doi:10.6041/j.issn.1000-1298.2024.09.022

基于不同时间尺度与特征优选的黄淮海平原冬小麦识别

周俊伟[1,2]　冯　浩[1,3]　董勤各[1,3]

(1. 中国科学院教育部水土保持与生态环境研究中心(中国科学院水利部水土保持研究所),陕西杨凌 712100;
2. 中国科学院大学,北京 100049;3. 西北农林科技大学水土保持科学与工程学院,陕西杨凌 712100)

摘要:准确及时地监测区域作物种植面积对保障我国粮食安全和农业可持续发展具有重要意义。本研究利用 Google Earth Engine(GEE)云平台和融合的 Sentinel-1 SAR 雷达影像与 Sentinel-2 SR 地表反射率影像,对黄淮海平原 2021 年冬小麦进行了监督分类。通过对 Sentinel 时间序列数据进行不同时间尺度合成与平滑处理,并对极化特征、光谱特征、植被指数、谐波系数和纹理特征进行优选,以探究不同时间尺度的影像序列及特征优选对黄淮海平原冬小麦识别精度和泛化能力的影响。结果表明:特征优选过程可以提高模型分类精度,在各类特征因子中,光谱特征重要性最高,其次为谐波系数、极化特征和纹理特征。随着影像序列时间尺度的缩减,可以得到更高的分类精度,尺度 30、20、10d 平均总体精度分别为 95.4%、95.6% 和 96.4%;但泛化能力也随之降低,对应的泛化能力分别为 0.935、0.919 和 0.918。短时间尺度影像序列能够更准确地捕获地物的特征细节,展现出更高的分类精度,但其对数据变化的适应能力更差。此外,模型泛化能力在空间上呈现"越近越相关"的规律。利用 GEE 平台及 Sentinel 系列卫星遥感数据,实现了对黄淮海平原冬小麦面积的准确识别。整体上,混淆矩阵总体精度(OA)和 F1 值均在 90% 以上,分类结果在空间细节上与高分辨率图像高度一致,同时提取的冬小麦种植面积与市级官方统计数据高度相关(决定系数 $R^2>0.9$)。

关键词:冬小麦;遥感识别;Google Earth Engine;随机森林;时间尺度;特征优选

中图分类号:S127;TP79　　**文献标识码**:A　　**文章编号**:1000-1298(2024)09-0262-13　　**OSID**:

Identification of Winter Wheat in Huang-Huai-Hai Plain Based on Different Time Scales and Feature Preference

ZHOU Junwei[1,2]　FENG Hao[1,3]　DONG Qin'ge[1,3]

(1. *The Research Center of Soil and Water Conservation and Ecological Environment, Chinese Academy of Sciences and Ministry of Education (Institute of Soil and Water Conservation, Chinese Academy of Sciences and Ministry of Water Resources), Yangling, Shaanxi* 712100, *China*
2. *University of Chinese Academy of Sciences, Beijing* 100049, *China*
3. *College of Soil and Water Conservation Science and Engineering, Northwest A&F University, Yangling, Shaanxi* 712100, *China*)

Abstract: Monitoring regional crop acreage accurately and promptly is critical for ensuring food security and promoting sustainable agricultural development in China. The Google Earth Engine (GEE) cloud platform, along with fused Sentinel-1 SAR radar and Sentinel-2 SR surface reflectance imagery were employed to classify winter wheat in 2021 within the Huang-Huai-Hai Plain. The Sentinel time series data were synthesized and smoothed across various temporal scales, and a prioritization of polarization features, spectral features, vegetation index, harmonic coefficients, and textural features were conducted to explore their impacts on the accuracy and generalization ability of winter wheat identification in the region. The results showed that the feature optimization process improved the classification accuracy of the model, and the spectral features were the most significant, followed by harmonic coefficients, polarization, and textural features. Reducing the time scale of image sequences led to higher classification accuracy, with overall accuracies of 95.4%, 95.6%, and 96.4% for 30 d, 20 d and 10 d scales, respectively. However, this also resulted in a decrease in generalization ability, with corresponding scores of 0.935, 0.919, and

收稿日期:2024-05-19　修回日期:2024-06-11

基金项目:国家自然科学基金项目(51879224、51609237)

作者简介:周俊伟(1999—),男,硕士生,主要从事农业遥感研究,E-mail:zhoujunwei22@mails.ucas.ac.cn

通信作者:董勤各(1982—),男,副研究员,博士,主要从事节水灌溉方法与技术研究,E-mail:qgdong2011@163.com

0.918. Shorter time scales captured finer details of ground features, achieving higher classification accuracy but showing less adaptability to data variations. Moreover, the model's generalization ability demonstrated a spatial pattern of 'the closer it was, the more relevant they were'. The identification of winter wheat areas using the GEE platform and Sentinel imagery was highly accurate, with overall accuracy and F1 scores of the confusion matrix exceeding 90%, and classification results were highly consistent in spatial detail with high-resolution images. Furthermore, the estimated areas of winter wheat showed a strong correlation with official municipal statistics (coefficient of determination $R^2 > 0.9$).

Key words: winter wheat; remote sensing imagery identification; Google Earth Engine; random forest; time scale; feature preference

0　引言

小麦作为我国重要的粮食作物,在全国各地广泛种植,其生产能力对全国粮食安全具有重要意义[1]。近年来,随着全球气候变暖、降水模式变化以及极端天气频率的增加,气候变化已严重影响到我国粮食安全[2]。而作为我国重要粮食生产基地之一的黄淮海平原,其冬小麦种植面积占全国冬小麦种植面积的65%以上[3],对我国粮食产能和供给平衡发挥着关键作用[4]。因此,及时准确获取黄淮海平原冬小麦种植面积及其空间分布特征对掌握我国主要粮食作物的动态变化规律,确保国家粮食安全和农业健康发展至关重要。

传统农田监测方法特别依赖于耗时的田间调查和数据统计手段,无法满足大尺度农田监测的技术需求,也难以提供及时准确的数据[5-6]。近年来,随着遥感技术的迅速发展,尤其是高分辨率卫星遥感数据的广泛应用,区域农田监测和管理方法取得了显著进步[7]。卫星遥感影像可以提供广泛的地理覆盖信息,同时具有高时间分辨率,能够频繁地捕捉农田的动态变化,这些特征优势使得遥感技术逐渐成为区域作物种植结构调查和分析的重要手段[8]。例如,高永道等[9]以河套灌区2000—2018年的MODIS卫星归一化植被指数(Normalized difference vegetation index, NDVI)时序影像为基础,结合玉米、小麦、向日葵和番瓜的物候期特征,构建了基于阈值分割的作物识别方法,分析了研究区主要农作物种植结构的变化规律。冯权泷等[10]以Sentinel-1和Sentinel-2遥感影像为基础,通过计算极化特征、光谱特征和纹理特征,成功提取了2021年黄淮海平原的冬小麦种植面积。尽管以往研究通过高分辨率影像进行作物识别,但忽略了高分辨影像中的图像缺失问题,且未对处理长时间序列遥感影像进行深入探讨。

提高作物分类精度关键还在于分类特征值的合理选择[11]。郝鹏宇等[12]通过构建NDVI、增强植被指数Ⅱ(Enhanced vegetation index Ⅱ, EVI2)和宽范围动态植被指数(Wide range dynamic vegetation index, WRDVI)时序数据,利用地面采样点确定植被指数的参考曲线和作物提取阈值,实现了新疆地区棉花、玉米、大豆等主要农作物种植面积的自动提取。李鑫川等[13]综合考虑作物的光谱和植被指数时序特征,成功提取了黑龙江地区农场玉米、大豆、水稻种植面积。在作物类型复杂多样区域,单一NDVI或增强植被指数(Enhanced vegetation index, EVI)指数特征方法存在局限,因此越来越多的研究尝试利用多种时序特征(光谱特征、植被指数、纹理特征等)更好地捕捉各类作物的经典特性,以实现作物种植结构的精准提取[14]。然而,如何结合研究区域作物种植结构特性,从众多时序特征中选取最佳特征组合实现作物种植结构的有效提取仍是目前亟待解决的技术难题。

近年来,随着Google Earth Engine(GEE)等遥感云平台的发展,其高性能计算服务和高效计算方法已可以提供广泛和复杂的遥感分析[15]。GEE平台是目前世界上最为先进的地理信息处理与空间分析云平台,该平台存储了全球尺度长时间序列的Landsat、MODIS、Sentinel等开源数据集,具有强大的数据存储、管理以及数据处理能力[16]。因此,本研究基于GEE云计算平台对Sentinel-1和Sentinel-2遥感影像进行预处理,并探讨不同影像预处理方式对模型精度和泛化能力的影响特征。同时,在综合考虑作物光学特征、植被指数特征和纹理特征的基础上,对特征因子进行优选。进而采用随机森林算法进行监督分类,实现对黄淮海平原冬小麦种植面积和结构的精确制图,以期为确保国家粮食安全和农业健康发展提供决策依据。

1　材料和方法

1.1　研究区概况

黄淮海平原位于中国东部沿海地区(31°36′~40°29′N、112°13′~120°53′E),覆盖安徽、河北、河南、江苏、山东五省和北京、天津两大直辖市,总面积约6.2×10^5 km^2(图1)。黄淮海平原属典型的温带大陆性季风气候,年平均气温在8~15℃之间,年平

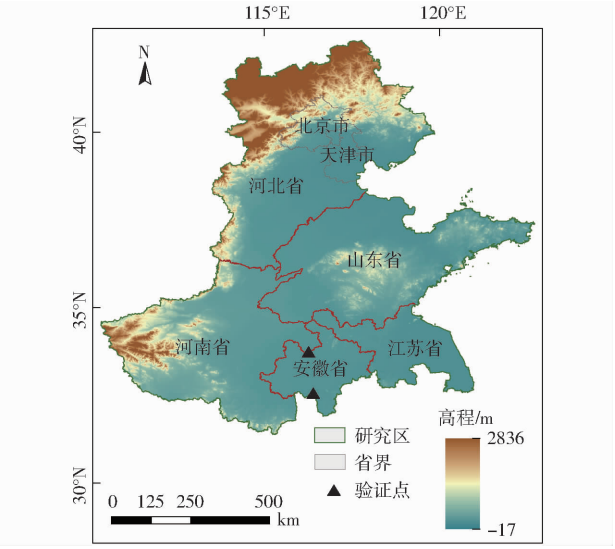

图 1 研究区概况

Fig. 1 Overview of study area

均降水量在 500 ~ 900 mm 之间[17]；土层深厚，土壤肥沃，适宜种植多种作物，包括小麦、玉米、大豆等，其中冬小麦-夏玉米轮作是主要的粮食种植制度，冬小麦于每年的 10 月下旬至 12 月播种，次年的 2 至 3 月返青，5 月下旬至 6 月上旬成熟[18]。本研究按行政边界将该研究区划分为安徽、京津冀、河南、江苏和山东 5 个地区。

1.2 数据来源及预处理

1.2.1 遥感数据及预处理

本研究使用的 Sentinel - 1 和 Sentinel - 2 卫星遥感影像来源于 Google Earth Engine(GEE)云平台(https://earthengine.google.com)，直接从 GEE 平台调用 2021 年黄淮海平原冬小麦主要生育期(12 月—次年 5 月)的 Sentinel - 1 SAR 数据(COPERNICUS/S1_GRD)和 Sentinel - 2 Level - 2A 地表反射率(Surface reflectance, SR)数据(COPERNICUS/S2_SR)。其中，Level - 2A 级数据主要包含经过辐射定标和大气校正的大气底层反射率数据。在 GEE 平台调用 Sentinel - 2 影像数据时，通过在线编写代码，实现对遥感影像预处理，主要包括批量去云、研究区裁剪、时间序列合成、线性插值和滤波处理等操作[19]。

采用 QA(Quality assurance)去云方法对 Sentinel - 2 影像进行快速去云操作。该操作基于官方提供的 QA 波段，用于掩盖云和阴影等质量低的像素。首先利用有效 Sentinel - 1 和 Sentinel - 2 观测值中位数分别生成时间间隔 10、20、30 d 的时间序列数据集[20]；其次使用线性插值方法填补数据空白；最后利用已在各类均匀间隔数据中得到很好应用的 S - G 滤波去除噪声，对插值数据进行平滑处理[21]。经过一系列影像预处理，得到研究区 2020 年 12 月—2021 年 5 月的时间序列数据集，该系列数据集覆盖冬小麦主要生长季节，以研究不同时间间隔预处理对分类精度和泛化能力的影响。上述预处理技术路线如图 2 所示，Var、Svar、Shade、Sent、Savg、Prom、Maxcorr、Inertia、Imcorr1、Imcorr2、Idm、Ent、Dvar、Diss、Dent、Corr、Contrast、Asm 分别表示方差、和方差、簇阴影、和熵、和平均值、突出性、最大相

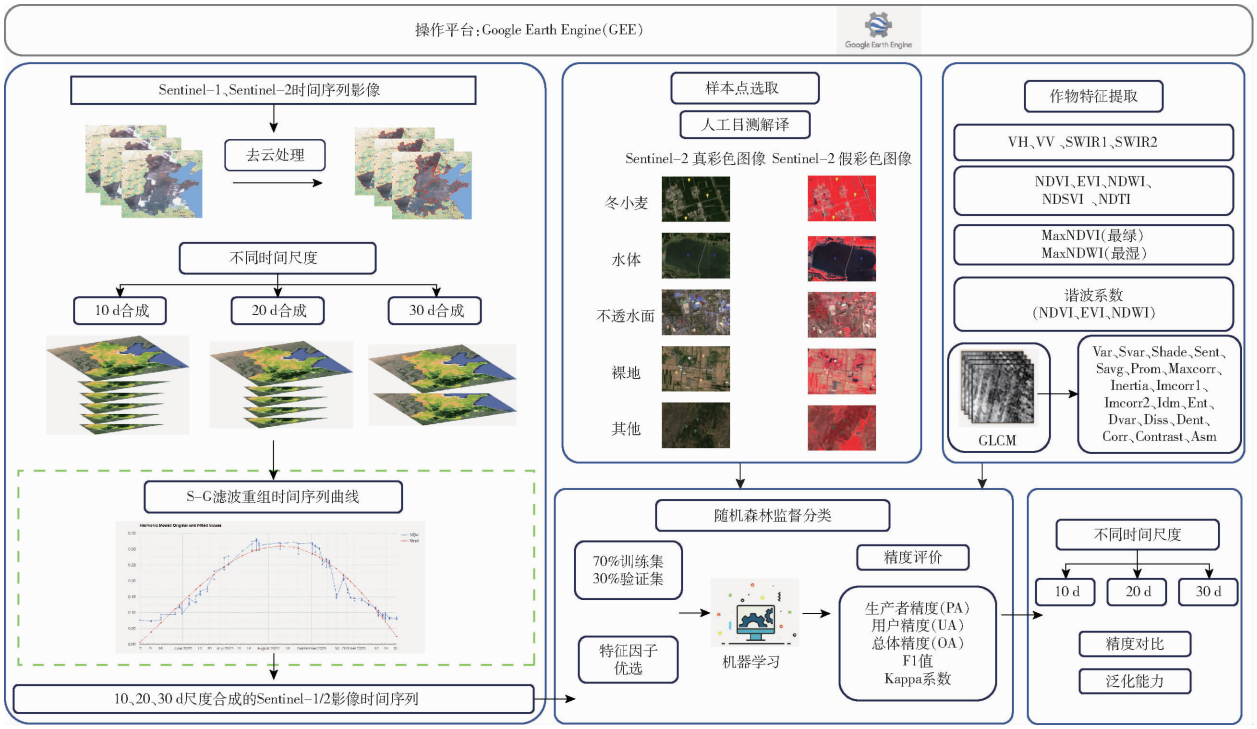

图 2 技术路线图

Fig. 2 Flow chart of proposed method

关系数、惯性、相关信息测度 1、相关信息测度 2、逆差矩、熵、差异方差、不相似度、差异熵、相关性、对比度、角二阶矩。

1.2.2　样本点及统计数据

结合地物类型分布特征，研究区域主要由冬小麦、水体、不透水面、裸地和其他（林地及其他植被）5 类地物组成。选取冬小麦返青期，即各类地物特征值差异最大的时期，作为样本选取的基础影像。通过目视解译 2021 年 3 月上旬的 Sentinel－2 影像（表 1），生成各类地物样本集，样本总数 19 433 个。京津冀地区北部和河南西部多为山区林地未进行取样，其他地区取样时遵循随机与均匀的原则（图 3）。在此基础上，利用 GEE 平台按照比例 7∶3随机将各类样本分为训练集和验证集。各地物类型样本点数量如表 2 所示。验证数据来自上述地区的 2021 年统计年鉴，利用各市冬小麦播种面积对提取结果进行验证。

表 1　目视解译

Tab. 1　Visual interpretation

地物类型	目视要点	Sentinel-2 真彩色图像	Sentinel-2 假彩色图像
冬小麦	在真彩色影像中为绿色，在假彩色影像中为红色，图像平滑，主要集中在村镇周边		
水体	在真彩色影像中为绿色，在假彩色影像中为深蓝色		
不透水面	主要包括各类建筑物和道路		
裸地	在真彩色和假彩色影像中均为土黄色		
其他	主要包括林地，在真彩色影像中为深绿色，在假彩色影像中为深红色		

1.3　特征集构建

结合 Sentinel－2 影像的 2 个反射率波段和 5 个植被指数，即短波红外波段 1（Short-wave infrared Ⅰ，SWIR1）、短波红外波段 2（Short-wave infrared Ⅱ，SWIR2）、归一化植被指数（NDVI）、增强植被指数（EVI）、归一化水体指数（Normalized difference water index，NDWI）、归一化差异衰老植被指数（Normalized difference senescence vegetation index，NDSVI）和归一化差异耕作指数（Normalized difference tillage index，NDTI），提取 NDVI 和 NDWI 最大值时的反射率波段及植被指数，利用这些特征指标进行地物分类。其中，NDVI 和 EVI 时间序列已被广泛用于提取作物特征和物候指标[22]；NDWI 可凸显影像中的水体信息[23]，易于提取水体；NDSVI 反映植物健康状态和水分状况[24]，可用于区分作物和其他植被；NDTI 用于检测农田中耕作活动的差异[25]，以区分作物和裸地。此外，利用灰度共生矩阵（Gray-level co-occurrence matrix，GLCM）计算 NDVI 和 EVI 的纹理特征，以描述不同地物类型之间的纹理差异[26]。最后，利用 3 个植被指数（NDVI、EVI 和 NDWI）的谐波系数提取时间序列曲线的时间特征[27]。

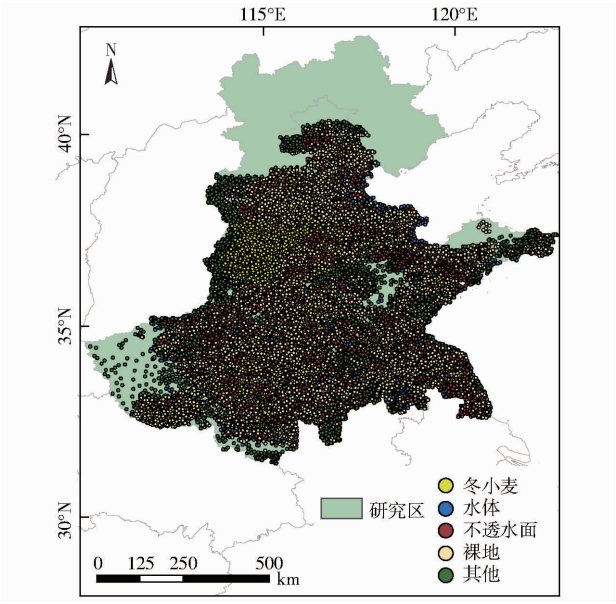

图 3　样本点空间分布

Fig. 3　Spatial distribution of sampling points

表 2　样本点数量分布

Tab. 2　Distribution of number of sample points

地区	冬小麦	水体	不透水面	裸地	其他
安徽	965	272	345	507	148
京津冀	1 099	303	542	967	465
河南	2 358	357	928	1 155	456
江苏	1 071	318	635	524	135
山东	1 841	578	1 209	1 608	647
总计	7 334	1 828	3 659	4 761	1 851

Sentinel－1 SAR 卫星主要基于微波遥感成像技术，对云层的穿透能力强，能够弥补 Sentinel－2 光谱遥感影像受云雨影响的不足。这也将使输入的影像数据更加多样化，从而达到提高分类精度的效果[28]。本研究选取 Sentinel－1 SAR 数据的极化特征 VH 和 VV 两个特征变量。所有用于地物分类的特征如表 3 所示。

1.4　分类方法与特征因子优选

采用随机森林算法（Random forest，RF）对研究区不同地物进行监督分类。RF 算法是一种机器学习算法，因其性能稳定、效率高、适应性强、抗噪声能力优越，在遥感地物分类领域得到了广泛应用[29－30]。此外，随机森林算法不仅在分类方面表现

表 3 分类的所有特征

Tab. 3 All features used for classification

类别	特征	数量
10 d/20 d/30 d 尺度合成	VH,VV,SWIR1,SWIR2,NDVI,EVI,NDWI,NDSVI,NDTI	9 ×(19/11/7)
最大 NDVI、NDWI	SWIR1,SWIR2,NDVI,EVI,NDWI,NDSVI,NDTI	7 × 2
谐波系数	NDVI,EVI,NDWI	3 × 5
纹理特征	NDVI,EVI	2 × 18

良好,同时在选择最优特征指标方面也具有优势[31-32]。在分类前,需对 RF 算法的主要参数(决策树数量和分裂节点数)进行调整。研究表明,默认情况下,分裂节点数设置为每次分类时输入特征因子数量平方根可以获得较好的结果。因此,本研究主要优化对象为决策树数量。拟采用 10 为间隔,在 0 ~ 500 范围内进行网格搜索,选择总体精度最大时的决策树数量作为最优参数设置。在经过测试的不同时间间隔(10、20、30 d)处理下,决策树数量分别设置为 150、50 和 80(图 4)。

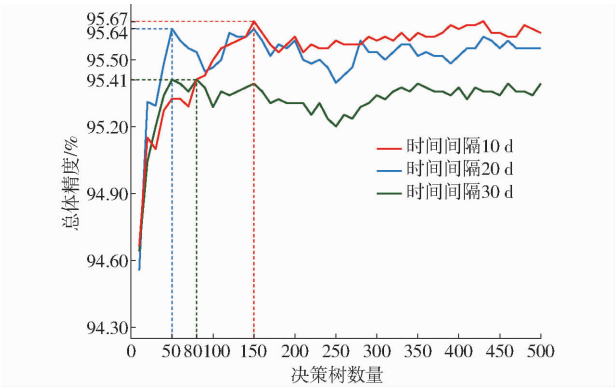

图 4 决策树数量优化

Fig. 4 Optimizing number of decision trees

特征选择在很大程度上决定机器学习的识别精度和计算效率,选取最优特征组合可以显著减少计算成本和数据冗余,避免模型过度拟合,特别是在处理大量特征值时效果更为明显[33]。然而,尚未知能更好地识别不同地物类型的波段范围或光谱指数。因此,为提高机器学习算法的识别精度和运行效率,本研究以 RF 算法的 Gini 系数为评价指标[34],在不同区域和不同时间间隔处理下分别对所有特征因子进行重要性分析(图 5,图中 1st ~ 19th 为第 n 个时

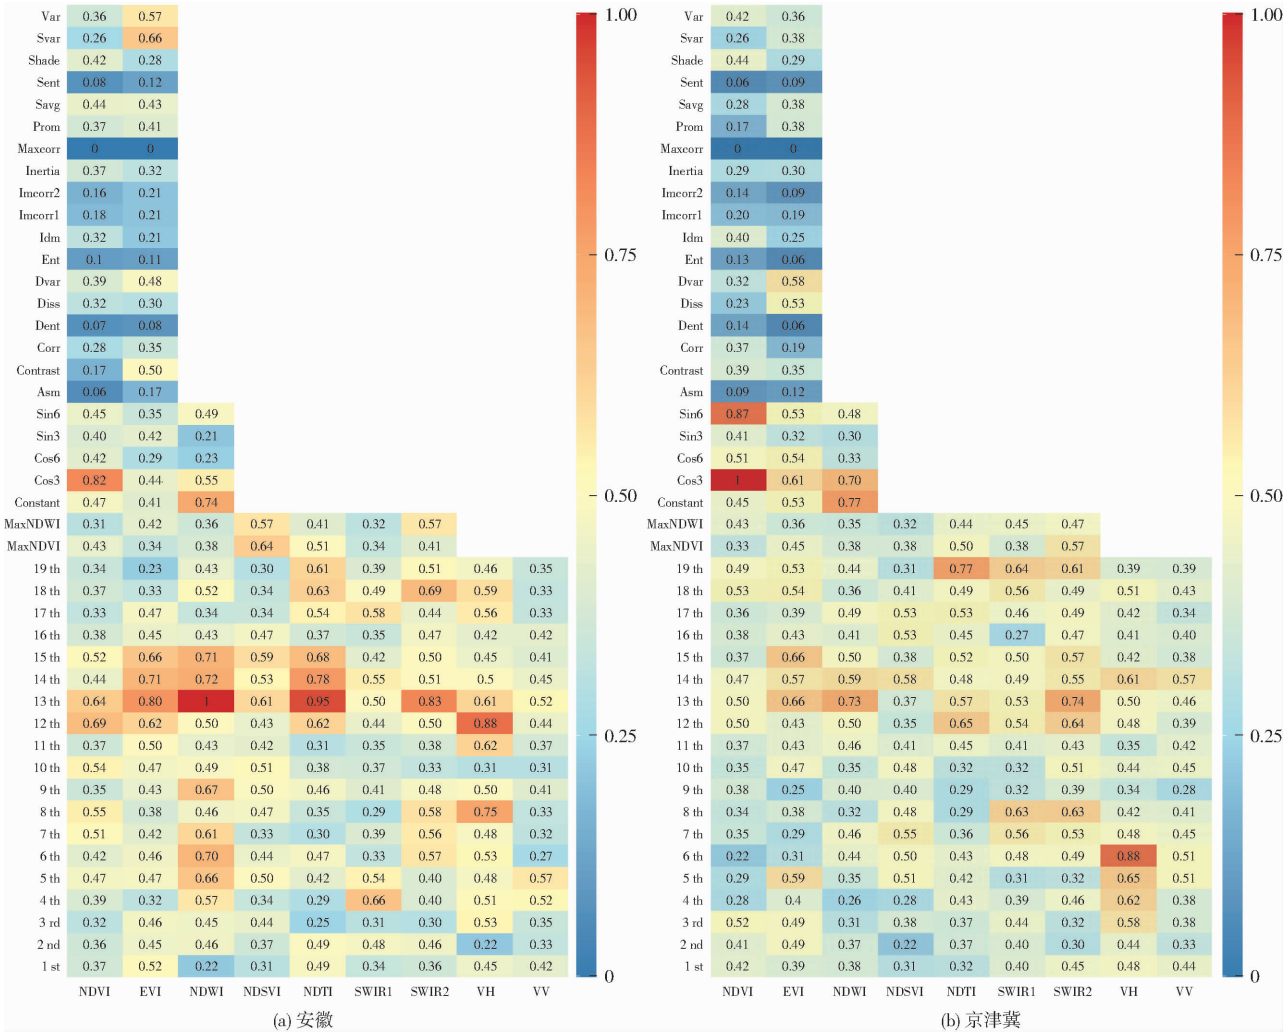

图 5 用于训练 RF 模型的特征重要性(以尺度 10 d 的安徽和京津冀地区为例)

Fig. 5 Importance of features used to train RF models (Anhui and Beijing - Tianjin - Hebei regions on a 10-day scale, for example)

间间隔；MaxNDVI 和 MaxNDWI 为最大 NDVI、NDWI；Constant、Cos3、Cos6、Sin3、Sin6 为谐波系数；Var、Svar、Shade、Sent、Savg、Prom、Maxcorr、Inertia、Imcorr1、Imcorr2、Idm、Ent、Dvar、Diss、Dent、Corr、Contrast、Asm 为纹理特征（GLCM））。此外，为降低特征因子之间的共线性，根据斯皮尔曼相关性对所有特征因子进行分层聚类，通过将阈值设定为 0.9，使其能有效地区分高度相关的特征因子，从而确保每一类特征因子间的独立性最大化[35]，将相关系数大于 0.9 的特征因子聚为一类，每类只保留重要性最大的特征因子。最后，按重要性从大到小的顺序逐一添加特征因子，当连续添加 5 个特征因子未使总体精度增大时，对应得到最高精度的特征因子组合为最优特征组。

1.5　精度评价方法

通过生成混淆矩阵，基于 30% 的验证样本对冬小麦识别结果进行精度评价，所使用的精度评价指标包括制图精度（Producer accuracy，PA）、用户精度（User accuracy，UA）、总体精度（Overall accuracy，OA）、F1 值和 Kappa 系数。然后，将提取的冬小麦面积与 2021 年各市统计年鉴内的冬小麦播种面积进行比较，以决定系数（R^2）和均方根误差（Root mean square error，RMSE）作为评价指标。

2　结果与分析

2.1　优选特征组合

首先利用 RF 算法的 Gini 系数，对所有特征因子进行重要性计算（图 5）。然后，基于 1.4 节中的特征优选过程，从不同时间间隔处理下的 128 ~ 236 个特征因子中选择 11 ~ 38 个最优特征，用于冬小麦识别（表 4）。与使用所有特征进行分类相比，除合成尺度 10、30 d 的京津冀地区和合成尺度 20 d 的江

表 4　各地区最优特征

Tab. 4　Optimal features in each region

时间间隔/d	地区	优选特征	特征数量
10	安徽	NDWI_13, NDTI_13, VH_12, swir2_13, NDVI_cos3, EVI_13, VH_8, NDWI_constant, swir2_18, NDVI_12, NDWI_9, swir1_4, EVI_h_svar, NDSVI_MaxNDVI, NDTI_18	15
	京津冀	NDVI_cos3, VH_6, NDVI_sin6, NDWI_constant, NDTI_19, swir2_13, NDWI_13, NDWI_cos3, EVI_13, NDTI_12, swir2_12, swir1_19, swir2_8, swir1_8, VH_4, swir2_19, EVI_cos3, VH_14, EVI_5, EVI_h_dvar, NDSVI_14, VV_14, swir2_MaxNDVI, NDTI_13, NDSVI_7, EVI_18	26
	河南	NDWI_8, NDVI_cos3, NDSVI_8, EVI_11, swir2_8, NDWI_9, NDSVI_19, EVI_7, NDSVI_7, EVI_5, NDWI_cos3, NDVI_9, NDSVI_11, NDWI_5, NDTI_19, NDWI_19, swir1_7, swir2_18, EVI_h_dvar, swir2_11, VV_15, VH_19, NDWI_18, VH_7, EVI_sin6, VH_9, NDSVI_2, VH_13, swir1_2, VV_12, EVI_15, NDTI_13, VH_8, NDTI_16, NDVI_19, VH_5, NDSVI_15, EVI_cos6	38
	江苏	NDVI_h_savg, swir2_13, NDWI_13, EVI_13, NDSVI_13, EVI_h_savg, swir1_19, NDWI_12, VH_12, swir2_12, VH_13, EVI_h_diss, swir1_6, NDTI_17, NDWI_8, swir2_4	16
	山东	NDVI_cos3, swir2_12, VV_12, NDWI_8, swir2_13, NDWI_constant, EVI_cos6, NDVI_7, EVI_13, NDWI_cos3, NDTI_19, NDSVI_12, NDWI_5, NDTI_13, EVI_14, VH_4, swir2_19, VH_5, NDVI_cos6, swir1_8, NDSVI_6, EVI_cos3, NDSVI_8, swir1_2, EVI_h_var, swir2_MaxNDVI, VH_14	27
20	安徽	VH_6, NDWI_6, EVI_h_savg, NDTI_6, swir2_6, NDSVI_4, VH_10, NDWI_10, swir1_3, NDVI_5, NDSVI_10, NDSVI_3, NDTI_9, VH_4, NDVI_constant, VH_6, swir1_MaxNDVI, swir1_5, NDWI_MaxNDWI	19
	京津冀	VH_7, EVI_7, swir2_7, NDWI_cos3, swir1_10, swir1_5, EVI_cos3, NDWI_constant, NDVI_cos3, NDVI_8, NDVI_3, NDSVI_11, NDVI_constant, NDWI_7, NDWI_8, NDTI_9, NDSVI_4, EVI_4, EVI_constant	19
	河南	NDSVI_5, swir2_5, NDVI_cos3, NDWI_5, NDVI_5, NDWI_cos3, NDTI_9, NDSVI_MaxNDVI, NDWI_constant, NDSVI_6, EVI_5, EVI_8, VH_5, VV_5, EVI_2, NDSVI_13	16
	江苏	EVI_7, NDVI_h_savg, swir2_7, VV_9, NDWI_constant, swir2_10, NDSVI_5, NDSVI_10, EVI_h_inertia, NDWI_5, swir2_2, NDTI_7, VH_7, swir1_4, NDTI_11, EVI_13	16
	山东	swir2_7, NDWI_7, EVI_6, NDWI_constant, NDWI_4, NDSVI_5, NDTI_10, EVI_8, NDVI_11, swir2_11, swir1_8, NDTI_7, swir2_4, NDWI_5, VV_9, NDVI_cos3, EVI_cos6, VH_7	18
30	安徽	EVI_5, NDVI_cos3, NDWI_constant, swir2_5, VH_5, NDWI_5, NDTI_5, NDVI_constant, EVI_4, VH_3, swir2_4, NDTI_4, NDTI_6, EVI_3, NDVI_h_savg, NDWI_6	16
	京津冀	NDWI_constant, NDSVI_3, swir1_3, NDVI_cos3, NDWI_3, NDTI_MaxNDVI, VH_5, NDTI_7, EVI_4, swir2_7, EVI_cos3	11
	河南	swir2_3, NDSVI_3, NDWI_constant, VV_5, NDVI_cos3, swir2_7, NDSVI_6, EVI_h_savg, NDSVI_4, EVI_4, NDVI_cos6, NDTI_5, NDWI_8, swir2_6, EVI_5, VH_3, NDTI_7, VH_5, NDSVI_6	19
	江苏	NDWI_constant, NDWI_3, swir2_5, swir2_1, NDVI_4, NDTI_4, EVI_5, NDSVI_5, NDVI_cos6, swir1_3, VH_3, VH_5	12
	山东	NDWI_3, swir2_5, NDVI_cos3, NDWI_constant, EVI_4, VH_3, swir1_8, VH_5, VV_6, NDSVI_5, VH_2, EVI_cos3, VH_6, NDSVI_6, swir2_3	15

苏地区的优选特征精度略微下降之外,其他地区特征优选后总体精度均更高(图 6)。总体上,特征选择过程不仅可以减少计算成本,还可以提高分类准确度。

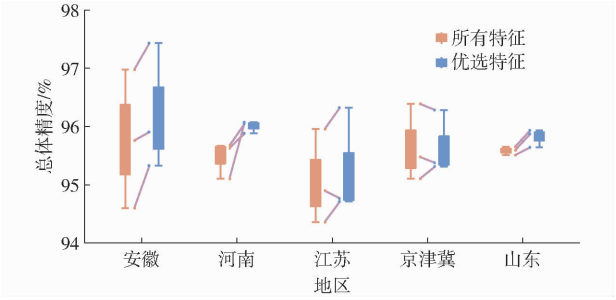

图 6 最优特征组与所有特征组分类精度对比

Fig. 6 Comparison of classification accuracy of the best feature group and all feature groups

2.2 冬小麦制图精度评价

利用混淆矩阵对地物类型进行验证(表 5)。除时间尺度 20 d 下江苏地区 OA 为 94.8% 和时间尺度 30 d 下江苏地区 OA 为 94.7% 外,其他地区 OA 均大于 95%,且时间尺度 10 d 下安徽地区 OA 最高(97.4%)。整体上平均 OA 为 95.8%,平均 Kappa 系数为 0.943。在所有地物分类中,冬小麦 PA、UA 和 F1 值平均值分别为 98.4%、97.7% 和 98.1%;水体 PA、UA 和 F1 值平均值分别为 95.9%、97.6% 和 96.7%;不透水面 PA、UA 和 F1 值平均值分别为 94.8%、95.1% 和 94.9%;裸地 PA、UA 和 F1 值平均值分别为 94.1%、94.3% 和 94.2%;其他地物 PA、UA 和 F1 值平均值分别为 98.0%、90.0% 和 89.4%。相对而言,冬小麦分类准确度最高,其次是水体、不透水面、裸地和其他地物。

在不同时间尺度处理中,10 d 合成的 OA 与 Kappa 系数平均值分别为 96.4% 和 0.951;20 d 合成为 95.6% 和 0.940;30 d 合成为 95.4% 和 0.937。具体而言,当时间尺度从 10 d 扩大至 20 d 和 30 d 时,安徽地区 OA 从 97.4% 下降至 95.9% 和 95.3%;京津冀地区从 96.3% 下降至 95.3% 和 95.4%;河南地区保持为 96.1% 然后下降至 95.9%;江苏地区从 96.3% 下降至 94.8% 和 94.7%;山东地区保持为 95.9% 然后下降至 95.6%。总体而言,随着时间尺度的增大,各地区冬小麦识别的分类精度呈现下降趋势。

为了验证分类结果,将分类结果与 Google Earth Engine 云平台的高分辨率图像进行对比(图 7a、7b 分别表示 2 个局部图像;第 1 ~4 列分别对应高分辨图像、10 d 合成尺度图像、20 d 合成尺度图像和 30 d 合成尺度图像)。从图 7 可见,分类结果在空间细节上与高分辨率图像高度一致,且农田边界较为清晰。在图 7a 的细节 1 处,时间尺度 10 d 和 20 d 的分类结果能够准确识别硬化道路,而时间尺度 30 d 则错误地将其分类为裸地。细节 2 中,位于水塘旁的冬小麦被时间尺度 10 d 正确识别,而时间尺度 20 d 和 30 d 分别错误地将其识别为不透水面和裸地。在细节 3 中,时间尺度 10 d 成功识别了水塘,而时间尺度 20 d 和 30 d 错误地识别为不透水面。在图 7b 的细节 1 中,2 块建筑大棚被时间尺度 10 d 和 30 d 正确识别,而时间尺度 20 d 则将其错误地识别为裸地。细节 2 中的水塘由时间尺度 10 d 正确识别,而时间尺度 20 d 仅识别了部分,时间尺度 30 d 则完全错误地将其识别为裸地。综上所述,不同时间尺度下的分类结果在局部细节上表现出明显差异;较短的时间尺度在地物识别方面展现了更高的准确性和空间细节的清晰度。

除利用混淆矩阵和高分辨率图像进行验证之外,本研究利用本地精度最高的时间尺度 10 d 处理方式,提取了各地区市级尺度冬小麦面积,并与各市统计数据进行比较分析,加以验证本研究冬小麦识别的可靠性(图 8)。由图 8 可知,所有地区冬小麦提取面积与统计数据高度相关($R^2 > 0.9$)。其中,河南地区统计数据相关性最强($R^2 = 0.983$),其次是山东地区、京津冀地区和安徽地区,而江苏地区统计数据相关性最差($R^2 = 0.939$)。总体而言,本研究提取的数据集与市级统计数据相比,具有可靠的准确性($R^2 > 0.9$)。

2.3 随机森林泛化实验

随机森林模型的泛化能力,也称为迁移性,是指模型对于未见过新样本的预测性能。本研究将某一地区已训练好的模型输入到另一地区的样本数据集中,通过在另一地区的总体分类精度评价模型的泛化能力(表 6)。具体地,在不同地区,通过比较在其他地区的平均精度与原始地区精度之比来衡量模型在各个地区的泛化能力。安徽、京津冀、河南、江苏、山东地区泛化能力分别为 0.875、0.921、0.915、0.950 和 0.965。除安徽地区外,随机森林模型在其他地区的迁移表现均能够保持在 90% 以上的原始预测准确度。

在不同时间间隔处理中(表 7),时间尺度 10、20、30 d 平均泛化能力分别为 0.918、0.919 和 0.935。尽管时间尺度增加会导致分类精度略微下降,但模型泛化能力相应地得到提升。其中,20 d 合成尺度模型泛化能力与 10 d 合成的十分接近,而 30 d 合成尺度模型泛化能力较 20 d 合成提升 1.6%。时间尺度从 10 d 到 30 d,泛化能力从 0.918 提升至 0.935,这表明长时间尺度更能适应不同的

表 5　地物类型制图混淆矩阵

Tab. 5　Confusion matrix of feature type maps

时间间隔/d	地区		冬小麦	水体	不透水面	裸地	其他	PA/%	UA/%	F1 值/%	OA/%	Kappa 系数
10	安徽	冬小麦	280	1	0	0	2	98.9	98.2	98.6	97.4	0.964
		水体	2	81	0	0	0	97.6	97.6	97.6		
		不透水面	1	0	97	4	1	94.2	99.0	96.5		
		裸地	0	0	1	155	2	98.1	97.5	97.8		
		其他	2	1	0	0	32	91.4	86.5	88.9		
	京津冀	冬小麦	294	2	0	2	2	98.0	96.7	97.4	96.3	0.951
		水体	3	79	0	0	0	96.3	97.5	96.9		
		不透水面	3	0	144	6	3	92.3	98.0	95.0		
		裸地	3	0	3	256	5	95.9	96.2	96.1		
		其他	1	0	0	2	134	97.8	93.1	95.4		
	河南	冬小麦	693	2	0	5	1	98.9	98.4	98.6	96.1	0.945
		水体	1	105	0	1	1	97.2	98.1	97.7		
		不透水面	0	0	263	9	4	95.3	97.4	96.3		
		裸地	6	0	7	340	10	93.7	92.6	93.2		
		其他	4	0	0	12	140	89.7	89.7	89.7		
	江苏	冬小麦	311	0	0	0	2	99.4	99.4	99.4	96.3	0.950
		水体	1	97	1	1	0	97.0	97.0	97.0		
		不透水面	0	2	181	6	1	95.3	96.3	95.8		
		裸地	1	1	6	166	3	93.8	93.3	93.5		
		其他	0	0	0	5	31	86.1	83.8	84.9		
	山东	冬小麦	546	2	3	5	2	97.8	97.7	97.8	95.9	0.947
		水体	0	170	1	0	0	99.4	96.0	97.7		
		不透水面	4	3	344	9	0	95.6	95.0	95.3		
		裸地	6	1	11	469	9	94.6	95.3	94.9		
		其他	3	1	3	9	170	91.4	93.9	92.6		
20	安徽	冬小麦	292	0	0	2	6	97.3	98.3	97.8	95.9	0.943
		水体	2	79	2	0	2	92.9	98.8	95.8		
		不透水面	0	0	105	1	1	98.1	93.8	95.9		
		裸地	0	0	3	149	2	96.8	97.4	97.1		
		其他	3	1	2	1	31	81.6	73.8	77.5		
	京津冀	冬小麦	332	0	2	2	3	97.9	96.0	96.9	95.3	0.938
		水体	4	81	1	0	1	93.1	98.8	95.9		
		不透水面	1	1	154	4	4	93.9	93.9	93.9		
		裸地	8	0	7	270	2	94.1	95.4	94.7		
		其他	1	0	0	7	139	94.6	93.3	93.9		
	河南	冬小麦	659	0	0	5	0	99.2	96.8	98.0	96.1	0.944
		水体	8	91	1	2	0	89.2	100	94.3		
		不透水面	2	0	274	7	1	96.5	95.5	96.0		
		裸地	10	0	12	311	3	92.6	93.7	93.1		
		其他	2	0	0	7	124	93.2	96.9	95.0		
	江苏	冬小麦	276	2	2	0	3	97.5	97.2	97.4	94.8	0.929
		水体	3	97	1	0	0	96.0	97.0	96.5		
		不透水面	1	1	164	4	0	96.5	91.1	93.7		
		裸地	3	0	11	141	3	89.2	95.9	92.5		
		其他	1	0	2	2	28	84.8	82.4	83.6		
	山东	冬小麦	560	2	2	1	2	98.8	98.4	98.6	95.9	0.946
		水体	0	171	2	0	0	98.8	96.6	97.7		
		不透水面	2	2	334	16	0	94.4	93.8	94.1		
		裸地	5	2	17	505	6	94.4	94.2	94.3		
		其他	2	0	1	14	196	92.0	96.1	94.0		

续表 5

时间间隔/d	地区		冬小麦	水体	不透水面	裸地	其他	PA/%	UA/%	F1 值/%	OA/%	Kappa 系数
30	安徽	冬小麦	302	0	0	1	0	99.7	96.8	98.2	95.3	0.934
		水体	2	82	0	3	1	93.2	96.5	94.8		
		不透水面	2	1	95	3	1	93.1	96.0	94.5		
		裸地	0	0	4	137	2	95.8	92.6	94.2		
		其他	6	2	0	4	37	75.5	90.2	82.2		
	京津冀	冬小麦	308	1	2	3	1	97.8	96.6	97.2	95.4	0.939
		水体	1	84	1	0	1	96.6	97.7	97.1		
		不透水面	2	0	152	3	2	95.6	91.6	93.5		
		裸地	4	0	8	269	3	94.7	95.7	95.2		
		其他	4	1	3	6	136	90.7	95.1	92.8		
	河南	冬小麦	706	1	0	5	0	99.2	98.6	98.9	95.9	0.941
		水体	3	95	1	1	1	94.1	99.0	96.4		
		不透水面	1	0	252	15	0	94.0	95.8	94.9		
		裸地	3	0	8	330	8	94.6	90.9	92.7		
		其他	3	0	2	12	108	86.4	92.3	89.3		
	江苏	冬小麦	326	4	1	1	1	97.9	98.5	98.2	94.7	0.928
		水体	0	94	0	1	0	98.9	94.0	96.4		
		不透水面	2	0	197	13	1	92.5	94.3	93.4		
		裸地	2	1	9	149	3	90.9	89.8	90.3		
		其他	1	1	2	2	40	87.0	88.9	87.9		
	山东	冬小麦	576	0	4	6	1	98.1	97.8	98.0	95.6	0.943
		水体	0	170	2	0	1	98.3	98.8	98.6		
		不透水面	3	2	358	13	1	95.0	94.5	94.7		
		裸地	8	0	15	443	9	93.3	93.5	93.4		
		其他	2	0	0	12	187	93.0	94.0	93.5		

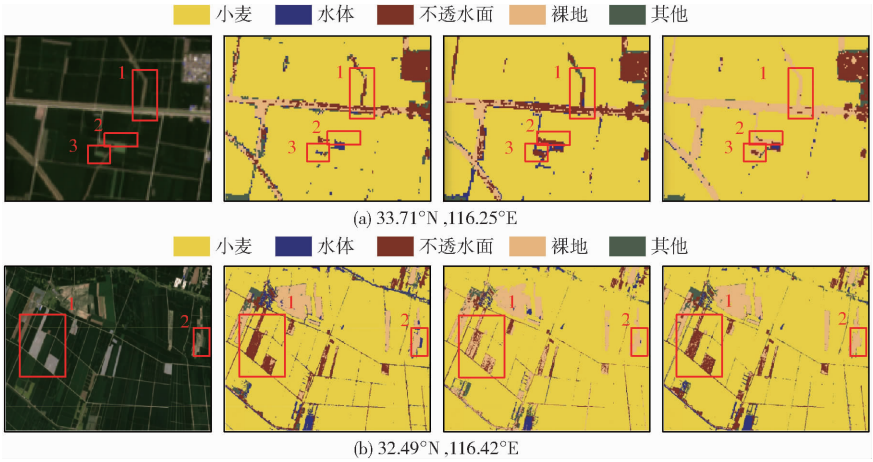

图 7 不同时间尺度分类结果与高分辨率图像空间细节比较

Fig. 7 Comparison analysis of spatial details in classification results at different time scales with high-resolution images

数据变化。然而,从 10 d 至 30 d,分类精度从 96.4% 降至 95.4%,揭示了精度与泛化能力之间的权衡。

2.4 冬小麦空间分布

在不考虑泛化能力的情况下,使用精度最高的 10 d 时间间隔为影像预处理方式,得到 2021 年黄淮海平原冬小麦空间分布制图(图 9a)。2021 年黄淮海平原冬小麦总面积为 17 433 388 hm^2,占研究区总面积的 27.20%。在 5 个地区中,河南地区冬小麦种植面积最多,约为 5 703 942 hm^2,占黄淮海平原冬小麦总面积的 32.72%;其次是山东地区、京津冀地区、江苏地区和安徽地区,分别为 3 981 807、2 787 066、2 649 777、2 310 796 hm^2,各占黄淮海平原冬小麦总面积的 22.84%、15.98%、15.20% 和 13.26%。从经纬度分布来看,黄淮海平原的冬小麦种植东西分布特征呈中间高两边低的变化趋势,南

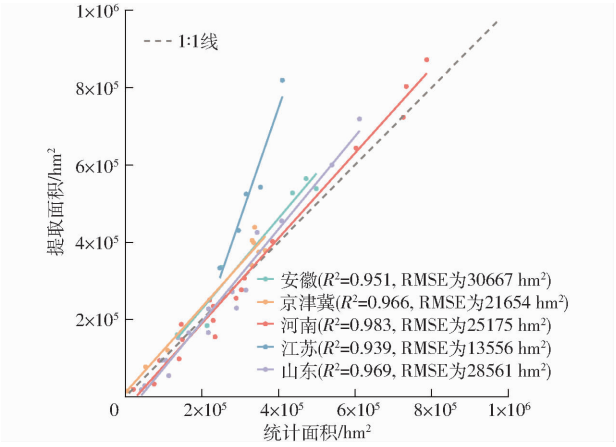

图 8　提取种植面积与官方统计数据对比

Fig. 8　Comparison of estimated planting area with official statistical data

表 6　随机森林模型泛化实验结果

Tab. 6　Experimental results on generalization of random forest model

地区	时间间隔/d	验证地区总体精度/%				
		安徽	京津冀	河南	江苏	山东
安徽	10	97.4	70.5	91.9	86.2	83.3
	20	95.9	74.7	89.6	87.5	83.9
	30	95.3	77.8	91.4	87.4	85.7
京津冀	10	89.3	96.3	88.8	87.1	91.5
	20	89.7	95.3	86.8	85.8	88.1
	30	85.7	95.4	88.3	86.1	90.0
河南	10	95.2	80.0	96.1	89.3	86.5
	20	93.1	75.2	96.1	87.1	87.8
	30	95.5	85.6	95.9	89.5	89.2
江苏	10	95.2	82.3	88.9	96.3	92.7
	20	92.8	83.4	91.2	94.8	92.1
	30	93.9	85.3	91.6	94.7	91.0
山东	10	94.6	93.0	92.0	91.5	95.9
	20	92.8	92.3	90.5	92.8	95.9
	30	92.3	92.4	92.9	92.5	95.6

表 7　不同时间尺度处理下模型性能和泛化能力对比

Tab. 7　Comparative analysis of model performance and generalization ability under different time scale treatments

参数	时间间隔/d		
	10	20	30
平均总体精度/%	96.4	95.6	95.4
平均泛化能力	0.918	0.919	0.935

北分布特征呈现由南向北的递减趋势(图 9b)。

3　讨论

3.1　不同特征类型重要性评价

不同特征变量选择是影响地物识别和分类精度的关键因素[36]。牛乾坤等[37]进行河套灌区种植结构提取时发现,光谱特征对分类精度起决定性作用,使用光谱特征和纹理特征组合的方案比单特征方案具有更高精度。ZHANG 等[38]在对黄淮海平原冬小麦面积快速提取时认为,地形和光谱特征的重要性高于纹理特征。在本研究的 3 种处理方式下,5 个地区共优选 15 个特征组合。在 283 个特征因子中,光谱特征(包括植被指数)占 182 个、谐波系数占 45 个、纹理特征占 12 个、极化特征占 44 个。相对而言,在黄淮海平原冬小麦识别中,光谱特征重要性最高,其次是谐波系数和极化特征,纹理特征重要性相对最小。

3.2　影像预处理方式对模型精度和泛化能力的影响

以往研究大多忽视了对影像预处理的深入分析,仅对遥感数据进行简单的月尺度或者其他尺度合成,未考虑云雨因素导致的影像缺失以及不同尺度序列合成对分类结果的影响[39-40]。例如,冯权泷等[10]进行黄淮海平原冬小麦识别时,对 Sentinel-2 卫星影像数据进行月尺度均值合成,但由于卫星过境时云雨天气的影响,部分像元可能会出现连续1~2 个月的影像缺失,需要解决填补影像的空缺难题。此外,大多数研究主观地将长序列影像进行月尺度或其他尺度合成,却未分析不同时间间隔处理之间的差异。针对以上问题,本研究利用线性插值和 S-G 滤波方法处理影像空缺,并对比分析不同时间间隔处理方式对模型精度和泛化能力的影响。研究发现,短时间尺度的影像预处理方式可以更准确获取地物的特征细节,具有更高的分类精度。而较长时间尺度在处理一些细节时容易出现错误,这可能是由于在较长的时间窗口内,地物特征变化或季节性变化对分类算法的影响更大,导致分类准确度下降。此外,短时间尺度影像也受气候等空间差异的影响显著,泛化能力也更低。如何权衡短时间尺度的高精度和长时间尺度的强泛化能力,是未来需要思考的问题。

在空间分布上,不同地区模型泛化能力呈现相似规律,各地区分类模型在离本地最近的地区泛化能力最强,在离本地较远的地区泛化能力更弱,即“越近越相关”。这种空间泛化能力的差异可能是气候及农业管理措施不同造成的。

3.3　基于多源遥感数据识别冬小麦的可行性

本研究使用的 Sentinel 系列遥感卫星影像,相比于空间分辨率 30 m 的 Landsat 卫星影像和空间分辨率 1 km 的 MODIS 卫星影像,具有更高的空间分辨率(10 m),可以识别更小的地块。与时间分辨率 16 d 的 Landsat 卫星影像相比,Sentinel-2 卫星影像时间分辨率 5 d 提供了更高的观测频率。同时,本

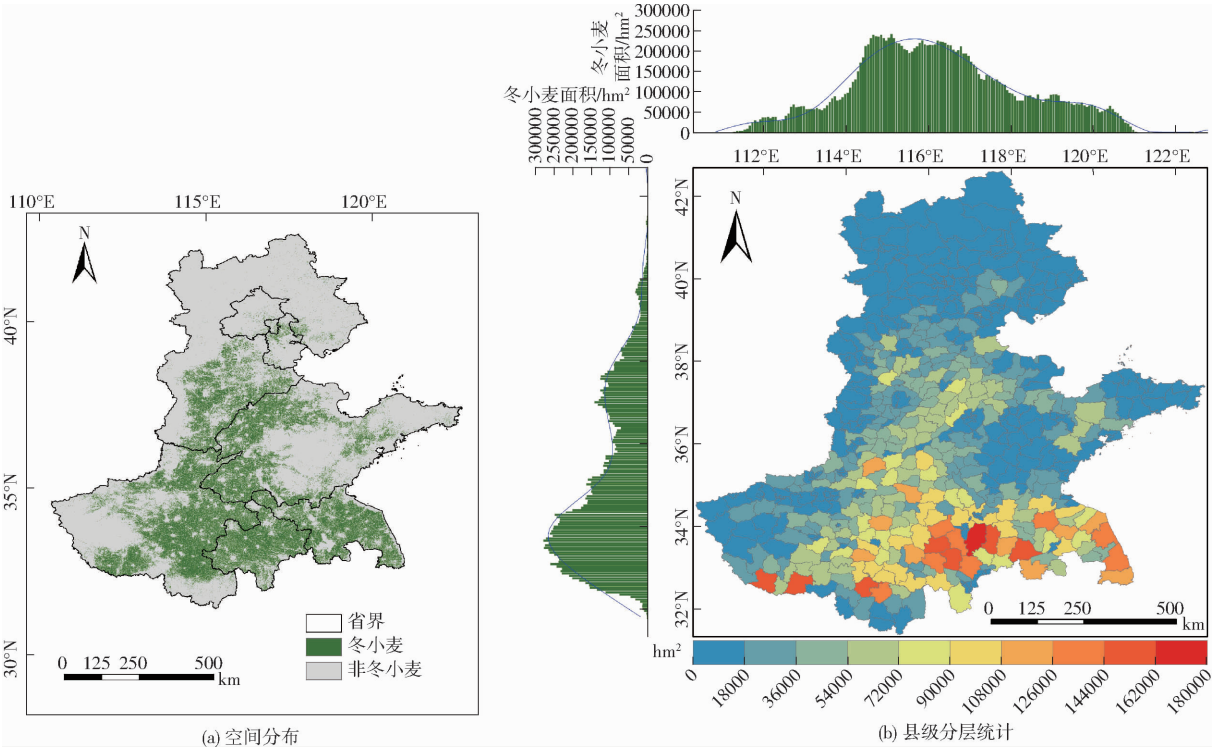

图 9 2021 年黄淮海平原冬小麦空间分布及县级分层统计

Fig. 9 Spatial distribution and county-level stratification of winter wheat in Huang - Huai - Hai Plain in 2021

研究使用的 Sentinel - 2 地表反射率(SR)数据与 TOA 反射率数据相比,减少了大气干扰的影响。此外,黄淮海平原冬小麦生长季节长、种植结构简单,降低了研究区作物识别难度。GEE 云计算平台提供了强大的存储和计算能力以及内置的机器学习算法包,为大规模地物制图提供了条件,可以满足遥感影像预处理、特征优选和监督分类算法的需求。

本数据集在不同地区的混淆矩阵验证结果显示,OA 和 F1 值均在 90% 以上,且提取的冬小麦种植面积与市级官方统计数据高度相关(R^2 >0.9)。

3.4 不确定性分析

本研究提供的冬小麦识别方法仍存在一定的不确定性,而造成这种不确定性的原因主要包括图像错误和样本错误:①遥感影像的可用性是地物分类的基础,图像缺失和云雨污染降低了数据集的时间连续性,削弱了地物特征的捕获。本研究采用插值方法填补影像空缺,与真实值之间的差异是影响冬小麦识别的不确定性因素。②收集大量具有代表性的样本一直以来都是地物分类的难题,而本研究中目视解译样本的准确性也是样本集的不确定性因素之一。

4 结论

(1)随机森林监督分类中,特征优选过程可以提高模型分类精度。在黄淮海平原冬小麦识别的各类特征因子中,光谱特征重要性最高,其次是谐波系数、极化特征和纹理特征。

(2)在不同时间间隔的影像预处理过程中,缩短时间尺度可以得到更高的分类精度,具体表现为尺度 30、20、10 d 平均总体精度分别为 95.4%、95.6% 和 96.4%。

(3)长时间尺度遥感影像更能适应不同数据的变化,随着时间尺度的缩短,泛化能力相应下降,具体而言,尺度 30、20、10 d 平均泛化能力分别为 0.935、0.919 和 0.918。此外,分类模型泛化能力在空间上遵循“越近越相关”的规律。

(4)利用 Google Earth Engine 平台和 Sentinel 系列卫星遥感数据,实现了对黄淮海平原冬小麦的准确识别。基于 30% 目视解译的混淆矩阵 OA 和 F1 值均在 90% 以上,分类结果在空间细节上与高分辨率图像高度一致,同时提取的冬小麦种植面积与市级官方统计数据高度相关(R^2 >0.9),证明了该识别方法的可靠性。

参 考 文 献

[1] 周丽涛,孙爽,张镇涛,等. 基于 Meta 分析华北冬小麦高产高效协同提升灌溉方案[J]. 中国农业气象,2022,43(7):515 - 526.
ZHOU Litao, SUN Shuang, ZHANG Zhentao, et al. High yield and water use efficiency synergistical improvement irrigation

scheme of winter wheat in North China Plain based on Meta-analysis[J]. Chinese Journal of Agrometeorology, 2022, 43(7): 515 – 526. (in Chinese)
[2] CUI K, SHOEMAKER S P. A look at food security in China[J]. NPJ Science of Food, 2018, 2(1): 4.
[3] 中华人民共和国国家统计局农村社会经济调查司. 中国农业统计资料汇编:1949—2019[M]. 北京:中国统计出版社, 2021.
[4] PAN Z, YANG S, ZHAO L, et al. Temporal and spatial variability of antibiotics in agricultural soils from Huang – Huai – Hai Plain, northern China[J]. Chemosphere, 2021, 272: 129803.
[5] 张超,高璐璐,郧文聚,等. 遥感技术获取耕地质量评价指标的研究进展分析[J]. 农业机械学报,2022,53(1):1 – 13.
ZHANG Chao, GAO Lulu, YUN Wenjun, et al. Research progress on obtaining cultivated land quality evaluation indexes by remote sensing[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(1): 1 – 13. (in Chinese)
[6] 郝卫平,梅旭荣,蔡学良,等. 基于多时相遥感影像的东北三省作物分布信息提取[J]. 农业工程学报,2011,27(1):201 – 207,393.
HAO Weiping, MEI Xurong, CAI Xueliang, et al. Crop planting extraction based on multi-temporal remote sensing data in Northeast China[J]. Transactions of the CSAE, 2011, 27(1): 201 – 207, 393. (in Chinese)
[7] 吴志峰,骆剑承,孙营伟,等. 时空协同的精准农业遥感研究[J]. 地球信息科学学报,2020,22(4):731 – 742.
WU Zhifeng, LUO Jiancheng, SUN Yingwei, et al. Research on precision agricultural based on the spatial-temporal remote sensing collaboration[J]. Journal of Geo-information Science, 2020, 22(4): 731 – 742. (in Chinese)
[8] 唐华俊. 农业遥感研究进展与展望[J]. 农学学报,2018,30(5): 167 – 171.
TANG Huajun. Progress and prospect of agricultural remote sensing research[J]. Journal of Agriculture, 2018, 30(5): 167 – 171. (in Chinese)
[9] 高永道,乔荣荣,季树新,等. 内蒙古河套灌区作物种植结构变化及其驱动因素[J]. 中国沙漠,2021,41(3):110 – 117.
GAO Yongdao, QIAO Rongrong, JI Shuxin, et al. Changes and driving factors of crops planting structure in Hetao Irrigation Region in Inner Mongolia[J]. Journal of Desert Research, 2021, 41(3): 110 – 117. (in Chinese)
[10] 冯权泷,任燕,姚晓闯,等. 基于多源光学雷达数据融合的黄淮海平原冬小麦识别[J]. 农业机械学报,2023,54(2):160 – 168.
FENG Quanlong, REN Yan, YAO Xiaochuang, et al. Identification of winter wheat in Huai – Hai – Plain based on multi-source optical radar data fusion[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(2): 160 – 168. (in Chinese)
[11] 胡琼. 基于时序 MODIS 影像的农作物遥感识别方法研究[D]. 北京:中国农业科学院, 2018.
HU Qiong. Research on methods of crop identification using MODIS time series data[D]. Beijing: Chinese Academy of Agricultural Sciences, 2018. (in Chinese)
[12] 郝鹏宇,牛铮,王力,等. 基于历史时序植被指数库的多源数据作物面积自动提取方法[J]. 农业工程学报,2012,28(23):123 – 131,297.
HAO Pengyu, NIU Zheng, WANG Li, et al. Multi-source automatic crop pattern mapping based on historical vegetation index profiles[J]. Transactions of the CSAE, 2012, 28(23): 123 – 131, 297. (in Chinese)
[13] 李鑫川,徐新刚,王纪华,等. 基于时间序列环境卫星影像的作物分类识别[J]. 农业工程学报,2013,29(2):169 – 176,298.
LI Xinchuan, XU Xin'gang, WANG Jihua, et al. Crop classification recognition based on time-series images from HJ satellite [J]. Transactions of the CSAE, 2013, 29(2): 169 – 176, 298. (in Chinese)
[14] XUAN F, DONG Y, LI J, et al. Mapping crop type in Northeast China during 2013—2021 using automatic sampling and tile-based image classification[J]. International Journal of Applied Earth Observation and Geoinformation, 2023, 117: 103178.
[15] ZHAO Q, YU L, LI X, et al. Progress and trends in the application of Google Earth and Google Earth Engine[J]. Remote Sensing, 2021, 13(18): 3778.
[16] MCNAIRN H, SHANG J. A review of multitemporal synthetic aperture radar (SAR) for crop monitoring[J]. Multitemporal Remote Sensing: Methods and Applications, 2016(1): 317 – 340.
[17] REN S, GUO B, WU X, et al. Winter wheat planted area monitoring and yield modeling using MODIS data in the Huang – Huai – Hai Plain, China[J]. Computers and Electronics in Agriculture, 2021, 182: 106049.
[18] SHI W, TAO F, LIU J. Changes in quantity and quality of cropland and the implications for grain production in the Huang – Huai – Hai Plain of China[J]. Food Security, 2013(5): 69 – 82.
[19] TAMIMININI H, SALEHI B, MAHDIANPARI M, et al. Google Earth Engine for geo-big data applications: a Meta-analysis and systematic review[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2020, 164: 152 – 170.
[20] ROY D P, WULDER M A, LOVELAND T R, et al. Landsat – 8: science and product vision for terrestrial global change research[J]. Remote Sensing of Environment, 2014, 145: 154 – 172.
[21] 李文,李佳田,陆美,等. 狄克松检验的时空信息加权 SG 时间序列滤波法[J]. 遥感信息,2023,38(1):112 – 120.
LI Wen, LI Jiatian, LU Mei, et al. Spatio-temporal information weighted SG time series filtering method based on Dixon test [J]. Remote Sensing Information, 2023, 38(1): 112 – 120. (in Chinese)
[22] SON N T, CHEN C F, CHEN C R, et al. A comparative analysis of multitemporal MODIS EVI and NDVI data for large-scale rice yield estimation[J]. Agricultural and Forest Meteorology, 2014, 197: 52 – 64.
[23] GAO B C. NDWI—a normalized difference water index for remote sensing of vegetation liquid water from space[J]. Remote Sensing of Environment, 1996, 58(3): 257 – 266.
[24] JOHN R, CHEN J, LU N, et al. Predicting plant diversity based on remote sensing products in the semi-arid region of Inner Mongolia[J]. Remote Sensing of Environment, 2008, 112(5): 2018 – 2032.
[25] ZHENG B, CAMPBELL J B, DE BEURS K M. Remote sensing of crop residue cover using multi-temporal Landsat imagery

[J]. Remote Sensing of Environment, 2012, 117: 177 - 183.
[26] ZULPE N, PAWAR V. GLCM textural features for brain tumor classification[J]. International Journal of Computer Science Issues (IJCSI), 2012, 9(3): 354.
[27] CAO R, CHEN Y, SHEN M, et al. A simple method to improve the quality of NDVI time-series data by integrating spatiotemporal information with the Savitzky - Golay filter[J]. Remote Sensing of Environment, 2018, 217: 244 - 257.
[28] XUE H, XU X, ZHU Q, et al. Object-oriented crop classification using time series sentinel images from Google Earth Engine [J]. Remote Sensing, 2023, 15(5): 1353.
[29] CHAN J C W, PAELINCKX D. Evaluation of random forest and Adaboost tree-based ensemble classification and spectral band selection for ecotope mapping using airborne hyperspectral imagery[J]. Remote Sensing of Environment, 2008, 112(6): 2999 - 3011.
[30] 何云,黄翀,李贺,等. 基于 Sentinel - 2A 影像特征优选的随机森林土地覆盖分类[J]. 资源科学,2019,41(5):992 - 1001.
HE Yun, HUANG Chong, LI He, et al. Land-cover classification of random forest based on Sentinel - 2A image feature optimization[J]. Resources Science,2019,41(5):992 - 1001. (in Chinese)
[31] IMMITZER M, VUOLO F, ATZBERGER C. First experience with Sentinel - 2 data for crop and tree species classifications in central Europe[J]. Remote Sensing, 2016, 8(3): 166.
[32] PERSSON M, LINDBERG E, REESE H. Tree species classification with multi-temporal Sentinel - 2 data[J]. Remote Sensing, 2018, 10(11): 1794.
[33] THENKABAIL P S, ENCLONA E A, ASHTON M S, et al. Accuracy assessments of hyperspectral waveband performance for vegetation analysis applications[J]. Remote Sensing of Environment, 2004, 91(3 - 4): 354 - 376.
[34] YOU N, DONG J, HUANG J, et al. The 10-m crop type maps in Northeast China during 2017—2019[J]. Scientific Data, 2021, 8(1): 41.
[35] TEKE A, KAVZOGLU T. Determination of effective predisposing factors using random forest-based Gini index in landslide susceptibility mapping[J]. Intercontinental Geoinformation Days, 2021(2): 198 - 201.
[36] ZHANG H, WANG Y, SHANG J, et al. Investigating the impact of classification features and classifiers on crop mapping performance in heterogeneous agricultural landscapes [J]. International Journal of Applied Earth Observation and Geoinformation, 2021, 102: 102388.
[37] 牛乾坤,刘浏,黄冠华,等. 基于 GEE 和机器学习的河套灌区复杂种植结构识别[J]. 农业工程学报,2022,38(6):165 - 174.
NIU Qiankun, LIU Liu, HUANG Guanhua, et al. Extraction of complex crop structure in the Hetao Irrigation District of Inner Mongolia using GEE and machine learning[J]. Transactions of the CSAE, 2022, 38(6): 165 - 174. (in Chinese)
[38] ZHANG D, ZHANG M, LIN F, et al. Fast extraction of winter wheat planting area in Huang - Huai - Hai Plain using high-resolution satellite imagery on a cloud computing platform[J]. International Journal of Agricultural and Biological Engineering, 2022, 15(1): 241 - 250.
[39] 刘昊. 基于 Sentinel - 2 影像的河套灌区作物种植结构提取[J]. 干旱区资源与环境,2021,35(2):88 - 95.
LIU Hao. Extraction of crop planting structure in Hetao irrigated area based on Sentinel - 2[J]. Journal of Arid Land Resources and Environment, 2021, 35(2): 88 - 95. (in Chinese)
[40] 张超,乔敏,刘哲,等. 基于时序光谱和高分纹理分析的制种玉米田遥感识别[J]. 农业机械学报,2018,49(5):218 - 225.
ZHANG Chao, QIAO Min, LIU Zhe, et al. Seed maize field identification based on analysis of remote sensing timing spectrum and high resolution texture[J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(5): 218 - 225. (in Chinese)

(上接第 225 页)

[20] 黄丽冰, 黄志明, 莫金莲, 等. 立创 EDA 结合 Altium Designer 快速完成 PCB 设计思路[J]. 现代制造技术与装备, 2020, 56(10): 65 - 67.
HUANG Libing, HUANG Zhiming, MO Jinlian, et al. EDA combined with Altium Designer to quickly complete PCB design ideas[J]. Modern Manufacturing Technology and Equipment, 2020, 56(10): 65 - 67. (in Chinese)
[21] ANUSHA A P, KAUR G. Artificial intelligence-based method to improve tourism with the help of Android studio[J]. International Journal of Innovative Technology and Exploring Engineering (IJITEE), 2021, 10(6): 50 - 53.
[22] LIU Z S. Research on switch power module parallel operation system[J]. Applied Mechanics and Materials, 2014, 3360(599 - 601): 1657 - 1660.
[23] 曲志强,夏铁铮,于虹博. 一种分离式变增量积分 PID 算法设计[J]. 电子设计工程,2023,31(7):52 - 56.
QU Zhiqiang, XIA Tiezheng, YU Hongbo. Design of a separate variable increment integral PID algorithm[J]. Electronic Design Engineering, 2023, 31(7): 52 - 56. (in Chinese)
[24] 王辉,胡建华,王慎航. 增量式光电编码器角位移拟合测速法[J]. 仪表技术与传感器,2014(10):99 - 101.
WANG Hui, HU Jianhua, WANG Shenhang. Angular position fitting velocity detection of incremental optical encoder[J]. Instrument Technique and Sensor, 2014(10): 99 - 101. (in Chinese)
[25] GB/T 17997—2008 农药喷雾机(器)田间操作规程及喷洒质量评定[S]. 2008.