# 一种针对小尺度风车的目标检测算法

鲍熠琳[1]，胡晋山[1]，康建荣[1]，朱益虎[2]，王胜利[2]
(1.江苏师范大学 地理测绘与城乡规划学院，江苏 徐州 221116；2.江苏省地质测绘大队，江苏 南京 211102)

**摘 要**：风车是将风能转换为电能的重要设施，针对遥感影像中小尺度风车识别过程中出现的漏检与误检问题，文章构建了新的高分二号风车数据集，提出了针对风车小目标检测任务的 YOLO-WM 算法。该算法在 YOLOv8 目标检测算法的基础上增加一个极小目标检测层，并在 Backbone 部分添加了 BSAM 动态注意力机制模块，使用轻量化 C2f_RepGhost 模块替换 C2f 模块，最后在预测阶段结合 SAHI 切片算法完成风车目标检测任务。实验结果表明，YOLO-WM 算法在降低算法复杂度的同时更好地保留了浅层卷积特征，能更准确地捕捉小尺度目标信息。该方法弥补了小目标检测数据集的不足，经验证，改进算法在小尺度风车上的效果优于其他算法。文章研究结果对于风能资源合理优化配置与地理要素联合分析具有一定参考价值。

**关键词**：风车；深度学习；小目标检测；YOLOv8；高分影像
**中图分类号**：TK81 **文献标志码**：A **文章编号**：1671-5292(2025)12-1638-09

## 0 引言

作为目前应用最为广泛的可再生能源之一，风能凭借其环保、低成本、总量丰富、高度自动化等优势成为推动能源结构优化的重要推动力。风车是转化风能的重要设备，风车组的规划与兴建对于合理高效地利用风能具有重要意义。以往风车的位置信息依靠数据库进行存储，既不直观也不易于与其他地理信息数据进行联合分析。

近年来，遥感技术发展迅速，各种类型的传感器可以提供大量遥感影像，为获取风车地理数据提供了有利条件[1]。常规的人工解译目标标注需要大量时间与人力成本，易出现漏检，而基于深度学习的目标检测方法仅须将待检测影像输入网络中，即可直接获取识别目标，检测效率大大提升。基于深度学习的目标检测方法包括 two stage 算法和 one stage 算法。其中，two stage 算法在生成目标提取区域后，再对每个候选区进行分类和回归，Faster-RCNN 是较为经典的 two stage 算法，该方法在目标检测上的精度较高，但模型十分复杂。one stage 算法则直接从输入图片回归类别和位置，实现在一次向前传播中完成检测，所以速度较快。YOLO(You Only Look Once)是其中最具代表性的算法。基于 YOLO 的目标检测被广泛应用于各个领域，包括人脸识别[2]、文本检测[3]、自动驾驶[4]、医学检测[5]等。当前面向大中型目标的检测算法研究已经比较完善，但针对小目标的识别依然存在一定的问题，一些学者通过增强算法模型提升对小目标特征的提取能力检测效果。曹健[6]对复杂道路场景下各种小目标车辆检测方法进行了总结，阐述了基于深度学习的多种道路小目标检测优化方法。Zhang L J[7]在 YOLOv8 的基础上，提出一种多尺度交通标志检测模型 CR-YOLOv8，提高了对不同尺度交通标志的检测精度。孙佳宇[8]以无人机影像为研究对象，设计了一种 C2_DCF 模块以增强小目标特征提取，同时使用 WIoU 为损失函数来改善小目标对梯度的影响，使改进算法在 DOTA 数据集上的平均精度提高了 2.4%。

注意力机制的出现为目标检测带来了新的思路，通过对不同信息赋予不同的权重来提升网络对检测目标的关注度。毛云龙[9]以 SAR 影像中的舰船为研究对象，将 CA 注意力机制引入 YOLOv7 网络，采用包含跳跃层和跨尺度连接的 GiraffeDet-Lite 结构来强化网络的特征提取能力，提高了识别准确率，却降低了检测效率。李耀龙[10]则将 YOLOv9 与稀疏注意力机制 BRA 结合，极大地改善了原算法在检测电路板表面细小缺陷时存在的误检问题，平均精度较改进前提高了 2.3%，但同时也带来了参数量与复杂度的增加。还有各种轻

**收稿日期**：2024-12-23。
**基金项目**：国家自然科学基金项目(52074133，41671395)。
**通信作者**：胡晋山(1973-)，男，博士，教授，硕士生导师，研究方向为时态 GIS 理论与应用。E-mail：xzjshu@163.com

量化方法被用于解决这一问题。王国刚[11]针对红外弱小目标提出了一种轻量级的目标检测算法FCN，该算法在YOLOv5的基础上采用了轻量化的上采样算子与多重注意力机制的检测头，使算法参数量明显减少，在红外弱小目标检测数据集上的准确率提升了4.3%。Wang K[12]分析了从遥感影像中提取细节的难点，而后在YOLOv8的基础上加入归一化注意力模块NAM,并采用更高效的C2f_RepGhost模块替代C2f模块，在保证精度的前提下提高了小目标检测能力。虽然上述算法弥补了小目标检测的一些问题，但在遥感影像小目标地物检测方面仍存在不足。

风车是由支架、发电机和三支叶片组成的特殊三叉结构地物,本文使用的风车数据集中80%以上样本满足目标尺寸不大于影像的10%,剩余样本因其细长的叶片结构导致长边超过阈值,但由于在遥感影像中所占像素较少，仍可视为小目标[13]。一方面,小目标检测对象在影像中可利用的信息较少,难以提取更多判别特征;另一方面,基于深度学习的目标检测方法受网络模型的局限,其逐层加深的多层卷积结构不可避免地造成细节信息的损失。针对上述问题,本文首先制作了风车光学遥感目标检测数据集；然后以YOLOv8网络结构为基础提出了针对小目标风车识别的YOLO-WM算法，在Neck部分增加极小目标检测头以减少网络对风车细节特征提取的遗漏,在Backbone部分加入BSAM（BiLevel Spatial Attention Module）注意力机制模块以实现空间与通道的动态双重关注,使用轻量化C2f_RepGhost模块替换C2f模块提升检测效率；最后在预测阶段结合SAHI(Slicing Aided Hyper Inference)算法提升检测精度。

## 1　数据采集与处理

### 1.1　数据集制作

本研究采用高分二号影像制作风车数据集。高分二号是中国发射的一颗高分遥感卫星，能够为国土资源监测、城市规划管理、地理资源开发等提供亚米级空间分辨率的遥感影像。

江苏省位于我国东部沿海区域，地势较为平坦,风能资源丰富。选取2022年3-5月江苏省部分沿海区域高分二号影像，将其裁剪为640×640像素的样本，选取1 306张样本构成本文的数据集,部分样本如图1所示。

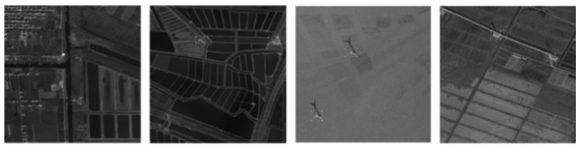


**图1　样本数据示例图**

Fig.1 Sample data example

### 1.2　数据集增强与划分

为了保证实验数据的多样性与平衡性，对原始数据集进行扩充。数据集扩充分为常规数据增强与基于上下文的复制、粘贴[14]两个部分。常规数据增强策略包括随机缩放、添加噪声、改变对比度等方式;基于上下文的复制、粘贴策略是指将样本框位置的目标复制,根据周围像素进行重复覆盖,以增加单张图像中的样本数量，该方法可以加强算法对于某些特殊角度风车样本数据的学习。本文按8:1:1的比例划分训练集、验证集和测试集,共得到训练集样本2 336张,验证集样本292张,测试集样本292张。

## 2　网络模型与改进方法

### 2.1　YOLOv8模型

YOLOv8算法模型由Input,Backbone,Neck,Head共4部分组成[15]。Input部分将图像处理成640×640像素输入网络;Backbone部分利用C2f结构针对各种不同尺度的模型调整通道数，以完成输入图像的特征提取工作;Neck部分将接收的上一步图像特征输入特征金字塔网络(Feature Pyramid Networks,FPN)结构;Head部分采用将分类与检测任务分离的解耦头结构，应用动态正负样本分配策略完成分类与回归操作,其中Loss函数使用了Distribution Focal Loss与CIoU Loss作为回归损失,BCE Loss作为分类损失。

由于遥感影像中的风车所占像素少，且形状受拍摄角度影响较大，所以本文对YOLOv8算法进行改进，在Neck部分增加一个针对极小目标的检测头,在Backbone部分加入BSAM动态双重注意力模块，用C2f_RepGhost模块替换C2f模块，检测部分结合SAHI算法增强检测头对小目标的敏感度,以提高风车识别的准确率。改进后的模型结构如图2所示。

### 2.2　极小目标检测头

YOLOv8在Neck部分共设置了3个针对不同大小目标的检测头,其中20×20像素检测头用

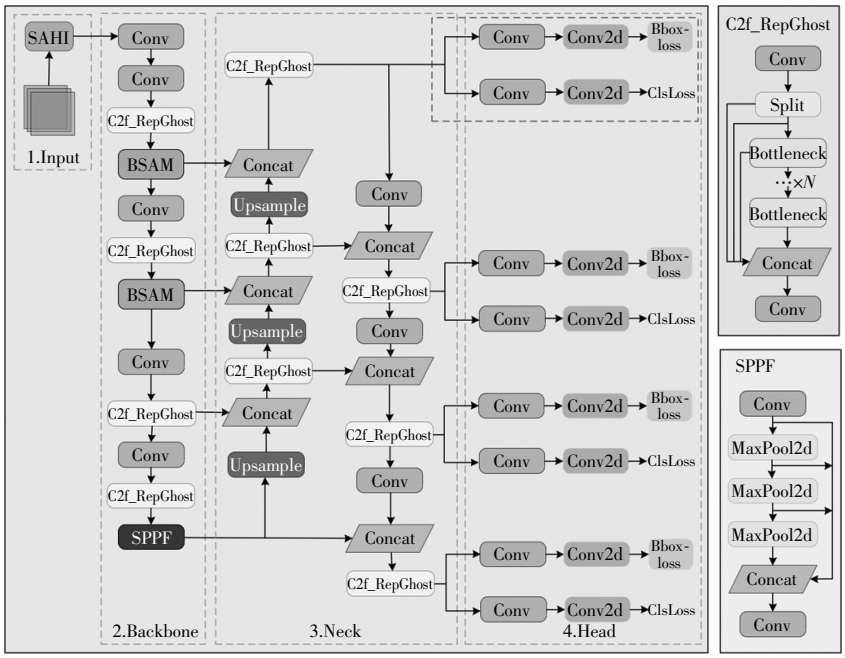



**图 2　改进网络结构图**

Fig.2 Improved network structure

于检测大目标,40×40 像素检测头用于检测中等目标,80×80 像素检测头用于检测小目标。随着网络层数不断加深，多次卷积造成了特征图的尺寸过大,小目标特征与位置信息逐渐丢失,深层语义信息缺乏,识别能力下降。虽然原检测头可以满足大部分对象的识别需要，但对于遥感影像中的风车这一极小目标仍会出现漏检，故在 P2 低层特征图的输出后增加一个 160×160 像素检测头,以提高极小目标检测效率。

### 2.3　BSAM 注意力机制

BSAM 是在 CBAM（Convolutional Block Attention Module）注意力机制的基础上结合动态稀疏机制得到的注意力模块。CBAM 是一种结合了通道和空间双重注意力机制的轻量级卷积模块，包含 CAM（Channel Attention Module）和 SAM（Spatial Attention Module)两个子模块[16],分别关注通道和空间特征。虽然 CBAM 机制能够加强模型对感兴趣区域的关注度，但由于其采用全局关注方式，使得与目标特征区相关性较弱的区域产生了冗余信息。

本文采用的 BSAM 注意力机制将 CBAM 中的 CAM 模块替换成了 BRA(BiLevel Routing Attention）模块,BRA 是一种动态稀疏的注意力机制[17],能够更灵活地计算和分配感知内容,具备动态的查询感知稀疏性,原理如图 3 所示。首先将输入的特征图(长、宽、通道数分别为 $H$,$W$,$C$)划分为 $S\times S$ 个不重叠区域，每个区域中包含了 $HW/S^2$ 个特征向量，此时原图区域由 $X\in H\times W\times C$ 变为

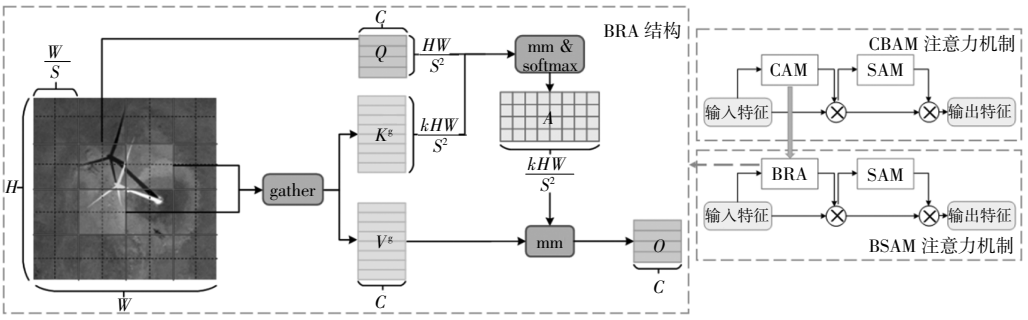



**图 3　BSAM 注意力机制结构图**

Fig.3 Structure diagram of BSAM attention mechanism

$X^r \in S^2\times(HW/S^2)\times C$,建立线性查询 $\boldsymbol{Q}$(Query)、键值 $\boldsymbol{K}$(Key)、张量 $\boldsymbol{V}$(Value)的投影关系,其计算式分别为

$$\boldsymbol{Q}=X^r W^q \tag{1}$$

$$\boldsymbol{K}=X^r W^k \tag{2}$$

$$\boldsymbol{V}=X^r W^v \tag{3}$$

式中:$W^q$,$W^k$,$W^v$ 分别为区域 $X^r$ 的 $\boldsymbol{Q}$,$\boldsymbol{K}$,$\boldsymbol{V}$ 投影权值。

利用每个区域的 $\boldsymbol{Q}^r$ 和 $\boldsymbol{K}^r$ 计算区域之间的亲和图邻接矩阵 $\boldsymbol{A}^r$,$\boldsymbol{A}^r$ 用于衡量两个区域在语义上的关联程度,其计算式为

$$\boldsymbol{A}^r=\boldsymbol{Q}^r(\boldsymbol{K}^r)^T \tag{4}$$

然后修建关联关系以保留每个区域的 top-k 连接,利用索引矩阵 $\boldsymbol{I}^r$ 计算逐行 top-k 算子(top-k 指前 $k$ 个最相关的指标),$\boldsymbol{I}^r$ 的计算式为

$$\boldsymbol{I}^r=topkIndex(\boldsymbol{A}^r) \tag{5}$$

对 $k$ 个索引区域的键值对进行整合得到 $K^g$,$V^g$[式(6),(7)],引入一个局部增强技术 LCE(Local Contrast Enhancement),得到复杂度为 $O$ 的注意力[式(8)]。

$$K^g=gather(K,\boldsymbol{I}^r) \tag{6}$$

$$V^g=gather(V,\boldsymbol{I}^r) \tag{7}$$

$$O=Attention(Q,K^g,V^g)+LCE(V) \tag{8}$$

### 2.4　C2f_RepGhost 轻量化卷积模块

卷积是深度学习的重要操作,通过对输入图像进行一系列卷积操作来提取所需目标的特征。C2f_RepGhost 模块将原 C2f 模块中的原始卷积替换为 RepGhost 卷积块。RepGhost 是在 Ghost 基础上提出的卷积方法[18],Ghost 使用特征重复技术将不同层特征图进行简单连接来获取额外特征。首先通过 1×1 卷积生成小通道数特征图来减少计算量,然后在此基础上采用深度可分离卷积生成新的特征图,最后使用 Concat 操作将新特征图与原始特征图合并得到最终输出的特征图。C2f_RepGhost结构图如图 4 所示。RepGhost模块去掉了Ghost中低效的 Concat 操作,改为以Add 操作方式进行特征融合,节省了硬件上的计算成本,减少了大量推理时间。RepGhost 分支中添加了归一化操作,并将深层卷积的 ReLU 移动到了 Add 运算之后,在推理过程中可以帮助模型快速完成特征融合,从而节省硬件的计算时间。

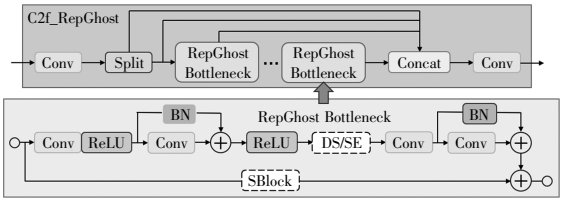
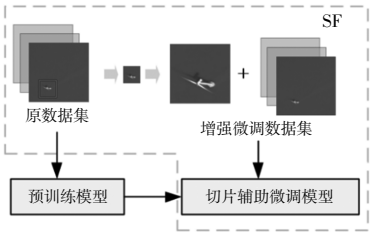



**图 4　C2f_RepGhost 结构图**

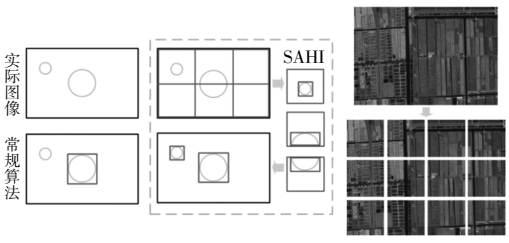
Fig.4 C2f_RepGhost structure diagram

### 2.5　SAHI 切片框架

SAHI 是一个针对小目标检测的通用切片辅助推理框架,可用于模型微调训练(Slicing aided Fine-tuning,SF) 和推理 (Full Inference,FL)[19]。SAHI 采用与滑动窗口相似的思路将待检测影像划分为重叠的切片,在模型训练之前,从预训练数据集中选择样本切割成较小的图片,再将这部分样本调整到用于训练的统一大小,这样原样本中的小尺度目标就能更好地为后续训练提供细节特征,即 SF 阶段的改进思路,原理如图 5(a)所示。同样的思路也被用于 FL 阶段,将待预测的图像切割为具有一定重叠度的切片,再对每一张小图像单独进行预测,SAHI 将切片进行拼接并合并相邻切片中重叠的检测框,最后通过非极大抑制(NMS)合并为原始影像大小,既提高了检测精度又降低了对小目标检测的遗漏,原理如图 5(b)所示。




(a)切片辅助微调训练原理图




(b)切片辅助推理原理图

**图 5　SAHI 原理示意图**

Fig.5 Schematic diagram of SAHI principle

当对遥感影像中的目标进行识别时,往往需要先将较大面积影像裁剪为合适大小的小面积影像输入模型进行检测,得到结果后再拼接为原始大小影像,这个过程费时费力。SAHI 辅助切片推理算法可以快速完成前面的操作,非常适用于

遥感影像的目标检测任务。

## 3 实验结果与分析

### 3.1 实验环境

数据采集平台与实验平台均为 Ubuntu 操作系统,使用 PyTorch 框架、PyCharm 编辑器、Python 编程语言进行模型训练。训练网络所用数据集为自行创建的风车遥感数据集，实验环境及配置见表 1。设置训练轮次为 200 轮,批次大小为 16,学习率为 0.01。

**表 1 实验环境及配置**

Table 1 Experimental environment and configuration

| 实验环境 | 配置 |
|---|---|
| CPU | 12 vCPU Intel(R) Xeon(R) Platinum 8255C CPU @ 2.50 GHz |
| GPU | RTX 3080(10 GB) |
| Python | 3.8(Ubuntu20.04) |
| Cuda | 11.7 |

### 3.2 消融实验

基于本文 1.1 中的风车数据集，对改进算法做进一步消融实验来验证每个不同的改进部分对算法性能的影响。本文使用平均精度(mean Average Precision,mAP)、参数量(Params)和浮点计算量(GFLOPs)作为算法评价指标。

mAP 是用来衡量训练好的模型在各类别上检测能力好坏的指标。其中,mAP@0.5 为在 50% IoU 阈值下的 mAP 值,mAP@0.5–0.95 为在 50%~95% IoU 阈值内每隔 5%个步长计算的 mAP 平均值。IoU 指真实框与预测框重叠情况的交并比。mAP 的计算式为

$$P=\frac{TP}{TP+FP} \tag{9}$$

$$R=\frac{TP}{TP+FN} \tag{10}$$

$$\mathrm{mAP}=\frac{\sum_{i=1}^{N}\left[\int_0^1 P(R)\mathrm{d}R\right]_i}{N} \tag{11}$$

式中:$TP$(True Positives)为被算法正确识别的正样本数量;$FP$(False Positive)为被算法错误识别为正样本的负样本数量;$FN$(False Negative)为被算法错误识别为负样本的正样本数量;$P$ 为所有识别出的风车中被正确识别的比例;$R$ 为实际的风车中被正确识别的比例;$P(R)$为以 $R$ 为横坐标,$P$ 为纵坐标的 $P$–$R$ 曲线函数;$N$ 为类别数。

参数量和浮点计算量均体现了算法的复杂程度。参数量是指算法模型包含的参数数量,即所占用的显存大小；而浮点计算量是指单位时间的浮点运算次数,即运算速度。一般来说,算法模型参数量越多,计算量越大,运算就越复杂,效率越低。

本文在算法 YOLOv8 基础上做了 3 部分改进,即添加 P2 极小目标检测头、添加 BSAM 注意力机制模块和替换 C2f_RepGhost 结构。故分别进行 YOLOv8 +P2 检测头、YOLOv8 +BSAM 和 YOLOv8+C2f_RepGhost 三种组合算法的目标检测任务，以验证改进的每一个部分对目标检测性能的提升。

消融实验结果如表 2 所示。从表 2 可以看出:

**表 2 消融实验结果**

Table 2 Ablation test results

| P2 检测头 | BSAM | C2f_RepGhost | mAP@0.5 | mAP@0.5–0.95 | Params | GFLOPs |
|---|---|---|---|---|---|---|
| | | | 0.958 6 | 0.588 8 | 25.9 | 79.1 |
| √ | | | 0.971 4 | 0.592 6 | 25.1 | 98.5 |
| | √ | | 0.975 7 | 0.594 0 | 25.2 | 110.3 |
| | | √ | 0.962 8 | 0.591 3 | 15.0 | 45.2 |
| √ | √ | √ | 0.978 3 | 0.595 1 | 14.0 | 69.2 |

注:“√”表示添加了改进部分。

单独添加P2 检测头使 mAP@0.5 提高了 1.3%,mAP@0.5–0.95 提高了 0.4%,参数量几乎不变,但计算量增加了 24%，这是因为主干网络没有变化,但 Neck 部分增加一个连接层;在 Backbone 部分添加 BSAM 注意力机制使 mAP@0.5 提高了 1.7%,mAP@0.5–0.95 提高了 0.5%,同时计算量也增加了 39%,这是因为注意力机制从算子上看类似于卷积结构,增大了计算过程,从而降低了运算效率；替换 C2f_RepGhost 使 mAP@0.5 提高了 0.3%,mAP@0.5–0.95 提高了 0.2%,与其他改进模型相比，平均精度提升较少，但参数量减少了 42.1%,计算量减少了 42.9%,运算效率大幅提升。虽然注意力机制的加入给模型带来了额外的计算成本，但算法的检测精度得到了明显提高,获

得了更优的小目标检测效果,C2f_RepGhost 模块从轻量化的角度弥补了参数量大与计算复杂的缺陷,使最终的改进模型兼具精度与效率。实验结果表明，每个改进部分均对风车检测算法精度与效率的提升起到了一定作用。

### 3.3　对比实验

基于本文 1.1 中的风车数据集,选取目前使用较为广泛的目标检测算法与本文改进的 YOLO-WM 算法,Faster-RCNN,YOLOv5,YOLOv8 进行对比实验。本文从平均精度、参数量和计算量 3 个方面进行综合评价,结果如表 3。由表 3 可以看出,改进后的算法无论在计算精度还是计算效率上,都比其他算法展现出更好的性能。

**表 3　对比实验结果**

Table 3 Comparative experimental results

| 模型 | mAP@0.5 | mAP@0.5-0.95 | Params | GFLOPs |
|---|---|---|---|---|
| Faster-RCNN (resnet50) | 0.939 3 | 0.543 9 | 41.3 | 251.4 |
| YOLOv5 | 0.958 4 | 0.587 6 | 21.2 | 49.0 |
| YOLOv8 | 0.958 6 | 0.588 8 | 25.9 | 79.1 |
| YOLO-WM | 0.978 3 | 0.595 1 | 14.0 | 69.2 |

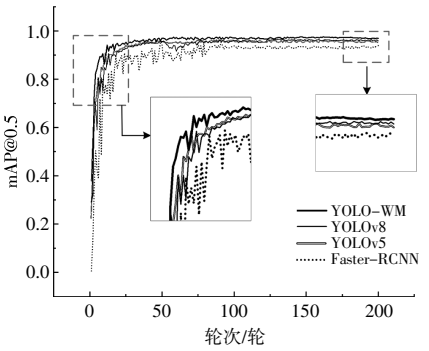



**图 6　平均精度对比折线图**

Fig.6 Comparison line chart of average accuracy

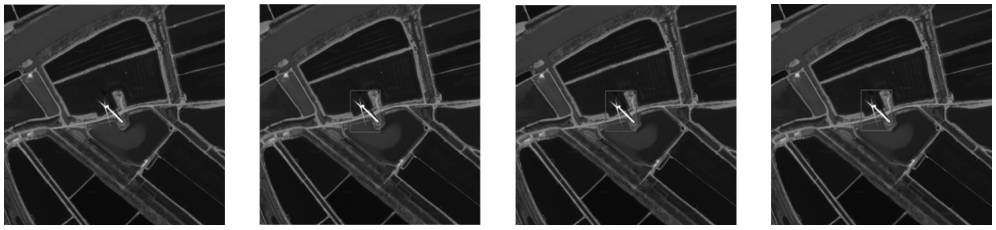
各算法的平均精度对比如图 6 所示。由图 6 可以看出，改进算法相较于其他算法可以更快地收敛,经过约 20 个训练轮次后,mAP@0.5 即可稳定在 0.9 以上。

Faster-RCNN 是经典的 two stage 模型，其两阶段的检测与分类结构并不能实时处理，且模型的池化层后存在大量全连接层计算，使得运算参数量远大于 YOLO 系列算法，所以 Faster-RCNN 需要消耗大量的计算和时间成本，不适宜处理包含大量样本的遥感场景。从表 3 可以看出，YOLO-WM 的参数量仅为 Faster-RCNN 的 1/3，计算效率提升了两倍多。YOLOv8 的检测精度略高于 YOLOv5，且 YOLOv8 在本研究数据集上训练时收敛速度更快。这是因为 YOLOv8 将 YOLOv5 中的 Anchor-based 检测头替换为了 Anchor-free 检测头,而 Anchor-based 检测头预设了大量锚框来回归和分类目标，冗余的锚框增加了内存消耗,且模型参数需反复调试设定。YOLOv8 虽使用了锚点但并不依赖指定先验锚框的大小和形状，减少了因锚框设置不合理导致的小目标漏检问题，故本文选择在 YOLOv8 的基础上进行优化改进。YOLO-WM 与 YOLOv8 相比,mAP@0.5 提高了 2.0%,mAP@0.5-0.95 提高了 0.7%，参数量减少了 45.9%,浮点计算量减少了 12.5%。由此可见,在风车识别场景下,改进算法拥有更高的检测精度与效率,更能满足任务需求。

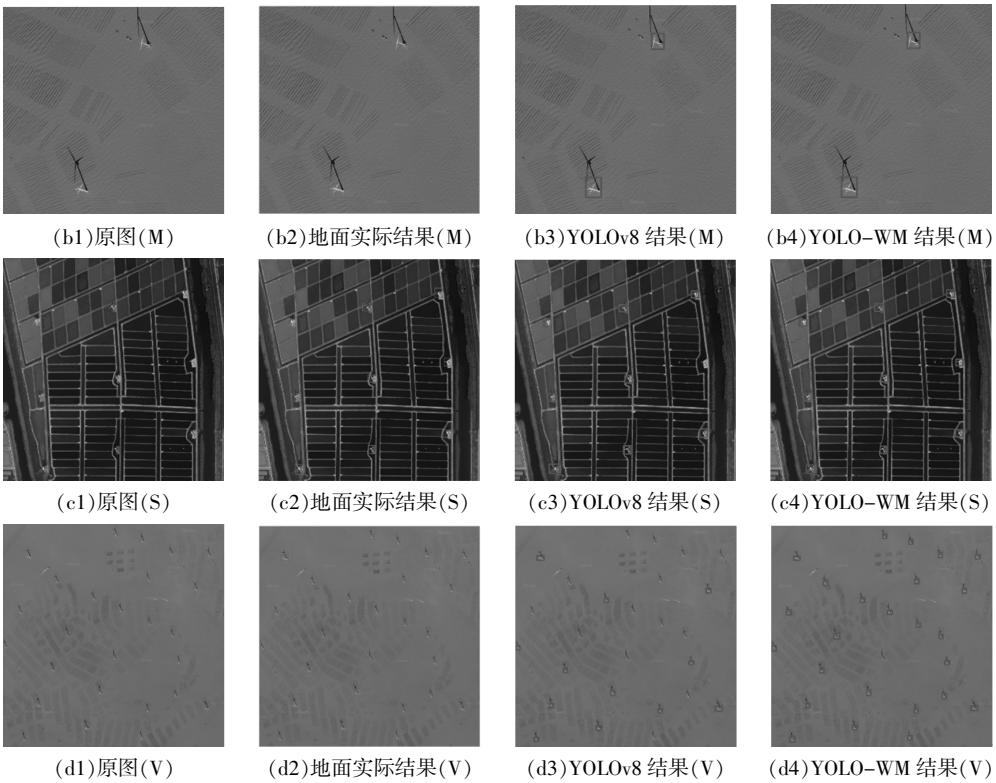
### 3.4　多尺度风车检测效果对比

为了验证本文算法对小尺度风车的检测效果,另取 4 幅包含不同尺度风车的影像,并将人工标注结果作为实际地面结果。分别使用 YOLOv8 与本文YOLO-WM 算法对这 4 幅影像中的风车进行识别,结果如图 7 所示。图中,L(Large)表示大尺度风车,M(Medium)表示中尺度风车,S(Small)表示小尺度风车,V(Very small)表示极小尺度风车。

从图 7 可以看出:图 7(a3,a4)与图 7(a2),图 7(b3,b4)与图 7(b2)的识别结果一致,说明对于图 7(a1)与图 7(b1)中的大、中尺度风车,YOLOv8 与 YOLO-WM 均可以准确识别;对于图 7(c1)中的小尺度风车,YOLOv8 结果出现了一个漏检,而



(a1)原图(L)　(a2)地面实际结果(L)　(a3)YOLOv8 结果(L)　(a4)YOLO-WM 结果(L)



(b1)原图(M) (b2)地面实际结果(M) (b3)YOLOv8 结果(M) (b4)YOLO-WM 结果(M)

(c1)原图(S) (c2)地面实际结果(S) (c3)YOLOv8 结果(S) (c4)YOLO-WM 结果(S)

(d1)原图(V) (d2)地面实际结果(V) (d3)YOLOv8 结果(V) (d4)YOLO-WM 结果(V)

**图 7 多尺度风车识别**

Fig.7 Multi-scale windmill identification diagram

改进后的算法未出现漏检;对于图 7(d1)中的极小尺度风车,YOLOv8 的识别结果出现大量漏检情况，说明未改进的算法不能很好地发掘极小目标特征,故不适宜处理该类检测任务;而 YOLO-WM 结果与实际结果相比,仅 1 台风车未被检出。

对图 7(d4)中漏检风车原因进行分析,由于该风机拍摄角度不佳,叶片存在严重重叠现象(图 8),给算法检测带来了难度,导致该风车检测可信度未达到规定阈值。从图 8 可以看出,上方矩形框内漏检风车与同一区域下方矩形框内正确识别风车相比,具有明显形态差异,检测特征不明显。综合以上结果,可以证明 YOLO-WM 更满足小目标风车高精度检测任务的需求。

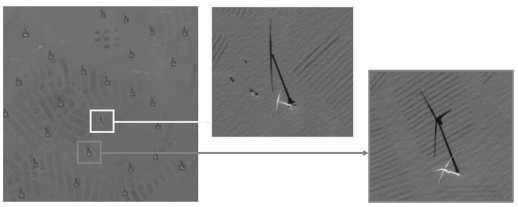


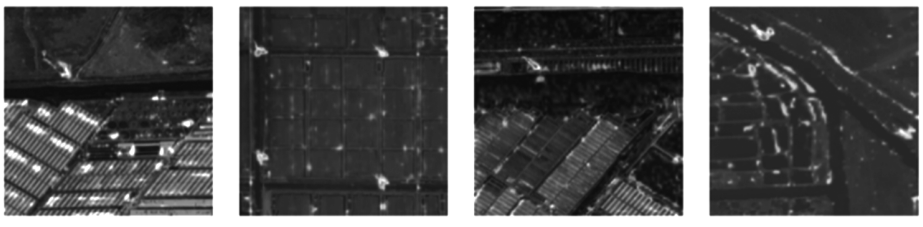
**图 8 漏检风车放大示意图**

Fig.8 Enlarged diagram of the missed windmill

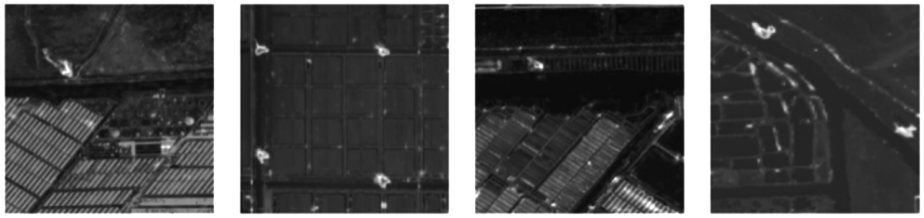
### 3.5 模型特征热力图

特征图显示了一张影像经过一系列卷积后捕捉到的特征，特征图中具有较高激活值的部分说明该模型对于该特征的关注程度更高。热力图是一种直观的可视化方式，它将特征图表示为颜色密度较高的区域，可以更方便地理解模型对于不同区域的关注程度，同时直观地展示图像中的哪些区域对于模型算法的决策是最重要的。

如图 9 所示，选取 4 张拥有不同背景的风车样本(包括耕地、道路、建筑、水系等),分别绘制基



(a)YOLOv8



(b)YOLO-WM

**图 9　改进前后特征热力对比图**

Fig.9 Comparison of characteristic thermal forces before and after improvement

于 YOLOv8 与 YOLO-WM 训练模型特征的可视化热力图,其中高亮区域表示模型关注度高的区域。由图 9 可见,相较于 YOLOv8,改进后的模型显著降低了对背景值与相似地物的关注度,这表明本文算法能更准确地提取风车目标特征,在目标检测任务中减少误检情况。

## 4　结束语

高分影像为获取风车地理信息提供了条件,为实现风能资源的合理利用,需要更高效地提取风车目标。针对遥感影像小目标风车漏检与误检率高的问题,本文提出了 YOLO-WM 小尺度风车检测算法,构建了一个极小目标检测层并使用切片推理框架,减少了多层卷积导致的细节丢失;将双重动态注意力机制插入特征提取结构,提高了网络对目标特征的捕捉能力;使用 RepGhost 结构大幅度节省计算成本,在保证精度的同时提升算法效率,实现极小目标的精准检测。实验结果表明,本文算法有针对性地提升了小尺度风车的检测效果,为风电资源的评估与规划提供了重要参考,可进一步应用于风电场与其他要素的联合分析。此外,由于风电场选址的多样性,本文构建的风车样本集还未能全面地涵盖各种复杂的风车背景,尤其是在特殊拍摄角度下,风车仍存在漏检问题,因此后续考虑借助风车阴影及多源影像补充进一步提升检测效果。

**参考文献:**


[1] 肖超,安玮,李朝旭,等.天基光学遥感动目标智能检测技术综述[J].遥感学报,2024,28(7):1681-1692.

[2] 巢渊,刘文汇,唐寒冰,等.基于改进 YOLO-v4 的室内人脸快速检测方法[J].计算机工程与应用,2022,58(14):105-113.

[3] 才让当知,黄鹤鸣,范玉涛,等.基于双注意力 YOLOv5 的场景藏文检测[J].计算机工程与设计,2023,44(11):3411-3419.

[4] 黄远宪,周剑,黄琦,等.融合相机与激光雷达的目标检测、跟踪与预测[J].武汉大学学报(信息科学版),2024,49(6):945-951.

[5] Hu B,Liu Y,Chu P Z,et al. Small object detection via pixel level balancing with applications to blood cell detection [J]. Frontiers in Physiology,2022,13:911297.

[6] 曹健,陈怡梅,李海生,等.基于深度学习的道路小目标检测综述[J].计算机工程,2023,49(10):1-12.

[7] Zhang L J,Fang J J,Liu Y X,et al. CR-YOLOv8: Multiscale object detection in traffic sign images [J]. IEEE Access,2024,12:219-228.

[8] 孙佳宇,徐民俊,张俊鹏,等.优化改进 YOLOv8 无人机视角下目标检测算法[J].计算机工程与应用,2025,61(1):109-120.

[9] 毛云龙,葛睿,未行成,等.基于 YOLO-v7 改进的 SAR 图像舰船小目标检测方法[J/OL].电讯技术,https://doi.org/10.20079/j.issn.1001-893x.240515004.

[10] 李耀龙,陈晓林,林浩,等.DySnake-YOLO:改进的 YOLOv9c 电路板表面缺陷检测方法[J].计算机工程与应用,2025,61(3):242-252.

[11] 王国刚,肖峰,刘云鹏.FCDN:一种新的多重注意力机制的轻量化红外弱小目标检测算法[J].信息与控制,2025,54(2):336-352.

[12] Wang K,Zhou H,Wu H,et al. RN-YOLO: A small target detection model for aerial remote-sensing images [J]. Electronics,2024,13(12):2383.

[13] Yu X H,Gong Y Q,Jiang N,et al. Scale match for tiny person detection [A]. Proceedings of the 2020 IEEE Winter Conference on Applications of Computer Vision [C].Snowmass:IEEE,2020.1246-1254.

[14] 肖进胜,赵陶,周剑,等.基于上下文增强和特征提纯的小目标检测网络 [J]. 计算机研究与发展,2023,60(2):465-474.

[15] Terven J,Córdova-Esparza D-M,Romero-González J-A. A comprehensive review of YOLO architectures in computer vision: From YOLOv1 to YOLOv8 and

YOLO -NAS [J].Machine Learning and Knowledge Extraction,2023,5(4):1680-1716.

[16] Wang W,Tan X N,Zhang P,et al. A CBAM based multiscale transformer fusion approach for remote sensing image change detection [J].IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing,2022,15:6817-6825.

[17] Zhu L,Wang X J,Ke Z H,et al. BiFormer:Vision transformer with Bi -Level routing attention [A]. Proceedings of the 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition [C]. Vancouver:IEEE,2023.10323-10333.

[18] Zhou JL,Zhang YY,Wang J P. RDE -YOLOv7: An improved model based on YOLOv7 for better performance in detecting dragon fruit [J]. Agronomy,2023,13(4):1042.

[19] Zheng YC,Zhan YY,Huang X Y,et al. YOLOv5s FMG: An improved small target detection algorithm based on YOLOv5 in low visibility [J].IEEE Access,2023,11:75782-75793.

# An object detection algorithm for small-scale windmills

Bao Yilin[1], Hu Jinshan[1], Kang Jianrong[1], Zhu Yihu[2], Wang Shengli[2]

(1.School of Geography, Geomatics and Planning, Jiangsu Normal University, Xuzhou 221116, China; 2.Jiangsu Geologic Surveying and Mapping Institute, Nanjing 211102, China)

**Abstract**: Windmills are important facilities that convert wind energy into electrical energy. This paper addresses the issues of missed detections and false detections in the process of identifying small-scale windmills in remote sensing images by constructing a new GF-2 windmill dataset. It proposes the YOLO-WM algorithm for the small target detection task of windmills, adding a tiny object detection layer based on the YOLOv8 object detection algorithm, and incorporates a BSAM dynamic attention mechanism module in the backbone section. It replaces the C2f module with the lightweight C2f_RepGhost module and finally utilizes the SAHI slicing algorithm in the prediction stage to complete the windmill target detection task. Experimental results show that the YOLO-WM algorithm can better retain shallow convolutional features while reducing algorithm complexity, allowing for more accurate capture of small-scale target information. This method compensates for the shortcomings of small object detection datasets, and it has been verified that the improved algorithm performs better in detecting small-scale windmills than other algorithms. This research provides valuable insights for the rational optimization and allocation of wind energy resources and the joint analysis of geographical elements.

**Keywords**: windmills; deep learning; small target detection; YOLOv8; GF images