

基于深度学习的生产建设项目扰动图斑提取算法和识别策略

卢慧中¹, 卞雪¹, 金秋¹, 雷少华¹, 耿韧¹, 徐春¹, 朱研²

(1. 南京水利科学研究院 水灾害防御全国重点实验室, 江苏 南京 210029;

2. 河海大学 农业科学与工程学院, 江苏 南京 211100)

[关键词] Unet 模型; 深度学习; 识别策略; 提取算法; 扰动图斑; 生产建设项目

[摘要] 深度学习已成为一种高效且精确的遥感图像分类方法。针对生产建设项目扰动图斑识别问题, 从目标识别和变化检测两种思路出发, 对比评价 Unet、Unet++ 和 Unet3+ 三种深度学习网络模型的识别精度, 以提出最优的扰动图斑识别策略。结果表明: 基于目标识别策略和变化检测策略时, 均为 Unet 模型表现最优, 其检测结果分割边界清晰平滑, 误检、漏检情况较少, 无冗余特征, 预测结果更接近于标签图像, 识别效果最佳。当遥感影像质量满足要求、需要精细化的认定结果时, 采用基于变化检测策略的 Unet 深度学习网络模型可作为生产建设项目扰动图斑提取的最优模型; 当遥感影像质量不佳或仅有单时相遥感影像, 且需要快速确定扰动区域时, 宜采用基于目标识别策略的 Unet 网络模型; 当训练数据集足够支撑模型训练时, 可考虑使用结构更加复杂、细节提取能力更强的 Unet++ 与 Unet3+ 网络模型。

[中图分类号] TP751; TP18 [文献标识码] A DOI: 10.3969/j.issn.1000-0941.2024.08.007

[引用格式] 卢慧中, 卞雪, 金秋, 等. 基于深度学习的生产建设项目扰动图斑提取算法和识别策略[J]. 中国水土保持, 2024(8): 23-28.

2022 年 12 月, 中共中央办公厅、国务院办公厅印发的《关于加强新时代水土保持工作的意见》提出, 全覆盖、常态化开展水土保持遥感监管, 全面监控、及时

发现、精准判别人为水土流失情况, 依法依规严格查处有关违法违规行为。2023 年 2 月, 水利部办公厅印发的《2023 年水土保持工作要点》提出, 要持续深化遥感

5 结论

1) 对龙华区 24 处道路边坡的景观影响度分析表明, 景观影响度极严重的 1 处, 占比约 4%; 严重的 1 处, 占比约 4%; 一般的 7 处, 占比约 29%; 轻微的 15 处, 占比约 63%。经过生态景观综合评价, A 类重点修复边坡占比 4%, B 类一般修复边坡占比 21%, C 类一般提升边坡占比 29%, D 类轻微可不改造边坡占比 46%, 其中需要进行生态景观综合治理和生态修复的边坡景观影响度大, 要高度重视。

2) 不同边坡的景观影响度结合现状植被生长情况, 治理措施不同。A 类边坡必须结合生物措施与工程措施(包括景观再造)进行综合治理; B 类边坡则宜以生物措施为主, 注重边坡的植被群落建设, 兼顾景观效果; C 类边坡以人工辅助植被恢复为主, 优化植物群落结构; D 类边坡以保持现状和自然恢复为主, 可不进行人工干预。

州: 暨南大学, 2011: 1-2.

- [2] 王伟. 深圳市坡面生态工程中类芦的开发利用[D]. 兰州: 甘肃农业大学, 2006: 3.
- [3] 郭锋, 章梦涛, 陈振峰. 裸露山体缺口景观影响度及其生态修复技术[J]. 中国园林, 2009, 25(11): 63-66.
- [4] 李秀珍, 肖笃宁. 城市的景观生态学探讨[J]. 城市环境与城市生态, 1995, 8(2): 26-30.
- [5] 柳长顺, 齐实. 深圳市裸露山体缺口景观影响程度研究[J]. 水土保持学报, 2001, 15(1): 36-38.
- [6] 张永伟, 刘怀念, 刘元本. 山东省损毁山体景观影响度分析[J]. 山东国土资源, 2009, 25(2): 24-26.
- [7] 史文飞, 彭冲, 何灿. 裸露山体缺口生态修复新技术及景观影响度评价: 以深圳市布吉郁南、吉岗采石场边坡整治绿化工程为例[J]. 亚热带水土保持, 2012, 24(2): 34-37.

收稿日期: 2023-05-07

第一作者: 沈彦(1980—), 男, 山西天镇人, 高级工程师, 硕士, 主要从事水土保持生态修复设计研究工作。

E-mail: shenyan@sztechand.com.cn

[参考文献]

- [1] 李采梅. 明清广东新安县城市地理若干问题研究[D]. 广

(责任编辑 徐素霞)

监管。组织开展覆盖全国范围的水土保持遥感监管,完善遥感解译判别、核查认定和问题销号标准,提升智能解译判别水平,是当前和今后一段时期我国水土保持工作的重要内容。

目前扰动图斑解译仍以传统人机交互目视解译为主,工作效率较低、成果标准不统一,难以满足新时期新形势下水土保持信息化监管的需求。随着人工智能、大数据等技术的快速发展,深度学习迅速成为一种高效且精确的遥感图像分类方法,它可以自动从像素级别的原始影像数据中提取地物特征信息,特征学习能力强,拟合、模型预测精度高^[1]。基于深度学习方法进行生产建设项目扰动图斑遥感影像的自动提取,已成为水土保持信息化监管的重点研究方向。目前对生产建设项目扰动图斑的识别,可以分为目标识别和变化检测两种思路。在利用同一时相影像进行扰动图斑识别方面,金平伟等^[2]基于深度学习原理,构建了生产建设项目扰动图斑自动识别分类 CNN 模型,并利用 2020 年高分一号遥感影像和已有的生产建设项目水土保持信息化监管成果数据对模型进行了训练和应用效果检验;伏晏民等^[3]以 2020 年四川省水土保持动态监测高分遥感影像作为数据源,引入残差思想与注意力机制改进 Unet 网络,模型预测结果中改进模型的分割边界相对于 Unet 模型更加清晰平滑,相对于 Attention Unet 模型(引入注意力模块的 Unet 模型)的预测结果更加接近于标签图像,模型更加稳定。在利用不同时相影像进行扰动图斑的变化检测方面,舒文强等^[4]选取时相为 2020 年 10—12 月和 2021 年 1—3 月的遥感影像,研究扰动图斑变化智能检测,结果表明通过比较两期影像的语义信息输出变化图斑,可以较为准确地定位地物类发生变化的区域,提取的变化图斑边界与实际变化区域较为贴合。

然而,目前很少有研究对目标识别和变化检测两种思路进行对比分析,此外,不同应用场景下扰动图斑的快速精准提取方法有待提高。因此,本研究以江苏省徐州市为研究区,从目标识别和变化检测两种思路出发,分别建立目标识别和变化检测生产建设项目扰动图斑数据集,分析生产建设项目扰动图斑临域、时序等图像特征,通过深度学习语义分割模型精度评价指标,对比分析生产建设项目扰动图斑的自动快速识别技术,并提出最优扰动图斑识别策略,以为生产建设项目扰动图斑自动识别、分类提取提供技术支撑。

1 研究区概况

徐州市位于江苏省西北部,地跨东经 116°22′~118°40′、北纬 33°43′~34°58′,东西长约 210 km,南北

宽约 140 km,土地总面积 11 765 km²,约占江苏省土地总面积的 11%。徐州市水土流失主要分布在生产建设活动相对集中的城区、采矿用地及坡度相对较陡且植被覆盖度较低的低山丘陵区等区域,生产建设活动导致的人为水土流失是当前徐州市水土流失的主要来源。

2 研究方法

2.1 技术路线

本研究采用的遥感影像数据源为高分一号卫星影像,包含红、绿、蓝 3 个波段,分辨率为 2 m,前时相为 2021 年 5 月,后时相为 2022 年 5 月。数据预处理过程主要包括大气校正、几何校正、深度转换、直方图匹配等。在单时相和多时相高分遥感数据的基础上,建立扰动图斑目标识别数据集,应用 Unet、Unet++、Unet3+ 三种深度学习网络模型进行目标识别和变化检测的模型训练、验证和预测,提取扰动图斑特征。对目标识别和变化检测两种扰动图斑识别方法进行精度评价,从识别效果、水土保持监管需求、应用难度 3 个方面分析扰动图斑识别策略。

2.2 数据集制作

以江苏省水土保持信息化监管工作成果为数据源,制作样本切片和标签,切片大小为 256×256 像素。目标识别数据集的标注原理为:将扰动图斑标记为 1,非扰动图斑标记为 0。变化检测数据集的标注原理为:将变化部分标记为 255,非变化部分标记为 0。为增加数据集规模,采用水平翻转、垂直翻转、随机裁切、上下左右平移变换等变换方式增加样本数据。数据样本增加后,目标识别生产建设项目扰动图斑数据样本为 4 420 个,变化检测生产建设项目扰动图斑数据样本为 10 440 个,将标注样本按 8:1:1 划分为训练集、验证集、测试集。

2.3 试验环境

试验平台配置为 Windows10 专业版操作系统配置飞桨(PaddlePaddle)深度学习平台, GPU 为 Tesla V100, CPU 为酷睿双核,内存为 16 GB,显存为 16 GB,硬盘容量为 100 GB,编程软件为 Python 3.7,深度学习框架系统为 PaddlePaddle 2.2.2。

2.4 深度学习网络模型

本研究采用 Unet、Unet++、Unet3+ 三种深度学习网络模型结构。Unet 在神经元结构分割方面取得了巨大的成功,由于功能在层之间传播,因此其框架是突破性的^[5]。后续在 Unet 的基础上涌现出许多优秀的架构,如 Unet++、Unet3+ 等。Unet 模型作为全卷积网络的一种,没有全连接层,而是依赖卷积层、池化层从影像中

提取不同的特征,利用反卷积层来还原影像大小。Unet++网络结构以 Unet 为基础,添加了重新设计的跳跃路径、密集的跳跃连接及深度监督,Unet++模型中的跳跃连接重点在于融合编码器和解码器之间语义上不同的特征^[6-7]。Unet3+去掉了 Unet++的稠密卷积块,提出了一种全尺寸跳跃连接。全尺寸跳跃连接改变了编

码器和解码器之间的互连,以及解码器子网之间的内连接,让每一个解码器层均融合了来自编码器中的小尺度和同尺度的特征图,以及来自解码器的大尺度特征图,这些特征图捕获了全尺度下的细粒度语义和粗粒度语义^[8]。3种网络模型结构见图1。

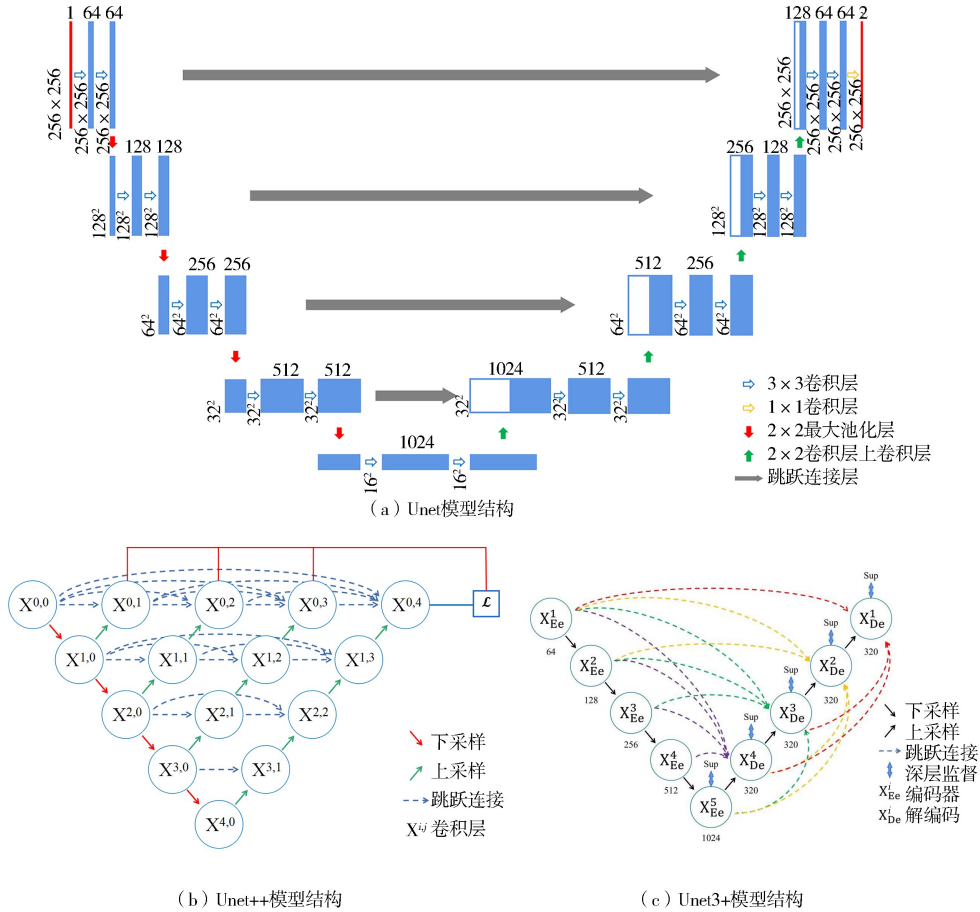


图1 Unet、Unet++、Unet3+网络模型结构

2.5 网络模型训练

在 PaddlePaddle 2.2.2 深度学习框架系统中,用训练集和验证集数据对 Unet、Unet++、Unet3+网络模型进行训练、验证,得到参数调整后的训练模型。在模型训练过程中,学习策略为高斯随机初始化参数,学习率为余弦退火策略,激活函数为 ReLUctant,并采用 Adam 优化器和混合损失函数。超参数初始设置为:学习率为 8×10^{-5} ;二元交叉熵损失函数权重为 0.3;洛瓦斯分类损失函数权重为 0.7;Epoch 设定为 30 轮;Batch size 设置 3 组,分别为 4、8、16。

2.6 精度评价指标

将实际为扰动图斑样本,且模型识别为扰动图斑样本(识别分类正确)的图斑样本记作 TP;实际为非扰动图斑样本,且模型识别为非扰动图斑样本(识别分类正确)的图斑样本记作 TN;实际为非扰动图斑样

本,但模型识别为扰动图斑样本(识别分类错误)的图斑样本记作 FP;实际为扰动图斑样本,但模型识别为非扰动图斑样本(识别分类错误)的图斑样本记作 FN。为客观评价不同结构网络模型的性能差异,采用准确率、均交并比(Mean Intersection over Union, MIoU)、Kappa 系数、F1 分数 4 个指标进行精度评价,计算公式为

$$A_c = \frac{C_{TP} + C_{TN}}{C_{TP} + C_{FP} + C_{FN} + C_{TN}} \quad (1)$$

$$MIoU = \frac{C_{TP}}{C_{FN} + C_{FP} + C_{TP}} \quad (2)$$

$$F = \frac{2C_{TP}}{2C_{TP} + C_{FN} + C_{FP}} \quad (3)$$

$$K_c = \frac{A_c - P_e}{1 - P_e} \quad (4)$$

$$P_e = \frac{(C_{TN} + C_{FN})(C_{TN} + C_{FP}) + (C_{FP} + C_{TP})(C_{FN} + C_{TP})}{(C_{TP} + C_{TN} + C_{FP} + C_{FN})^2} \quad (5)$$

式中: A_C 、 $MIoU$ 、 F 、 K_C 、 P_e 分别为准确率、均交并比、F1 分数、Kappa 系数、理论一致率; C_{TP} 、 C_{FP} 、 C_{TN} 、 C_{FN} 分别为 TP、FP、TN、FN 数量。

3 结果与分析

3.1 基于目标识别策略的单时相遥感影像扰动图斑识别

基于目标识别策略,采用 3 种网络模型在不同测试集上扰动图斑的识别精度评价结果见表 1。对于 Unet 模型,在 Batch size 为 4 时所有精度评价指标表现均为最好,即准确率为 0.967 9、均交并比为 0.864 3、Kappa 系数为 0.924 1、F1 分数为 0.848 2,训练时间为 81 min。对于 Unet++ 模型,在 Batch size 为 8 时的所有指标表现均为最好,即准确率为 0.955 2、均交并比为 0.834 1、Kappa 系数为 0.905 2、F1 分数为 0.810 5,训练时间为 79 min。对于 Unet3+ 模型,在 Batch size 为 4 时所有指标表现均为最好,即准确率为 0.962 4、均交并比为 0.848 6、Kappa 系数为 0.914 3、F1 分数为 0.828 7,训练时间为 241 min。

表 1 基于目标识别策略的扰动图斑识别精度评价

网络模型	Batch size	准确率	均交并比	Kappa 系数	F1 分数	训练时间/min
Unet	4	0.967 9	0.864 3	0.924 1	0.848 2	81
	8	0.964 5	0.854 5	0.918 0	0.836 0	67
	16	0.962 3	0.843 0	0.910 5	0.821 1	63
Unet++	4	0.949 7	0.812 3	0.890 6	0.781 3	92
	8	0.955 2	0.834 1	0.905 2	0.810 5	79
	16	0.941 5	0.797 6	0.880 9	0.762 2	74
Unet3+	4	0.962 4	0.848 6	0.914 3	0.828 7	241
	8	0.961 2	0.843 8	0.911 2	0.822 5	232
	16	0.961 5	0.846 8	0.913 2	0.826 4	237

为了全面评估 3 种网络模型结构对扰动图斑的识别精度,分别选择 Unet、Unet++、Unet3+ 模型在训练预测中表现最优的结果进行对比分析。在准确率方面, $Unet(0.967 9) > Unet3+(0.962 4) > Unet++(0.955 2)$; 在均交并比方面, $Unet(0.864 3) > Unet3+(0.848 6) > Unet++(0.834 1)$; 在 Kappa 系数方面, $Unet(0.924 1) > Unet3+(0.914 3) > Unet++(0.905 2)$; 在 F1 分数方面, $Unet(0.848 2) > Unet3+(0.828 7) > Unet++(0.810 5)$; 在训练时间上, $Unet++(79 \text{ min}) < Unet(81 \text{ min}) < Unet3+(241 \text{ min})$ 。综合所有精度评价指标来看,Unet 模型表现为最优,其次是 Unet3+ 模型,Unet++ 模型表现最差,然而 Unet3+ 模型因网络结构最为复杂,故训

练时间最长,远高于 Unet 模型和 Unet++ 模型。

基于目标识别策略,采用 3 种网络模型结构的扰动图斑预测结果见图 2。综合来看,Unet 模型的检测结果分割边界波动幅度小,与真实地物标签吻合度最好,误检、漏检情况最少,冗余特征较少,预测结果最接近于标签图像。Unet++ 和 Unet3+ 模型的检测结果分割边界不清晰、破碎、波动幅度大,冗余特征较多,误检、漏检的情况也较多,预测结果与标签图像差异较大。虽然 3 种网络模型的检测结果均存在误检、漏检情况,但 Unet 模型的预测效果最为稳定。其原因可能是:一方面目标检测数据集为整个施工扰动区域,边界不够明确;另一方面 Unet++ 和 Unet3+ 模型相比 Unet 模型,结构更加复杂,特征提取能力更强,所需的训练样本数量也更多,在训练数据集较小的情况下,出现了训练过拟合与提取了错误地物特征的现象。总体来看,基于 Unet 模型的预测效果最好,Unet3+ 网络的预测效果优于 Unet++ 模型。

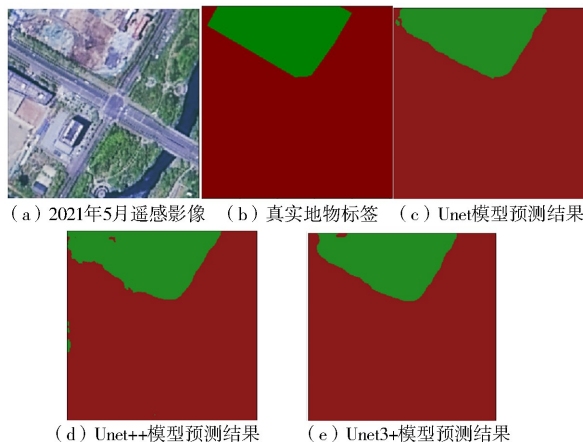


图 2 基于目标识别策略的 3 种网络模型扰动图斑预测结果

3.2 基于变化检测策略的多时相遥感影像扰动图斑识别

基于变化检测策略,采用 3 种网络模型在不同测试集上的扰动图斑识别精度评价结果见表 2。对于 Unet 模型,在 Batch size 为 16 时所有精度评价指标表现均为最好,即准确率为 0.991 7、均交并比为 0.945 6、Kappa 系数为 0.971 5、F1 分数为 0.943 0,训练时间为 84 min。对于 Unet++ 模型,在 Batch size 为 4 时所有指标表现均为最好,即准确率为 0.986 7、均交并比为 0.914 6、Kappa 系数为 0.953 9、F1 分数为 0.907 9,训练时间为 110 min。对于 Unet3+ 模型,在 Batch size 为 4 时所有指标表现均为最好,即准确率为 0.989 9、均交并比为 0.933 9、Kappa 系数为 0.965 0、F1 分数为 0.930 0,训练时间为 263 min。

表 2 基于变化检测策略的扰动图斑识别精度评价

网络模型	Batch size	准确率	均交并比	Kappa 系数	F1 分数	训练时间/min
Unet	4	0.990 3	0.936 5	0.966 5	0.932 9	103
	8	0.991 5	0.944 2	0.970 7	0.941 4	88
	16	0.991 7	0.945 6	0.971 5	0.943 0	84
Unet++	4	0.986 7	0.914 6	0.953 9	0.907 9	110
	8	0.986 2	0.911 8	0.952 3	0.904 7	107
	16	0.986 4	0.913 0	0.953 0	0.906 0	105
Unet3+	4	0.989 9	0.933 9	0.965 0	0.930 0	263
	8	0.983 7	0.897 8	0.944 1	0.888 2	303
	16	0.981 2	0.884 3	0.935 9	0.871 7	312

为了全面评估 3 种网络模型对扰动图斑的检测效果,分别选择 Unet、Unet++、Unet3+模型在训练预测中表现最优的结果进行对比分析。在准确率方面,Unet (0.991 7) > Unet3+ (0.989 9) > Unet++ (0.986 7); 在均交并比方面,Unet (0.945 6) > Unet3+ (0.933 9) > Unet++ (0.914 6); 在 F1 分数方面,Unet (0.943 0) > Unet3+ (0.930 0) > Unet++ (0.907 9); 在 Kappa 系数方面,Unet (0.971 5) > Unet3+ (0.965 0) > Unet++ (0.953 9); 在训练时间方面,Unet (84 min) < Unet++ (110 min) < Unet3+ (263 min)。综合所有精度评价指标来看,与基于目标识别策略的扰动图斑识别效果相同,Unet 模型表现为最优,其次是 Unet3+模型,Unet++模型表现最差,但 Unet3+模型训练时间最长。

基于变化检测策略,采用 3 种网络模型结构的扰动图斑预测结果见图 3。综合来看,基于 Unet 模型的检测结果分割边界清晰平滑,无误检、漏检,无冗余特征,预测结果接近于标签图像。基于 Unet++和 Unet3+模型的检测结果分割边界不清晰、破碎,有大量冗余特征被误检,与基于 Unet 模型的检测结果相比,错误预测了一些建筑物边缘阴影、空隙和道路,检测结果与标签图像存在较大差异。原因可能是 Unet++和 Unet3+在训练数据集较小的情况下,出现了训练过拟合与提取了错误地物特征的现象。总体来看,与基于目标识别

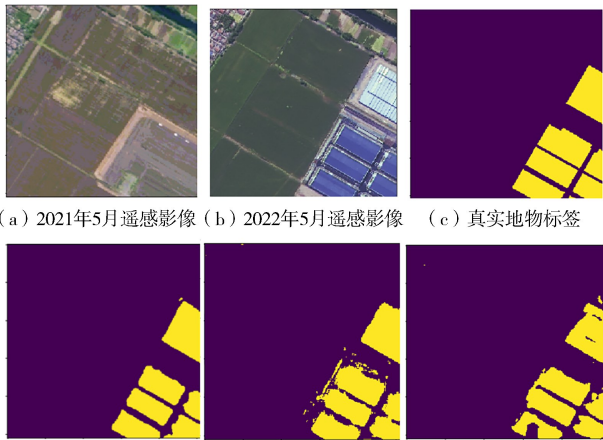


图 3 基于变化检测策略的 3 种网络模型扰动图斑预测结果

策略的扰动图斑识别效果相同,Unet 模型的检测效果最佳,Unet3+模型优于 Unet++模型。

4 扰动图斑识别策略研究

由表 1 和表 2 对比分析可以看出,基于变化检测识别策略的扰动图斑识别效果,除训练效率稍低于目标识别策略外,其余各精度评价指标均表现更加优秀。对于 3 种网络模型结构,基于两种识别策略时,Unet 模型均表现最优,其次是 Unet3+模型,最后是 Unet++模型。具体来说:准确率和 Kappa 系数在基于两种识别策略时差距较小;均交并比和 F1 分数在基于变化检测策略时的结果要明显优于基于目标识别策略;基于目标识别策略时的训练时间少于基于变化检测策略。其原因主要包括:①基于变化检测策略时,需要融合前后 2 个时相的遥感影像作为输入数据,数据处理量要大于基于目标识别策略,由此可以获得更多的邻域对比语义信息,但是另一方面也增加了训练时间。②基于变化检测策略时,数据集样本量要明显多于基于目标识别策略的数据集样本量,在更大的数据集支撑下,基于变化检测策略的训练效果要优于基于目标识别策略。

从识别效果、水土保持监管需求、应用难度 3 个方面分析两种扰动图斑识别策略的优缺点。

1) 在识别效果方面,目标识别策略与变化检测策略实际上都是像素级语义分割任务,主要区别在于目标识别策略仅针对单时像遥感影像,而变化检测将前后 2 个时相的遥感影像在像素层级上连接在一起,作为深度学习训练的输入影像。相比于单时相遥感影像的 3 个特征输入通道,变化检测策略将两时段数据在通道层结合,将特征输入通道增加至 6 通道,丰富了学习的浅层特征,补充了不同时序下目标邻域的对比语义信息,有利于深度学习神经网络提取出更全面的深层抽象语义特征信息,提升模型的识别效果。

2) 水土保持监管工作中,部分未超过追认年限的已完工违规违法项目仍有监管需求,目标识别策略仅从单时相遥感影像出发,缺失关键的多时序及领域对比信息,无法将已完工违规违法建设项目同合规建设项目进行区分,极易出现误识别、漏识别的现象;而变化检测识别策略可以基于不同领域、不同时序对生产建设项目水土保持扰动图斑特征进行全面考量,可以显著改善对已完工项目的性质认定出现错误的问题。

3) 在应用难度方面,虽然变化检测策略的总体识别效果优于目标识别策略,但是对 2 个时相的遥感影像预处理工作要求较高,几何配准、大气校正、直方图匹配、位深同步均有硬性要求,若无法满足遥感影像预

处理要求,则识别效果必然大打折扣,甚至无法使模型进行预测识别。与之相比,目标识别策略是基于单时相遥感影像进行扰动图斑的提取,可以从根源上解决双时相遥感影像的配准处理问题,同时训练模型所需的样本标注可以采用水土保持监管工作中扰动图斑的认定成果,经过简单处理后就可以批量制作训练数据集,无需针对双时相遥感影像的对比变化进行图斑细化认定工作,训练的模型在当期影像上就可获得较好的泛化效果。

本研究中采用的 3 种深度学习网络模型中,Unet 模型的识别效果最优秀,分割边界清晰平滑,误检、漏检情况较少,无冗余特征,预测结果接近于标签图像。同时 Unet 模型网络结构精简,参数量少,训练速度最快,有利于高效应用。由于研究数据集样本量较小,因此 Unet++模型和 Unet3+模型受限于复杂的网络架构,提取了大量的冗余特征,但是当数据集样本量较大时,Unet++模型和 Unet3+模型因其更强的细节提取能力,故可能有更好的识别效果。综上,当遥感影像质量满足要求,且需要精细化的认定结果时,基于变化检测策略,采用 Unet 模型结构可作为提取生产建设项目扰动图斑的最佳模式;当遥感影像质量不佳,或仅有单时相遥感影像,且需要快速确定扰动区域时,宜采用基于目标识别策略的 Unet 模型;当训练数据集较大,可以支撑复杂模型训练时,Unet++模型和 Unet3+模型均可能会有更好的识别效果。

5 结论

针对生产建设项目扰动图斑识别问题,从目标识别和变化检测两种思路出发,依托徐州市生产建设项目水土保持监管工作中扰动图斑认定成果,建立了徐州市生产建设项目水土流失扰动图斑目标识别、变化检测数据集,分析单时相和多时相遥感影像的生产建设项目扰动图斑特征,对比评价 Unet、Unet++和 Unet3+三种网络模型的识别精度,提出最优的扰动图斑识别策略。基于目标识别策略时,Unet 模型表现最优,其中准确率为 0.967 9、均交并比为 0.864 3、Kappa 系数为 0.924 1、F1 分数为 0.848 2;基于变化检测策略时,同样是 Unet 模型表现最优,其中准确率为 0.991 7、均交并比为 0.945 6、Kappa 系数为 0.971 5、F1 分数为 0.943 0。基于 Unet 网络的检测结果分割边界清晰平滑,误检、漏检情况较少,无冗余特征,预测结果更接近于标签图像,识别效果最佳。从识别效果、水土保持监管需求、应用难度 3 个方面分析了扰动图斑识别策略的实用性,当遥感影像质量满足要求,且需要精细化的认定结果时,采用基于变化检测策略的 Unet 网络模型

可作为生产建设项目扰动图斑提取的最优模型;当遥感影像质量不佳或仅有单时相遥感影像,且需要快速确定扰动区域时,宜采用基于目标识别策略的 Unet 网络;当训练数据集足够支撑模型训练时,可考虑使用结构更加复杂、细节提取能力更强的 Unet++与 Unet3+网络模型。

[参考文献]

- [1] 王小燕,李静澜,白艳萍,等. 基于深度学习的遥感影像分类方法研究[J]. 中国水土保持,2023(12):7-10.
- [2] 金平伟,黄俊,姜学兵,等. 基于深度学习的生产建设项目扰动图斑自动识别分类[J]. 中国水土保持科学,2022,20(6):116-125.
- [3] 伏晏民,曾涛. 引入残差和注意力机制的 U-Net 模型在水土保持遥感监管人为扰动地块影像自动分割中的研究[J]. 测绘,2022,45(1):16-21.
- [4] 舒文强,蒋光毅,郭宏忠,等. 基于深度学习理论的山地城市水土保持卫星影像变化图斑提取实践[J]. 中国水土保持,2022(5):26-29.
- [5] RONNEBERGER O, FISCHER P, BROX T. U-net: convolutional networks for biomedical image segmentation[C]//International Conference on Medical Image Computing and Computer-Assisted Intervention, Springer, 2015:234-241.
- [6] HUANG G, LIU Z, LAURENS V, et al. Densely connected convolutional networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Honolulu: IEEE, 2017:2261-2269.
- [7] ZHOU Z W, SIDDIQUEE M M R, TAJBAKHS N, et al. UNet++: a nested u-net architecture for medical image segmentation[C]//Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support, Granada: Springer, 2018:3-11.
- [8] HUANG H M, LIN L F, TONG R F, et al. UNet 3+: a full-scale connected unet for medical image segmentation[C]//IEEE International Conference on Acoustics, Speech and Signal Processing, Barcelona: IEEE, 2020:1055-1059.

收稿日期: 2024-01-09

基金项目: 中央级公益性科研院所基本科研业务费专项(Re923003, Y921004, Y922003, Y923005); 安徽省自然科学基金项目(2308085US04); 南京水务科技项目(202303)

第一作者: 卢慧中(1990—), 女, 黑龙江方正人, 高级工程师, 博士, 主要研究方向为土壤侵蚀与水土保持。

通信作者: 金秋(1983—), 男, 吉林省吉林市人, 高级工程师, 博士, 主要研究方向为农村水利与水土保持。

E-mail: fengyuwuzujq@163.com

(责任编辑 李佳星)