

融合全局特征YOLOv8n网络的稀土矿区复垦植被检测方法

李兴梅¹, 李恒凯¹, 刘银铭², 王秀丽³

1. 江西理工大学 土木与测绘工程学院, 赣州 341000;

2. 江西省地质局地理信息工程大队, 南昌 330000;

3. 江西理工大学 经济管理学院, 赣州 341000

摘要: 离子吸附型稀土矿因溶浸开采造成土壤污染, 导致复垦植被长势差、成活率低, 利用无人机影像监测有助于科学监管。然而矿区复杂环境下导致复垦植被整体特征差异较大使得无人机影像自动识别困难, 识别准确率低。为了提高对无人机影像中矿区复垦植被单棵植株快速、精确的自动识别和定位, 提出了融合全局特征YOLOv8n网络的矿区复垦植被检测方法(YOLOv8-AS)。该方法在YOLOv8n的基础上做了以下改进:(1)使用降采样模块ADown进行特征卷积操作, 降低标准卷积随模型训练深度加深过程中导致的特征损失;(2)采用SPPF-GFP(Spatial Pyramid Pooling Fast-Global Feature Pool)模块进行特征提取, 提高模型对整体特征差异较大的复垦植被的检测能力。结果表明:在自建复垦植被数据集上, YOLOv8-AS相较于YOLOv8n的mAP@0.5和mAP@0.5-0.95分别提升1.6%和2.4%; YOLOv8-AS的模型大小、参数量和浮点计算量较YOLOv8n分别下降了11%、10%和9%。YOLOv8-AS算法的mAP@0.5和mAP@0.5-0.95分别达到了91.1%、46.8%, 相较于SSD、Faster R-CNN、RT-DETR、YOLOv5、YOLOv7和YOLOv7-tiny模型mAP@0.5分别提高了14.07%、23.32%、1.2%、2.3%、3.3%、2.9%和1.2%。此外, YOLOv8-AS能够针对小目标、简单和复杂场景进行快速、精准地检测复垦植被, 同时较好地提升了对复垦植被单棵植株的识别和定位能力。该方法可为矿区生态恢复提供准确有效的技术支持。

关键词: 深度学习, 目标检测, YOLOv8n, 无人机影像, 稀土矿区, 复垦植被

中图分类号: P2

引用格式: 李兴梅, 李恒凯, 刘银铭, 王秀丽. XXXX. 融合全局特征YOLOv8n网络的稀土矿区复垦植被检测方法. 遥感学报, XX (XX): 1-14

LI Xingmei, LI Hengkai, LIU Kunming, WANG Xiuli. XXXX. Revegetation Detection Method for Rare Earth Mining Areas Using YOLOv8n Network with Integrated Global Features. National Remote Sensing Bulletin, DOI:10.11834/jrs.20244338]

1 引言

稀土资源在众多行业都扮演着不可或缺的角色, 尤其是离子吸附型稀土矿更是不可再生的重要战略资源 (Ba 等, 2022)。离子吸附型稀土矿主要是以池浸、堆浸和原地浸矿等特殊方式进行开采, 这造成稀土矿区土壤结构破坏、肥力降低、有机质缺乏和沙化等环境问题 (C. Li 等, 2024; Liu 等, 2016; Liu 等, 2020), 导致稀土矿区复垦

植被生长遭受了巨大威胁。因此, 加强稀土矿区生态环境修复与可持续发展势在必行。在中国实施稀土开采配额管制以及全面推进矿山复垦修复的当下, 监测矿区复垦植被恢复进展是保障稀土行业可持续发展的重要前提之一 (Wu 等, 2021; Wu 等, 2024; 赵银娣等, 2022)。因此, 探索新型自动化、智能化的矿区复垦植被监测方式已经迫在眉睫。

随着无人机遥感技术的发展, 利用高分辨率

收稿日期: XXXX-XX-XX; 预印本: XXXX-XX-XX

基金项目: 国家自然科学基金项目(编号:42161057); 江西省自然科学基金重点项目(编号:20232ACB203025); 江西理工大学河流源头水生态保护江西省重点实验室(编号:2023SSY02031)

第一作者简介: 李兴梅, 研究方向为矿区遥感图像处理、目标检测。E-mail: 16224366242@qq.com

通信作者简介: 李恒凯, 从事遥感建模与分析等方面的研究。E-mail: giskai@jxust.edu.cn

遥感影像结合人工智能技术实现矿区复垦植被长势变化智能化监测是目前研究的热点(董新宇等, 2019; Guo等, 2024; Hackin等, 2022)。随着深度学习技术快速发展, 其超强的图像理解与语义提取能力成为目标检测和分类问题的主流技术(徐丹青和吴一全, 2024; 王浩等, 2023; 汪西莉等, 2023), 这为矿区复垦植被的精准检测提供了新方法。利用深度学习完成目标检测任务, 具有高效、精准和自动化的检测特点, 已经成为了高分遥感影像解译的主流方法之一(Krizhevsky等, 2012; 赵昊等, 2022)。目标检测算法主要分为两类, 一类是基于候选区域的双阶段算法, 如目前比较主流的Faster R-CNN算法(Ren等, 2017); 另一类是基于回归的SSD(Wei等, 2016)和YOLO系列算法(Cheng等, 2023; Redmon等, 2016; C. Y. Wang等, 2022)。

其中YOLO系列常以其快速精准的检测性能而成为众多检测任务的首选。在YOLO系列中YOLOv8继承了前几代的优点(Varghese and Sambath, 2024)。目前YOLOv8及其改进和优化的模型已经应用到了茶叶嫩芽、固废、棉田杂草以及植被病虫害检测等不同的场景中(P. Li等, 2024; G. Wang等, 2023; Xie and Sun, 2023; Zheng等, 2024; 马超伟等, 2024)。由此可见, YOLOv8在不同领域中具有较强的实用性和灵活性。此外, 还有众多的学者将YOLO系列方法应用于单木或树冠的检测。G. X. Wang等(2023)将YOLOv5、SSD和Faster R-CNN这三种算法均应用到哈夫树的检测中, 发现YOLOv5相较于另外两种算法能够提高哈夫树的检测精度, 但YOLOv5达到的整体精度不高。所以将YOLO模型应用到具体场景下的单木检测还需要对其进行改进和优化。马永康等(2022)根据红树林幼苗目标较小的特点改进YOLOv5模型, 提高了红树林小目标的检测精度; X. Wang等(2022)将改进后的YOLOv5网络模型应用到防护林中的枯死树木检测任务中, 实现了防护林的智能化监测; 王凯等(2024)针对杨梅树在不同拍摄背景下的特征差异改进YOLOv7模型, 提高了不同场景下的杨梅树检测精度。现有的研究将改进和优化后YOLO系列算法引入单木识别应用中, 均取得了较好的检测效果。这些研究主要是针对同一场景下的小目标检测或是轻量化模型后的小目标检测, 且他们的研究主

要是针对于长势较好的成林区域的单木进行检测。然而在矿区复杂自然环境下, 复垦植被的长势和空间分布存在不同特征差异, 仅研究小目标或轻量化检测下的小目标则会忽略掉复垦植被的整体特征信息。因此, 需要进一步探索稀土矿区复垦植被的精准检测方法。

本研究以赣南离子吸附型稀土矿区复垦植被为研究对象, 在YOLOv8的基础上进行改进和优化, 提出了一种高效的复垦植被检测方法YOLOv8-AS。这将有助于稀土矿区场景下能更好的平衡复垦植被的综合特征, 实现矿区复垦植被高精度的检测。研究结果能够对稀土矿区开采与复垦植被恢复情况的精准监测提供智能化的技术支持。

2 融合全局特征YOLOv8网络

2.1 YOLOv8算法

YOLOv8(Varghese and Sambath, 2024)作为目标检测领域的重大突破, 以高效前向传播和卓越设计实现精度与速度的双重飞跃。该算法在继承YOLO系列优势的基础上, 引入单阶段检测策略直接预测目标类别与位置, 进一步加速推理过程。其通过深度优化主干网络及多尺度特征融合技术, 提升了目标的检测效能。此外, 通过调整损失函数和硬件加速技术, 确保了实时高效的目标检测能力。该模型由主干(Backbone)、颈部(Neck)及头部(Head)检测网构成(Shuang and Hongwei, 2023), 其中主干网络负责多尺度特征提取融合, 颈部网络采用PAN强化特征传递, 头部网络解耦任务, 实现精细化处理。同时, 在数据预处理时引入马赛克增强、自适应锚框及灰度填充策略, 增强模型泛化能力(Sohan等, 2024)。该模型提供了 n 、 s 、 l 、 m 、 x 五种变体以满足不同需求, 其中YOLOv8 n 以其轻量级与高性能成为理想选择。简而言之, YOLOv8以精简模型、卓越性能及高度灵活性, 成为快速响应与高精度检测场景下的首选方案。

2.2 融合全局特征YOLOv8 n 矿区复垦植被检测算法

虽然YOLOv8算法相较于其他算法具有一定的优势, 但是其模型结构中的标准卷积随着网络深

度的加深，在传递过程中会更容易导致特征信息的丢失，如果将其应用于空间分布不均且形状大小不一的复垦植被的检测任务中，会导致关键特征信息的丢失不利于区分与复垦植被特征相似的背景噪声。因此针对当前矿区复垦植被检测中存在的复垦植被长势不齐，形状不一以及空间分布不均等导致的模型检测精度低、漏检率高，模型

参数较大等问题，本研究主要对其网络结构中的卷积模块（Conv）和空间金字塔池化融合模块（SPPF）进行改进，以实现更高的检测性能和更低的计算成本，提出一种基于改进YOLOv8的复垦植被检测YOLOv8-AS。改进模型的结构如图1所示。

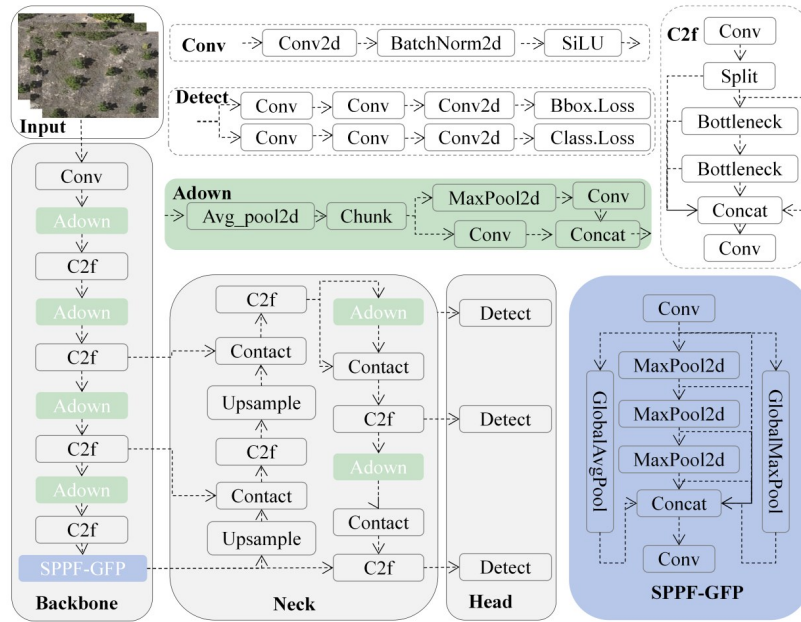


图1 YOLOv8-AS模型结构

Fig. 1 YOLOv8-AS model structure

Conv为卷积模块,Concat为特征连接模块,Upsample为上采样模块,Detect为检测头,ADown为降采样模块,SPPF-GFP为改进空间金字塔池化模块,MaxPool2d为最大池化下采样,BatchNorm2d为批归一化层,SiLU为激活函数,Bbox Loss和Class Loss分别为边界框损失和分类损失。

Conv is the convolution module, Concat is the feature connection module, Upsample is the upsampling module, Detect is the detection header, ADown is the downsampling module, SPPF-GFP is the improved spatial pyramid pooling module, MaxPool2d is the maximum pooled downsampling,

BatchNorm2d is the batch normalization layer. SiLU is the activation function, Bbox Loss and Class Loss are the bounding box loss and classification loss respectively.

2.2.1 ADown降采样模块

YOLOv8模型中的标准卷积（Conv）操作使用固定大小的卷积核，这导致在处理不同形状和大小的复垦植被时不够灵活。并且该卷积随着训练层数和深度加深，不仅会增加整个模型的参数数量同时也会导致特征信息的丢失，因此该卷积不能很好地适应。本文实验选取的研究区域中的复垦植被长势不齐、空间分布不均等特征。针对以上问题，本文在实验中通过引入ADown（Wang等，2024）模块替换原始模型中的Conv卷积来进行改进。该模块是一个轻量化的下采样模块，主要由平均池化层、通道分割、3×3标准卷积、最大池化

层、1×1的标准卷积、融合函数六个部分组成。

首先利用平均池化函数对输入进行平均池化操作；进一步通过chunk函数将平均池化输出的结果沿着通道维度分割成两部分，其中一部分进行卷积核3×3的卷积计算，另一部分则先通过最大池化函数进行最大池化运算之后再行卷积核1×1的卷积运算，最后对两部分结果作为Concat函数的输入，进行拼接后输出。相较于原始的Conv卷积而言，首先该模块首先通过增加平均池化运算，通过计算池化窗口内所有值的平均值，可以帮助模型在特征图上获取更广泛的空间上下文信息。与此同时，通过降低特征图的宽度和高度，从而

减少网络中的参数数量，降低计算复杂度，并防止过拟合。这有助于网络学习更高级别的特征表示。平均池化的主要过程是假设其中输入的为其第K个特征层，并将其划分为N个矩形区域，然后求得每个矩形区域的平均值，最终将平均池化计算完的特征层作为一个新的特征层输出。平均池化的计算过程如式1所示。

$$X_{out} = \frac{1}{|R_{ij}|} \sum_{(p,q) \in R_{ij}} X_{input} \quad (1)$$

式中 X_{out} 为第K个特征层中对应的矩形区域 R_{ij} 的平均池化输出结果， X_{input} 表示在第K个特征层中位于矩形区域 R_{ij} 的 (p, q) 处的元素， $|R_{ij}|$ 则表示输入特征层中矩形区域 R_{ij} 中包含的元素个数。

其次，进行通道维度分割运算，使其可以分别进行 3×3 和 1×1 两种不同尺度卷积核的运算，这避免了使用固定大小的卷积核而导致对不同大小和形状的复垦植被的不灵活性。而在进行 1×1 卷积之前增加一个最大池化层运算，最大池化操作能够增强模型对输入图像中特征位置的鲁棒性。由于它只保留每个池化窗口内的最大值，因此即使输入图像中的特征发生了微小的位置变化（如平移或旋转），经过最大池化后的特征表示也可能保

持不变。这种特性使得模型对于图像的局部变换具有更好的泛化能力。该模块通过减小特征图的空间尺寸，最大池化层间接地扩大了后续卷积层的感受野，有助于网络捕获更全局的信息。通常在卷积层之后，特征图中相邻位置的像素值往往具有很高的相关性，这会导致信息冗余。而最大池化操作通过只保留每个池化窗口内的最大值来减少这种冗余，从而提取出更具代表性的特征。假设其中输入的为其第K个特征层，则最大池化的计算过程如式2所示。

$$X_{out} = \text{Max}_{(p,q) \in R_{ij}} X_{input} \quad (2)$$

式中 X_{out} 为第K个特征层中对应的矩形区域 R_{ij} 的最大池化输出结果， X_{input} 表示在第K个特征层中位于矩形区域 R_{ij} 的 (p, q) 处的元素个数。

最后将上述两部分结果进行融合输出，作为下一层的输入层。至此 A_{down} 的一个完整卷积过程结束。综上所述， A_{down} 模块在既尽可能多的保留图像信息的同时可以根据不同的数据场景进行调整，比 $Conv$ 更适应复垦植被数据集的特征。相较于 $Conv$ 而言，该模块还减少了参数量、降低了模型的复杂度、以及提高了模型的运行效率。 A_{down} 模块结构如图2所示。




图2 A_{down} 结构

Fig. 2 A_{down} structure

Input 为输入模块，avg_pool2d 为平均池化，Chunk 为通道分割函数，MaxPool2d 为最大池化下采样，Conv 为卷积模块（其中 $k1$ 和 $k3$ 分别表示卷积大小为 1 和 3； $s1$ 和 $s2$ 分别表示卷积步长为 1 和 2），Concat 为特征连接模块，Output 为输出模块。

Input is the input module, avg_pool2d is the average pooling, Chunk is the channel segmentation function, MaxPool2d is the maximum pooling subsampling, Conv is the convolution module (where $k1$ and $k3$ represent the convolution size of 1 and 3, respectively; $s1$ and $s2$ represent the convolution step size of 1 and 2), Concat is the feature connection module, and Output is the output module.

2.2.2 SPPF-GFP 模块

空间金字塔池化 SPPF 模块主要作用是提取多尺度特征信息，通过捕捉不同尺度下的目标信息进一步提高算法的检测精度，其结构主要由标准卷积 Conv、最大池化 MaxPool2d、融合函数 Concat 三部分构成。其中输入的特征信息先经过标准卷

积进行特征提取，之后连续三次从具有残差结构且卷积核大小为 5×5 的最大池化层进行池化运算。为了对通道数进行调整，最后将三次池化前和池化后的结果通过融合后输出特征信息至卷积核为 1×1 的标准卷积。虽然 SPPF 模块利用三次连续池化，并且结合了每一层的输出，在保证多尺度融合的同时，降低了计算量，并且进一步增大了

算法的感受野。但只使用局部最大池化方法也导致SPPF只能关注边缘信息而忽略背景信息，从而导致模型的鲁棒性和泛化能力较差。此外虽然输入特征图大小固定，但同一特征影像中复垦植被的形状和大小差异明显，且长势较差的植被容易和相似的背景噪音混淆等问题。

针对以上问题，我们提出了SPPF-GFP(Spatial Pyramid Pooling Fast-Global Feature Pool)方法，即在原始的SPPF结构中加入全局平均池化层(GlobalAvgPool)和全局最大池化层

(GlobalMaxPool)。SPPF-GFP结构相较于SPPF而言，主要是通过加入一些全局背景信息和边缘信息，以帮助网络更好的做出判断。通过获取全局视角信息以减轻不同尺度大小所带来的影响，相较于传统的全连接，全局平均池化技术则是在不需要参数的情况下建立特征图和类别之间的关系，有效地避免过拟合的情况。此外，其可以对空间信息进行求和，更好地提高了输入的空间变化的鲁棒性改进后的SPPF-GFP结构如图3所示。




图3 SPPF-GFP结构

Fig. 3 SPPF-GFP structure

Input为输入,Conv为卷积模块,k1表示卷积核大小为1,k5表示卷积核大小为5,MP为局部最大池化下采样,GAP为全局平均池化,GMP为全局最大特征池化,Concat为特征连接模块,Output为输出。

Input is the input, Conv is the convolution module, k1 means the convolution kernel size is 1, k5 means the convolution kernel size is 5, MP is the local maximum pooling downsampling, GAP is the global average pooling, GMP is the global maximum feature pooling, Concat is the feature concatenation module, and Output is the output.

3 实验环境

3.1 研究区概况

本研究区域位于中国赣州市安远县的岗下稀土矿区(115°25'41"~115°26'48" E, 25°15'10"~25°16'47" N)。目前该矿区已全面停止采矿活动,并且正处于人工复垦修复矿区裸露地表阶段。但该矿区的环境污染造成复垦植被长势缓慢,同时不同复垦植被类型的长势存在差异,这进一步导致复垦植被在无人机影像中存在空间分布不均、形状各异(周贝贝等,2023)。研究区概况如图4所示。

3.2 数据集

由于当前不存在稀土矿区复垦植被检测的公开数据集,而高质量样本数据集对于模型训练至关重要。因此,针对稀土矿区复垦植被特征的识别任务,本文的实验主要采用固定翼CW-10无人机搭载的ca102传感器以120m的行高实地航测获

取的光学影像数据,最终生成分辨率为0.04m的多光谱影像,该影像分辨率为47242×74486能够清晰分辨单株复垦植株,满足本文实验的数据集构建要求。

由于初始影像尺寸较大,不宜直接带入模型进行训练。因此,利用Python编写影像分割程序,将影像规则切割为320×320像素大小的TIF格式图片,再进一步筛选出影像中含复垦植被的图片,最后通过人工标注的方式制作矿区复垦植被数据集共1627张。将其按照6:2:2的比例划分为训练集、验证集和测试集,其中包含训练集976张图像,验证集325张图像,测试集326张图像。最后将标注好的XML标签文件转化为适应YOLOv8网络训练的.txt标签文件,以此作为模型的输入数据集对模型进行训练。为保证模型检测的全面性,本文在实验中将无人机获取的目标较小的小目标场景a、种植较规则的简单场景b、有复垦植被和背景噪音(如杂草)较多的复杂场景c以及同时包含三种场景的自然场景进行检测,其中部分样

本示例如图5所示。

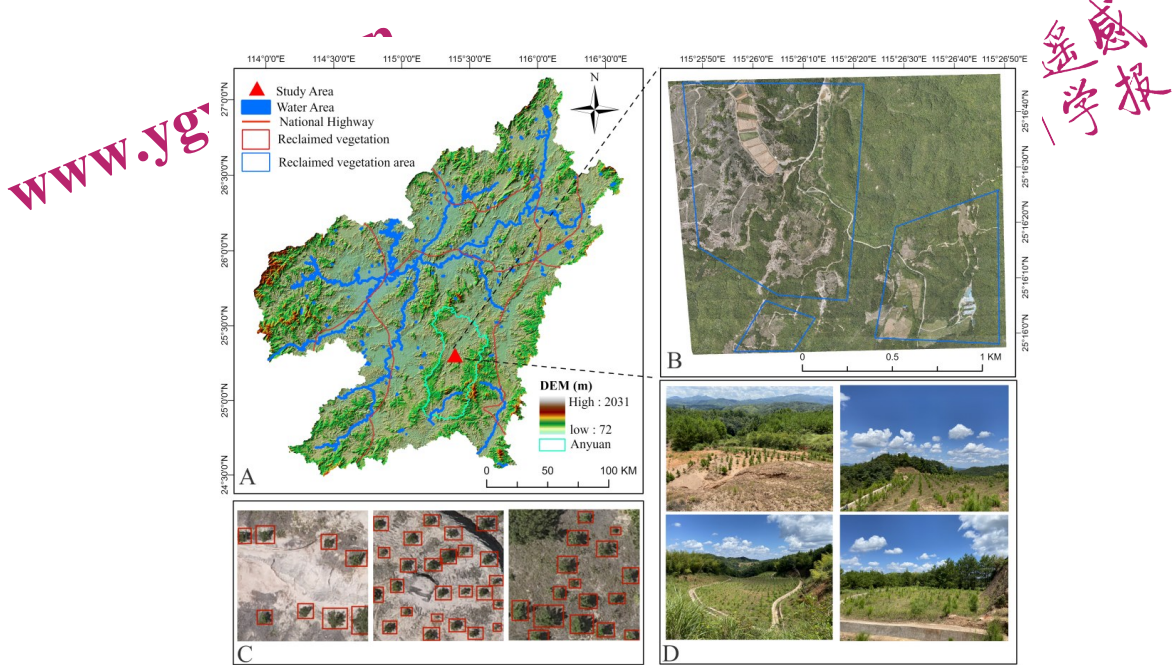


图4 研究区域概况,其中A为赣州市地形图,B为岗下稀土矿区无人机遥感影像,C为部分复垦植被样本,D为稀土矿区复垦植被现场照片。

Fig. 4 Overview of the study area, where A is the topographic map of Ganzhou City, B is the drone remote sensing image of the rare earth mining area under the gang, C is part of the reclaimed vegetation samples, and D is the on-site photos of the reclaimed vegetation in the rare earth mining area.



图5 部分复垦植被图像样本数据

Fig. 5 Sample data of some reclaimed vegetation image

3.3 评价指标

目标检测中通常用平均精准度 AP (Average Precision) 和平均准确率 mAP (mean Average Precision) 来评价模型的检测效果和性能 (Sohan

等, 2024), AP 为精确率 P (Precision) 和召回率 R (Recall) 曲线下的面积。其中 P 表示模型检测出正确的目标数占总目标数的比例, 体现出模型在目标检测时的准确度; R 为已检测出的目标数量占总目标数量的比例, 体现了模型识别的查全能力。

假设 N_{TP} 为检测出正确的正样本个数, N_{FP} 为检测出错误的正样本个数, N_{FN} 为检测出错误的负样本个数。由此得到 P、R、AP 和 mAP 的计算公式如下:

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}} \quad (3)$$

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}} \quad (4)$$

$$AP = \int_0^1 P(R) dR \quad (5)$$

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (6)$$

由于精确率与召回率成反比且会受置信度的影响, 若只采用精确率或召回率某一单一指标来评价模型性能, 会存在一定的不科学性和局限性。由于本文中的检测目标为单一目标, 故 mAP 等于

AP, 因此主要用 mAP 来评估模型的检测效果。此外, 为了更好地验证模型的整体性能, 本文最终主要采用精确度、召回率、mAP@0.5、mAP@0.5-0.95、模型大小、参数量 (Parameters) 和计算量 (GFLOPS) 等指标对模型进行综合评估。其中 mAP@0.5 和 mAP@0.5-0.95 分别表示 IOU 阈值为 0.5、0.5-0.95 时的平均精确度。

3.4 模型训练环境

本文实验的环境配置主要分为硬件和软件两部分配置, 其中硬件配置包括: CPU 为内存 16 GB 的 Intel (R) Core (TM) i5-13400@2.50 GHz, GPU 为显存 6G 的 NVIDIA GeForce GTX1660; 软件配置包括: Windows10 操作系统、编程语言 python3.9, 深度学习框架为 Pytorch2.2.0, CUDA11.8。模型训练时输入图像的尺寸大小为 320×320, 采用的学习率自适应的优化算法为 AdamW, 初始学习率 (Learning Rate, LR) 是 0.002, 动量 (Momentum) 设为 0.9, 批量大小 (batch size) 与训练轮次 (epoch) 分别设置为 16 与 100, 其余超参数均为默认。

4 结果与讨论

4.1 不同目标检测算法对比分析

为验证本文算法 YOLOv8-AS 相较于其他常见目标检测算法的检测性能, 将 YOLOv8-AS 算法分别与 SSD、Faster R-CNN、RT-DETR、YOLOv5、YOLOv7、YOLOv7-tiny、YOLOv8 算法在相同的条件下进行对比试验。由表 1 可知, 在包含小目标场景、简单场景和复杂场景的自然场景下, YOLOv8-AS 算法相较于其他目标检测算法在各个评价指标的整体表现较好, 在保证参数量较小的同时平均准确率 mAP 在 IOU 阈值 0.5 和 0.5-0.95 时分别达到了 91.1%、46.8%。

同时, 在自然场景下, YOLOv8-AS 算法较 SSD 算法的平均准确率 mAP@0.5 和 mAP@0.5-0.95 指标, 分别提升了 14.07%、12.8%。YOLOv8-AS 算法相较于模型较大的 Faster R-CNN 算法和参数量较大的 RT-DETR 算法无论是在 IOU 阈值 0.5 还是 0.5-0.95 的情况下平均准确率都更优异, 其中较 Faster R-CNN 算法 mAP@0.5 和 mAP@0.5-0.95 分别提升了 23.78%、12.6%; 而相较 RT-DETR 算法

mAP@0.5、mAP@0.5-0.95 分别提升了 1.2%、6.7%。YOLOv8-AS 算法与 YOLO 系列的典型算法进行了对比实验, 有意思的是我们发现在本文数据集上 YOLOv7 的表现略差于 YOLOv7-tiny, 甚至性能不如 YOLOv5, 而 YOLOv8-AS 算法相较于 YOLOv5、YOLOv7、YOLOv7-tiny、YOLOv8 在较参数量较少的同时保证了更好的复垦植被检测效果。

此外, 我们提出的算法 YOLOv8-AS 在各个场景下的 mAP@0.5 和 @mAP@0.5~0.95 都要优于其他模型。YOLOv8-AS 在简单场景下的 mAP@0.5 和 @mAP@0.5~0.95 相对于原始模型分别提高了 1.2% 和 1.6%, 精度分别达到了 93.9% 和 50.4%; 在小目标较多的场景和背景噪音较多的复杂场景下, YOLOv8-AS 的 mAP@0.5 分别增加了 2.3% 和 1.8%, 达到了 89.5% 和 89%。

为验证 YOLOv8-AS 网络模型的实际场景的检测效果, 我们将其分别应用于小目标场景 (a1、a2 和 a3)、简单场景 (b1、b2 和 b3) 和复杂场景 (c1、c2 和 c3) 三种不同场景下的复垦植被检测, 进而验证算法在不同场景下的综合检测性能。同时与其他几种算法的预测结果进行对比分析, 不同算法在三种场景下的检测结果如图 6 所示。在复垦植被长势较差的小目标场景下, 每一种算法均出现了漏检和误检的情况, 尤其是 Faster R-CNN 算法漏检较多, 而 YOLOv8-AS 算法则在复垦植被形状、大小差异较大时很好的检测出长势较差的复垦植被。在复垦植被分布较均匀且长势较好的简单场景下, 虽然所有算法的整体表现都较好, 但 SSD 算法在预测时出现了较多的误检情况, 错误地将一些背景噪音检测为复垦植被。针对特征相似的背景噪音导致的误检问题, YOLOv8-AS 算法能够很好的区分影像中与复垦植被特征相似的背景, 从而降低误检。在复垦植被的空间分布不均, 且有许多相似特征的背景噪音的复杂背景下, 其他模型都出现了大量的漏检和误检情况, 而 YOLOv8-AS 算法即使是在复杂情况下也能够精确地识别出复垦植被, 有效地区分复垦植被和背景噪音, 相较于其他算法可以达到很好的检测效果。

4.2 消融实验分析

为验证本文所提出的改进模块的有效性, 以

原始模型 YOLOv8n 为基线模型，并以 $mAP@0.5$ 、 $mAP@0.5\sim 0.95$ 、模型大小、参数量、浮点计算量作为评价指标，分别将标准卷积替换为 Adwon 模块和改进 SPPF-GFP 模块与原始模型进行消融试验，结果如表 2 所示。首先本文提出的两种改进方法相对基线模型 YOLOv8n 而言 $mAP@0.5$ 、 $mAP@0.5\sim 0.95$ 都有所提升，且参数量也有所降低。其次在原始模型中单独更换 Adown 模块之后，模型的 $mAP@0.5$ 、 $mAP@0.5\sim 0.95$ 分别提高了 0.9 个百分点和 1.2 个百分点，同时模型的大小、参数量、浮点计算量分别降低了 13.0%、13.8%、11.1%；在实验中，我们发现单独改进 Adown 模块的整体性能略优于单独改进 SPPF-GFP，我们分析这可能是在原来较长的标准卷积传递过程中出现特征丢失的同时又在特征融合过程中我们加入了全局信息，导致其在精确率和 $mAP@0.5\sim 0.95$ 要略低于前者的改进。最后，我们将两个改进模块融合后的算法相较于基线模型而言 $mAP@0.5$ 提高了 1.6%、 $mAP@0.5\sim 0.95$ 提高了 2.4%，模型大小降低了 11%、参数量降低了 10%、浮点计算量降低了 9%。本文提出的改进方法既能保证精度又能消耗较小的计算成本。

此外，不同模块组合在不同场景下的消融实验结果表明，我们提出的两个改进模块对稀土矿区复垦植被检测精度均有所提高，这进一步证明了 YOLOv8-AS 算法能够在稀土矿区复杂自然环境下实现高精度的复垦植被检测。我们改进的模型为稀土矿区的复垦植被智能化监测提供了新方法。

为了进一步验证本文提出的改进模块的有效性，我们进行了不同模块在三种场景下的检测效果对比，检测效果如图 8 所示。由图 8 可知，基线模型在小目标场景下出现漏检和误检、在简单场景下出现误检、在复杂场景下出现大量漏检等情况，而在加入 Adwon 模块后因为避免了原始卷积在较长传递过程中的特征丢失情况，进而较基线模型更好地减少了误检和漏检情况；在改进 SPPF 模块后，因为本文提出的 SPPF-GFP 模块加入了全局特征信息，在三种的场景下的误检已经不存在，但由于标准卷积的较长传递过程中的特征丢失，仍然存在个别漏检情况；最后两个模块融合后的算法在三种场景下的复垦植被识别任务中已经很好地避免了误检和漏检的问题。

4.3 讨论

本文提出了一种基于 YOLOv8 改进的稀土矿区复垦植被检测模型 YOLOv8-AS。在稀土矿区复杂的自然环境下，利用该算法对复垦植被进行检测是非常有应用价值的。我们用 YOLOv8-AS 对稀土矿区其中一部分区域进行了复垦植被的检测实验发现（图 8），使用 Adown 减少卷积传递深度并在卷积操作中融合不同尺度的特征信息能够较好的保证特征信息的完整性，从而降低模型的漏检率。同时，由于利用 SPPF 进行特征提取的过程中单一的局部卷积和局部特征池化的操作会导致模型在特征提取时会忽略一些重要的全局特征信息。因此，我们在 SPPF 中融合了全局平均池化和全局最大池化操作。这有效的提高了对空间分布不均、形状各异的复垦植被检测精度，提高了稀土矿区复杂自然环境下的复垦植被检测性能。总体而言，运用 YOLOv8-AS 算法能够为矿区复垦植被智能化监测提供技术参考。

但是需要指出的是，其一，该研究主要采用传统的 RGB 三通道遥感影像，在以后的工作中有必要进一步探究多波段遥感影像对复垦植被检测的影响。同时，进一步丰富复垦植被数据集，探索如何充分利用高分辨率影像信息，实现不同矿区复垦植被检测，是该方法广泛应用的前提。其二，矿区复垦植被特殊的地理分布以及矿区复垦植被长势不齐、空间分布不均等因素导致复垦植被在检测的过程中只有成活的树苗会被识别。因此在实现对矿区复垦植被自动化识别的基础上，需要进一步结合稀土矿区复垦植被种植规划统计未存活的点位信息计算出矿区复垦植被的成活率。

表 1 不同算法对比实验

Table 1 Comparison of different algorithms

Mode	不同场景	Precision/%	Recall/%	mAP@ 0.5/%	mAP@ 0.95/%	Model size/ MB	Parameter/ MB	FLOPs/G
SSD	自然场景	88.87	65.82	77.03	34.2	92.78	-	-
	小目标场景	88.83	64.45	74.97	32			
	简单场景	71.4	92.68	82.97	40.1			
	复杂场景	88.2	60.9	73.8	32.1			
Faster R-CNN	自然场景	48.14	79.75	67.32	30.3	110.77	-	-
	小目标场景	45.08	80.88	65.70	28.9			
	简单场景	55.04	83.93	74.32	39.8			
	复杂场景	46.18	79.97	64.56	28.4			
RT-DETR	自然场景	88.9	87.3	89.9	40.1	66.1	32	-
	小目标场景	87.2	84.3	87.4	37.1			
	简单场景	92	90.3	92.9	44.1			
	复杂场景	87.4	84	88	38.6			
YOLOv5	自然场景	89.5	83.2	88.8	43.9	5.2	2.5	7.1
	小目标场景	87.1	81.1	87	41.9			
	简单场景	92.6	87.6	92.5	47.7			
	复杂场景	87.8	81.9	86.5	42.4			
YOLOv7	自然场景	88.2	84	87.8	36.6	74.8	105.1	37.2
	小目标场景	87.4	85.2	84.6	36			
	简单场景	92.3	86.7	90.8	43			
	复杂场景	87	84.2	85.7	35.5			
YOLOv7-tiny	自然场景	89	83	88.2	36.3	12.2	6.0	13.2
	小目标场景	89.5	83.8	85	35.4			
	简单场景	92.6	87.4	91	41.7			
	复杂场景	88.4	86	86.3	35.7			
YOLOv8	自然场景	89.9	84.4	89.5	44.4	6.2	3.0	8.1
	小目标场景	87.6	81.9	87.2	41.7			
	简单场景	93.4	88.2	92.7	48.8			
	复杂场景	88	82.1	87.2	42.2			
Ours	自然场景	90.8	86	91.1	46.8	5.5	2.7	7.3
	小目标场景	88.8	83.8	89.5	45.3			
	简单场景	93.3	89	93.9	50.4			
	复杂场景	90	84.3	89	44.8			




图 6 不同算法在小目标场景(即 a1、a2 和 a3)、简单场景(即 b1、b2 和 b3)和复杂场景(即 c1、c2 和 c3)三种场景的预测效

Fig. 6 The prediction effect of different algorithms in three scenarios (small target scenarios (a1, a2 and a3), simple scenarios (b1, b2 and b3) and complex scenarios (c1, c2 and c3))

NATIONAL
REMOTE
SENSING BULLETIN | 遥感学报

www.ygxb.ac.cn

www.ygxb.ac.cn

NATIONAL
REMOTE
SENSING BULLETIN | 遥感学报

表 2 消融实验
Table 2 Ablation experiments

不同模块组合	不同场景	Precision/%	Recall/%	mAP@0.5/%	mAP@0.95/%	Model Size/MB	Parameters/MB	FLOPs/G
Conv+SPPF	自然场景	89.9	84.4	89.5	44.4	6.2	3.0	8.1
	小目标场景	87.6	81.9	87.2	41.7			
	简单场景	93.4	88.2	92.7	48.8			
	复杂场景	88	82.1	87.2	42.2			
Adown+SPPF	自然场景	90.1	85.4	90.4	45.6	5.4	2.6	7.2
	小目标场景	88.4	83.7	89.4	43.6			
	简单场景	93.4	87.6	93	49.5			
	复杂场景	88.6	84.2	88.1	43.7			
Conv+SPPF_GFP	自然场景	89.2	85.8	90.4	45	6.3	3.0	8.1
	小目标场景	89.1	83.2	88.7	44.7			
	简单场景	92.8	89.9	93.7	50.2			
	复杂场景	90	84.3	89	44.8			
Adown+SPPF_GFP	自然场景	90.8	86	91.1	46.8	5.5	2.7	7.3
	小目标场景	88.8	83.8	89.5	45.3			
	简单场景	93.3	89	93.9	50.4			
	复杂场景	90	86.3	90.2	45.8			




图 7 不同改进模块在小目标场景(即 a1、a2 和 a3)、简单场景(即 b1、b2 和 b3)和复杂场景(即 c1、c2 和 c3)三种场景的预测效果

Fig. 7 The prediction effect of different improvement modules in three scenarios: small target scenarios (i.e. a1, a2 and a3), simple scenarios (i.e. b1, b2 and b3) and complex scenarios (i.e. c1, c2 and c3)



图8 大范围的复垦植被检测结果

Fig. 8 A wide range of reclaimed vegetation detection results

5 结论

针对无人机遥感影像中的复垦植被整体特征差异较大而造成的自动检测困难的问题，以YOLOv8为基础，提出了更精准的复垦植被检测方法（YOLOv8-AS）。在改进算法方面，增加了不同尺度特征融合进一步减少模型训练过程中的特征损失，优化了传统的标准卷积操作；在原有的基础上改进了特征提取操作模块，增加了全局语义特征信息，使特征提取过程中能够充分利用复垦植被的整体特征信息。YOLOv8-AS的整体性能要优于SSD、Faster R-CNN、RT-DETR、YOLOv5、YOLOv7、YOLOv7-tiny算法，其中mAP@0.5和mAP@0.5-0.95分别达到了91.1%、46.8%。同时，YOLOv8-AS相较于基准模型YOLOv8n的mAP@0.5和mAP@0.5-0.95分别提高了1.6%、2.4%，此外，该算法在较大范围的复垦植被检测任务中达到了较好的检测效果。实验结果为稀土矿区复垦植被检测提供了技术支持，同时也为无人机等移动终端检测装备部署应用复垦植被智能检测提供了参考。

参考文献(References)

- Bai J J, Xu X, Duan Y T, Zhang G G, W Z, W L and Zheng C L. 2022. Evaluation of resource and environmental carrying capacity in rare earth mining areas in China. *Scientific Reports*, 12(1), 6105. [DOI:10.1038/s41598-022-10105-2]
- Cheng P C, Tang X, Liang W Q, Li Y, Cong W, and Zang C Z. 2023. Tiny-YOLOv7: Tiny Object Detection Model for Drone Imagery. *Image and Graphics*, Cham. [DOI: 10.1007/978-3-031-46311-2_5]
- Dong X Y, Li J G, Chen H Y, Zhao L, Zhang L M and Xing S H. 2019.

- Extraction of individual tree information based on remote sensing images from an Unmanned Aerial Vehicle. *Journal of Remote Sensing*, 23(6): 1269 - 1280 (董新宇, 李家国, 陈瀚阅, 赵磊, 张黎明, 邢世和. 2019. 无人机遥感影像林地单株树木信息提取. *遥感学报*, 23(6): 1269 - 1280 [DOI: 10.11834/jrs.20198073])
- Guo Z H, Cai D D, Zhou Y Y, Xu, T Y and Yu, F H. 2024. Identifying rice field weeds from unmanned aerial vehicle remote sensing imagery using deep learning. *Plant methods*, 20(1), 105. [DOI: 10.1186/s13007-024-01232-0]
- Krizhevsky A, Sutskever I, and Hinton G E. 2012. Image Net Classification with Deep Convolutional Neural Networks. *Advances in neural information processing systems*, 25(2): 84-90 [DOI: 10.1145/3065386]
- Li C G, Li H K, Zhou Y B and Wang X L. 2024. Detailed Land Use Classification in a Rare Earth Mining Area Using Hyperspectral Remote Sensing Data for Sustainable Agricultural Development. *Sustainability*, 16(9), 3582. [DOI: 10.3390/su16093582]
- Li P, Xu J Y and Liu S B. 2024. Solid Waste Detection Using Enhanced YOLOv8 Lightweight Convolutional Neural Networks. *Mathematics*, 12(14): 2185 [DOI: 10.3390/math12142185]
- Liu S H, Liu, Liu W, Yang M X, Zhou L Y and Liang H. 2016. The genetic diversity of soil bacteria affected by phytoremediation in a typical barren rare earth mined site of South China. *SpringerPlus*, 5: 1131 [DOI: 10.1186/s40064-016-2814-0]
- Liu W, Anguelov D, Erhan D, Szegedy C, Reed S, Fu C Y and Berg A C. 2016. SSD: Single Shot MultiBox Detector. *Springer, Cham*. 9905 [DOI: 10.1007/978-3-319-46448-0_2]
- Liu Y, Zhong X, Huot H, Liu, Wenshen, Liu C, Guo M N, Li Y Y, Fei Y H, Chao Y Q, Wang S Z, Tang, Y T and Qiu, R L. 2020. Reclamation with organic amendments and plants remodels the diversity and structure of bacterial community in ion-adsorption rare earth element mine tailings. *Journal of Soils and Sediments*, 20: 3669-3680 [DOI: 10.1007/s11368-020-02704-1]
- Ma C W, Zhang H, Ma X M, Wang J L, Zhang Y S and Zhang X A. 2024. Method for the lightweight detection of wheat disease using improved YOLOv8. *Transactions of the Chinese Society of Agricultural Engineering*, 40(5): 187-195 (马超伟, 张浩, 马新明, 王键霖, 张永爽, 张小艾. 2024. 基于改进YOLOv8的轻量化小麦病害检测方法. *农业工程学报*, 40(5): 187-195 [DOI: 10.11975/j.issn.1002-6819.202309211])
- Ma Y K, Liu H, Ling C X, Zhao F, Jiang Y and Zheng Y T. 2022. Object Detection of Individual Mangrove Based on Improved YOLOv5. *Laser and Optoelectronics Progress*, 59(18): 11 (马永康, 刘华, 凌成星, 赵峰, 姜怡, 张雨桐. 2022. 基于改进YOLOv5的红树林单木目标检测研究. *Laser and Optoelectronics Progress*, 59(18): 1106-4125 [DOI: 10.3788/L0P202259.1828003])
- Redmon J, Divvala S, Girshick R and Farhadi A. 2016. You Only Look Once: Unified, Real-Time Object Detection. *Computer Vision and Pattern Recognition*, arXiv Preprint arXiv: 1506.02640 [DOI: 10.48550/arXiv.1506.02640]
- Ren S Q, He K M, Girshick R and Sun J. 2016. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Net-

- works. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(6): 1137-1149 [DOI: 10.1109/TPAMI.2016.2577031]
- Sohan M, Sai Ram T and Reddy Rami C V. 2024. A review on yolov8 and its advancements. *International Conference on Data Intelligence and Cognitive Informatics*, 529-545 [DOI: 10.1007/978-981-99-7062-2_39]
- Tian H X, Fang X P, Lan Y B, Ma C Y, Huang H S, Lu X Y, Zhao D H, Liu H C and Zhang Y L. 2022. Extraction of Citrus Trees from UAV Remote Sensing Imagery Using YOLOv5s and Coordinate Transformation. *Remote Sensing*, 14(17): 4208. [DOI: 10.3390/rs14174208]
- Varghese R and Sambath M. YOLOv8: A Novel Object Detection Algorithm with Enhanced Performance and Robustness. 2024. *International Conference on Advances in Data Engineering and Intelligent Computing Systems (ADICS)*, 1-6 [DOI: 10.1109/ADICS58448.2024.10533619]
- Xie S and Sun H W. 2023. Tea-YOLOv8s: A Tea Bud Detection Model Based on Deep Learning and Computer Vision. *Sensors (Basel, Switzerland)*, 23(14): 6576 [DOI: 10.3390/s23146576]
- XU D Q, WU Y Q. 2024. Research Progress of Deep Learning Algorithms for Object Detection in Optical Remote Sensing Images. *National Remote Sensing Bulletin*, 1-30 (徐丹青, 吴一全. 2024. 光学遥感图像目标检测的深度学习算法研究进展. *遥感学报*, 1-30 [DOI: 10.11834/jrs.20243166])
- Wang C Y, Yan F H and Liao H. 2024. YOLOv9: Learning What You Want to Learn Using Programmable Gradient Information. *Computer Vision and Pattern Recognition*. arXiv Preprint arXiv: 2402.13616 [DOI: 10.48550/arXiv.2402.13616]
- Wang C Y, Bochkovskiy A and Liao H Y M. 2022. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors. *Computer Vision and Pattern Recognition*. arXiv Preprint arXiv: 2207.02696 [DOI: 10.48550/arXiv.2207.02696]
- Wang G, Chen Y F, An P, Hong H Y, Hu J H and Huang T. 2023. UAV-YOLOv8: A Small-Object-Detection Model Based on Improved YOLOv8 for UAV Aerial Photography Scenarios. *Sensors*, 23(16): 7190 [DOI: 10.3390/s23167190]
- Wang G X, Leoncé A, Edirisinghe E A, Khafaga T, Simkins G, Yahya U and Sher Shah M. 2023. Ghaf Tree Detection from Unmanned Aerial Vehicle Imagery Using Convolutional Neural Networks. 2023 *International Symposium on Networks, Computers and Communications (ISNCC)*, 1-8 [DOI: 10.1109/ISNCC58260.2023.10323713]
- Wang H, Xia K, Yang Y H and Feng H L. 2023. Urban cinnamomum camphora crown detection research using RGB-DSM images and deep learning. *National Remote Sensing Bulletin*, 27(12): 2762-2773 (王昊, 夏凯, 杨垠晖, 冯海林. 2023. 结合 RGB-DSM 图像和深度学习的城市樟树树冠检测. *遥感学报*, 27(12): 2762-2773 [DOI: 10.11834/jrs.20221613])
- Wang K, Chen Y L and Xu H L. 2024. Detection of individual trees of bayberry using improved YOLOv7. *Transactions of the Chinese Society of Agricultural Engineering*, 40(11): 159-167 (王凯, 陈优良, 胥寒莉. 2024. 基于改进 YOLOv7 的杨梅树单木检测. *农业工程学报*, 40(11): 159-167 [DOI: 10.11975/j.issn.1002-6819.202401091])
- Wang X L, Liang Z Y and Liu T. 2023. Feature attention pyramid-based remote sensing image object detection method. *National Remote Sensing Bulletin*, 27(2): 492-501 (汪西莉, 梁正印, 刘涛. 2023. 基于特征注意力金字塔的遥感图像目标检测方法. *遥感学报*, 27(2): 492-501 [DOI: 10.11834/jrs.20235011])
- Wang X W, Zhao Q Z, Jiang P, Zheng Y C, Yuan L M Z and Yuan P L. 2022. LDS-YOLO: A lightweight small object detection method for dead trees from shelter forest. *Computers and Electronics in Agriculture*, 198: 107035 [DOI: 10.1016/j.compag.2022.107035]
- Wu Z B, Li H K and Wang Y Q. 2021. Mapping annual land disturbance and reclamation in rare-earth mining disturbance region using temporal trajectory segmentation. *Environmental Science and Pollution Research*, 28: 69112-69128 [DOI: 10.1007/s11356-021-15480-3]
- Wu Z B, Li H K, Wang Y Q and Long B P. 2024. MCCANet: A multi-spectral class-constraint attentional neural network for object detection in mining scenes. *Expert Systems with Applications*, 247(3): 123233 [DOI: 10.1016/j.eswa.2024.123233]
- Zhao H, Liu W P, Zhou Y, Luo Y Q, Zong S X and Ren L L. 2022. Method for detecting pine forest discoloured epidemic wood based on semi-supervised learning. *Transactions of the Chinese Society of Agricultural Engineering*, 38(20): 164-170 (赵昊, 刘文萍, 周焱, 骆有庆, 宗世祥, 任利利. 2022. 基于半监督学习的松林变色疫木检测方法. *农业工程学报*, 38(20): 164-170 [DOI: 10.11975/j.issn.1002-6819.2022.20.019])
- Zhao Y D, Wei H Y, Dong J H and Dong C. 2022. Opencast coal mine scene recognition based on sub-region multi-label learning. *National Remote Sensing Bulletin*, 26(9): 1849-1858 (赵银娣, 卫虹宇, 董霁红, 董畅. 基于子区域多标签学习的露天煤矿区场景识别[J]. *遥感学报*, 2022, 26(09): 1849-1858 [DOI: 10.11834/jrs.20210001])
- Zheng L, Yi J C, He P, Tie J, Zhang Y B, Wu W B and Long L Y J. 2024. Improvement of the YOLOv8 Model to the Optimization of the Weed Recognition Algorithm in Cotton Field. *Plants (Basel)*, 13(13): 1843-1843 [DOI: 10.3390/plants13131843]
- Zhou B B, Li H K and Long B P. 2023. Variation Analysis of Spectral Characteristics of Reclaimed Vegetation in an Ionic Rare Earth Mining Area. *Spectroscopy and Spectral Analysis*, 43(12): 3946-3954 (周贝贝, 李恒凯, 龙北平. 2023. 离子吸附型稀土矿区复垦植被光谱特征变异提取与分析. *光谱学与光谱分析*, 43(12): 3946-3954 [DOI: 10.3964/j.issn.1000-0593(2023)12-3946-09])

Revegetation Detection Method for Rare Earth Mining Areas Using

YOLOv8n Network with Integrated Global Features

LI Xingmei¹, LI Hengkai¹, LIU Kunming², WANG Xiumi³

¹School of Economics and Management, Jiangxi University of Science and Technology, Ganzhou 341000, China;

²Geospatial Information Engineering Team, Jiangxi Provincial Geological Bureau, Nanchang 330000, China;

³School of Civil and Surveying Engineering, Jiangxi University of Science and Technology, Ganzhou 341000, China

Abstract: The leaching mining of ion-adsorbed rare earth ore primarily employs in-situ leaching, pile leaching, and pool leaching methods, which result in significant soil pollution. This pollution presents serious environmental challenges, particularly affecting the growth and survival rates of reclaimed vegetation in rare earth mining areas. The restoration of reclaimed vegetation is crucial for mitigating environmental damage and restoring ecological balance. However, the application of intelligent technology to monitor and manage the health and growth of reclaimed vegetation in these mining areas encounters substantial challenges due to the complexities of the natural environment. Unmanned aerial vehicle (UAV) remote sensing image technology has emerged as a promising tool for monitoring and evaluating ecological restoration efforts in rare earth mining areas. The UAV can rapidly capture high-resolution images over large areas, facilitating efficient monitoring of reclaimed vegetation growth in these regions. However, the uneven spatial distribution, varying shapes and diverse overall characteristics of reclaimed vegetation present significant challenges for achieving high-precision automatic recognition from UVA images. Consequently, relying solely on traditional image processing technique for vegetation detection and classification proves to be inadequate. To address these challenges and enhance the automatic recognition and localization capabilities of individual reclaimed vegetation in UAV images, this paper proposes a method for reclaimed vegetation detection in rare earth mining areas (YOLOv8n), which integrates the global feature YOLOv8-AS. This method represents an innovative improvement over YOLOv8n: first, the downsampling module ADown is introduced to optimize the feature convolution operation, thereby reducing the feature loss during the deep model training process. Second, the SPPF-GFP (Spatial Pyramid Pooling Fast - Global Feature Pool) module is employed for feature extraction, significantly enhancing the detection capability of reclaimed vegetation with substantial variations in overall features. The results showed that in the self-constructed rare earth mining reclamation vegetation dataset, YOLOv8-AS outperforms YOLOv8n by 1.6% and 2.4% in terms of mAP@0.5 and mAP@0.5-0.95, respectively. Compared to YOLOv8n, the model size, number of parameters, and floating point computation of YOLOv8-AS decreased by 11%, 10%, and 9%, respectively. The mAP@0.5 and mAP@0.5-0.95 for the YOLOv8-AS algorithm are 91.1% and 46.8%, respectively. When compared to SSD, Faster R-CNN, RT-DETR, YOLOv5, YOLOv7 and YOLOv7-TINY models regarding mAP@0.5, YOLOv8-AS shows improvements of 14.07%, 23.32%, 1.2%, 2.3%, 3.3%, 2.9% and 1.2%, respectively. According to the comparative experimental results of YOLOv8-AS and YOLOv8 across three scenarios—characterized by a predominance of small targets, simplicity, and complexity—the mAP@0.5-0.95 of YOLOv8-AS increased by 2.3%, 1.2%, and 3%, respectively, when compared to the baseline model YOLOv8. Furthermore, we applied YOLOv8-AS to the reclamation vegetation detection task in a larger scene within a rare earth mining area. The visualization results indicate that, regardless of the scenario—whether featuring numerous small targets, simple scenes, or complex environments—this method significantly enhanced its capacity to identify and accurately locate individual plants in the reclamation vegetation. This finding further substantiates its efficacy in accurately detecting reclaimed vegetation across various conditions. Such advancements are crucial for effectively monitoring the progress of ecological restoration in mining areas and provide essential support for achieving sustainable mining development.

Key words: Deep Learning, Object Detection, YOLOv8n, UAV Imagery, Rare Earth Mining Area, Reclaimed Vegetation

Supported by Supported by National Natural Science Foundation of China (No. 42161057); Key Project of Natural Science Foundation of Jiangxi Province (No.20232ACB203025); Key Laboratory Opening Fund of the Ministry of Natural Resources (No. 2023IRERE402)