

## 复杂背景下输电线路缺陷检测算法研究

邬春明, 王调君

引用本文

邬春明, 王调君. 复杂背景下输电线路缺陷检测算法研究[J]. 计算机科学, 2024, 51(6A): 230500178-6.

WU Chunming, WANG Tiaojun. Study on Defect Detection Algorithm of Transmission Line in Complex Background [J]. Computer Science, 2024, 51(6A): 230500178-6.

---

### 相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

#### [基于SAMNV3的滚动轴承智能故障诊断方法](#)

Intelligent Fault Diagnosis Method for Rolling Bearing Based on SAMNV3

计算机科学, 2024, 51(6A): 230700167-6. <https://doi.org/10.11896/jsjx.230700167>

#### [基于LSTM和注意力机制的远程会诊需求预测](#)

Forecasting Teleconsultation Demand Based on LSTM and Attention Mechanism

计算机科学, 2024, 51(6A): 230800119-7. <https://doi.org/10.11896/jsjx.230800119>

#### [融入类别标签和主题信息的用户兴趣识别方法](#)

User Interest Recognition Method Incorporating Category Labels and Topic Information

计算机科学, 2024, 51(6A): 230500169-8. <https://doi.org/10.11896/jsjx.230500169>

#### [基于注意力的多尺度蒸馏异常检测](#)

Attention-based Multi-scale Distillation Anomaly Detection

计算机科学, 2024, 51(6A): 230300223-11. <https://doi.org/10.11896/jsjx.230300223>

#### [基于改进Deeplabv3+算法的滚珠丝杠驱动表面点蚀缺陷检测](#)

Detection of Pitting Defects on the Surface of Ball Screw Drive Based on Improved Deeplabv3+ Algorithm

计算机科学, 2024, 51(6A): 240200058-6. <https://doi.org/10.11896/jsjx.240200058>

# 复杂背景下输电线路缺陷检测算法研究

邬春明 王调君

东北电力大学电气工程学院 吉林 吉林 132012

(wuchunming@neepu.edu.cn)

**摘要** 输电线路定期巡检对保障电力系统安全稳定运行具有重要的意义。针对输电线路航拍图像背景复杂、目标尺度变化大、小目标多等问题,提出了基于YOLOv5s的输电线路目标检测算法。该算法采用特征细化模块优化微小目标特征,并在网络中嵌入SimAM注意力模块,通过能量函数统一权值的方式优化模型的特征提取,最后引入NWD损失函数削弱模型对小目标位置偏差的敏感性,提升模型对小目标的识别检测能力。实验结果表明,该模型对输电线路目标的平均检测精度高达98.8%,相较于基准模型,提高了1.2%。

**关键词**: 输电线路缺陷检测;注意力机制;NWD损失;特征细化

**中图分类号** TP391

## Study on Defect Detection Algorithm of Transmission Line in Complex Background

WU Chunming and WANG Tiaojun

College of Electrical Engineering, Northeast Electric Power University, Jilin, Jilin 132012, China

**Abstract** Regular inspection of transmission lines is of great significance to ensure the safe and stable operation of power systems. For the problems of complex background of transmission line aerial images, large changes in target scale and many small targets, a transmission line target detection algorithm based on YOLOv5s is proposed. The algorithm adopts feature refinement module to optimize tiny target features, and embeds SimAM attention module in the network to optimize the feature extraction of the model by means of unified weights of energy functions, and finally introduces NWD loss function to weaken the sensitivity of the model to small target position deviation and improve the recognition and detection ability of the model for small targets. Experimental results show that the average detection accuracy of the model for transmission line targets is as high as 98.8%, which is 1.2% higher compared with the benchmark model.

**Keywords** Transmission line defect detection, Attention mechanism, NWD loss, Feature refinement

### 1 引言

作为支撑国民经济的基础产业,电力系统的安全稳定运行具有重要的现实意义。为确保各产业电力供应的万无一失,电网公司需定期对输电线路进行巡视检查以保障电力系统安全稳定运行。据统计,近年来国家电网公司220kV及以上电压等级的电力系统故障中,由架空输电线路故障引起的非计划停运高达490次,占电力系统故障的43.86%<sup>[1]</sup>,且呈逐年增长的趋势。

随着我国输电线路里程不断增加,加之复杂地理地势气候环境的影响,工作时长、强度大的人工巡线方式<sup>[2]</sup>已无法满足当前的巡检需求,为此,高工作效率和高准确度的无人机巡检方式应运而生。输电线路图像检测往往有多种类型,根据图像类型的不同,分工不同。其中红外图像常用于检测电力设备温度是否异常,激光雷达图像主要用于传输线路上非法建筑或树木障碍物的检测,光学图像主要检测输电线路传输部件是否异常,如防震锤锈蚀、杆塔鸟窝、绝缘子缺陷等,上述部件隐患随时可能造成输电线路故障、跳闸,甚至威胁整个电力系统的运行。数据显示,2016—2021年间,铁塔鸟窝和绝缘子是引起220kV及以上架空线路非计划停运次数较多

的前两位部件因素,且平均停运时间分别高达62.273小时/次、10.092小时/次<sup>[1]</sup>。因此,本文主要对杆塔鸟窝和绝缘子缺陷部件进行检测。

### 2 相关工作

早期的输电线路部件识别需人为手工设计提取目标特征,并将特征送往分类模型进行有效识别,但其适用场景单一,不够灵活。由于深度学习模型具有良好的背景适应性和灵活、优秀的检测能力,已成为输电线路目标检测的热点。

高精度的RCNN<sup>[3]</sup>系列网络一经提出,就受到研究人员的广泛关注。为更好地进行输电线路部件检测,不少研究人员在两阶段的RCNN系列网络的基础上,采用特征金字塔(Feature Pyramid Network, FPN)网络<sup>[4-6]</sup>和其他特征融合方式<sup>[7-9]</sup>来适应输电线路航拍图像中目标的多尺度变化,提高小目标的检测精度,并在此基础上,结合区域选择策略(Region Proposal Network, RPN)网络<sup>[10-11]</sup>代替选择性搜索,提高网络检测速度。随后,研究人员从感兴趣区域(Region of Interest, ROI)的角度出发,采用双线性插值<sup>[12]</sup>和深度可分离卷积(Depthwise Separable Convolution, DSC)<sup>[13]</sup>来放大区域几何细节,实现绝缘子和螺栓的检测。

高检测速度的 YOLO(You Only Look One)<sup>[14]</sup> 系列往往应用在对实时性有要求的场景中。同时,为了兼顾精度,文献[15]引入特征融合、文献[16]采用平行卷积头和卷积神经网络共同定位故障区域,文献[17]通过将 DenseNet 和多集映射模块相结合的方式获取丰富的上下文层网络信息,实现了不同背景干扰下的绝缘子检测,但其网络运行时间高于 YOLOv3。随后,该研究团队采用轻量级 TINY-YOLO 网络<sup>[18]</sup>,并结合多尺度检测和空间金字塔池(SPP)实现多尺寸目标的检测。随后,研究人员通过建立丰富数据集<sup>[19]</sup>、设计自动生成的数据标注<sup>[20]</sup>,以及利用 K-means 聚类算法<sup>[21]</sup>设计锚框过滤机制等方式实现线路输电线路部件检测。

综上,现有的输电线路部件缺陷检测研究多集中在绝缘子、螺栓的检测上,且大多只针对一个目标种类进行检测,因此往往会针对目标的某种特征来设计数据标注、特征提取网络。其次,已有的检测算法对输电线路缺陷尺寸差异大、小目标多等问题不能很好解决<sup>[22]</sup>。针对上述问题,本文提出了适用于输电线路缺陷检测网络,以实现绝缘子缺陷、鸟窝以及正常绝缘子 3 类目标的检测。该方法为进一步改进 YOLOv5s 模型对小目标的检测能力,引入了一种特征细化模块 FRM 来精细化微小目标特征,以解决输电线路缺陷小目标特征容易被忽略的问题;利用注意力机制监督模型训练过程,提高模型检测精度;引入 NWD 损失函数,以解决模型对小目标位置偏差的敏感性,提高模型对小目标的识别检测能力。

### 3 方法介绍

#### 3.1 特征细化网络

YOLOv5 以其良好的检测速度和精度受到各界研究人员的青睐,其在 Neck 部分采用 FPN<sup>[23]</sup> 与 PAN<sup>[24]</sup> 相结合的方式实现多尺度目标检测。二者均使用层次结构,不同的是,FPN 自顶向下采样传递高层语义信息,PAN 自底向上采样传递目标定位信息,进而实现不同主干层对不同检测层的参数聚合。FPN 与 PAN 相结合的方式优化了网络对多尺度目标的检测,但直接融合不同尺度特征的操作忽略了不同特征之间的语义差,同时冗余的信息冗余和矛盾信息降低了多尺度表达能力。为改善上述情况,本文提出了一种特征细化网络优化特征金字塔网络,其整体结构图如图 1(a)所示。

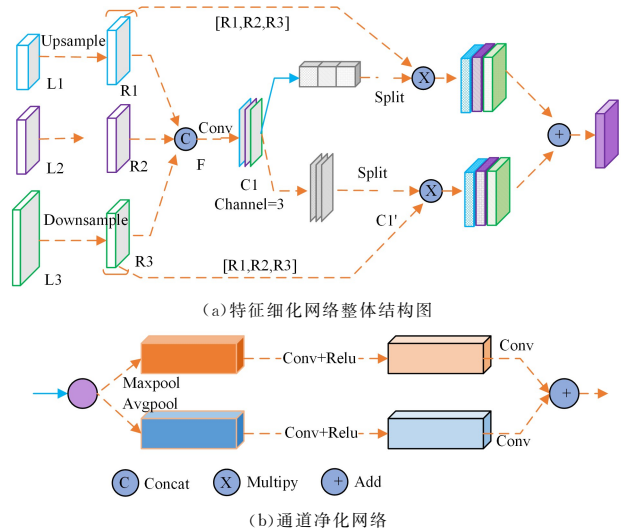


图 1 特征细化网络结构图

该网络由上、下两个并行分支组成,分别从通道和空间两个维度优化小目标特征提取,滤除不必要的信息以防冲突信息淹没掉微小目标特征。上分支的通道净化部分将网络输入特征聚合成可代表图像全局特征的空间信息,随后采用自适应最大池化和平均池化模块不断修正细化全局特征,使其能更精准地表达图像中的小目标信息,如图 1(b)所示。

$$\mathbf{K}_{x,y}^m = a^m \cdot \mathbf{X}_{x,y}^{1,m} + b^m \cdot \mathbf{X}_{x,y}^{2,m} + c^m \cdot \mathbf{X}_{x,y}^{3,m} \quad (1)$$

其中, $\mathbf{K}_{x,y}^m$ 表示该分支在第  $m$  层位置  $(x, y)$  处的输出向量。 $a, b, c$  分别为各特征通道的自适应权重,其大小均为  $1 \times 1 \times 1$ ,具体定义如式(2)所示

$$[a^m, b^m, c^m] = \sigma(AP(F) + MP(F)) \quad (2)$$

其中, $F$ 表示通过 Concat 操作生成的特征, $\sigma$ 表示 Sigmoid 激活函数, $AP$ 和  $MP$ 分别表示平均池化和最大池化。Sigmoid 函数将精细化后的特征处理后生成通道的自适应权重。

下分支的空间净化部分原理比较简单,借助 Softmax 操作直接生成各位置相对于通道的权重,引导特征向更关键的方向学习。

$$\phi_{x,y}^m = \sum_{c=1}^3 \sum_{k,x,y} \mu_{c,x,y}^m \cdot \mathbf{X}_{k,x,y}^{(1,m)} + \nu_{c,x,y}^m \cdot \mathbf{X}_{k,x,y}^{(2,m)} + \eta_{c,x,y}^m \cdot \mathbf{X}_{k,x,y}^{(3,m)} \quad (3)$$

其中, $(x, y)$ 为特征图的空间位置, $k$ 为输入特征通道, $\phi_{x,y}^m$ 表示该分支在第  $m$  层位置  $(x, y)$  处的输出向量。

同理,该分支采用 Softmax 操作将聚合特征映射  $F$  在通道方向上进行归一化处理,得到同一位置不同通道的相对权重,如式(4)所示:

$$[\mu^m, \nu^m, \eta^m] = \text{Softmax}(F) \quad (4)$$

最后,将两个分支的特征输出聚合形成网络总的特征输出。

$$\mathbf{P}^m = \mathbf{K}^m + \phi^m \quad (5)$$

空间和通道双维度引导特征可更全面地引导特征向更关键、更重要的方向学习,以此来优化小目标特征提取,防止其被大量的冲突信息淹没。

#### 3.2 SimAM 注意力

YOLOv5s 将通过 3 个检测通道来实现图像目标的多尺度检测,但在实际检测过程中,不同通道和位置的特征输出大小不同,对应的各通道的重要性不同,针对不同的检测需求,我们根据目标特征引入注意力机制强调其重要性。不同的注意力承担不同的功能,一维通道注意力通过调整通道权重区别不同通道,二维空间注意力机制区别对待不同的空间位置。现有的 CBMA 网络并行或串行地将空域注意力和通道注意力组合,以实现两个维度重要性强调,人脑注意力一般是两种注意力协同工作,为此,引入模仿人脑注意力的统一权值的 SimAM<sup>[25]</sup>来强调重要特征层输出特征,其网络结构如图 2 所示。




图 2 SimAM 注意力

图 2 SimAM attention mechanism

Fig. 1 Diagram of feature refinement network structure

神经科学理论中,含有丰富信息的活跃神经元与其他周围神经元呈现的放电方式不同,同时活跃神经元会抑制周围神经元的活动,即重要神经元往往具有较为明显的空间抑制效应。一般会通过测量一个目标神经元和其他神经元之间的线性可分离性寻找重要神经元。首先,为每个神经元定义一个能量函数,如式(6)所示:

$$e_t(\omega_t, b_t, y, x_i) = (y - \hat{t})^2 + \frac{1}{M-1} \sum_{i=1}^{M-1} (y_0 - \hat{x}_i)^2 \quad (6)$$

其中,  $\hat{t} = \omega_t t + b$  为目标神经元,通过更新  $\omega_t$  和  $b$  更新目标函数;  $\hat{x}_i = \omega_t x_i + b_t$  为周围其他神经元,  $i$  为空间维度;  $M$  代表通道上的神经元数量。

随后,为简化运算,采用二值化标签和正则项分别优化  $y_t$  和  $y_0$ ,得到最终的能量函数方程,如式(7)所示:

$$e_t(\omega_t, b_t, y, x_i) = \frac{1}{M-1} \sum_{i=1}^{M-1} (-1 - (\omega_t x_i + b_t))^2 + (1 - (\omega_t + b_t))^2 + \lambda \omega_t^2 \quad (7)$$

理论上每个通道均有  $M$  个能量函数,而该函数的求解依赖于一些迭代优化器,如 SGD。但式(7)采用更新  $\omega_t$  和  $b$  的方式找到更简单、快速的优化方案,通过求解除  $t$  以外的所有神经元的均值和方差进行函数更新,如式(8)、式(9)所示:

$$\omega_t = -\frac{2(t - \mu_t)}{(t - \mu_t)^2 + 2\sigma_t^2 + 2\lambda} \quad (8)$$

$$b_t = -\frac{1}{2}(t + \mu_t)\omega_t \quad (9)$$

假定各单通道中所有像素采用同一种像素分配策略,则式(8)、式(9)所示的均值和方差可用于所有神经元。此时,神经元之间的线性可分性可由能量函数最小化得到,如式(10)所示:

$$e_t^* = \frac{4(\hat{\sigma}^2 + \lambda)}{(t - \hat{\mu})^2 + 2\hat{\sigma}^2 + 2\lambda} \quad (10)$$

其中,  $\hat{\mu} = \frac{1}{M} \sum_{i=1}^M x_i$ ,  $\hat{\sigma}^2 = \frac{1}{M} \sum_{i=1}^M (x_i - \hat{\mu})^2$ 。

分析式(10)可知,能量函数值越小,神经元  $t$  与周围神经元间的差异越大,其重要性越高,即其重要性为最小能量函数值的倒数  $1/e_t^*$ 。挖掘完神经元能量函数后需将所有神经元的能量值相加,并对集合  $E$  中能量值进行相应的特征增强处理。值得注意的是,该特征增强过程采用 Sigmoid 可限制  $E$  中过大值,不会对神经元之间的相对重要性产生影响,如式(11)所示:

$$\hat{\mathbf{X}} = \text{Sigmoid}\left(\frac{1}{E}\right) \odot \mathbf{X} \quad (11)$$

此外,现有的注意力模块需要借助额外的子网络来生成注意力权重,该过程会给网络带来一定的参数量和网络开销。而 SimAM 主要以能量函数统一权重,无需额外的子网络生成权重,所以并不会增加网络参数和开销。

### 3.3 改进损失函数

损失函数可反映模型的性能,一个好的损失函数对网络训练具有很好的正向作用。输电线路数据集中各部件目标都有自己的形态特征,不是严格意义上的矩形,因此,其矩形边界框中往往会包含一些与检测对象特征无关的前景、背景信息。原 YOLOv5 模型使用的 CIoU 边界框损失函数虽能在  $P \cap G = 0$  和  $P \cap G = P$  或  $G$  时提供梯度信息,但其对小尺寸目标的位置偏差比较敏感,不能很好地消除小尺寸目标预测

框和真实框之间的差距。因此,本文引入基于 Wasserstein 距离的 NWD<sup>[26]</sup> 损失衡量预测框与真实框之间的相似性,消除预测框与真实框之间的性能差距。

为了更好地描述包围框中不同像素的权重,将边界框建模为二维高斯分布,其中边界框中心的像素权重最高,其余像素重要性由中间到边界逐渐降低。对于某一边界框  $R$ ,其中中心像素点坐标为  $(c_x, c_y)$ ,则该边界框中的内切椭圆方程为:

$$\frac{(x - \mu_x)^2}{\sigma_x^2} + \frac{(y - \mu_y)^2}{\sigma_y^2} = 1 \quad (12)$$

并由此可得边界框内像素点的二维高斯分布函数。

$$f(x|\mu, \Sigma) = \frac{\exp\left(-\frac{1}{2}(x - \mu)^\top \Sigma^{-1}(x - \mu)\right)}{2\pi |\Sigma|^{\frac{1}{2}}} \quad (13)$$

其中,  $\mu$  和  $\Sigma$  为高斯分布的均值和方差。

对于两个边界框  $A$  和  $B$ ,每个边界框之间各不相同但具有一定的相似性,其相似性可由左右传输理论中的 Wasserstein 距离衡量。

$$\begin{aligned} W_{\frac{1}{2}}(\mu_1, \mu_2) &= \|\mu_1 - \mu_2\|_2 + \text{Tr}(\Sigma_1 + \Sigma_2 - \\ & 2(\Sigma_1^{1/2} \Sigma_2 \Sigma_1^{1/2})^{1/2}) \\ &= \|\mu_1 - \mu_2\|_2 + \|\Sigma_1^{1/2} + \Sigma_2^{1/2}\|_F^2 \end{aligned} \quad (14)$$

CIoU 损失在  $(0, 1)$  范围内变化以衡量预测边界框和真实框之间的损失。对上述概率分布距离度量进行指数型归一化处理,如式(15)所示:

$$\text{NWD}(N_a, N_b) = \exp\left(-\frac{\sqrt{W_{\frac{1}{2}}(N_a, N_b)}}{C}\right) \quad (15)$$

式(15)中的常数  $C$  与数据集密切相关,分析并统计数据集中不同尺寸目标的数据分布来确定常数  $C$  的大小。本文根据输电线路数据集的特点,将常数  $C$  设为 0.5。

基于 Wasserstein 距离的回归损失如式(16)所示:

$$L_{\text{NWD}} = 1 - \text{NWD}(N_p, N_g) \quad (16)$$

其中,  $N_p$  为预测框  $P$  的二维高斯分布,  $N_g$  为目标真实框  $g$  的高斯分布。

## 4 实验结果与分析

### 4.1 数据集

由于本课题实验研究的任务是面向电力系统输电线路检修场景的,加之电网系统的保密性原则,目前网络上没有公开的输电线路数据集。因此,本课题组研究团队根据国网公司提供的输电线路无人机航拍图像,建立了一个具有高质量监督信息的数据集以验证本课题研究方案。该自制输电线路数据集共包含 5365 张图片,分辨率多为  $5472 \times 3648$  像素,涵盖绝缘子、鸟窝、杆塔等典型的电力线路部件。在实验前需对数据集进行整理并用 LabelImg 进行标记,具体的数据集示例如图 3 所示。




图 3 输电线路数据集示例

Fig. 3 Example of a transmission line dataset

## 4.2 实验环境及训练参数

本课题数据集为航拍图像,需运用 GPU 进行实验加速训练,其所需实验配置如表 1 所列。

表 1 实验配置  
Table 1 Experimental configuration

项目	内容
CPU	Intel(R) Xeon(R) Silver 4110 CPU @ 2.10 GHz
RAM	16 GB
GPU	NVIDIA GeForce RTX 3090
Python 框架	Python 3.8
Pytorch	1.8.1
Cuda	11.1

本课题模型训练过程基于 Pytorch 深度学习框架,采用 SGD 优化器,设置 batch\_size 为 16,将数据集按 9:1 的比例分为训练集和验证集,动量参数设置为 0.9,权值衰减系数设为 0.0005,初始学习率设置为 0.01,设置总训练轮数为 100。

## 4.3 实验评价指标

本文采用平均检测精度 (mAP) 和检测速度 FPS 共同衡量分类回归模型的整体性能,具体如式(17)、式(18)所示:

$$mAP = \frac{\sum_{i=1}^k AP_i}{k} = \frac{\sum_{i=1}^k \int_0^1 P(r) dr}{k} \quad (17)$$

$$FPS = 1.0 / \left( \frac{TotalTime}{FrameCount} \right) \quad (18)$$

网络模型的速度与硬件设施、网络层数和激活函数等参数相关。在同一硬件条件下,不同模型对图像的处理速度不同,图像所需的浮点数越小,同一时间模型处理图像的数量会越多,帧率也会随之增大。

## 4.4 检测性能对比分析

损失函数衡量预测值与真实值之间的差距,因此,本文首先对模型改进前后的损失值进行对比分析,如图 4 所示。

图 4 展示了模型改进前后的训练损失曲线,其中实线代表本文方法的训练损失函数值变化,虚线代表基准 YOLOv5s 的训练损失函数值的变化。图像显示,在模型训练初期,本文方法损失函数收敛速度略慢于基准的 YOLOv5s 模型,但在训练轮数达到 75 以后,两个模型的收敛速度趋于一致,并在损失值达到 0.03 左右趋于收敛。

表 2 消融实验分析

Table 2 Analysis of ablation experiments

YOLOv5s	特征细化	SimAM	NWD	AP/%			mAP/%	FPS/(帧/s)	参数量
				绝缘子	缺陷绝缘子	杆塔鸟窝			
✓				96.30	97.90	98.60	97.60	<b>131</b>	<b>7018216</b>
✓	✓			97.70	98.50	99.30	98.50	118	7034774
✓		✓		97.00	98.40	99.00	98.30	128	7018216
✓			✓	97.30	98.30	99.10	98.20	121	7018216
✓	✓	✓	✓	97.60	98.70	99.30	<b>98.80</b>	105	7034774

表 2 从各个目标的检测精度、所有目标的平均检测精度、FPS、参数量 4 个角度出发,进行消融实验,分析对比本文提出的检测模型中各成分的重要性。从所有类别间的平均检测精度来看,特征细化网络、转置卷积、SimAM 分别将基准方法改进了 0.9,0.7 和 0.6 个 mAP,从各目标的检测精度 AP 来看,不同改进方案对不同目标检测效果的影响不同,但总体检测效果还是呈现上升趋势。与此同时,改进模型检测精度的提高付出的代价是模型检




图 4 改进前后损失函数对比图

Fig. 4 Comparison of loss function before and after improvement

为了更直观地展示本文提出模型的有效性,将基准模型 YOLOv5s 与本文提出模型在同一张图像中的检测效果进行对比,如图 5 所示。




图 5 同一图片不同模型视觉效果对比图

Fig. 5 Visual effect comparison of different models in the same picture

在图 5 中,(a)为 YOLOv5s 的检测效果,(b)为本文方法的检测效果图。YOLOv5s 对数据集中部分图像目标存在一定的误检、漏检情况,本文方法均可正确检测。而 YOLOv5s 可以正确检测出的目标,本文方法均可正确检测,且能够得到更加精确的包围框和较高的分类得分。因此,本文检测模型在输电线路目标检测中效果更佳,检测性能有所提升,能更好地应用于实际输电线路巡检任务。

为了验证本文提出的各改进方案的有效性,我们逐步将特征细化模块、SimAM 注意力和 NWD 损失函数应用到基准模型 YOLOv5s 中,进行消融实验分析,结果如表 2 所列。

测速度的降低和参数量的增加,但仍能满足实时检测的要求。

为了验证本文方法的优越性,将本文改进的模型与一阶段检测模型 SSD、Center-Net 和两阶段的 Faster RCNN 实验结果进行对比,其结果如表 3 所列。表 3 数据显示,本文方法在正常绝缘子、缺陷绝缘子和杆塔鸟窝目标上的检测精度分别提高了 2.04%,1.43%和 0.11%,所有类别平均 AP 提高了 1.2%。

表3 同一数据集在不同模型下的检测效果

Table 3 Detection effects of the same dataset in different models

模型	主干网络	AP/%			mAP/%
		杆塔鸟窝	缺陷绝缘子	绝缘子	
SSD <sup>[27]</sup>	VGG-16	90.78	91.64	89.43	90.62
Faster RCNN <sup>[28]</sup>	VGG-16	91.19	91.87	90.74	91.27
Center-Net <sup>[29]</sup>	ResNet-50	91.72	92.87	92.19	92.26
YOLOv5s	CSPDarknet-53	98.60	97.90	96.30	97.60
Ours	CSPDarknet-53	99.30	98.70	97.60	98.80

由于输电线路所处地理环境的多样性,检测模型需要适应不断变化的环境背景。图6展示了模型在农田、森林、阴天、荒地、水域和阳光曝晒6类背景下对目标的识别检测效果。

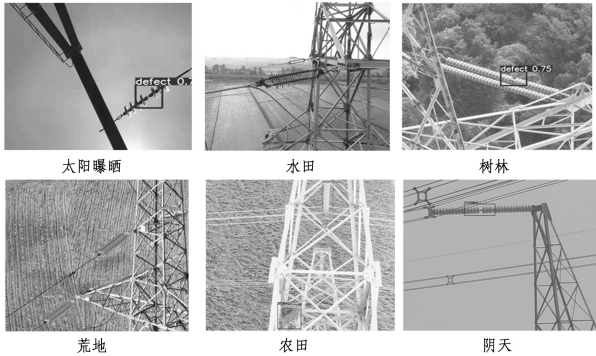


图6 不同背景下的检测效果

Fig. 6 Detection effects in different backgrounds

由图6可以看出,本文检测模型在复杂多变的环境下均能检测出目标,对于复杂背景有很好的适应能力,且在大部分场景下都能获得很好的分类函数,但面对小部分阴影较大、目标类内类间严重遮挡的情况时,其虽能检测出目标,但置信度分数表现不佳,总体来说取得了很好的效果。本文检测模型适应能力强且具有较高的检测精度,对实际输电线路监测系统的发展具有重要意义。

**结束语** 目标检测模型的高精度和快速实时性对输电线路智能巡检具有重要的现实意义。本文提出的基于改进YOLOv5s的输电线路缺陷目标检测算法通过特征细化网络和基于 Wasserstein 距离的 NWD 损失共同优化模型对小目标的识别检测能力,随后引入无参数的 SimAM 注意力机制从通道和空间两个维度强调重要特征通道。实验结果表明,该方法能有效检测复杂环境下的鸟巢、绝缘子缺陷目标,检测精度高达 98.8%,但仍存在一定的漏检、误检。理想的检测状态是无误检、漏检情况的发生,在实际的电网系统中,通常不希望有漏检,但允许一定程度的误检。因此,为确保高压、特高压输电线路安全稳定运行,还需巡检人员对检测监控画面进行一定的核验和复查。未来,将在不降低检测精度的同时优化检测速度,以实现实时性检测并将模型部署到嵌入式移动设备中。

参考文献

[1] National Energy Administration. 2016-2021 National Power Reliability Annual Report [R]. <http://prpq.nea.gov.cn/ndbg/8540.htm>.  
 [2] CHEN K, LIU X, JIA L J, et al. Insulator defect detection based on lightweight network and enhanced multi-scale feature fusion [J]. High Voltage Technology, 2013; 1-14.

[3] ZHOU M, WANG J, LI B. ARG-Mask RCNN: An Infrared Insulator Fault-Detection Network Based on Improved Mask RCNN [J]. Sensors, 2022, 22(13): 4720.  
 [4] ZHAO W Q, XU M F, CHENG X F, et al. An insulator in transmission lines recognition and fault detection model based on improved Faster RCNN [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 5016408.  
 [5] CHEN Y Q, WANG H X, SHEN J, et al. Application of Data-Driven iterative learning algorithm in transmission line defect detection [J]. Scientific Programming, 2021, 2120 (Pt 3): 9976209. 1-9976209. 9.  
 [6] LI H, DONG Y, LIU X, et al. Abnormal target detection method for transmission lines based on two-stage deep network [J]. Control and Decision, 2022, 37(7): 1873-1882.  
 [7] GAO Z, YANG G, LI E, et al. Novel feature fusion module-based detector for small insulator defect detection [J]. IEEE Sensors Journal, 2021, 21(15): 16807-16814.  
 [8] XIAO Y, LI Z, ZHANG D, et al. Detection of pin defects in aerial images based on cascaded convolutional neural network [J]. IEEE Access, 2021, 9: 73071-73082.  
 [9] ZHAO Z B, QI H Y, QI Y C, et al. Detection method based on automatic visual shape clustering for pin-missing defect in transmission lines [J]. IEEE TRANSACTIONS ON INSTRUMENTATION AND MEASUREMENT, 2020, 69(9): 6080-6091.  
 [10] TAO X, ZHANG D P, WANG Z H, et al. Detection of power line insulator defects using aerial images analyzed with convolutional neural networks [J]. IEEE Transactions on Systems Man Cybernetics-Systems, 2020, 50(4): 1486-1498.  
 [11] LI F, XIN B, CHEN T, et al. An Automatic Detection Method of Bird's Nest on Transmission Line Tower Based on Faster RCNN [J]. IEEE Access, 2020, 8: 164214-164221.  
 [12] WEN Q D, LUO Z Q, CHEN R T, et al. Deep learning approaches on defect detection in high resolution aerial images of insulators [J]. Sensors, 2021, 21(4): 1033.  
 [13] HE H, LI Y C, YANG J, et al. Pin-missing defect recognition based on feature fusion and spatial attention mechanism [J]. Energy Reports, 2022, 8: 656-663.  
 [14] XU S Y, DENG J C, HUANG Y R, et al. Research on insulator defect detection based on an improved mobilenetV1-YOLOv4 [J]. Entropy, 2022, 24(11): 1-18.  
 [15] ZHENG H B, SUN Y H, LIU X H, et al. Infrared image detection of substation insulators using an improved fusion single shot multibox detector [J]. IEEE Transactions on Power Delivery, 2021, 36(6): 3351-3359.  
 [16] LIU X Y, MIAO X R, JIANG H, et al. Box-Point detector: A diagnosis method for insulator faults in power lines using aerial images and convolutional neural networks [J]. IEEE TRANSACTIONS ON POWER DELIVERY, 2021, 36(6): 3765-3773.  
 [17] LIU C Y, WU Y Q, LIU J J, et al. Improved YOLOv3 network for insulator detection in aerial images with diverse background interference [J]. Electronics, 2021, 10(7): 771-791.  
 [18] LIU C Y, WU Y Q, LIU J J, et al. MTI-YOLO: A light-weight and real-time deep neural network for insulator detection in complex aerial images [J]. Energies, 2021, 14(5): 1426-1446.  
 [19] SHI C X, HUANG Y P. Cap-Count guided weakly supervised insulator cap missing detection in aerial images [J]. IEEE Sen-

- sors Journal, 2021, 21(1) 685-691.
- [20] ZHANG J, WANG J Y, ZHANGS H. An ultra-lightweight and ultra-fast abnormal target identification network for transmission line [J]. IEEE Sensors Journal, 2021, 21 (20): 23325-23334.
- [21] LIU J, JIA R, LI W, et al. High precision detection algorithm based on improved RetinaNet for defect recognition of transmission lines [J]. Energy Reports, 2020, 6: 2430-2440.
- [22] WANG C Y, YUAN H, WU H Y, et al. CSP-Net: A new backbone that can enhance learning capability of cnn [C] // Proceedings of the IEEE Conference on Computer Vision and Patten. IEEE, 2020.
- [23] LIN T Y, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Norway, 2017: 2117-2125.
- [24] LIU S, QI L, QIN H F, et al. Path aggregation network for instance segmentation [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Norway, 2018: 8759-8768.
- [25] YANG L, ZHANG R Y, LI L, et al. SimAM: A Simple, Parameter-Free Attention Module for Convolutional Neural Networks [C] // International Conference on Machine Learning. PMLR, 2021.
- [26] WANG J W, XU C, YANG W, et al. A Normalized Gaussian Wasserstein Distance for Tiny Object Detection [C] // Computer Vision and Pattern Recognition (CVPR). 2022.
- [27] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single Shot MultiBox Detector [C] // European Conference on Computer Vision. Cham: Springer, 2016.
- [28] NI H, WANG M, ZHAO L. An improved Faster R-CNN for defect recognition of key components of transmission line [J]. Mathematical Biosciences and Engineering: MBE, 2021, 18(4): 4679-4695.
- [29] XIA H Y, YANG B H, LI Y L, et al. An improved CenterNet model for insulator detection using aerial imagery [J]. Sensors, 2022, 22(8): 1-17.



**WU Chunming**, born in 1966, master, professor. His main research interests include image processing and deep learning.



**WANG Tiaojun**, born in 1998, master. Her main research interest is defect detection of transmission line components.