引文格式：韦秋莲,李正洪,全昌文,等. 顾及季节影响的无人机影像水稻田提取方法[J]. 地理空间信息, 2025, 23(7): 115-119. doi:10. 3969/j. issn. 1672-4623.2025.07.023

顾及季节影响的无人机影像水稻田提取方法

韦秋莲[1,2]，李正洪[1,2]，全昌文[1,2]，张春宗[1,2*]，黄景金[2,3]，戴展望[4]

（1. 广西壮族自治区自然资源调查监测院，广西 南宁 530219；2. 自然资源部北部湾经济区自然资源监测评价工程技术创新中心，广西 南宁 530219；3. 广西壮族自治区自然资源信息中心，广西 南宁 530022；4. 舟山市自然资源测绘设计中心，浙江 舟山 316000）

摘　要：针对不同季节影像水稻田提取适用性不高的问题，借鉴卫星影像智能解译方法，提出了基于高分辨率无人机影像和顾及季节变化的水稻田提取方法。以无人机影像为数据源，分析了水稻不同生长时期的影像特征，并建立水稻田季节性特征样本库；结合卷积注意力机制、空洞空间金字塔池化、残差结构改进U-Net网络模型，以提高在复杂背景中获取目标地物重要特征和上下文信息的能力；利用季节性特征样本库进行模型训练验证，以提高模型在不同季节的适用性。对比分析结果表明，该方法能从不同季节的高分辨无人机影像中准确提取水稻田，各季节提取结果的平均召回率、平均交并比分别达到95.54%、91.20%以上，优于原始的U-Net、DeepLabV3等模型。

关键词：季节影响；无人机影像；水稻田提取；U-Net；深度学习

中图分类号：P231　　**文献标志码：**B　　**文章编号：**1672-4623（2025）07-0115-05

Extraction Method of Rice Paddy from UAV Images Considering Seasonal Effects

WEI Qiulian[1,2], LI Zhenghong[1,2], QUAN Changwen[1,2], ZHANG Chunzong[1,2], HUANG Jingjin[2,3], DAI Zhanwang[4]

(1. Guangxi Institute of Natural Resources Survey and Monitoring, Nanning 530219, China;
2. Technology Innovation Center for Natural Resources Monitoring and Evaluation of Beibu Gulf Economic Zone, Ministry of Natural Resources, Nanning 530219, China;
3. Natural Resources Information Center of Guangxi Zhuang Autonomous Region, Nanning 530022, China;
4. Zhoushan Natural Resources Surveying and Mapping Design Center, Zhoushan 316000, China)

Abstract: In response to the challenges posed by the varying phenological characteristics of rice paddy during different growth stages and the limited sample size, we put forward an extraction method of rice paddy based on high-resolution UAV images and accounting for seasonal variations. Taking UAV images as the data source, we analyzed the image characteristics of rice paddies at different growth stages, and established their seasonal characteristic sample library. Combined with the convolutional block attention module, the atrous spatial pyramid pooling and the residual block, we improved the U-Net model to enhance its ability to obtain important features and contextual information of target objects in complex backgrounds. We used the seasonal characteristic sample library for model training and validation to improve the feasibility of model in different seasons. Experimental comparative analysis demonstrates that this method can precisely extract rice paddies from high-resolution UAV images across various seasons. In each season, the improved U-Net model achieved the average recall and average IoU exceeding 95.54% and 91.20%, respectively, surpassing the original U-Net, DeepLabV3, and other models.

Key words: seasonal effect, UAV image, rice paddy extraction, U-Net, deep learning

水稻是我国南方地区的主要粮食作物，其种植面积居国内粮食作物播种面积首位。基于遥感影像进行水稻田提取是政府有关部门获取水稻种植面积、进度和变化情况的重要手段。深度学习是高分辨率遥感影像地物信息提取和识别的常用方法，具有分类效率和精度高、泛化性强等优点[1-2]。由于天气等因素的影响，遥感影像获取的季节往往无法完全一致；而水稻田在不同季节、不同生长阶段表现的影像纹理不同[3-4]，且与撂荒耕地、草地、水体、裸土等背景地物特征较相似。早期研究大多忽略了农作物本身的物候特征差异和季节因素影响，导致模型在不同季节影像中的适用性不高，制约了提取分析的精度[4]。近年来，部分学者[5-7]开始关注农作物生长周期对作物提取的影响，但研究成果主要集中于中高分辨率卫星遥感影像，针对超高分辨率无人机影像的研究成果较少。相较于卫星遥感影像，无人机影像的机动性高、成本

项目来源：广西重点研发计划资助项目（桂科AB22080077）。

第一作者简介：韦秋莲（1996—），硕士，工程师，主要研究方向为遥感图像智能解译、自然资源调查监测，E-mail：1041859333@qq.com。

通信作者：张春宗（1972—），本科，高级工程师，主要从事自然资源调查监测工作，E-mail：52678166@qq.com。

低、时空分辨率更高[8]，可提供更丰富的地物细节和上下文信息，同时自动提取的难度也更大[9-10]。因此，搭建一个高性能的深度学习模型，构造具有不同季节水稻田纹理特征信息的样本库，是提高无人机影像水稻田提取精度的关键。

U-Net模型是一种常用的轻体量影像分割深度学习模型，将浅层特征和深层特征在通道上进行拼接，得到多层特征的跳跃连接操作，使其能在背景简单、样本较少的医学语义分割任务中取得很好的效果[11]；但在样本背景复杂、分类数目较多时，会出现过拟合或物体边缘分割不够精细的情况[12]，由于模型网络层数较多，还易出现模型收敛慢、梯度消失等问题[13]。面对复杂的地物背景，根据实际应用场景对深度学习模型进行有针对性的改进[14-15]是提高U-Net模型性能的有效方法。本文以高分辨率无人机正射影像为数据源，顾及不同季节水稻田纹理特征的差异，建立了水稻田季节特征样本库；再引入卷积注意力机制、空洞空间金字塔池化、残差结构改进U-Net模型；最后利用样本库训练和验证改进模型，以提高各季节水稻田提取的精度。

1 研究区概况与数据来源

本文选取的研究区位于广西壮族自治区南部；属南亚热带季风性气候，降水充沛，年平均温度在20℃以上，年均降水量在1 500~2 000 mm之间。受冬夏季风交替影响，广西南部地区降水量季节变化不均，4—9月的降水量占全年降水量的70%~85%。水稻种植制度为一年两熟双季稻，早稻通常在3—4月种植，7月收割；晚稻通常在7—8月种植，11月收割。

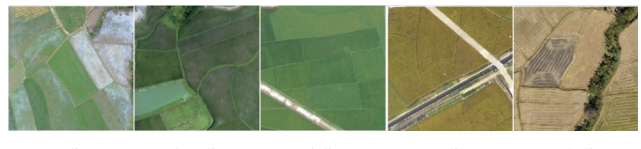
本文采用的影像为无人机正射影像，分辨率优于0.2 m，包括红、绿、蓝3个波段；分为样本影像和实验影像，样本影像用于建立模型训练的样本库，实验影像为模型预测过程水稻田提取的输入。本文通过非连续矩形采样的方法，在贵港市、玉林市、钦州市的水稻种植区获取了总面积26.37 km^2的无人机正射影像作为样本影像。实验影像包括5个区域，即玉林市北流市塘岸镇长塘村（6 800像元×3 000像元）、玉林市北流市民安镇丰村冲头组（3 500像元×4 600像元）、玉林市北流市塘岸镇利民村（5 590像元×4 690像元）、贵港市港北区武乐镇逢宜村（7 500像元×6 000像元）、贵港市桂平市厚禄乡陈村（9 500像元×14 500像元）。对于每个实验区域，分别于2021年11月（水稻生长后期或收割期）、2022年9月和2023年6月（水稻生长中期）拍摄3幅影像，共15幅，总面积为7.35 km^2。

2 研究方法

顾及季节影响的水稻田提取方法的关键步骤为：①基于无人机正射影像，对不同生长时期水稻田样本进行人工标注和数据扩增，建立广西水稻田季节形态特征样本库；②引入卷积注意力机制、空洞空间金字塔池化和残差结构对U-Net模型进行改进；③将样本库划分为训练集和验证集，输入改进的U-Net模型进行模型训练，获取最佳模型参数；④利用训练好的模型对实验区水稻田进行提取。

2.1 水稻田季节特征样本库建立

不同生长时期、不同季节的水稻在无人机影像中的纹理特征存在较大差异，因此建立丰富的季节特征样本库，是提高各季节水稻田提取精度的关键。水稻田季节特征样本库建立主要包括各生长期水稻生长特征分析、各生长期影像获取、样本标签采集、样本标签栅格化、滑动窗口裁剪、数据扩增等6个步骤。根据不同的纹理特征，本文将水稻分为生长早期、生长中早期、生长中期、生长后期、收割期5个生长期。生长早期水稻在影像纹理上类似于池塘等水体特征；生长中早期水稻呈青绿色，在影像上可观察到部分田中的土和少量的水；生长中期水稻长势茂盛，影像表现纹理致密，光线较弱时呈深绿色，阳光较强时呈青绿色；生长后期水稻的颜色由绿转为黄绿色或金黄色，部分水稻已开始收割，可观察到黄色的稻茬、秸秆以及收割痕迹；收割期水稻影像中仍能观察到黄色的稻茬、秸秆和收割痕迹，还有可能观察到黑色稻田土和秸秆焚烧或堆积现象（图1）。根据不同生长期的水稻田特征，在研究区耕地范围内寻找不同季节的水稻田影像，通过非连续矩形选取各生长期的水稻田样本影像，生长早期、生长中早期、生长中期、生长后期、收割期影像面积分别为2.50、9.50、5.97、7.28、1.13 km^2。采用人工目视解译的方式采集样本影像中水稻田样本标签，并经栅格化、滑动窗口裁剪等处理，得到原始水稻季节特征样本库。



早期 中早期 中期 后期 收割期

图1 各生长期的水稻田影像

为充分利用已采集样本，模拟不同成像形态，本文采用对角镜像、高斯模糊、椒盐噪声、图像锐化、

线性拉伸、伽马变换6种扩增技术对原始样本库的正样本进行数据随机扩增，最终得到总样本数为59 878个，其中生长早期样本4 699个、占比为7.85%，生长中早期样本18 521个、占比为30.93%，生长中期样本14 789个、占比为24.70%，生长后期样本19 672个、占比为32.85%，收割期样本2 197个、占比为3.67%。

2.2　改进的U-Net模型

U-Net模型是深度神经网络中全卷积神经网络的延伸，整体为编码器（下采样）—跳跃连接—解码器（上采样）结构。U-Net模型在样本背景复杂、分类数目较多的情况下，易出现模型过拟合、收敛慢、梯度消失等问题，因此本文搭建了改进的U-Net模型。模型编码器部分主要参考ResNet50的主干进行改进，影像输入后先通过基础残差块进行初始采样，再依次经过4个由瓶颈残差模块堆叠而成的组合，包含的残差模块分别为3、4、6、3个，每个组合前端的第一个残差模块均为具有下采样功能的瓶颈残差块，其余为普通瓶颈残差块；在第3个组合的末端，嵌入注意力机制（CBAM）。模型桥连接部分采用空洞空间金字塔池化（ASPP）替代原始U-Net的两层卷积。模型编码器部分为4个由上采样模块、通道拼接模块和瓶颈残差块组成的组合。通过Softmax激活函数计算，得到分类结果的概率分布。

CBAM首先利用通道注意力获取每个特征通道的重要性并赋予权重，以提取特征图上的重要特征；再通过空间注意力模块对输入特征图（通道注意力模块的输出）进行空间域的处理，以提高关键区域的表达。本文将CBAM插入模型编码器中，能将注意力集中在影像的感兴趣区域，更加快速高效地分析复杂场景信息。ASPP是由空洞卷积和金字塔池化衍生而来，通过设置合适的采样间隔，利用空洞卷积增大模型的感受野；同时利用金字塔池化的思想，融合不同尺度的特征获得不同尺度、不同比例的上下文信息。本文将ASPP模块替代U-Net模型的桥连接，从编码器末端输出的高级语义信息特征图中获取不同尺度的上下文信息，以提高模型提取目标地物的性能。残差结构是He等[16]提出的ResNet系列模型的基本单元，能解决模型网络深度很深时模型性能下降而产生的退化问题。残差结构分为两种：应用于网络层数较少（ResNet34模型）的基础残差块，主要由两个3×3卷积层和短路连接构成；应用于ResNet50等深层模型的瓶颈残差块，残差路径先后经过1×1卷积、3×3卷积、1×1卷积计算，大大减少了使用两个3×3卷积的网络参数量，节省了时间和内存，能有效防止模型深度增加而导致的退化问题。同时，通过调整瓶颈残差块的3×3卷积以及将短路连接卷积层的卷积步长设置为2，代替原始U-Net模型中的最大池化层进行特征图层下采样，可减少下采样中信息丢失的问题。

2.3　精度评价指标

本文以召回率（Recall）、平均交并比（mIoU）作为水稻田提取的精度评价指标，计算公式为：

$$\mathrm{Recall}=\frac{TP}{TP+FN} \tag{1}$$

$$\mathrm{IoU}=\frac{TP}{TP+FN+FP} \tag{2}$$

$$\mathrm{mIoU}=\frac{\sum_{i}^{N}\mathrm{IoU}}{N} \tag{3}$$

式中，*TP*为分类准确的正类；*FP*为被误分为正类的负类；*TN*为分类准确的负类；*FN*为被误分为负类的正类。

2.4　模型训练

实验平台硬件采用Intel(R) Xeon(R) W-2245 CPU @ 3.90GHz八核处理器，配置64 G内存，搭载Nvidia GeForce RTX 3090 24 GB显存的显卡；软件采用Python编程语言，选取以TensorFlow框架为后端的深度学习框架Keras作为模型搭建工具，采用CUDA11.6版本的GPU运算平台和cuDNN8.5.0深度学习GPU加速库。本文以原始U-Net、经残差结构改进的ResU-net50模型和DeepLabV3模型为对照组，以ResU-net50+CBAM+ASPP模型为实验组，采用相同的训练参数、数据集进行模型训练。采用基于IoU的Lovasz Softmax Loss函数进行模型参数优化，优化器为Adam算法。模型输入尺寸为512×512×3，训练轮次为200，批次为4。为使模型学习时能跳出局部最小解，采用周期性余弦退火更新策略来更新学习率，其中算法预热期为2，预热期学习率为10^{-5}，最大学习率为10^{-4}，最小学习率为10^{-5}。模型训练阶段，本文按照7∶3的比例将水稻田季节特征样本库的所有样本随机划分为训练样本和验证样本。

各模型训练和验证的精度和损失曲线见图2，可以看出，随着训练轮次的增加，原始U-Net模型的训练损失值不断减小、验证损失值波动较大，说明该模型的性能不稳定；经残差结构改进的ResUnet50和DeepLabV3模型则比原始U-Net模型有所改善；ResUnet50+CBAM+ASPP模型在训练后期比其他模型收敛得更加稳定，最终实现损失最小、精度最高。

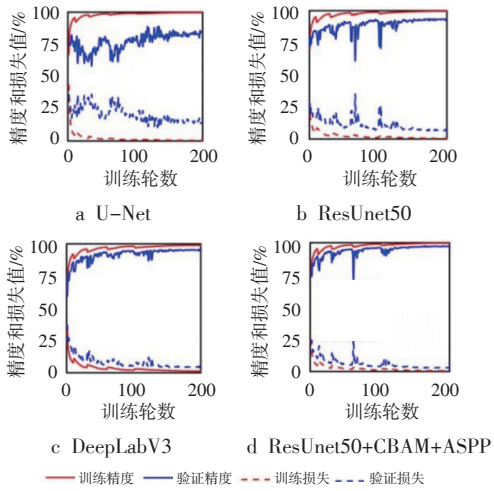


图2 各模型训练和验证的精度与损失对比图

3 实验结果与分析

各模型不同季节水稻田提取结果细节对比见图3~5，可以看出，原始U-Net模型提取结果的图斑完整性较差，在2022年9月、2023年6月的实验中几乎无法完整识别水稻田，说明其无法适应不同季节的复杂背景；经残差结构改进的ResUnet50模型、DeepLabV3模型的提取结果比原始U-Net模型有所提高，但存在较多漏提取和图斑内部孔洞较多的情况；ResUnet50+CBAM+ASPP模型的提取效果明显优于原始U-Net模型，其余两个模型中的漏提取和图斑内孔洞也得到明显改善，各季节提取效果均比较理想。

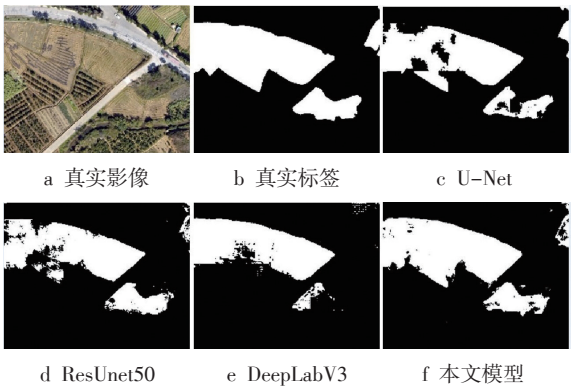


图3 各模型2021年11月的水稻田提取结果细节对比图

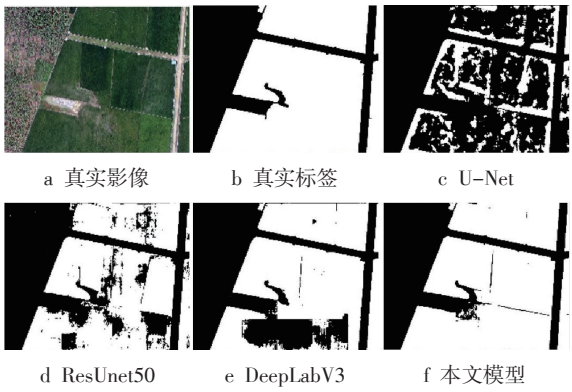


图4 各模型2022年9月的水稻田提取结果细节对比图

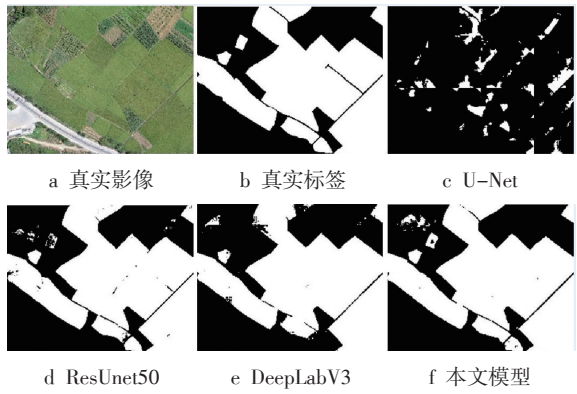


图5 各模型2023年6月的水稻田提取结果细节对比图

各模型提取水稻田的精度见表1，可以看出，本文模型各季节提取结果的Recall、mIoU均高于3个对比模型，说明该模型更适用于实验区域的水稻田提取；其中，相较于原始的U-Net模型，2021年11月提取结果的Recall、mIoU分别提升3.72%、5.58%，2022年9月提升19.42%、29.02%，2023年6月提升27.46%、38.58%。此外，本文模型各季节提取最佳结果和最差结果的Recall、mIoU分别相差2.42%、4.60%，而原始U-Net模型则分别相差21.32%、28.40%，说明本文模型在各季节水稻田提取中均具有良好的鲁棒性和泛化性。在本文模型的提取结果中，2023年6月的精度指标最高，2022年9月次之，2021年11月最低，说明该模型在水稻生长茂盛时期的提取精度略优于非生长茂盛期，其原因在于生长茂盛期的水稻田与周围地物的相似性低，而水稻生长后期大部分水稻已被收割，水稻田在影像表现上与裸土、推土区和翻耕的旱地等黄色地物特征相似，提取效果不佳。此外，即使是最优的提取结果，水稻田提取图斑内部仍存在少量细小孔洞，该问题需进一步研究完善。

表1 各模型多时相无人机影像水稻提取结果精度评价统计表/%

模型	2021年11月		2022年9月		2023年6月	
	Recall	mIoU	Recall	mIoU	Recall	mIoU
U-Net	91.82	85.62	77.54	65.48	70.50	57.22
ResUnet50	94.66	89.76	95.00	90.18	97.02	93.42
DeepLabV3	95.08	90.86	96.52	93.88	97.72	95.12
本文模型	95.54	91.20	96.96	94.50	97.96	95.80

4 结 论

本文通过分析水稻不同季节、不同生长时期的纹理特征，建立了基于高分辨率无人机影像的水稻田季节特征样本库；同时考虑无人机影像地物复杂、视野较小的特征，引入CBAM、ASPP和残差结构对U-Net模型进行改进，以增强模型对目标地物的关注，扩大模型视野，在网络深度增加的情况下提高模型性能。

在不同季节无人机影像的水稻田提取对比实验中，本文模型的提取精度高于对照组模型，其中平均Recall达到95.54%以上，mIoU达到91.20%以上，且各季节无人机水稻田提取精度差异均小于原始U-Net模型。本文模型在考虑季节性变化影响的情况下有效提高了水稻田的提取精度，可为水稻田种植面积和产量估算、变化检测和自然资源监测监管等工作提供借鉴，还可进一步扩展到其他耕地类别，改善耕地提取结果。

参考文献

[1] 牛鑫鑫,孙阿猛,王钎沣,等. 基于深度学习的遥感图像分类研究[J]. 激光杂志,2021,42(5):10-14

[2] 王斌,范冬林. 深度学习在遥感影像分类与识别中的研究进展综述[J]. 测绘通报,2019(2):99-102

[3] 王灵玥. 基于预训练卷积神经网络的水稻种植制度遥感分类研究[D]. 北京:中国地质大学(北京),2020

[4] 张新长,黄健锋,宁婷. 高分辨率遥感影像耕地提取研究进展与展望[J]. 武汉大学学报(信息科学版),2023,48(10):1 582-1 590

[5] Bargiel D. A New Method for Crop Classification Combining Time Series of Radar Images and Crop Phenology Information[J]. Remote Sensing of Environment,2017,198:369-383

[6] Liu L, Xiao X M, Qin Y W, et al. Mapping Cropping Intensity in China Using Time Series Landsat and Sentinel-2 Images and Google Earth Engine[J]. Remote Sensing of Environment, 2020,239:111 624

[7] 黄晓涵,黄文龙. 基于深度学习的多时序遥感影像水稻提取研究[J]. 地理空间信息,2023,21(8):61-64

[8] 任秋如,杨文忠,汪传建,等. 遥感影像变化检测综述[J]. 计算机应用,2021,41(8):2 294-2 305

[9] Li Q, Yang W X, Liu W X, et al. From Contexts to Locality: Ultra-high Resolution Image Segmentation Via Locality-aware Contextual Correlation[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision,2021:1-10

[10] 胡伟,文武,魏敏. 改进U-Net的高分辨率遥感图像轻量化分割[J]. 计算机系统应用,2022,31(12):135-146

[11] Ronneberger O, Fischer P, Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation[C]// Proceedings of the 18th International Conference on Medical Image Computing and Computer-assisted Intervention,2015: 234-241

[12] 王振庆,周艺,王世新,等. IEU-Net高分辨率遥感影像房屋建筑物提取[J]. 遥感学报,2021,25(11):2 245-2 254

[13] 王硕. 基于U-net提取GF-2遥感影像县域水体的研究[D]. 廊坊:北华航天工业学院,2020

[14] 徐文娜. 基于高分辨率全卷积网络的遥感影像耕地提取方法研究[D]. 深圳:中国科学院大学(中国科学院深圳先进技术研究院),2020

[15] 吴瑞姣. 混合U-Net模型下南方丘陵地区耕地识别[J]. 测绘通报,2023(12):57-62

[16] He K M, Zhang X Y, Ren S Q, et al. Deep Residual Learning for Image Recognition[C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition,2016:770-778

（上接第85页）

[13] Nie X, Ma M, Ji J, et al. The Spatial Distribution of Traditional Intangible Cultural Heritage Medicine of China and Its Influencing Factors[J]. Heritage Science,2023,11(1):90

[14] 邱族周,钱惠,李薇,等. 国家级传统美术类非物质文化遗产项目空间分布特征及影响因素研究[J]. 装饰,2023(6):133-135

[15] 李旭芳,沈伟棠,翁飞帆,等. 福建省乡土聚落的空间分布及其驱动机制 [J]. 风景园林,2023,30(6):121-129

[16] Li C, Qian Y, Li Z, et al. Identifying Factors Influencing the Spatial Distribution of Minority Cultural Heritage in Southwest China[J]. Heritage Science,2024,12(1):117

[17] 李亚恒,陈金华. 福建省非物质文化遗产空间分布特征及其影响因素[J]. 福建行政学院学报,2019(2):109-120

[18] Wang X, Zhang T, Duan L, et al. Spatial Distribution Characteristics and Influencing Factors of Intangible Cultural Heritage in the Yellow River Basin [J]. Journal of Cultural Heritage,2024,66:254-264

[19] 茹成谦,李文翎. 广东省特色小镇空间分布及其影响因素分析[J]. 地理空间信息,2024,22(4):12-15

[20] 王劲峰,徐成东. 地理探测器:原理与展望 [J]. 地理学报,2017,72(1):116-134

[21] 田磊,孙凤芝,张淑娴. 黄河流域非物质文化遗产空间分布特征及影响因素[J]. 干旱区资源与环境,2022,36(5):186-192

[22] Liu C, Kang L. How Do Geographical Factors Affect the Distribution of Intangible Cultural Heritage: A Case Study of Xinjiang, China [J]. Sustainability,2023,15(11):8 943

[23] 孙向裕,郑耀星. 福建传统音乐类非物质文化遗产标准化保护研究[J]. 海南师范大学学报(自然科学版),2015,28(2):212-217

[24] 马冬雪. 福建省体育非物质文化遗产的活态传承研究 [D]. 福州:福建师范大学,2016

[25] 刘书成,刘鑫,王彬. 福建省非物质文化遗产空间分布特征及成因探究[J]. 海南师范大学学报(自然科学版),2016,29(1):96-101

[26] 王厚雷,朱建勇,张怡. 长三角体育非物质文化遗产空间分布特征与影响因素研究[J]. 南京体育学院学报,2024,23(3):28-34