Zhanqi, XIAO Dongyang. Paddy rice planting area extraction in county-level based on spatiotemporal data fusion[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(4): 156－163. (in Chinese)

[10] 谢登峰，张锦水，潘耀忠，等. Landsat 8 和 MODIS 融合构建高时空分辨率数据识别秋粮作物[J]. 遥感学报，2015，19(5)：791－805.
XIE Dengfeng，ZHANG Jinshui，PAN Yaozhong，et al. Fusion of MODIS and Landsat 8 images to generate high spatial-temporal resolution data for mapping autumn crop distribution[J]. Journal of Remote Sensing，2015，19(5)：791－805.（in Chinese）

[11] 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.

[12] ZHENG Y，WU B，ZHANG M，et al. Crop phenology detection using high spatio-temporal resolution data fused from SPOT5 and MODIS products[J]. Sensors，2016，16(12)：2099.

[13] MOOSAVI V，TALEBI A，MOKHTARI M H，et al. Estimation of spatially enhanced soil moisture combining remote sensing and artificial intelligence approaches[J]. International Journal of Remote Sensing，2016，37(23－24)：5605－5631.

[14] ZHOU X J，WANG P X，TANSEY K，et al. Developing a fused vegetation temperature condition index for drought monitoring at field scales using Sentinel－2 and MODIS imagery[J]. Computers and Electronics in Agriculture，2020，168：105144.

[15] MENG L H，LIU H J，ZHANG X L，et al. Assessment of the effectiveness of spatiotemporal fusion of multi-source satellite images for cotton yield estimation[J]. Computers and Electronics in Agriculture，2019，162：44－52.

[16] ZHOU X J，WANG P X，TANSEY K，et al. Reconstruction of time series leaf area index for improving wheat yield estimates at field scales by fusion of Sentinel－2，－3 and MODIS imagery[J]. Computers and Electronics in Agriculture，2020，177：105692.

[17] GHOSH S M，BEHERA M D，PARAMANIK S. Canopy height estimation using Sentinel series images through machine learning models in a mangrove forest[J]. Remote Sensing，2020，12(9)：1519.

[18] MERCIER A，BETBEDER J，BAUDRY J，et al. Evaluation of Sentinel－1 & －2 time series for predicting wheat and rapeseed phenological stages[J]. ISPRS Journal of Photogrammetry and Remote Sensing，2020，163：231－256.

[19] OLESK A，PRAKS J，ANTROPOV O，et al. Interferometric SAR coherence models for characterization of hemiboreal forests using TanDEM－X data[J]. Remote Sensing，2016，8(9)：700.

[20] 王鹏新，冯明悦，孙辉涛，等. 基于主成分分析和 Copula 函数的干旱影响评估研究[J]. 农业机械学报，2016，47(9)：334－340.
WANG Pengxin，FENG Mingyue，SUN Huitao，et al. Drought impact assessment based on principal component analysis and Copula function[J]. Transactions of the Chinese Society for Agricultural Machinery，2016，47(9)：334－340.（in Chinese）

[21] 解毅，王鹏新，刘峻明，等. 基于四维变分和集合卡尔曼滤波同化方法的冬小麦单产估测[J]. 农业工程学报，2015，31(1)：187－195.
XIE Yi，WANG Pengxin，LIU Junming，et al. Winter wheat yield estimation based on assimilation method combined with 4DVAR and EnKF[J]. Transactions of the CSAE，2015，31(1)：187－195.（in Chinese）

[22] 白雪娇，王鹏新，解毅，等. 基于结构相似度的关中平原旱情空间分布特征[J]. 农业机械学报，2015，46(11)：345－351.
BAI Xuejiao，WANG Pengxin，XIE Yi，et al. Spatial distribution characteristics of droughts in Guanzhong Plain based on structural similarity[J]. Transactions of the Chinese Society for Agricultural Machinery，2015，46(11)：345－351.（in Chinese）

[23] 王鹏新，孙辉涛，解毅，等. 基于 LAI 和 VTCI 及粒子滤波同化算法的冬小麦单产估测[J]. 农业机械学报，2016，47(4)：248－256.
WANG Pengxin，SUN Huitao，XIE Yi，et al. Winter wheat yield estimation based on particle filter assimilation algorithm and remotely sensed LAI and VTCI[J]. Transactions of the Chinese Society for Agricultural Machinery，2016，47(4)：248－256.（in Chinese）

[24] SAVITZKY A，GOLAY M J E. Smoothing and differentiation of data by simplified least squares procedures[J]. Analytical Chemistry，1964，36(8)：1627－1639.

[25] RUMELHART D E，HINTON G E，WILLIAMS R J. Learning representations by back-propagating errors[J]. Nature，1986，323：533－536.

[26] LEVENBERG K. A method for solution of certain problems in least squares[J]. The Quarterly of Applied Mathematics，1944，2(2)：164－168.

[27] MARQUARDT D W. An algorithm for least-squares estimation of non-linear parameters[J]. Journal of the Society for Industrial and Applied Mathematics，1963，11(2)：431－441.

[28] BISQUERT M，SANCHEZ J M，CASELLES V. Evaluation of disaggregation methods for downscaling MODIS land surface temperature to Landsat spatial resolution in Barrax test site[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing，2016，9(4)：1430－1438.