



肖庆云,程涛,顾兴健,等. 基于多尺度及 DESTIN 约束的高分遥感影像田块语义分割方法研究[J]. 南京农业大学学报,2024,47(5):989-999.
XIAO Qingyun, CHENG Tao, GU Xingjian, et al. Semantic segmentation of agricultural fields from high resolution remote sensing imagery based on multi-scale and DESTIN constraints[J]. Journal of Nanjing Agricultural University, 2024, 47(5): 989-999.

基于多尺度及 DESTIN 约束的高分遥感影像 田块语义分割方法研究

肖庆云¹,程涛²,顾兴健¹,朱艳²,黄芬^{1*}

(1.南京农业大学人工智能学院,江苏 南京 210031;2.南京农业大学国家信息农业工程技术中心/
智慧农业教育部工程研究中心/农业农村部农作物系统分析与决策重点实验室/江苏省信息农业重点实验室/
现代作物生产省部共建协同创新中心,江苏 南京 210095)

摘要:[目的]本研究旨在改善基于深度学习的遥感影像田块语义分割中出现的区域不封闭、边缘不贴合、噪点问题,并进一步修正语义分割的识别错误。[方法]以安徽省阜南县、江苏省淮安市为研究地点,自建了农田田块数据集,引入考虑影像多尺度特征的尺度分割思想与基于物候学的 DESTIN(delineation by fusing spatial and temporal information)分割算法,提出了基于多尺度及 DESTIN 约束的高分遥感影像农田田块语义分割方法。[结果]多尺度与 DESTIN 约束下基于深度模型的田块语义分割有效改善模型出现的区域不封闭、边缘不贴合、噪点和块状模糊等问题,一定程度修正了深度模型语义分割的错误识别,IoU 指标在 2 个测试集上分别达到 94.08%和 90.79%,相较深度模型的遥感影像田块语义分割分别提高 1.65%和 2.32%,对研究区域的田块提取区域更完整、精度更高。[结论]多尺度及 DESTIN 约束进一步改善了田块语义分割问题,有助于提高高分遥感影像的田块识别精度。

关键词:语义分割;多尺度分割;DESTIN 分割;农田田块提取;高分遥感影像

中图分类号:S127;TP391

文献标志码:A

文章编号:1000-2030(2024)05-0989-11

Semantic segmentation of agricultural fields from high resolution remote sensing image based on multi-scale and DESTIN constraints

XIAO Qingyun¹, CHENG Tao², GU Xingjian¹, ZHU Yan², HUANG Fen^{1*}

(1. College of Artificial Intelligence, Nanjing Agricultural University, Nanjing 210031, China;
2. National Information Agriculture Engineering Technology Center/Engineering Research Center of Smart Agriculture, Ministry of Education/Key Laboratory of Crop System Analysis and Decision Making, Ministry of Agriculture and Rural Affairs/Jiangsu Provincial Key Laboratory of Information Agriculture/Collaborative Innovation Center for Modern Crop Production, Nanjing Agricultural University, Nanjing 210095, China)

Abstract:[Objectives]The objective of this study was to address the problems of region non-closure, edge non-fitting and noise in the semantic segmentation of remote sensing images based on deep learning, and to further correct the recognition errors of semantic segmentation. [Methods]Taking Funan County of Anhui Province and Huai'an City of Jiangsu Province as the research sites, this paper built its own farmland plot dataset, introduced the idea of scale segmentation considering the multi-scale characteristics of images and the DESTIN(delineation by fusing spatial and temporal information) segmentation algorithm based on phenology, and proposed a semantic segmentation method for farmland plots based on multi-scale and DESTIN constraints. [Results]The field semantic segmentation based on the deep model under multi-scale and DESTIN-constrained effectively improved the problems of unenclosed region, non-fitting edges, noise and block-like blurring in the model, and corrected the misidentification area of the deep model semantic segmentation to a certain extent, and the IoU index reached 94.08% and 90.79% on the two test sets, respectively, and increased the semantic segmentation of the field by 1.65% and 2.32% compared with the remote sensing image of the deep model, respectively. The extraction area of the field in the study area was more complete and the accuracy was higher. [Conclusions]Multi-scale and DESTIN constraints further improved the semantic segmentation problem of fields, which was helpful to improve the accuracy of field recognition in high-resolution remote sensing images.

Keywords:semantic segmentation; multi-scale segmentation; DESTIN segmentation; extraction of farmland blocks; high resolution remote sensing image

收稿日期:2023-06-05

基金项目:国家重点研发计划项目(2016YFD0300607)

*通信作者:黄芬,博士,副教授,研究方向为深度学习与农业大数据分析、遥感影像,Email:fenhuang@njau.edu.cn.

作为一种典型的环境资源,高标准农田是保证农业可持续发展的关键^[1-3]。农田边界识别和地块信息监测是管理和保障高标准农田建设的关键。卫星遥感观测技术的发展,使得遥感影像分辨率越来越高,包含的细节信息也更加丰富,高分辨率遥感影像可以更全面反映地物形状、结构和纹理等空间特征^[4],以其作为数据源有利于实现农田田块的准确提取。

传统的基于像元方法认为田块识别是一个边缘检测问题,并在中低分辨率遥感影像地物识别中利用光谱特征与光谱差异取得一定效果,但仅仅利用地物光谱特征会带来错分、误分的同谱异物和同物异谱问题,以及地物重叠后的混合像元问题^[5],田块提取精度和效果不理想。以影像分割对象为基础的面向对象分割方法,应用以分割区域为最小单位的光谱特征并综合对象区域的纹理、形状、大小等低层次特征,以减少基于像元带来的椒盐噪声问题^[6-7]。谷鹤等^[8]为解决像元尺度下提取田块破碎的问题,利用多源高分卫星影像与支持向量机获取地块级时空谱特征,提取的田块精度更高、更完整。Wagner等^[9]提出了一种基于图像的生长轮廓的农田提取方法,包括边界检测和场多边形提取步骤,能够自动提取农业区域中复杂的边界。Rydberg等^[10]将梯度边缘检测器获得的边缘信息与基于区域生长图像分割算法相结合,通过使用有效多光谱信息,并在单波段中添加按边缘方向加权后的边缘,以消除“噪声”。上述面向对象分割方法具有不依赖标签数据、无需人工解译的优势,但对于大面积田块的提取效率、精度较低。

传统图像分割方法未能充分利用高分辨遥感影像的空间特征^[11]。深度学习因其强大的特征学习和高阶语义特征提取能力,使基于深度模型的田块语义分割方法成为目前的研究热点。Shelhamer等^[12]提出了一种全新的端到端全卷积网络(fully convolutional networks, FCN), Musyoka等^[13]基于FCN的深度特征学习能力,提取高层次的语义信息和低层次的位置信息,从WorldView-3卫星影像中提取出农田边界。Unet(U-Net)、DeepLab系列等语义分割网络也取得了优于传统图像分割方法的田块提取效果和精度。Du等^[14]选择DeepLabV3+对WorldView-2高分遥感影像提取作物田块区域,获得相比支持向量机、随机森林两种传统机器学习方法更高的分类精度及更清晰的作物种植区边界,但是未能分辨出与田块具有相似光谱、纹理和地形特征的地物。Aung等^[15]在Unet基础上引入时间信息实现了时空Unet,添加时间数据后的模型在不同形状的农田田块中表现良好,但是无法分割出小型田块区域。Waldner等^[16]基于设计的ResUNet-a网络,能对高分遥感影像准确检测出农田区域边界,但存在噪点和区域不封闭问题。端到端的全卷积网络在遥感影像农田田块语义分割中以像元为基本单位,往往存在小面积区域和周围区域属于不同类别的噪点现象、区域不封闭问题^[17-18],其下采样操作引起细节丢失导致小区域农田无法提取、农田边界不贴合等问题^[19]。

针对深度学习模型对遥感影像进行田块语义分割的噪点现象、区域不封闭与边缘不贴合问题,考虑田块的物候学特征及影像的多尺度特征,本文引入面向对象的多尺度分割和基于物候学的DESTIN(delineation by fusing spatial and temporal information)^[20]分割,构建基于多尺度与DESTIN约束的高分遥感影像农田田块分割模型,进一步提升田块的语义分割精度。

1 数据来源及预处理

从网站(<https://data.cresda.cn/#/2dMap>)下载获取安徽省阜南县部分区域的高分二号遥感影像(2020年1月29日,空间分辨1 m,大小35 292×34 512)。对影像进行辐射定标、大气校正、正射校正、图像融合等预处理后,采用自编写脚本将栅格影像批量不重叠裁剪为512×512像素的PNG格式图像2 500张;人工标注后剔除田块占比较少图像304张,构建安徽省(Anhui Province, AH)样本数据集(2 196张标注图像)。在AH中选择100张相邻区域的图片作为测试集AH-A(后续约束试验需要拼接相邻图像,并添加测试需要的地理编码信息),余下按8:2随机划分训练集AH-B(1 677张)和验证集AH-C(419张)。

对2幅面积1.5 km×1.5 km、分辨率0.5 m、3 000×3 000像素的WorldView-2江苏省淮安市影像,辐射定标、大气校正、正射校正、图像融合、影像配准、格式转换、影像裁剪等预处理为512×512像素的200张影像,挑选100张无云遮挡影像,结合实地调查和目视解译进行田块标注,构建与AH-A处于不同地理位置的江苏省(Jiangsu Province, JS)测试集。

训练集和验证集分别为AH-B、AH-C,测试集为AH-A和JS,图1为部分原始影像及对应标注数据。两地影像中均包含农田与非农田,农田呈现无规则、大小不一的特点,非农田则包含水体、建筑、田埂、荒地。农田区域中存在与周围区域属于不同类别的小田块,无法在深度网络方法中分割出来,并且容易产生

噪点现象、区域不封闭问题。非农田中水体和建筑的地物特征与农田区别明显,但是非农田中田埂和荒地的地物特征与农田非常相似,深度网络难以区分这类与田块具有相似地物特征的非农田。本文所提问题的地物特征,在选取的两地影像数据集上均有体现。统计各数据集中田块像素级占比为 40%~90%的图像样本数与数据集总样本数的比例(图 2),AH-B、AH-C、AH-A 和 JS 的比例分别为 77.0%、86.4%、64%、70%。相较于 AH-A,JS 的田块占比分布不规律,与训练集、验证集分布不一致。设计 2 个不同地理位置且分布不一致的测试集(AH-A 和 JS),进一步评估模型对不同数据源的泛化性。

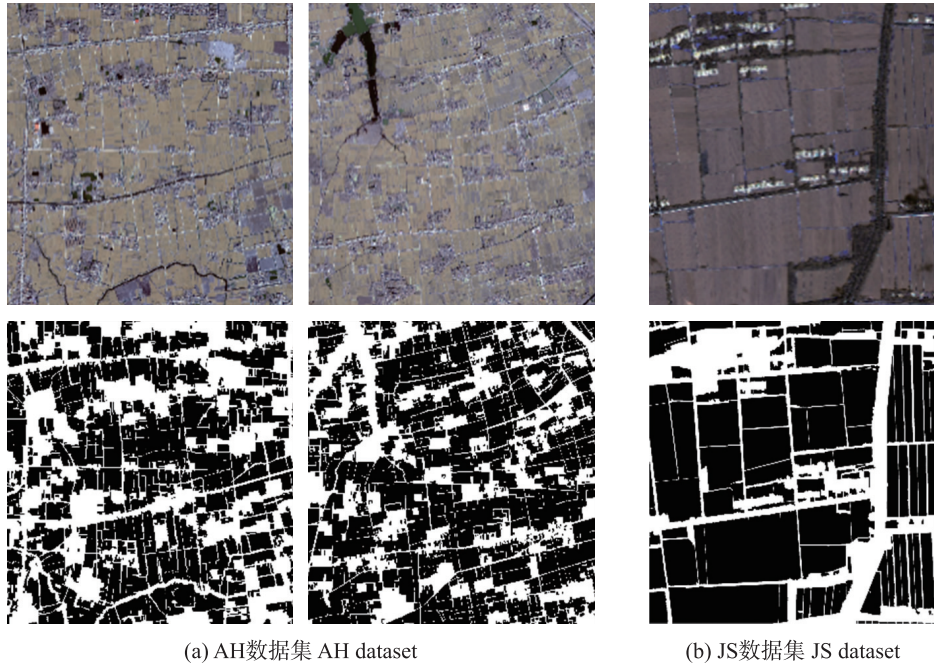


图 1 部分原始影像与对应标注数据集

Fig. 1 Part of the original imagery and corresponding labeled dataset

AH:安徽省阜南县;JS:江苏省淮安市。下同。

AH:Funan County of Anhui Province;JS:Huai'an City of Jiangsu Province. The same below.

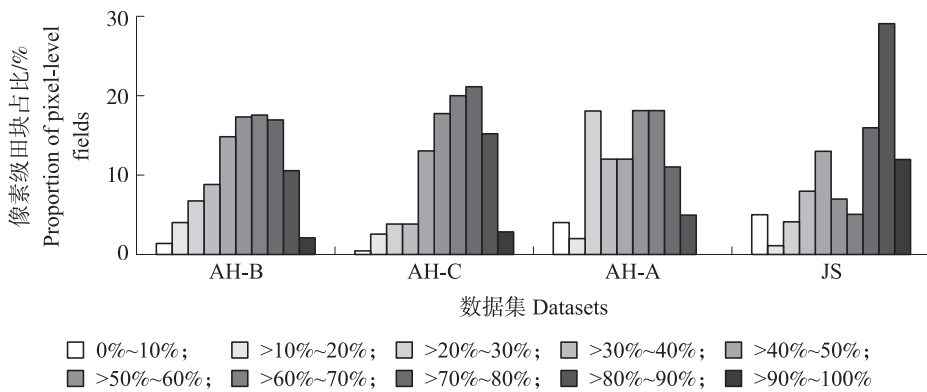


图 2 各数据集中田块像素占比

Fig. 2 Proportion of pixel-level field blocks in each dataset

AH-B 和 AH-C 为训练集和验证集,AH-A 和 JS 为测试集。下同。

AH-B and AH-C are the training and validation sets,and AH-A and JS are the test sets. The same below.

2 研究方法

2.1 基于遥感影像的农田田块语义分割

选用 Unet、ResUNet-a 和 DMA-TTL-SD 三种精度较高的典型深度学习模型进行遥感影像田块分割试验。Unet^[21]是一种对称编码解码的 U 型结构神经网络,使用 Overlap-Tile、边缘加权等策略,能同时获取上、下文信息和位置信息;减少因训练样本较少而出现的过拟合^[22];重视边缘像素的权重,但是在多层卷

积和池化后会损失空间信息和低级特征^[23],生成破碎田块。ResUNet-a^[24]在Unet基础上添加了Resblock、PSP pooling、空洞卷积模块,期望解决全局场景先验信息不足、感受野外信息丢失等问题,更好提取图像特征;但是ResUNet-a会产生不封闭的边界^[16]。DMA-TTL-SD^[25]为解决某些区域表征能力较弱、知识转移过程信息丢失问题,在Deeplabv3+基础上添加了多支注意力及传递迁移学习,能提取复杂形状小面积农田区域;但是较为粗糙、存在噪点^[25]。

针对上述3种模型在田块提取中存在的不同问题,首先分析这3种模型的高分遥感影像农田田块语义分割试验,确定较优模型,获取该模型的语义分割结果记为A;引入多尺度及DESTIN约束进一步优化田块语义分割方法。

2.2 多尺度约束的田块语义分割

高分遥感影像中田块空间结构复杂、大小不一,单一尺度分割易导致分割区域破碎,结构不完整。多尺度约束的语义分割通过提供尺度变化的田块区域空间结构差异性信息约束,有望提升遥感影像的田块语义分割精度。

2.2.1 多尺度分割 田块的分割尺度太小或太大会导致后期影像的过分割或欠分割,田块大小不同,适宜分割尺度不同。基于多尺度约束的语义分割,首先需根据田块尺度变化的差异性空间信息,为不同大小田块确定适宜分割尺度^[26-27]。

在一定尺度范围进行影像多尺度分割试验,绘制多尺度分割结果的波段亮度均值方差-尺度变化曲线^[28],提取均值方差峰值处的多个分割尺度及对应尺度下的分割影像。根据区域内同质性最大、区域间异质性最大原则^[29],计算Moran指数并融合各尺度分割影像,获取适应不同田块大小的适宜多尺度的完整分割结果,称结果为B1。

设某分割尺度将影像划分为 n 个区域, m 为区域 j 内像元总数; X_{Ri} 为区域 j 第 i 个像元 R 波段亮度值, X_{Rj} 是影像内区域 j 中 R 波段亮度均值, \bar{X}_R 是整幅影像 R 波段亮度均值, S_R^2 为当前尺度下影像 R 波段的均值方差。

$$X_{Rj} = \frac{1}{m} \sum_{i=1}^m X_{Ri} \quad (1)$$

$$\bar{X}_R = \frac{1}{n} \sum_{j=1}^n X_{Rj} \quad (2)$$

$$S_R^2 = \frac{1}{n} \sum_{j=1}^n (X_{Rj} - \bar{X}_R)^2 \quad (3)$$

Moran指数值的正负分别表示区域内的空间正相关或负相关,相关性随值的大小由强变弱,相关性越弱,空间差异越大,等于0时,空间呈随机性。

均值方差峰值处各适宜尺度对应每幅分割影像,大尺度分割区域包含下级小尺度多个分割区域的层级包含关系并表现为一种树形结构。根据Moran指数融合多尺度分割影像时,从大尺度开始进行尺度下推和区域替换,遍历同尺度下的各区域,直至最小尺度。若区域Moran指数超过阈值 B ,认为该区域相关性强,区域内地物空间结构差异小,该尺度适宜后期的语义分割,保留该区域及对应尺度;若区域Moran指数小于阈值 B ,认为该区域相关性弱,区域内地物空间结构差异大,易导致语义欠分割,尺度降到下级尺度,区域替换为其下级子区域。将下推过程保留的各区域按照地理位置拼接融合为最终适宜多尺度分割结果。

Moran指数(M_{Rw})的计算公式:

$$M_{Rw} = \frac{n \sum_{i=1}^n \sum_{j=1, j \neq i}^n w_{ij} (x_i - \bar{x}_w) (x_j - \bar{x}_w)}{\left(\sum_{i=1}^n \sum_{j=1}^n w_{ij} \right) \sum_{i=1}^n (x_i - \bar{x}_w)^2} \quad (4)$$

$$w_{ij} = \begin{cases} 1 & \text{区域 } i \text{ 与区域 } j \text{ 相邻} \\ 0 & \text{区域 } i \text{ 与区域 } j \text{ 不相邻或 } i=j \end{cases} \quad (5)$$

式中: n 是当前分割尺度 R 下区域 w 包含的下一尺度子区域总数; w_{ij} 是子区域 i 和子区域 j 的邻接关系; x_i 和 x_j 分别是区域 i 、 j 的属性值; \bar{x}_w 是区域 w 的属性均值。

2.2.2 多尺度约束的田块语义分割 统计 B1 中每个 Polygon 区域内模型分割结果 A 的语义信息,投票法确定影像各区域语义,当区域内田块语义超过半数,确定区域为田块,反之为非田块,获取多尺度约束下田块语义分割结果 C1。

2.3 DESTIN 约束的田块语义分割

语义分割生成的矢量文件中,同一个 Polygon 区域内同时出现田块正确和错误识别,造成分割区域不封闭问题,导致多尺度约束对区域不封闭问题较弱的纠错能力,引入 DESTIN 进一步纠正田块分割的识别错误,改善分割区域的不封闭。

Cheng 等^[20]为提高田块分割精度提出的 DESTIN 方法主要有 4 步:EGM(edge gradient magnitude)边缘检测算法生成边缘强度图;自适应阈值分割(adaptive threshold segmentation,ATS)算法提取空地;基于作物与非作物归一化植被指数(normalized difference vegetation index,NDVI)的显著差距构建分类阈值,区分具有相同地物特征的田块与非田块;使用形态学处理对作物田块形态细化。DESTIN 方法从亚米级 WorldView-2 遥感影像中提取精度较高的作物田块边界,但出现噪点、边缘不贴合等问题。

引入 DESTIN 约束模型语义分割前,进行了 DESTIN 方法 JS 和 AH-A 两个测试集的田块分割试验,IoU 值分别为 91.55%和 70.31%,表现较高的田块与非田块识别能力。引入 DESTIN 约束,统计深度模型分割结果 A 中每个 Polygon 区域内 DESTIN 结果 B2 的语义信息,投票法确定各区域的语义,获取 DESTIN 约束下田块语义分割结果 C2。

2.4 多尺度和 DESTIN 约束的田块语义分割

深度模型将识别为田块的每个区域均处理为一个 Polygon(本文将 Polygon 内实际对象均为同类的称为同质 Polygon,若同时存在田块和非田块实际对象的 Polygon 称为异质 Polygon),非田块区域则为空,2.3 节引入 DESTIN 约束的设计只能纠正同质 Polygon 区域内的识别错误,但不能纠正异质 Polygon 区域内的识别错误,以及置为空的非田块区域的识别错误。可见,仅施加 DESTIN 约束对语义分割识别错误的纠正能力有限;而多尺度约束在将语义分割区域划分成具有不同大小(多尺度)的多个同质区域时可进行子区域再分类,实现错误与正确区域的分离,从而将深度模型提取的异质 Polygon 分割为更小尺度的同质 Polygon,多尺度约束叠加 DESTIN 约束有望进一步纠正深度模型的识别错误。因此,首先对语义分割进行多尺度约束,寻求解决语义分割区域内部小块区域识别不准确(噪点)、块状模糊及区域不封闭的问题,再施加 DESTIN 约束进一步纠正语义分割区域内的识别错误,改善语义分割的区域不封闭现象,获取多尺度和 DESTIN 约束下遥感影像农田田块语义分割结果 C。

3 结果与分析

进行 3 种模型(Unet、ResUNet-a、DMA-TTL-SD)田块语义分割试验,IoU 指标和目视对比分析法选择田块分割的适宜深度模型,对选择模型的分割结果进行多尺度、DESTIN 和二者约束的田块分割试验。

3.1 模型比较

训练集 AH-B 和验证集 AH-C 分别训练 3 个模型,测试集 AH-A 和 JS 上分别生成 512×512 像素 PNG 文件,构成各自的语义分割结果分别记为 A_AH-A 和 A_JS。图 3 显示,3 个模型 2 个测试集上的田块语义分割结果均出现不同程度的噪点、边缘不贴合、块状模糊(即区域破碎)、区域不封闭和分类错误等问题。

AH-A 真实边界 a,Unet 和 DMA-TTL-SD 均能很好区别田块、田埂和非田块,田块区域的识别较完整(图 3-a-1、a-3),但噪点较多,且存在边缘不贴合、块状模糊,区域不封闭、分类错误等问题,其中,DMA-TTL-SD 的边缘不贴合问题更为严重;ResUNet-a 表现最差,块状模糊的问题最为严重,且错误识别的区域较大,将河流误判为田块(图 3-a-2 绿框)。JS 的真实边界 b,DMA-TTL-SD 的田块与非田块区域识别最为精确,噪点、块状模糊和错误识别较少,但边缘不贴合与区域不封闭问题仍然存在,主要表现在农田边界与田埂有较大重合(图 3-b-3 红框);Unet 的块状模糊和噪点问题较为严重(图 3-b-1),ResUNet 强于 Unet,但弱于 DMA-TTL-SD,区域识别错误较少,但在田块区域内部噪点很多,导致区域不完整、一些田埂无法识别(图 3-b-2)。

3 个模型 2 个测试集上的 IoU 值见表 1。Unet 和 DMA-TTL-SD 分别在 AH-A 和 JS 取得 90.61%和 92.43%的最高 IoU 值,AH-A 上 DMA-TTL-SD 的 IoU 值为 88.47%,弱于 Unet 的 90.61%,JS 上 DMA-TTL-SD 的 IoU 值为 92.43%,明显优于 Unet 的 79.87%;ResUNet-a 对 AH-A 的表现最差,JS 上的 IoU 值为 81.55%

明显低于 DMA-TTL-SD 的 92.43%。

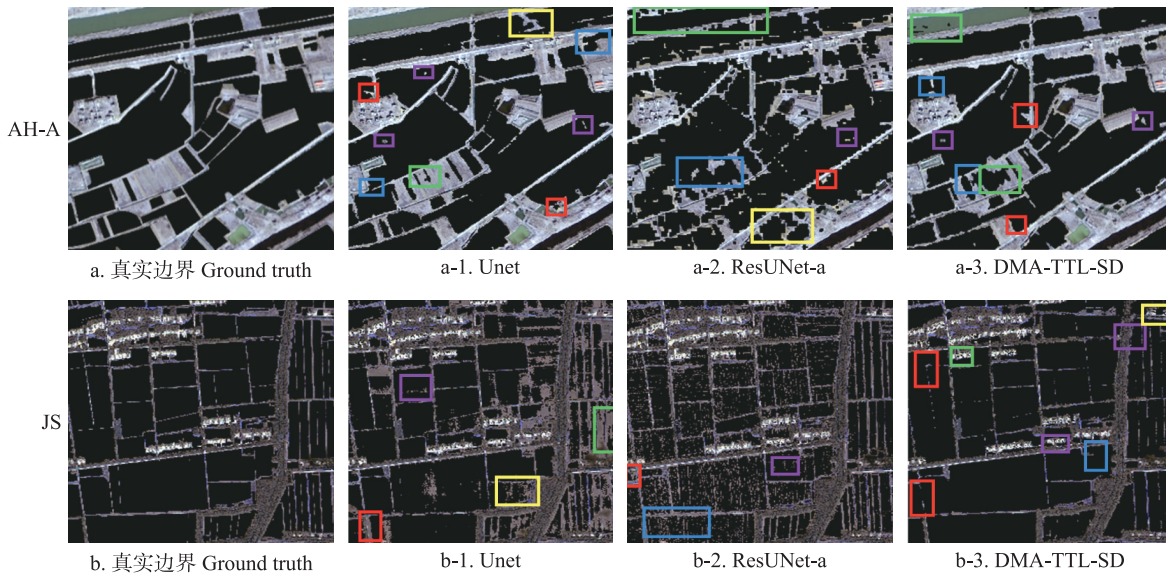


图 3 3 种模型在 2 个测试集上的目视结果

Fig. 3 Visual results of three models on two test sets

紫、红、黄、蓝和绿框分别表示噪点、边缘不贴合、块状模糊(即区域破碎)、区域不封闭和分类错误。下同。

Purple, red, yellow, blue, and green boxes respectively represent noise, edge misalignment, blocky blurring (i.e. area fragmentation), unclosed areas, and classification errors. The same below.

分析认为, ResUNet-a 存在提取边界不连续问题^[16]导致田块提取问题较为严重, IoU 值较低; Unet 损失空间信息和低级特征导致田块提取不完整、噪点以及小型田块识别不佳等问题, 且精度不稳定, IoU 值在 JS 和 AH-A 数据集上相差过大; 相较于另 2 个模型, DMA-TTL-SD 虽难以区分具有相似地物特征

的农田与非农田, 导致边缘不贴合与区域不封闭问题, 但在 2 个测试集上的 IoU 值相对较高且更稳定, 泛化性能更好, 田块识别问题较少, 故针对 DMA-TTL-SD 存在问题, 研究引入约束方法进一步优化。

3.2 语义分割方法的优化

DMA-TTL-SD 虽对田块识别精度较高, 但也出现了不同程度的噪点、块状模糊、分类错误及区域不封闭等问题, 且边缘不贴合较为突出。设计多尺度、DESTIN 和多尺度及 DESTIN 约束下的 DMA-TTL-SD 语义分割试验, 寻求改善语义分割问题和识别错误。

DMA-TTL-SD 生成的 2 个测试集分割结果 A_AH-A 和 A_JS 为 PNG 文件, 添加地理编码信息后拼接成 5 120×5 120 的栅格文件(TIF 格式), 再转换为矢量文件(SHP 格式), 共同作为 3 个约束试验的输入。

3.2.1 多尺度约束的农田田块提取 多尺度分割基于光谱空间位置将遥感影像分割为边缘较为贴合的若干不规则大小的封闭区域, 区域内不会出现噪点现象和块状模糊。引入多尺度约束能够改善 DMA-TTL-SD 出现的噪点、边缘不贴合、块状模糊、区域不封闭等问题, 提高消除模型噪声的能力。

采用商业软件 eCongition 中的多尺度分割算法 FNEA (fractal net evolution approach), 输入测试集 AH-A 的 TIF 文件, 进行范围 10~160、隔 10 的多尺度分割试验。首先, 确定各波段、光谱因子、形状因子和紧致度因子的最终权重, 各分割尺度下采用穷举目测法确定因子权重为 1.0、0.9、0.3、0.9, 具有最好的分割效果; 其次, 构建多尺度分割均值方差-尺度曲线(图 4), 确定峰值处适宜尺度为 30、60、120, 分别提取 3 个尺度下的适宜影像分割区域; 再次, 基于 Moran 指数融合 3 个尺度下的分割区域, 获取整体分

表 1 模型在 2 个测试集上的 IoU 值

数据集 Datasets	模型 Models		
	Unet	ResUNet-a	DMA-TTL-SD
JS	79.87	81.55	92.43
AH-A	90.61	74.54	88.47




图 4 均值方差-尺度变化曲线

Fig. 4 Mean variance-scale change curve

割结果 B1_AH-A(SHP 文件),同种方法得到 JS 的尺度融合结果 B1_JS(SHP 文件);最后,基于 B1_AH-A 和 B1_JS,采用投票法确定 DMA-TTL-SD 语义分割结果 A_AH-A 和 A_JS 中每个 Polygon 区域内的语义信息,获取多尺度约束下农田田块提取结果,记为 C1_AH-A 和 C1_JS。

2 个测试集上模型及约束优化下的分割结果见图 5,其中图 5-b 是从 JS 测试集上挑选的一幅出现 5 种语义分割问题的较典型样本,称为 JS-1。引入多尺度约束后有效消除了语义分割在样本 a 上的噪点(图 5-a-1 紫框)、样本 b 的块状模糊(图 5-b-1 黄框),样本 a 和 b 中部分不封闭区域得到改善或消除(图 5-a-1、b-1 蓝框),样本 a 的边缘更贴合田块区域(图 5-a-1 红框),纠正样本 a 和 b 中部分识别错误(图 5-a-1、b-1 绿框)。但同时导致某些区域边缘凹凸不平有毛刺、不平滑(图 5-a-2、b-2 红色椭圆)。

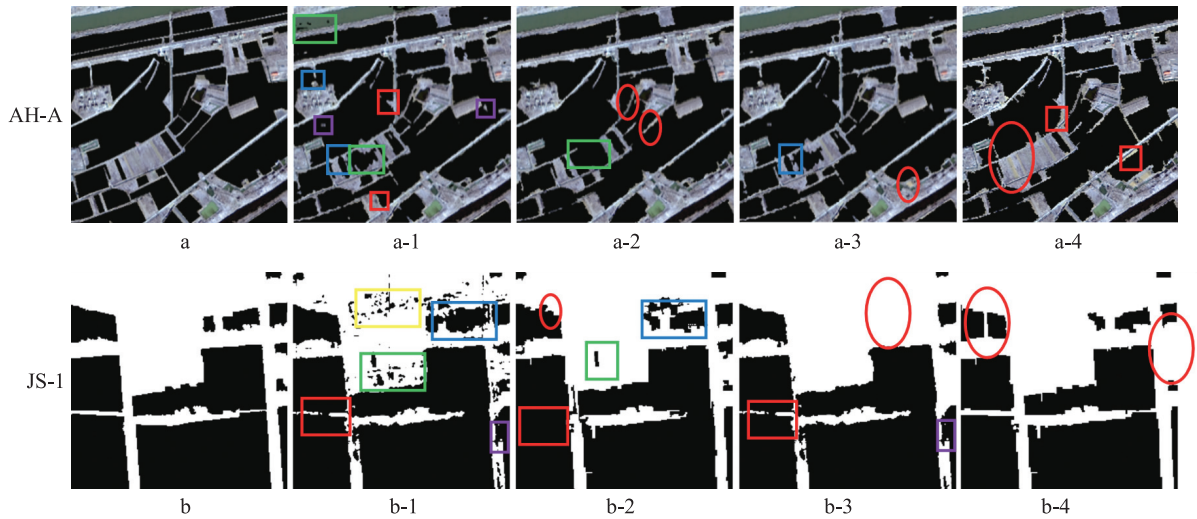


图 5 DMA-TTL-SD 模型及约束优化下 2 个测试集的视觉结果

Fig. 5 Visual results of two test sets under DMA-TTL-SD model and constraint optimization

图像从左往右,第 1 至 5 分别为真实边界、基于深度学习的田块提取、多尺度约束、DESTIN 约束、多尺度与 DESTIN 约束下的田块提取。红色椭圆表示负优化。

In images from left to right, the first to fifth are true boundary, field extraction based on deep learning, multi-scale constraint, DESTIN constraint, multi-scale and DESTIN constraints. The red ellipse represents the negative optimization.

2 个测试集上模型分割及约束优化后的 IoU 值见表 2, IoU 值未见有效提高,多尺度约束在 AH-A 上的 IoU 值(87.58%)低于语义模型(88.47%), JS 上的 IoU 值(92.73%)高于语义模型(92.43%)。这说明基于尺度变化的田块区域空间结构差异性信息约束可有效消除噪点、块状模糊,一定程度优化语义分割区域的破碎不完整,但由于对具有相同地物特征区域的区分能力较弱,有待进一步纠正识别错误以改善区域不封闭问题;同时,由于像素多尺度特点会导致边缘毛刺等问题使得 IoU 值未得到提高,后续可以尝试边缘优化对该问题进行改善。

表 2 DMA-TTL-SD 模型及约束优化下 2 个测试集的 IoU 值

Table 2 IoU values of two test sets under DMA-TTL-SD model and constraint optimization

数据集 Datasets	语义分割 Semantic segmentation	DMA-TTL-SD				Unet
		多尺度约束 Multiscale constraints	DESTIN 约束 DESTIN constraint	多尺度与 DESTIN 约束 (阈值=0) Multiscale and DESTIN constraints (threshold = 0)	多尺度与 DESTIN 约束 (阈值=-900) Multiscale and DESTIN constraints (threshold = -900)	多尺度与 DESTIN 约束 (阈值=-900) Multiscale and DESTIN constraints (threshold = -900)
JS	92.43	92.73	93.03	93.95	94.08	86.49
AH-A	88.47	87.58	89.10	89.08	90.79	90.60

3.2.2 DESTIN 约束的农田田块提取 2 个测试集的 TIF 文件输入 DESTIN 算法,获取 DESTIN 分割结果 B2_AH-A(SHP 文件)和 B2_JS(SHP 文件),分别对 DMA-TTL-SD 语义分割结果 A_AH-A 和 A_JS 施加约束,得到 DESTIN 约束的分割结果 C2_AH-A 和 C2_JS。

图 5 和表 2 的结果显示,DESTIN 约束对语义分割结果中同质 Polygon 区域识别结果的纠错能力较强,语义模型的部分识别错误得以纠正(图 5-a-1、b-1 绿框),2 个测试集的 IoU 值也分别从语义模型的

88.47%、92.43% 提高到 89.10%、93.03% (表 2); 但由于 DESTIN 约束未能纠正语义分割结果中的异质 Polygon 和非 Polygon 区域的识别结果, 不封闭区域(图 5-a-1、b-1 蓝框, 即异质 Polygon 区域)、边界不贴合问题(图 5-a-1、b-1 红框) 未见改善。考虑通过多尺度约束有效提取尺度不一的完整地块, 将异质 Polygon 区域转变为多尺度的同质区域, 为 DESTIN 约束提供更多尺度不一的完整封闭的同质区域, 发挥其同质区域的纠错能力, 改善语义分割的区域不封闭问题, 提高分割精度。分析同时发现, 施加 DESTIN 约束后错误修改了语义模型的正确识别(图 5-b-3、a-3 红色椭圆), 本文称为负优化。

3.2.3 多尺度及 DESTIN 约束的农田田块提取 综合多尺度分割对噪点、块状模糊、边缘不贴合及不封闭问题的优势, 及 DESTIN 优于多尺度分割的纠错能力, 设置约束算法中投票阈值为 0, 对 3.2.1 节 2 个多尺度约束结果 C1_AH-A 和 C1_JS 进一步施加 DESTIN 约束, 获取双约束下田块提取结果 C_AH-A 和 C_JS。

相较于深度模型、多尺度约束、DESTIN 约束的语义分割, 双约束下 JS 的 IoU 值分别从 92.43%、92.73%、93.03% 提高到 93.95%, 深度模型、多尺度约束、DESTIN 约束的语义分割和双约束下 AH-A 的 IoU 值分别为 88.47%、87.58%、89.10% 和 89.08% (表 2)。图 5 显示, AH-A 的双约束对语义分割识别错误的纠正能力强于仅多尺度约束或 DESTIN 约束(图 5-a-2、b-2 绿框), 并解决了 DESTIN 约束因异质区域不封闭未能纠错的问题(图 5-a-3 蓝框), 同时将多尺度约束部分不封闭区域转换为封闭区域(图 5-b-2 蓝框), 块状模糊与噪点的解决程度与多尺度约束一致, 强于 DESTIN 约束, 但是 DESTIN 分割粗糙并出现了边界不贴合问题(图 5-a-4 红框); JS 同样体现出双约束对语义分割的纠错能力(图 5-b-1 绿框), 且对块状模糊、边缘不贴合及区域不封闭等问题的解决优于仅多尺度约束或 DESTIN 约束(图 5-b-1 紫、黄、蓝、红、绿 5 个矩形)。同时, 2 个数据集均出现了负优化问题(图 5-a-4、b-4 红色椭圆), 进一步通过阈值优化探讨解决双约束下语义分割负优化问题的可能性。

3.2.4 阈值优化 分析双约束对模型语义分割错误的纠正情况, 进一步优化约束投票阈值, 提升分割精度。对模型和双约束方法在 AH-A 测试集上的田块与非田块分割正确与否进行像素点占比统计(表 3), 将优化情况划分为正优化、负优化和无优化 3 类。正优化的 4 种情况中, 正正正和负负负表示模型和双约束 2 种方法均能正确识别田块和非田块, 而正负正和负正负表示双约束修正了模型对田块和非田块的错误识别; 负优化的正正负和负负正表示双约束错误修改了模型对田块和非田块的正确识别, 而无优化的正负负和负正正则表示双约束未能修正模型对田块和非田块的识别错误。可见, 为提升分割精度, 应尽量提高正优化的比例, 降低无优化和负优化的比例。

表 3 阈值为 0 与 -900 的模型和双约束语义分割的像素点占比统计

Table 3 Proportion statistics of pixels with thresholds of 0 and -900 on model and double-constrained semantic segmentation

真实边界区域类别 True boundary area category	语义分割区域类别 Semantic segmentation area categories	双约束下的语义分割区域类别 Semantic segmentation of regional categories under double constraints	像素点占比/% Proportion of pixels		优化情况 Optimization situation
			阈值=0 Threshold = 0	阈值=-900 Threshold = -900	
正 Positive	正 Positive	正 Positive	52.63	53.89	正 Positive
		负 Negative	2.81	1.55	负 Negative
	负 Negative	正 Positive	1.41	1.59	正 Positive
		负 Negative	1.68	1.50	无 No
负 Negative	正 Positive	正 Positive	1.59	1.70	无 No
	负 Negative	负 Negative	2.69	2.58	正 Positive
		正 Positive	1.16	1.40	负 Negative
	负 Negative	负 Negative	36.03	35.79	正 Positive

注: 正代表田块; 负代表非田块。

Note: Positive represents field block; negative represents non-field block.

从表 3 可见, 图像融合阈值(即投票阈值)为 0 时的 2 种负优化占比中正正负的比例(2.81%)比负负正的比例(1.16%)高, 需要将双约束下错误判定为负的区域修正为正, 即判定为田块, 从而降低正正负的比例。对比分析 3.2.3 节提取结果 C_AH-A 和引入 DESTIN 约束的粗糙分割结果(图 5-a-4 红框和红色椭圆, a-3 红色椭圆, b-4 红色椭圆), 可能是部分区域出现负优化的原因。可考虑通过优化图像融合阈值, 适当降低语义分割上施加 DESTIN 约束的权重。

降低施加 DESTIN 约束的权重相应会减少双约束下语义分割的负语义比例,提高正语义比例同时降低负语义比例,有可能提高正正正(正优化)、正负正(正优化)、负正正(无优化)、负负正(负优化)的比例,降低正正负(负优化)、正负负(无优化)、负正负(正优化)、负负负(正优化)的比例,而其中正负正与正正正比例的提高、正正负比例的降低是修改阈值所希望出现的结果。通过试验量化数据分析阈值优化的可行性。

在测试集 AH-A 上进行 11 组阈值(范围-1 100~0,步长 100)的探索性试验,分割精度和目视解译发现阈值为-900 时试验结果最优。阈值为-900 和 0 时双约束下田块与非田块分割的正确和错误比例见表 3,阈值为-900 时 2 种负优化(正正负和负负正)的占比之和 2.95% 低于阈值 0 的 3.97%,其中,正正负的比例从阈值为 0 的 2.81% 降低到阈值为-900 的 1.55%;阈值为-900 两种无优化的占比之和 3.20% 与阈值 0 的 3.27% 基本一致;阈值为-900 时 4 种正优化的占比之和 93.84% 高于阈值 0 的 92.76%。可见,双约束下对阈值的调整和优化可进一步提升语义分割精度,阈值为-900 在调高正优化比例、降低负优化比例的同时,保持了无优化比例。

表 2 显示,DMA-TTL-SD 在 2 个测试集上的多尺度和 DESTIN 约束语义分割试验,阈值为-900 的 IoU 值均高于阈值为 0,分别从 89.08%、93.95% 提高到 90.79%、94.08%。图 6 显示,阈值为-900 时,DESTIN 负优化的问题得到解决(图 6-a 红色椭圆),但面积过大区域的负优化问题仍未解决(图 6-b 绿框),阈值为 0 对不封闭区域的改善(图 6-b 蓝框)重新变回不封闭区域,且像素多尺度特点导致的边缘毛刺问题仍然存在。综上,优化图像融合阈值为-900 后,能进一步发挥 DESTIN 约束的纠错能力,提取的田块区域噪点少、无块状模糊、边缘贴合,区域封闭更完整。

考虑 DMA-TTL-SD 两个测试集的 IoU 值相对较高且更稳定,选择其为基础模型,但 DMA-TTL-SD 在 AH-A 上的 IoU 值 88.47% 低于 Unet 的 90.61%(表 1),阈值为-900 时增加了 Unet 两个数据集的双约束试验(表 2),AH-A 测试集上 Unet 的 IoU 值 90.60% 低于 DMA-TTL-SD 的 90.79%。Qi 等^[30]采用改进的 TransUNet 网络分割算法,对安徽地区与本文相同区域的高分二号遥感原始影像提取田块进行试验,IoU 值(86.28%) 低于本方法在 AH-A 上的 90.79%。本文优化后 DMA-TTL-SD 在-900 阈值下取得相对更高的 IoU 值(90.79%)。可见本文算法虽尚未很好解决边缘毛刺及少数负优化问题,但总体精度具有一定的优势。

4 结论

本文针对遥感影像田块提取存在区域不封闭、边缘不贴合、噪点、块状模糊和区域识别错误等问题,提出基于多尺度及 DESTIN 约束语义分割方法,实现基于遥感影像的高精度农田田块提取。

1) 多尺度约束 DMA-TTL-SD 模型对形状复杂的田块具有较强的建模能力,为提取完整的田块提供基础。

2) DESTIN 约束语义分割模型对田块和非田块区域具有较强的区分能力,提高了田块提取的精度。

3) 本模型对江苏淮安和安徽阜阳的遥感影像的田块提取平均交并比分别达到 94.08% 和 90.79%,满足相关领域的要求。

参考文献 References:

- [1] 冯丽英. 基于深度学习技术的高分辨率遥感影像建设用地信息提取研究[D]. 杭州:浙江大学,2017.
Feng L Y. Research on construction land information extraction from high resolution images with deep learning technology[D]. Hangzhou: Zhejiang University,2017(in Chinese with English abstract).
- [2] 熊曦柳,胡月明,文宁,等. 耕地遥感识别研究进展与展望[J]. 农业资源与环境学报,2020,37(6):856-865.
Xiong X L,Hu Y M,Wen N,et al. Progress and prospect of cultivated land extraction research using remote sensing[J]. Journal of Agricultural Resources and Environment,2020,37(6):856-865(in Chinese with English abstract).




图 6 AH-A 上阈值为 0 和-900 目视结果对比
Fig. 6 Comparison of visual results with a threshold of 0 and -900 on AH-A

- [3] 王晓青,史文娇,孙晓芳,等. 黄淮海高标准农田建设项目综合效益评价及区域差异[J]. 农业工程学报,2018,34(16):238-248,300.
Wang X Q, Shi W J, Sun X F, et al. Comprehensive benefit evaluation and regional differences of construction projects of well-facilitated farmland in Huang-Huai-Hai region [J]. Transactions of the Chinese Society of Agricultural Engineering, 2018, 34 (16) : 238 - 248, 300 (in Chinese with English abstract).
- [4] 郑双朋. 基于语义分割网络的多波段遥感影像耕地提取[D]. 上海:上海交通大学,2020.
Zheng S P. Farmland extraction from multi-band remote sensing image based on semantic segmentation network [D]. Shanghai: Shanghai Jiao Tong University, 2020 (in Chinese with English abstract).
- [5] 孙家波,张晓艳,牛鲁燕,等. 基于高分辨率遥感影像的耕地信息快速提取方法研究[J]. 山东农业科学,2018,50(3):132-136,141.
Sun J B, Zhang X Y, Niu L Y, et al. Farmland information extraction method based on high-resolution remotely-sensed images [J]. Shandong Agricultural Sciences, 2018, 50 (3) : 132 - 136, 141 (in Chinese with English abstract).
- [6] 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):1582-1590.
Zhang X C, Huang J F, Ning T. Progress and prospect of cultivated land extraction from high-resolution remote sensing images [J]. Geomatics and Information Science of Wuhan University, 2023, 48 (10) : 1582 - 1590 (in Chinese with English abstract).
- [7] Devi Y A S, Krishna I V M. Pixel-based and object-oriented classification of high resolution satellite images [J]. Canadian Journal on Electrical and Electronics Engineering, 2012, 3 (1) : 31 - 34.
- [8] 谷鹤,尚坤,秦爱玲,等. 地块尺度下基于多源卫星遥感数据的粮食作物识别[J]. 农业工程学报,2022,38(16):33-41.
Gu H, Shang K, Qin A L, et al. Identification of grain crop using multi-source satellite remote sensing data at field parcel scale [J]. Transactions of the Chinese Society of Agricultural Engineering, 2022, 38 (16) : 33 - 41 (in Chinese with English abstract).
- [9] Wagner M P, Oppelt N. Extracting agricultural fields from remote sensing imagery using graph-based growing contours [J]. Remote Sensing, 2020, 12 (7) : 1205.
- [10] Rydberg A, Borgefors G. Integrated method for boundary delineation of agricultural fields in multispectral satellite images [J]. IEEE Transactions on Geoscience and Remote Sensing, 2001, 39 (11) : 2514 - 2520.
- [11] Li M M, Long J, Stein A, et al. Using a semantic edge-aware multi-task neural network to delineate agricultural parcels from remote sensing images [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2023, 200 : 24 - 40.
- [12] Shelhamer E, Long J, Darrell T. Fully convolutional networks for semantic segmentation [C] // 2017 IEEE Transactions on Pattern Analysis and Machine Intelligence. IEEE, 2017: 640 - 651.
- [13] Musyoka G M. Automatic delineation of small holder agricultural field boundaries using fully convolutional networks [D]. Enschede: University of Twente, 2018.
- [14] Du Z R, Yang J Y, Ou C, et al. Smallholder crop area mapped with a semantic segmentation deep learning method [J]. Remote Sensing, 2019, 11 (7) : 888.
- [15] Aung H L, Uzcent B, Burke M, et al. Farm parcel delineation using spatio-temporal convolutional networks [C] // 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. IEEE, 2020: 76 - 77.
- [16] Waldner F, Diakogiannis F I. Deep learning on edge: extracting field boundaries from satellite images with a convolutional neural network [J]. Remote Sensing of Environment, 2020, 245 : 111741.
- [17] 李雨慧. 基于深度学习的高分辨率遥感影像多尺度语义分割[D]. 上海:上海交通大学,2018.
Li Y H. Multi-scale semantic segmentation of high-resolution remote sensing images based on deep learning [D]. Shanghai: Shanghai Jiao Tong University, 2018 (in Chinese with English abstract).
- [18] Wang M, Wang J, Cui Y P, et al. Agricultural field boundary delineation with satellite image segmentation for high-resolution crop mapping: a case study of rice paddy [J]. Agronomy, 2022, 12 (10) : 2342.
- [19] 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.
Xu W N. Research on cultivated land extraction technology of remote sensing image based on high resolution full convolutional network [D]. Shenzhen: Shenzhen Institutes of Advanced Technology, University of Chinese Academy of Sciences, 2020 (in Chinese with English abstract).
- [20] Cheng T, Ji X S, Yang G X, et al. DESTIN: a new method for delineating the boundaries of crop fields by fusing spatial and temporal information from WorldView and Planet satellite imagery [J]. Computers and Electronics in Agriculture, 2020, 178 : 105787.
- [21] Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation [C] // 2015 International Conference on Medical Image Computing and Computer-Assisted Intervention. Cham: Springer, 2015: 234 - 241.
- [22] Srivastava N, Hinton G E, Krizhevsky A, et al. Dropout: a simple way to prevent neural networks from overfitting [J]. Journal of Machine Learning Research, 2014, 15 (1) : 1929 - 1958.
- [23] 李倩楠,张杜娟,潘耀忠,等. MPSPNet 和 UNet 网络下山东省高分辨耕地遥感提取[J]. 遥感学报,2023,27(2):471-491.
Li Q N, Zhang D J, Pan Y Z, et al. High-resolution cropland extraction in Shandong Province using MPSPNet and UNet network [J]. National Remote Sensing Bulletin, 2023, 27 (2) : 471 - 491 (in Chinese with English abstract).
- [24] Diakogiannis F I, Waldner F, Caccetta P, et al. ResUNet-a: a deep learning framework for semantic segmentation of remotely sensed data [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2020, 162 : 94 - 114.
- [25] 黄品于. 基于高分辨率遥感影像农田语义分割模型构建与优化[D]. 南京:南京农业大学,2022.
Huang P Y. Construction and optimization of field semantic segmentation model based on high resolution remote sensing images [D]. Nanjing:

- Nanjing Agricultural University,2022(in Chinese with English abstract).
- [26] Gu H Y,Han Y S,Yang Y,et al. An efficient parallel multi-scale segmentation method for remote sensing imagery[J]. Remote Sensing,2018,10(4):590.
- [27] 潘俊虹,梁明. 多尺度分割的高分辨率遥感影像分类对比研究[J]. 现代计算机,2022,28(22):56-60.
Pan J H,Liang M. A comparative study of high-resolution remote sensing image classification based on multi-scale segmentation[J]. Modern Computer,2022,28(22):56-60(in Chinese with English abstract).
- [28] 张吉星,程效军,郭王. 一种高分辨率遥感影像最优分割尺度确定的方法[J]. 地矿测绘,2016,32(2):12-14,31.
Zhang J X,Cheng X J,Guo W. A method of determining optimal segmentation scale of high resolution remote sensing image[J]. Surveying and Mapping of Geology and Mineral Resources,2016,32(2):12-14,31(in Chinese with English abstract).
- [29] 洪亮,楚森森,彭双云,等. 顾及全局和局部最优的高分辨率遥感影像多尺度分割优化算法[J]. 遥感学报,2020,24(12):1464-1475.
Hong L,Chu S S,Peng S Y,et al. Multiscale segmentation-optimized algorithm for high-spatial remote sensing imagery considering global and local optimizations[J]. Journal of Remote Sensing,2020,24(12):1464-1475(in Chinese with English abstract).
- [30] Qi L,Zuo D F,Wang Y R,et al. Convolutional neural network-based method for agriculture plot segmentation in remote sensing images[J]. Remote Sensing,2024,16(2):346.

责任编辑:沈 波