

李长春, 翟伟广, 王春阳, 等. 基于 Sentinel-1A 影像的原阳县玉米和水稻分类时间窗选择[J]. 江苏农业学报, 2023, 39(2): 413-422.
doi: 10.3969/j.issn.1000-4440.2023.02.014

基于 Sentinel-1A 影像的原阳县玉米和水稻分类时间窗选择

李长春¹, 翟伟广¹, 王春阳¹, 陈伟男¹, 吴喜芳¹, 顾明明²

(1. 河南理工大学测绘与国土信息工程学院, 河南 焦作 454000; 2. 河南省有色金属地质矿产局第一地质大队, 河南 郑州 450000)

摘要: 使用遥感技术可以快速、准确地识别作物类型。本研究以河南省原阳县为试验区, 基于 Google Earth Engine (GEE) 云平台, 以玉米、水稻关键生育期的 Sentinel-1A 影像为数据源, 分析各类地物的极化特征时序曲线。对 6 期 Sentinel-1A 影像进行穷举组合, 使用随机森林算法对所有影像组合分类, 分析各生育期影像对作物分类的重要性, 选出玉米、水稻分类最佳时间窗。结果表明, 作物生长中后期影像对作物分类更重要, 其中玉米的乳熟期最重要, 水稻的灌浆期最重要。全生育期影像组合中玉米的用户精度和生产者精度分别为 90.43% 和 90.53%, 水稻的用户精度和生产者精度分别为 88.89% 和 89.01%。经过优选, 大喇叭口期至成熟期为玉米分类最佳时间窗, 相较于全生育期影像组合, 此生育期影像组合的玉米用户精度和生产者精度分别提高了 3.38 个百分点和 5.26 个百分点; 拔节期至成熟期为水稻分类最佳时间窗, 相较于全生育期影像组合, 此生育期影像组合的水稻用户精度和生产者精度分别提高了 4.73 个百分点和 2.66 个百分点。本研究结果可以为 Sentinel-1A 影像在原阳县及其附近区域的玉米、水稻种植结构监测研究提供理论依据。

关键词: Sentinel-1A 影像; 玉米; 水稻; 生育期; 随机森林; 时间窗

中图分类号: S127 **文献标识码:** A **文章编号:** 1000-4440(2023)02-0413-10

Time window selection of corn and rice classification in Yuanyang County based on Sentinel-1A image

LI Chang-chun¹, ZHAI Wei-guang¹, WANG Chun-yang¹, CHEN Wei-nan¹, WU Xi-fang¹, GU Ming-ming²

(1. School of Surveying and Land Information Engineering, Henan Polytechnic University, Jiaozuo 454000, China; 2. The First Geological Brigade of Henan Province Nonferrous Metals Geology and Mineral Bureau, Zhengzhou 450000, China)

Abstract: The use of remote sensing technology can quickly and accurately identify crop types. Taking Yuanyang County of Henan province as the research area, based on Google Earth Engine (GEE) cloud platform and Sentinel-1A images of corn and rice at the key growth period, the polarization characteristic time series curves of various ground objects were analyzed. The six Sentinel-1A images were combined exhaustively, and the random forest algorithm was used to classify all image combinations, analyze the importance of images in each growth period to crop classification, and select the best time window for corn and rice classification. The results showed that the image of the middle and late growth stages of crop growth was more important for classification. The milk ripening stage of maize was the most important, and the filling stage of rice was the most important. In the whole growth period image combination, the user accuracy and producer accuracy of corn were 90.43% and 90.53% respectively,

收稿日期: 2022-04-28

基金项目: 国家自然科学基金项目(41871333); 河南省科技攻关项目(212102110238, 222102110038)

作者简介: 李长春(1976-), 男, 河南周口人, 博士, 教授, 主要从事农业定量遥感研究。(E-mail) lichangchun610@126.com

通讯作者: 翟伟广, (E-mail) zwg170607@163.com

and the user accuracy and producer accuracy of rice were 88.89% and 89.01% respectively. After optimization, the best time window for maize classification was from big bell stage to mature stage. Compared with the image combination in the whole growth stage, the user accuracy and producer accuracy of maize improved by 3.38 percentage points and

5.26 percentage points, respectively. The best time window for rice classification was from jointing stage to maturity stage. Compared with the image combination in the whole growth stage, the user accuracy and producer accuracy of rice increased by 4.73 percentage points and 2.66 percentage points, respectively. The results of this study can provide a theoretical basis for the monitoring and research of corn and rice planting structure in Yuanyang County and its nearby areas with Sentinel-1A image.

Key words: Sentinel-1A image; corn; rice; growth period; random forest; time window

随着城市的快速发展以及人口的不断增加,粮食安全已逐渐成为人们共同关注的问题^[1-3]。及时、准确获取作物种植类型和空间分布信息可以保障粮食安全,促进社会经济发展^[4]。传统的农作物空间分布信息获取方法需要大量人员实地考察统计,该过程不仅繁琐且获取的农作物空间分布信息准确度较低。遥感技术在经济性、时效性等方面的优势,为快速、准确获取农作物空间分布信息提供了可能^[5]。

光学遥感影像在作物分类研究中发挥着重要作用,是目前作物分类研究主要的数据源。基于单生育期光学影像进行作物分类会受到异物同谱的影响,导致分类结果中存在较多的错分、漏分。使用多生育期光学影像,结合作物各时期的光谱差异性,可有效解决异物同谱和同物异谱引起的错分、漏分问题^[6]。前人基于长时序光学影像对作物进行了较为精确的分类提取,如 Xu 等^[7]使用多生育期多源光学遥感数据完成了山东省 2018 年冬小麦空间分布图的绘制;吴静等^[8]使用时序 Sentinel-2 光学影像对甘肃省景泰县的作物进行了分类;蔡耀通等^[9]基于关键物候期的多时相多源遥感数据,使用卷积神经网络(CNN)算法对水稻种植信息进行提取,其总体精度达到 92.11%;白燕英等^[10]提出了一种基于 Landsat-8 时序归一化植被指数(NDVI)曲线的作物种植信息提取方法,作物分类精度达到 82.00%以上。但是云雨天气的影响极大地限制了光学影像的应用,本研究的试验区河南省原阳县的夏季存在频繁的厚云和降雨,获取长时序的高质量光学影像存在一定难度。

合成孔径雷达(SAR)分辨率高,重访周期短,且不受云雨天气的限制,可以全天候、全天时对地面进行观测^[11-13]。与此同时,雷达遥感具有穿透性,获取的影像可以反映作物的叶、茎、枝干等信息^[14-16]。近些年,使用 SAR 数据进行作物分类研究已取得较大进展。李俐等^[17]基于时序 Sentinel-1A 数据对河北省涿州市夏玉米进行了提取,精度高达 92.96%;刘警鉴等^[18]使用多时相 Sentinel-1A 影像对早稻面积进行了提取,其总体精度达到 89.01%;Frate 等^[19]基于多时

相 SAR 数据,使用神经网络算法进行了精确的作物分类;Zeyada 等^[20]使用全极化 Radarsat-2 数据结合多种机器学习算法有效提高了多种农作物的分类精度,总体精度达 94.48%。以上研究结果表明,使用多时相和多极化的 SAR 数据进行作物分类可以取得较高精度,因此 SAR 数据在作物分类研究上具有重大意义^[21]。由于光学遥感影像的质量无法得到保证,一定程度上限制了利用光学遥感影像对作物的分类,因此本研究选择 Sentinel-1A 影像作为数据源。

与前人基于全生育期 SAR 数据对作物进行分类的研究不同,本研究主要探讨作物生育期时间窗的优化对作物分类的影响。优化作物生育期时间窗可以获得最优的作物分类结果,确定作物生长周期内哪个生育期对作物分类更重要,减少对整个作物生长周期影像数据的需求,降低数据冗余并提高分类精度。

本研究拟选取原阳县玉米和水稻关键生育期的 Sentinel-1A 影像,对其进行穷举组合,使用随机森林算法对上述所有影像组合方案进行分类,根据分类结果优选玉米、水稻分类最佳时间窗,以期 Sentinel-1A 影像在玉米、水稻种植结构监测研究中的应用提供理论依据。

1 材料与方法

1.1 研究区概况

本研究以原阳县为研究区,其地处河南北部(北纬 34°55'~35°11',东经 113°36'~114°15'),区域总面积 1 022 km²。原阳县地处黄河北岸,是河南省玉米和水稻的主要产区之一,该地区为温带季风气候,夏季和早秋多阴雨天气。研究区作物一年两熟,秋收作物主要为玉米和水稻,2 种作物的生长周期较为相似,图 1 为研究区地理位置图。

1.2 Google Earth Engine (GEE) 云平台与遥感数据获取

GEE 云平台是由谷歌公司开发的遥感云计算处理平台,该平台可以对全球尺度的遥感影像进行可视化处理与分析。GEE 云平台具有以下优势:面向大众

的公益平台;使用简单,无需配置复杂的设备;数据处理迅速。GEE 云平台在作物分类研究中具有巨大潜力^[22-23]。

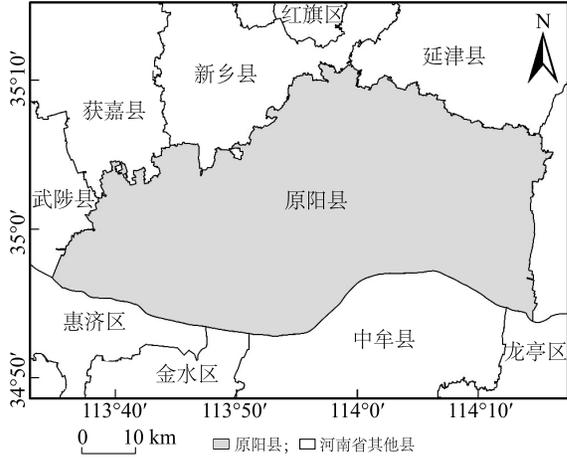


图1 研究区地理位置

Fig.1 Geographical location of the study area

Sentinel-1A 雷达卫星是欧洲航天局哥白尼计划中的地球观测卫星,具有双极化、重访周期短等优势^[11-15]。GEE 云平台中的 Sentinel-1A 影像已使用 Sentinel-1 工具箱进行过预处理,预处理包括:轨道矫正、热噪声去除、相干斑滤波、辐射定标和地形矫正。在 GEE 云平台中使用少量代码即可对预处理过的 Sentinel-1A 影像进行处理和分析。Sentinel-1A 影像的基本参数见表 1。

表1 Sentinel-1A 影像的基本参数

Table 1 Basic parameters of Sentinel-1A image

参数	基本设置
工作模式	干涉宽幅模式 (IW)
极化方式	垂直发送和垂直接收 (VV)、垂直发送和水平接收 (VH)
数据类型	地距多视 (GRD)
像元大小	10×10
成像方式	升轨模式

本研究选取了研究区 6 月到 9 月作物关键生育期的 Sentinel-1A 影像。表 2 列出了作物关键生育期及其对应的影像获取时间,并对不同时期影像进行标记。

1.3 样本数据获取

2020 年 8 月,在研究区进行野外调查记录,使用中海达 V30 型 GPS 采样,并结合目视解译 Google Earth 高分辨率影像,选出精确可靠的样本数据。将地物分为 5 大类:玉米、水稻、其他植被(树林、草地

等)、建筑(道路、裸地等)和水体(人造湖、河流等)。本研究共获取 2 090 个样本数据,其中水稻 455 个、玉米 464 个、水体 383 个、建筑 408 个、其他植被 380 个。将样本数据随机划分为训练集和验证集,其中约 80% 的样本数据用作构建训练集;约 20% 的样本数据用作构建验证集。

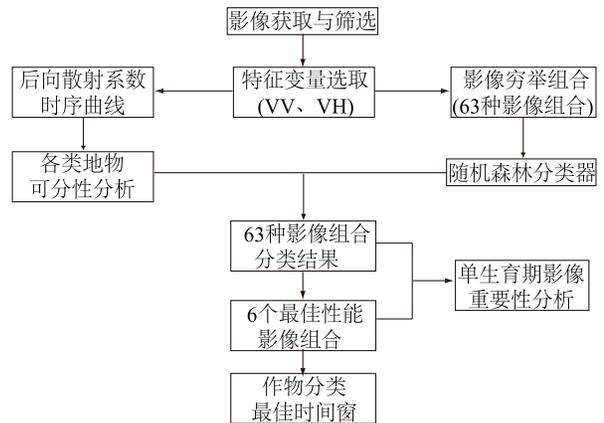
表2 研究区作物生育期及影像获取时间

Table 2 Crop growth period and image acquisition time in the study area

影像获取日期 (年-月-日)	生育期		标记
	玉米	水稻	
2020-06-14	出苗期	移栽期	A
2020-07-08	三叶期	分蘖期	B
2020-08-01	大喇叭口期	拔节期	C
2020-08-13	开花期	抽穗期	D
2020-09-06	乳熟期	灌浆期	E
2020-09-18	成熟期	成熟期	F

1.4 试验方法

首先选取研究区作物关键生育期的 Sentinel-1A 影像,通过分析各类地物的后向散射系数时序变化特征,探讨各类地物的可分性;然后对各单生育期影像进行穷举组合,采用随机森林算法对上述所有影像组合进行分类,分析各生育期影像对作物分类的重要性,优选作物分类最佳时间窗。技术流程见图 2。



VV:垂直发送和垂直接收;VH:垂直发送和水平接收。

图2 技术流程图

Fig.2 Technology flow chart

1.4.1 特征变量数据集 在作物生长周期内,作物的后向散射特性会随着作物的生长发生变化,因此利用极化特征进行作物识别可以取得良好的效

果^[24-25]。本研究选取 Sentinel-1A 影像 VV 和 VH 这 2 种极化方式的极化特征,这 2 种极化特征在作物分类方面有广泛的应用场景^[26-27]。

1.4.2 影像数据穷举组合 对作物各生育期 Sentinel-1A 影像进行穷举组合。每种数量影像组合的个数可以用公式(1)计算:

$$C_n^m = \frac{A_n^m}{m!} = \frac{n!}{m!(n-m)!} \quad (1)$$

所有影像组合的数量(C_{All})用公式(2)计算:

$$C_{All} = \sum_{m=1}^n C_n^m \quad (2)$$

式中 m : 影像组合中单期影像个数(取 1~6);
 n : 所有单期影像数量(取 6)。

1.4.3 分类方法 本研究采用随机森林算法进行分类,在诸多遥感分类方法中,随机森林算法应用广

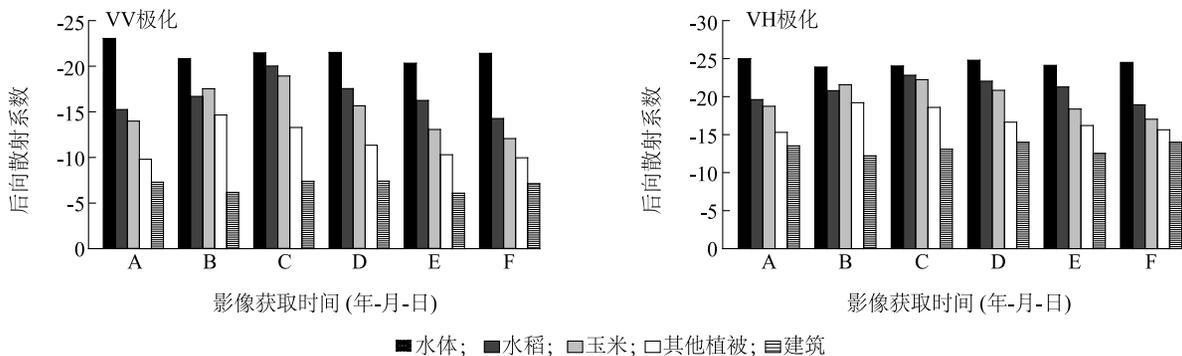
泛,分类效果较优^[28-31]。以往研究结果表明,随机森林决策树为 50 时分类精度高,运算效率高,因此本研究设置决策树数量为 50^[32]。

1.4.4 精度评定指标 为有效评估不同影像组合的分类结果,本研究采用总体精度(OA)、Kappa 系数、用户精度和生产者精度^[33]对分类结果进行综合性分析和评估。

2 结果与分析

2.1 后向散射系数时序曲线分析

绘制研究区内各类地物 VV 极化、VH 极化后向散射系数时序曲线(图 3),通过分析各类地物的后向散射系数变化探究各类地物的可分性。



VV:垂直发送和垂直接收;VH:垂直发送和水平接收。A:2020-06-14;B:2020-07-08;C:2020-08-01;D:2020-08-13;E:2020-09-06;F:2020-09-18。

图3 各类地物后向散射系数时序曲线

Fig.3 Time series curve of backscattering coefficient of various ground objects

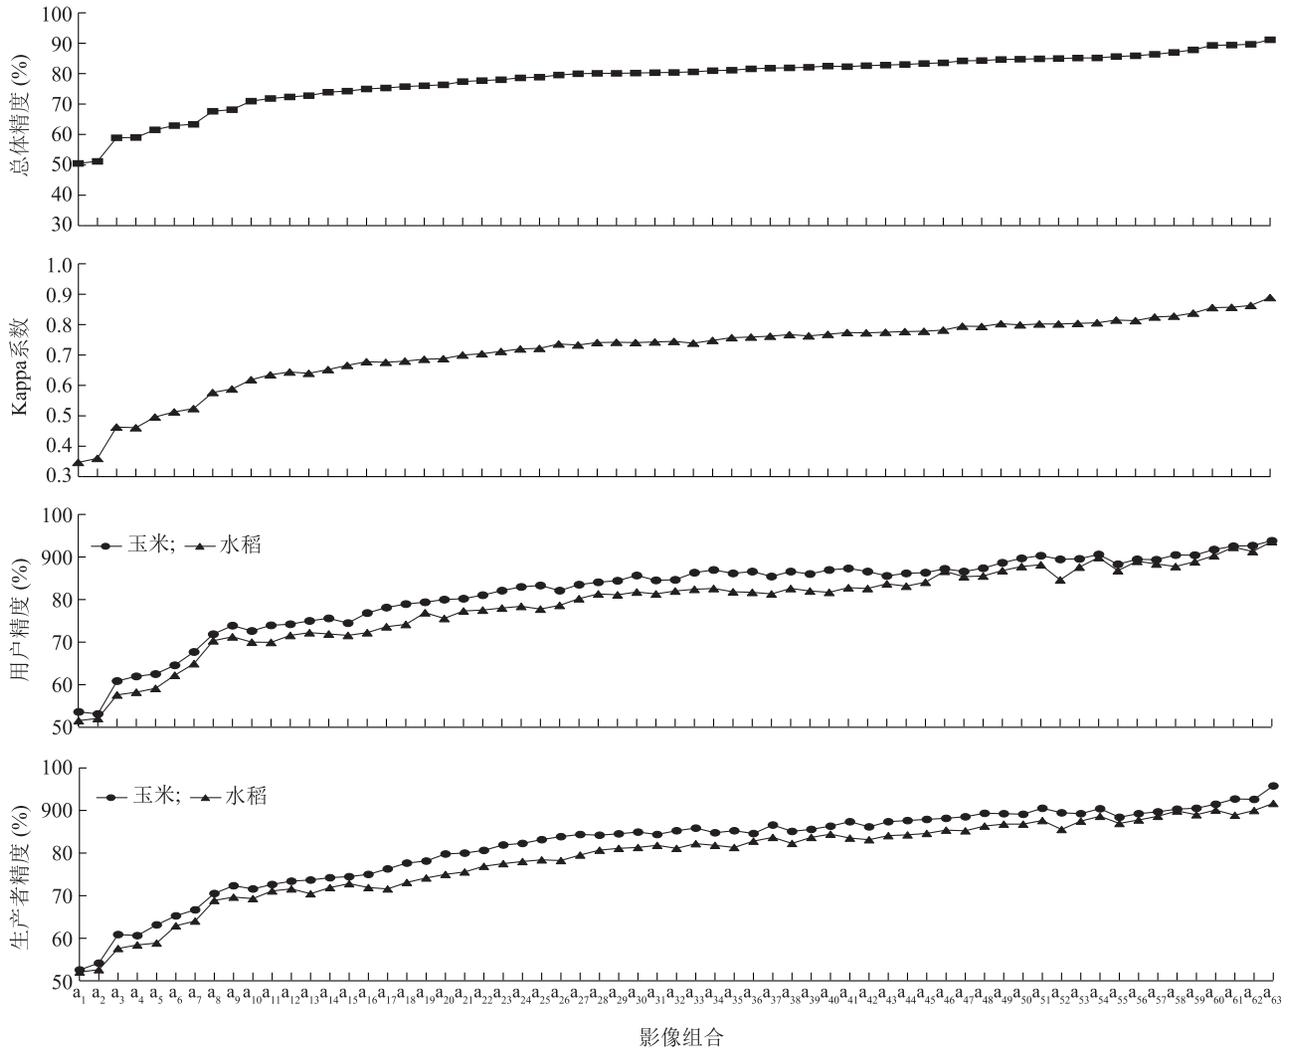
不同地物的后向散射系数存在较大差异,其中建筑的后向散射系数最大,水体的后向散射系数最小,这 2 种地物的后向散射系数在不同时间均没有太大变化;其他植被的后向散射系数先降低后升高,7 月 8 日降至最低,然后开始升高;玉米和水稻的后向散射系数先降低后升高,8 月 1 日降至最低,然后开始升高,9 月 18 日升至最高。2 种作物的后向散射系数前期差异较小,后期差异较大,玉米后期的后向散射系数比水稻高。表明利用极化特征对作物进行分类具有较好的可分性。

分析各类地物的极化特征时序曲线,可以得到以下结论:①2 种作物的后向散射系数先降低后升高,这是因为作物播种后,前期植株矮小、密度较低,此时土壤的散射作用占据主导地位,后向散射系数较高。随着作物生长,作物覆盖度逐渐升高,冠层散射作用逐渐增强,后向散射系数随冠层密度的增加逐渐变小,玉米的大喇叭口期、水稻的拔节期降至最低。之

后进入作物生长后期,由于果实的生成,叶片逐渐衰老,植被含水率逐渐降低,使土壤的散射作用逐渐增强,后向散射系数逐渐升高。②随着时间的推移,2 种作物之间的后向散射系数差异逐渐明显,并且玉米的后向散射系数高于水稻。这是因为玉米、水稻种植环境不同,2 种作物的地质差异较大,玉米种植地含水率较小,水稻种植地含水率较大,尽管 2 种作物在生长后期含水率都呈下降趋势,但是受地质影响,玉米含水率始终低于水稻,以致玉米的后向散射系数较高且随着生育期的推移与水稻差异逐渐增大。因此,玉米和水稻后期的分类效果相较于前期会更好。

2.2 最佳时间窗分析

对 6 期影像进行穷举组合,共计 63 种组合,所有影像组合的 OA、Kappa 系数以及 2 种作物的用户精度、生产者精度(以总体精度为基准,从小到大排序)见图 4。



影像组合

a₁: A; a₂: B; a₃: C; a₄: AB; a₅: D; a₆: F; a₇: AC; a₈: AD; a₉: E; a₁₀: BC; a₁₁: BD; a₁₂: AF; a₁₃: AE; a₁₄: BF; a₁₅: ABC; a₁₆: CD; a₁₇: ABD; a₁₈: BE; a₁₉: CF; a₂₀: ABF; a₂₁: DF; a₂₂: ACD; a₂₃: CE; a₂₄: ABE; a₂₅: DE; a₂₆: BCD; a₂₇: ACF; a₂₈: ACE; a₂₉: ADF; a₃₀: EF; a₃₁: ADE; a₃₂: BCF; a₃₃: ABCD; a₃₄: BCE; a₃₅: BDF; a₃₆: BDE; a₃₇: AEF; a₃₈: ABCF; a₃₉: CDF; a₄₀: BEF; a₄₁: ABCE; a₄₂: ABDF; a₄₃: CDE; a₄₄: ACDF; a₄₅: ABDE; a₄₆: CEF; a₄₇: ABCDF; a₄₈: ABEF; a₄₉: ABCDE; a₅₀: ACDE; a₅₁: BCDF; a₅₂: ACEF; a₅₃: BCDE; a₅₄: ABCEF; a₅₅: DEF; a₅₆: ABDEF; a₅₇: ADEF; a₅₈: ACDEF; a₅₉: ABCDEF; a₆₀: BCEF; a₆₁: BDEF; a₆₂: BCDEF; a₆₃: CDEF。A~F 见表 2。

图 4 影像组合的各项评定指标

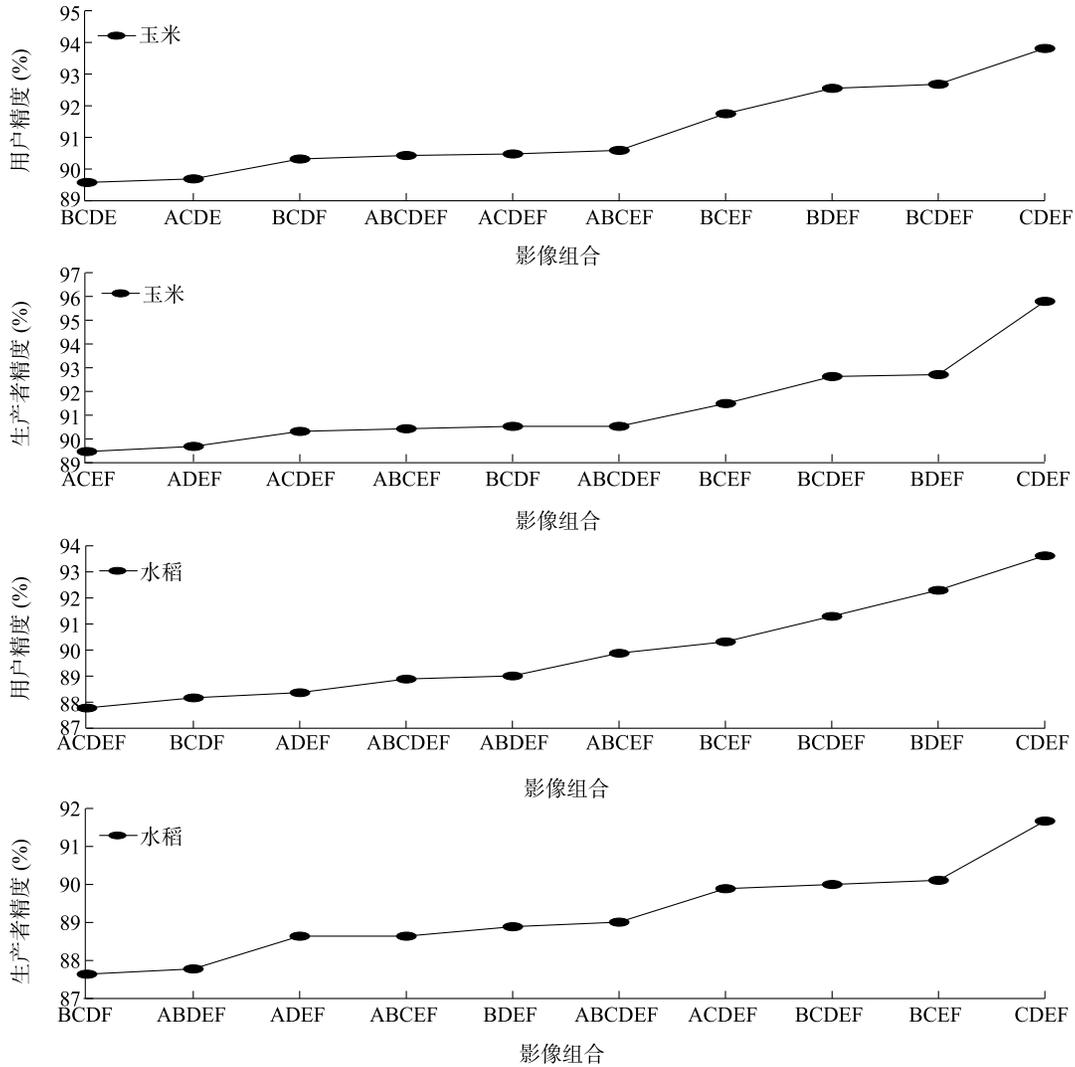
Fig.4 Various evaluation indices of image combination

图 4 显示,基于影像数量多的组合对作物进行分类,其分类精度不一定比影像数量少的组合高。3 期中后期影像组合 DEF 相较于 4 期前中期影像组合 ABCD,玉米的用户精度和生产者精度分别提高了 1.98 个百分点和 2.55 个百分点,水稻的用户精度和生产者精度分别提高了 4.39 个百分点和 4.74 个百分点;2 期后期影像组合 EF 相较于 3 期前期影像组合 ABC,玉米的用户精度和生产者精度分别提高了 11.20 个百分点和 10.48 个百分点,水稻的用户精度和生产者精度分别提高了 10.21 个百分点和 8.49 个百分点。这是因为玉米

和水稻在刚播种时,植株矮小,密度较低,未进入生长期,分类特征不明显,所以前期识别精度较低。随着玉米和水稻进入生长中期,2 种作物植株增大,冠层密度变大,特征明显,此时 2 种作物易与其他地物区分。之后玉米和水稻进入生长后期,玉米含水率比水稻低,2 种作物的后向散射系数差异逐渐增大,此时玉米和水稻易于区分。说明利用中后期影像分类效果更佳,对作物分类更重要,多生育期影像组合中添加更多的中后期影像,可以使分类器捕获更多作物类别之间的差异。

图 4 显示,2 种作物的用户精度和生产者精度均在 4 期影像组合方案 CDEF 中取得最大值。为分析其原因,统计 2 种作物用户精度和生产者精度排名前 10 的组合。图 5 显示,排名前 10 的影像组合均为 4 期及 4 期以上影像组合。排名前 10 的 4 期、5 期和 6 期影像组合的玉米平均用户精度分别为 91.28%、91.25%和 90.43%,玉米平均生产者精度

分别为 91.61%、91.13%和 90.53%,水稻平均用户精度分别为 90.56%、89.49%和 88.89%,水稻平均生产者精度分别为 89.39%、89.08%和 89.01%。排名前 10 的组合中,4 期影像组合处理 2 种作物的平均用户精度和生产者精度均为最高。由此可知,4 期影像组合分类性能达到最佳,继续增加影像会因为数据冗余导致分类精度降低。



A~F 见表 2。

图 5 玉米和水稻的用户精度、生产者精度排名前 10 组合

Fig.5 Top ten combinations of user accuracy and producer accuracy for corn and rice

分析全生育期影像组合中各单生育期影像特征变量权重,图 6 显示,不同生育期影像特征权重不同,随着作物的生长,各生育期影像特征权重整体呈上升趋势,证明了作物生长中后期影像对作物分类更重要的结论,这与周涛等^[12]的研究结果一致。E 影像的特征权重最大,其次分别是 F 影像、D 影像和

C 影像,因此 4 期影像组合中 CDEF 影像组合的分类精度最高,玉米的用户精度和生产者精度分别为 93.81%和 95.79%,水稻的用户精度和生产者精度分别为 93.62%和 91.67%。在此基础上,增加 A、B 影像的全生育期影像组合 ABCDEF 的玉米用户精度和生产者精度分别为 90.43%和 90.53%,水稻的

用户精度和生产者精度分别为 88.89% 和 89.01%, 因为数据冗余导致玉米的用户精度和生产者精度分别降低了 3.38 个百分点和 5.26 个百分点, 水稻的用户精度和生产者精度分别降低了 4.73 个百分点和 2.66 个百分点。

统计不同影像数量组合的 OA、Kappa 系数以及 2 种作物用户精度、生产者精度的最大值。结果(图 7)表明, 影像数量 1 至 6 个最佳性能组合分别为 E、EF、DEF、CDEF、BCDEF、ABCDE, 其特点是都包含了中后期影像。

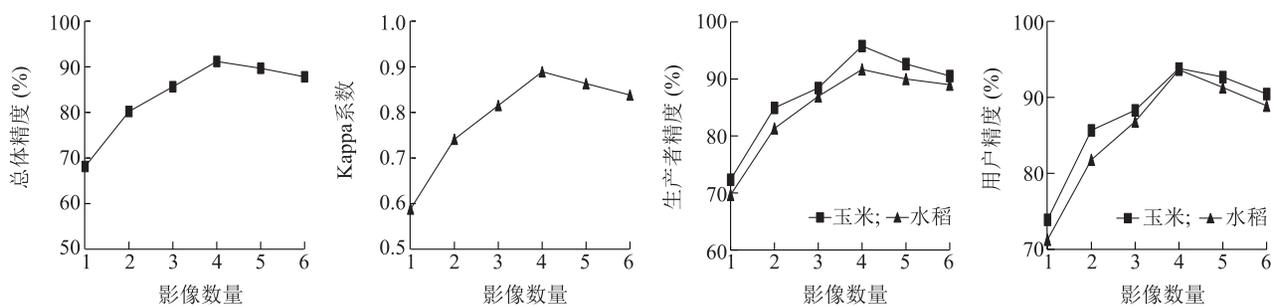


图 7 不同影像数量组合的各项评定指标最大值
Fig.7 Maximum value of each evaluation index for different number of image combinations

统计最佳性能组合中单期影像出现的频数, 表 3 显示, 影像 E(对应玉米的乳熟期, 水稻的灌浆期)出现的频数最高, 其次是影像 F 和影像 D, 进一步证明作物生长中后期影像对作物分类更重要。

表 3 不同生育期影像出现的频数

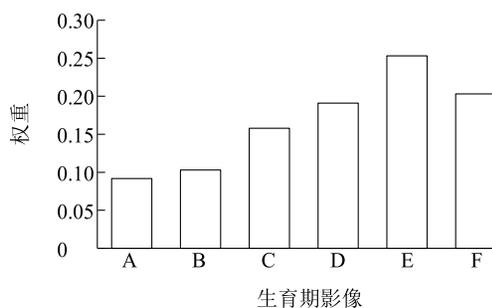
Table 3 Image marking frequency at different growth stages

影像	A	B	C	D	E	F
频数	1	2	3	4	6	5

A~F 见表 2。

2.3 分类结果

2.3.1 典型区域分类结果分析 选择包含 5 种地物类型的典型区域, 将上述 6 个最佳性能组合的分类结果进行对比分析。其中绿色为玉米, 红色为水稻, 白色为其他地物。结果(图 8)表明, 单生育期 Sentinel-1A 影像和多生育期 Sentinel-1A 影像在作物分类方面存在较大差异。单生育期影像 E 存在严重的错分和漏分, 很难区分玉米和水稻; 所提取的玉米和水稻较为破碎, 零碎的种植地块提取效果较



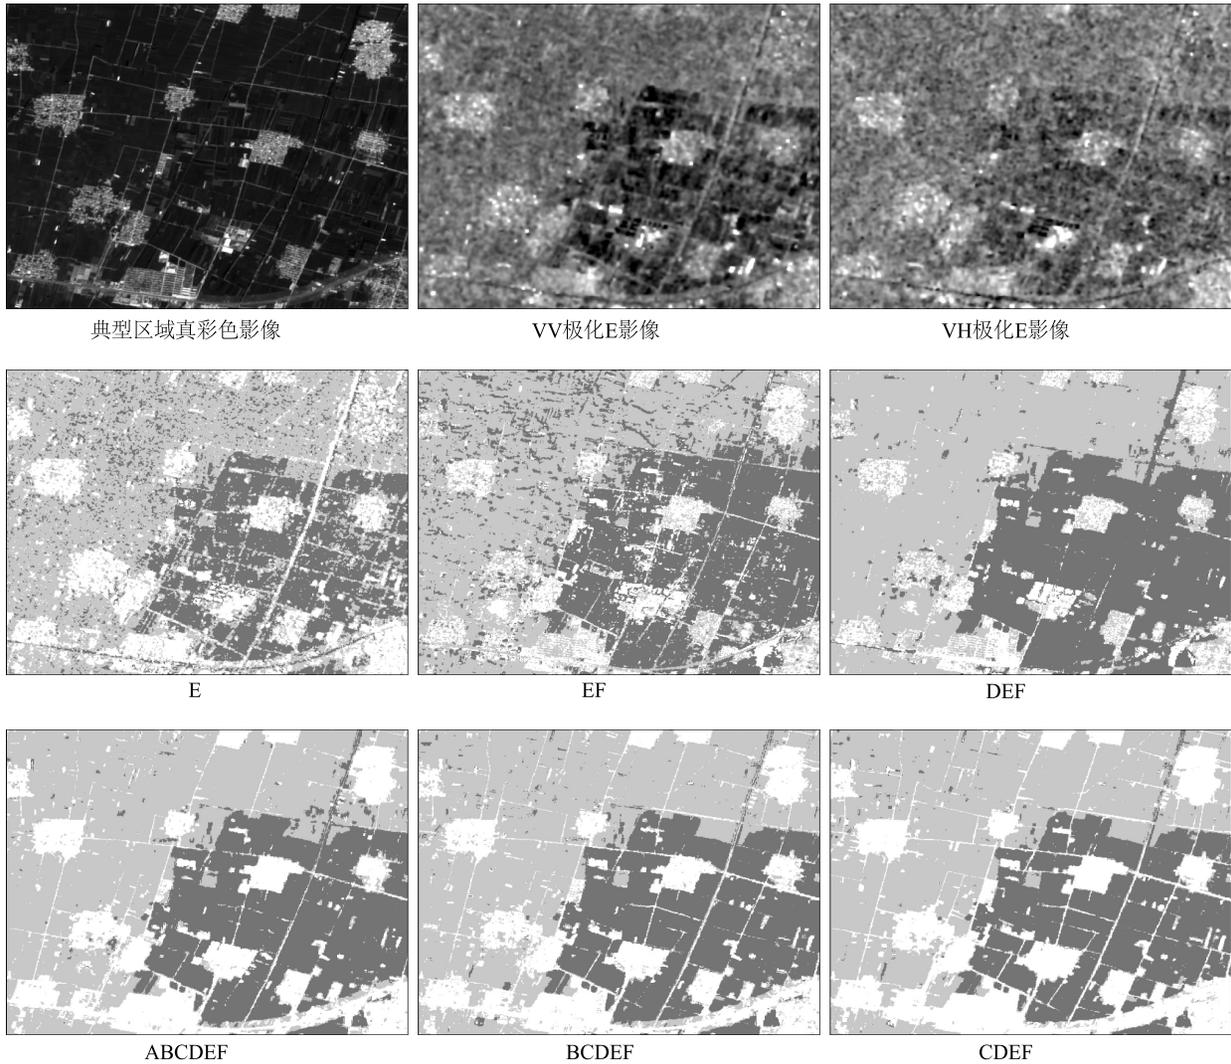
A~F 见表 2。

图 6 各生育期影像特征权重

Fig.6 Feature weight of images in each growth period

差; 受椒盐噪声影响, 在此分类结果中, 水稻呈散落分布。这与单生育期 Sentinel-1A 影像包含的散射信息较少且玉米和水稻的极化特征相似有关。说明单生育期 Sentinel-1A 影像在作物分类研究中存在一定的局限性。

相较于单生育期影像, 多生育期影像组合分类结果得到明显改善。EF 影像组合的玉米和水稻分类结果较为粗糙; DEF 影像组合的椒盐噪声明显减少, 但仍存在部分道路旁的林地被误分为作物的现象, 导致道路很难完整地提取出来; ABCDEF 影像组合的玉米和水稻之间的边界逐渐明显, 所提取的玉米和水稻种植地块较为完整; BCDEF 影像组合中比较窄的道路被提取出来, 分类效果进一步提升; CDEF 影像组合中的种植规整、大面积的玉米和水稻地块完全分离, 零碎的种植地块也被提取出来, 其分类结果与目视解译结果最为接近, 且分类效果最好。这是因为多生育期 Sentinel-1A 影像具有更多的分类特征, 包含的散射信息也更多。因此, 多生育期 Sentinel-1A 影像分类效果更好。



A~F 见表 2。VV:垂直发送和垂直接收;VH:垂直发送和水平接收。

图 8 典型区域真彩色影像、VV 极化影像、VH 极化影像及分类结果对比

Fig.8 Comparison of true color image, VV polarization image, VH polarization image and classification results of typical areas

2.3.2 研究区作物空间分布情况 4 期影像组合 CDEF 的分类效果最好,玉米、水稻的用户精度和生产者精度最高,因此选取玉米大喇叭口期至成熟期为玉米分类最佳时间窗,选取水稻拔节期至成熟期为水稻分类最佳时间窗。基于 4 期影像组合 CDEF 绘制原阳县玉米和水稻的空间分布图(图 9),玉米种植广泛,在全县都有种植,主要种植在适合大规模灌溉和机械化的土地上。原阳县是河南省水稻重要的生产、加工基地,因此水稻主要集中在城市周边和交通发达的地区,其余地区种植较为零散。表 4 显示,玉米的用户精度和生产者精度高于水稻的用户精度和生产者精度,这是因为研究区内玉米种植面积较大,地块较为规整,分类效果较好;水稻的种植规模较小,地块较为破碎,影像中存

在较多的混合像元,因此分类精度低于玉米。

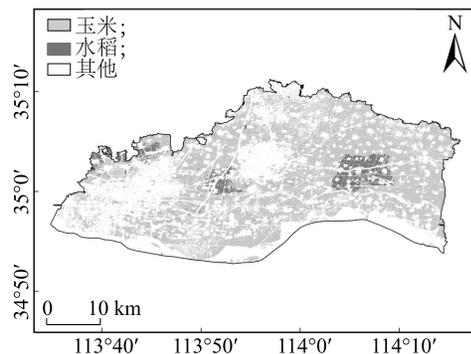


图 9 2020 年原阳县玉米和水稻的分布图

Fig.9 Distribution map of corn and rice in Yuanyang County in 2020

表 4 CDEF 影像组合混淆矩阵

Table 4 CDEF image combination confusion matrix

地物类型	分类结果						生产者精度 (%)	总体精度 (%)	Kappa 系数
	玉米	水稻	水体	建筑	其他植被	总数			
玉米	91	1	0	0	3	95	95.79	91.15	0.889
水稻	2	88	1	0	5	96	91.67		
水体	0	1	74	1	1	77	96.10		
建筑	1	0	1	68	6	76	89.47		
其他植被	3	4	0	7	60	74	81.08		
总数	97	94	76	76	75	418			
用户精度 (%)	93.81	93.62	97.37	89.47	80.00				

3 结论

后向散射系数时序曲线分析结果表明,玉米、水稻与其他地物的后向散射系数差异明显;在玉米和水稻的生长过程中,后向散射系数前期差异较小,后期差异较大,为玉米和水稻的分类提供了理论依据。

不同生育期的 Sentinel-1A 影像对作物分类的效果存在差异,通过对 63 种影像组合和 6 个最佳性能影像组合分析可知,作物生长中后期的影像对作物分类更重要,多生育期影像组合中添加更多的中后期影像分类效果更好。

全生育期的影像组合并非最优分类组合,优选出的玉米和水稻分类最佳时间窗影像组合相较于全生育期影像组合,2 种作物的用户精度和生产者精度均得到了不同程度的提升。这说明增加影像数量在一定程度上可以提高分类精度,但是过多的分类特征会引起数据冗余,影响分类效果。优选作物分类最佳时间窗可以减少对作物整个生长周期时间序列数据的需求,有效降低数据冗余并提高分类精度。

参考文献:

- [1] 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.
- [2] 宋宏利,雷海梅,尚明. 基于 Sentinel2A/B 时序数据的黑龙江流域主要农作物分类[J]. 江苏农业学报, 2021, 37(1): 83-92.
- [3] DONG Q, CHEN X, CHEN J, et al. Mapping winter wheat in north China using sentinel 2A/B data: a method based on phenology-time weighted dynamic time warping [J]. Remote Sensing,

2020, 12(8):1274.

- [4] 李卫国. 作物旱涝灾情遥感监测进展与思考[J]. 江苏农业学报, 2013, 29(6): 1503-1506.
- [5] 王庆林,李卫国,王荣富. 基于不同时相遥感的冬小麦种植面积提取[J]. 江苏农业学报, 2014, 30(6): 1286-1291.
- [6] ZHONG L, HU L, ZHOU H. Deep learning based multi-temporal crop classification [J]. Remote Sensing of Environment, 2019, 221: 430-443.
- [7] XU F, LI Z, ZHANG S, et al. Mapping winter wheat with combinations of temporally aggregated sentinel-2 and Landsat-8 data in Shandong province, China[J]. Remote Sensing, 2020, 12(12): 2065.
- [8] 吴静,吕玉娜,李纯斌,等. 基于多时相 Sentinel-2A 的县域农作物分类[J]. 农业机械学报, 2019, 50(9): 194-200.
- [9] 蔡耀通,刘书彤,林辉,等. 基于多源遥感数据的 CNN 水稻提取研究[J]. 国土资源遥感, 2020, 32(4): 97-104.
- [10] 白燕英,高聚林,张宝林. 基于 Landsat8 影像时间序列 NDVI 的作物种植结构提取[J]. 干旱区地理, 2019, 42(4): 893-901.
- [11] LIU C, SHANG J, VACHON P, et al. Multiyear crop monitoring using polarimetric RADARSAT-2 data.[J]. IEEE Transactions on Geoscience and Remote Sensing, 2013, 51(4): 2227-2240.
- [12] 周涛,潘剑君,韩涛,等. 基于多时相合成孔径雷达与光学影像的冬小麦种植面积提取[J]. 农业工程学报, 2017, 33(10): 215-221.
- [13] 王迪,周清波,陈仲新,等. 基于合成孔径雷达的农作物识别研究进展[J]. 农业工程学报, 2014, 30(16): 203-212.
- [14] SKAKUN S, KUSSUL N, SHELESTOV A Y, et al. Efficiency assessment of multitemporal C-band Radarsat-2 intensity and Landsat-8 surface reflectance satellite imagery for crop classification in Ukraine[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2016, 9(8): 3712-3719.
- [15] 郭交,朱琳,靳标. 基于 Sentinel-1 和 Sentinel-2 数据融合的农作物分类[J]. 农业机械学报, 2018, 49(4): 192-198.
- [16] TORRES R, SNOEIJ P, GEUDTNER D, et al. GMES sentinel-1 mission[J]. Remote Sensing of Environment, 2012, 120: 9-24.

- [17] 李 俐,孔庆玲,王鹏新,等. 基于时间序列 Sentinel-1 A 数据的玉米种植面积监测研究[J]. 资源科学, 2018,40(8): 1608-1621.
- [18] 刘警鉴,李洪忠,华 璿,等. 基于 Sentinel-1A 数据的临高县旱稻面积提取[J]. 国土资源遥感, 2020, 32(1): 191-199.
- [19] FRATE F D, SCHIAVON G, SOLIMINI D, et al. Crop classification using multiconfiguration C-band SAR data[J]. IEEE Transactions on Geoscience and Remote Sensing, 2003, 41(7): 1611-1619.
- [20] ZEYADA H, EZZ M M, NASR A H, et al. Evaluation of the discrimination capability of full polarimetric SAR data for crop classification[J]. International Journal of Remote Sensing, 2016, 37(11): 2585-2603.
- [21] KUSSUL N, LAVRENIUK M, SKAKUN S, et al. Deep learning classification of land cover and crop types using remote sensing data[J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(5): 778-782.
- [22] KUMAR L, MUTANGA O. Google earth engine applications since inception: usage, trends, and potential [J]. Remote Sensing, 2018, 10(10): 1509.
- [23] PHAN T N, KUCH V, LEHNERT L W. Land cover classification using Google Earth Engine and random forest classifier—the role of image composition[J]. Remote Sensing, 2020, 12(15): 2411.
- [24] SMALL D. Flattening gamma: radiometric terrain correction for SAR imagery[J]. IEEE Transactions on Geoscience and Remote Sensing, 2011, 49(8): 3081-3093.
- [25] ALCANTARA C, KUEMMERLE T, PRISHCHEPOV A V, et al. Mapping abandoned agriculture with multi-temporal MODIS satellite data[J]. Remote Sensing of Environment, 2012, 124: 334-347.
- [26] 胡 琼,吴文斌,宋 茜,等. 农作物种植结构遥感提取研究进展[J]. 中国农业科学, 2015, 48(10): 1900-1914.
- [27] SRIKANTH P, RAMANA K V, DEEPIKA U, et al. Comparison of various polarimetric decomposition techniques for crop classification[J]. Journal of the Indian Society of Remote Sensing, 2016, 44(4): 635-642.
- [28] LAWRENCE R L, WOOD S D, SHELEY R L. Mapping invasive plants using hyperspectral imagery and Breiman Cutler classifications (RandomForest) [J]. Remote Sensing of Environment, 2006, 100(3): 356-362.
- [29] 李彬彬,谢 欢,童小华,等. 基于随机森林的 ICESat-2 卫星数据地表覆盖分类[J]. 红外与激光工程, 2020, 49(11): 115-121.
- [30] 刘 毅,杜培军,郑 辉,等. 基于随机森林的国产小卫星遥感影像分类研究[J]. 测绘科学, 2012, 37(4): 194-196.
- [31] LOOSVELT L, PETERS J, SKRIVER H, et al. Random forests as a tool for estimating uncertainty at pixel-level in SAR image classification[J]. International Journal of Applied Earth Observation and Geoinformation, 2012, 19: 173-184.
- [32] 郭群佐,邓荣鑫,魏义长,等. 河南省原阳县引黄灌区水稻田信息提取研究[J]. 湿地科学, 2021, 19(1): 40-46.
- [33] 马战林,刘昌华,薛华柱,等. GEE 环境下融合主被动遥感数据的冬小麦识别技术[J]. 农业机械学报, 2021, 52(9): 195-205.

(责任编辑:王 妮)