文章编号：1674-0629(2026)09-0089-10 中图分类号：TM755 文献标志码：A
DOI：10.13648/j.cnki.issn1674-0629.2026.09.008

融合全维动态卷积与聚焦调制网络的输电线路防振锤缺陷检测模型

蔡智雯，邱志斌，陈瑞婷
（南昌大学能源与电气工程系，南昌 330031）

摘要：在输电线路防振锤缺陷检测中，常常面临缺陷样本不平衡、环境背景复杂以及防振锤尺寸较小等挑战。基于此，提出了一种用于输电线路防振锤缺陷检测的FSO-YOLO模型。在YOLOv8s的主干和颈部结构中引入全维动态卷积模块(omni-dimensional dynamic convolution，ODConv)，增强了算法对小目标缺陷特征提取和融合的能力；在模型中加入聚焦调制网络(focal modulatoin network，FMNet)，提高了模型聚焦关键区域的识别能力；使用样本加权函数Slideloss取代原分类损失函数，以缓解样本不均衡问题。实验结果表明所提出的FSO-YOLO模型能够有效检测输电线路防振锤缺陷，平均精度均值(mean average precision，mAP)可达95.3 %，浮点计算量(floating point operations，GFLOPs)比原模型降低了32 %，检测速度(frames per second，FPS)为51帧/s，可以更加快速精准地定位识别缺陷。
关键词：输电线路；深度学习；防振锤；缺陷检测；YOLOv8s

Transmission Line Damper Defect Detection Model Integrating Full-Dimensional Dynamic Convolution and Focus Modulation Network

CAI Zhiwen, QIU Zhibin, CHEN Ruiting
(Department of Energy and Electrical Engineering, Nanchang University, Nanchang 330031, China)

Abstract: In the defect detection of dampers for transmission lines, practitioners often face challenges such as imbalanced defect datasets, complex environmental backgrounds, and the small size of these dampers. To address these issues, this paper proposes a FSO-YOLO model specifically designed for the defect detection of transmission line dampers. The FSO-YOLO model integrates an omni-dimensional dynamic convolution (ODConv) module into the backbone and neck architectures of YOLOv8s to enhance the algorithm's capability in extracting and fusing features of small-scale defect targets; a focal modulation network (FMNet) is incorporated, and the model's ability to focus on and recognize key areas is enhanced; furthermore, a sample weighting function named Slideloss is employed to replace the original classification loss function, thereby mitigating the problem of sample imbalance. Experimental results demonstrate that the proposed FSO-YOLO model is effective in detecting defects in transmission line dampers, achieving an average accuracy (mAP) of 95.3 %, reducing the floating-point operations (GFLOPs) by 32 % compared to the baseline model, and achieving a detection speed of 51 frames per second (FPS), enabling faster and more accurate localization and identification of defective targets.
Key words: transmission line; deep learning; damper; defect detection; YOLOv8s

0 引言

防振锤在输电线路中可以有效抑制线路因风力振动产生的导线断股、金具破坏等危害[1]。但防振锤长期处在野外环境中，易引发缺损、腐蚀、移位相撞等缺陷，已有统计数据显示运行中的输电线路防振锤完好率仅为74 %，缺陷率高达26 %。例如衡水供电公司所辖3 300 km高压输电线路每年仅地

基金项目：国家自然科学基金资助项目(52167001)；江西省“双千计划”创新领军人才长期(青年)项目(jxsq2019101071)。
Foundation item: Supported by the National Natural Science Foundation of China (52167001); the Innovative Leading Talents Long-Term Project of Jiangxi “Double Thousand Plan” (jxsq2019101071).

线防振锤移位缺陷就达10余起，若不及时处理会进一步引发导地线断线或接地跳闸的重大事故；国内学者研究指出，高压输电线上的防振锤长期经受各种恶劣自然条件影响，容易出现重锤坠落、锈蚀、移位等问题，缺损锈蚀的防振锤会大幅降低防振性能，增加导线疲劳断股的风险，严重阻碍输电线路的正常运行[2]。因此，需要定期对输电线路防振锤进行安全巡检消除其潜在隐患[3-4]。近年来无人机在输电线路巡检任务应用广泛逐渐成了了电网部门巡检的主流方式[5-7]。而无人机巡检势必会采集海量图像，由于防振锤在无人机拍摄的图像中占比较小，且单张图像中往往存在多个防振锤标注目标，人工查找并标注缺陷位置容易造成视觉疲劳，从而导致错检或漏检，亟需开展智能化的防振锤识别与缺陷检测技术研究[8-9]。

随着计算机视觉技术的快速发展[10-11]，利用深度学习算法对输电线路上关键部件缺陷进行自动识别已成为电网智能巡检的发展方向[12-14]。文献[15]改进了YOLOv5算法的结构与损失计算机制，可有效提升输电线路中绝缘子故障识别的准确率，多个相关研究均验证了这一结论：针对输电线路绝缘子检测任务改进的YOLOv5算法，实验结果显示其对绝缘子的检测准确率可达99.4 %；面向绝缘子缺陷检测改进的YOLOv5算法，在公开数据集上的检测精度达到95.0 %，相比原YOLOv5算法提升了2.5 %；另一种结合轻量化改进的YOLOv5算法针对包含绝缘子缺陷的数据集测试中mAP值可达85.9 %，可实现绝缘子破损等故障的实时检测。文献[16]针对输电线路耐张线夹压接缺陷检测任务，在YOLOX网络模型中加入空间、通道卷积注意力机制对网络进行改进，最终实现了对输电线路耐张线夹压接缺陷准确高效的检测与识别，还提升了对细微缺陷的检测效果。文献[17]在研究输电线路不同覆冰类型的检测中将弱监督和分段迁移学习的方法应用于YOLOv5网络。文献[18]引入全维动态卷积ODConv对YOLOv5网络进行了改进，对输电线路鸟巢进行检测，在提升了检测能力的同时使模型更加轻量化。已有相关研究表明，ODConv能够在卷积核的4个维度引入多维度注意力机制动态调整卷积权重，可作为常规卷积的替代品平衡模型精度与效率，在各类CNN架构中应用均能实现性能提升，同时还能减少额外参数量，实现模型的轻量化。在ImageNet和MS-COCO等公开数据集的大量实验也证实ODConv可以为各类主流CNN主干网络带来可靠的精度提升。文献[19]设计了一种全新的两阶段检测算法，将Faster R-CNN中的后处理程序换为了Soft-NMS，对输电线路小目标进行检测。相较于其他电力设备，针对输电线路防振锤缺陷的智能识别已有少量研究，例如，文献[20]针对输电线路金具检测中目标相互遮挡导致定位不准的问题，在SSD模型引入嵌入遮挡关系模块，增加了包括防振锤在内的金具定位框的识别准确度，但是对于缺陷的判断效果难以尽如人意。文献[21]在Faster R-CNN算法的基础上建立了多种设备缺陷检测模型，但没有对防振锤的缺陷类别进行细化，同时，受基础Faster R-CNN本身特性限制，缺陷检测精度也没有得到很好的改善。现有同方向研究已经证实，通过对Faster R-CNN引入改进模块，可以有效提升设备缺陷检测的精度，例如针对变电站设备缺陷检测的研究显示，引入哈希辅助分支改进Faster R-CNN后，能够抑制背景区域干扰，有效提高检测精度；针对圆柱形金属工件表面缺陷检测的研究显示，优化特征提取方式的Faster R-CNN在置信度阈值为0.9时，查全率可达95.0 %，查准率可达96.0 %，具备良好的检测效果。文献[22]在YOLOv4的基础上引入空间注意力机制进行防振锤缺陷检测，现有研究也已证实在YOLO系列检测模型中引入改进空间注意力机制可有效提升小目标缺陷的检测召回率，仅在计算开销增加3 %的条件下就能将模型平均精度提升4.2 %，目前基于深度学习的防振锤缺陷检测模型可达到90.7 %的训练精度与91.0 %的训练召回率，但文献[22]改进后的模型仅能检测防振锤正常及缺陷等3类情况，检测类别覆盖范围仍有局限。深度学习算法具有较强的图像特征提取与目标定位能力，但目前输电线路防振锤的缺陷检测仍不够细致。

针对上述问题，本文构建了4类输电线路防振锤及其缺陷的图像数据集；利用YOLOv8s目标检测算法建立了FSO-YOLO防振锤缺陷检测模型，在主干特征提取网络和特征融合网络中将梯度分流模（csp bottleneck with 2 convolutions，C2）中瓶颈模块Bottleneck的Conv卷积替换为全维动态卷积ODConv，增强网络模型特征表达能力；将主干网络的空间金字塔池化模（spatial pyramid pooling

with fpn，SPP）替换成聚焦调制网（focal modulatoin network，FMNe），聚焦不同防振锤尺寸的提取特征；在 Head 部分采用 Slideloss 样本加权函数缓解缺陷样本不平衡问题。通过测试集图像进行防振锤缺陷检测，已有同类型基于 YOLO 架构的防振锤缺陷检测模型可达到训练精度 90.7%、训练召回率 91.0 %的检测效果，据此验证了 FSO-YOLO 检测模型的准确性，可为输电线路防振锤缺陷检测提供智能化工具。

1　输电线路防振锤缺陷检测框架

FSO-YOLO 的整体工作流程如图 1 所示。首先，通过无人机航拍得到原始数据集，包含天空、森林、田野、沙地、住宅在内背景下的图像，并按照 8∶1∶1 的比例划分为训练集、测试集和验证集。训练阶段对训练数据进行数据扩充，采用加噪声、亮度调节、旋转、图像裁剪、平移、镜像 6 种方法完成样本扩充，以提高模型的泛化能力；然后数据通过 FSO-YOLO 模型的特征提取网络、聚焦调制网络、特征融合网络和分类预测网络，由分类预测网络的检测头得到预测框，输出防振锤检测结果。

2　输电线路防振锤缺陷检测模型

2.1　YOLOv8s 算法原理

YOLOv8s 算法基于 YOLOv5 改进得到[23]，在新增功能的基础上又做了多处改进，以实现更高的检测性能与部署灵活性。YOLOv8s 算法不仅拥有轻量、快速的特点，还可以在多种硬件平台上部署。该算法由主干特征提取网络 Backbone、特征融合网络 Neck 和分类预测网络 Head 3 个部分构成。

当目标图像输入到主干网络 Backbone，首先会经过两个由卷积层、批量归一化层和激活函数构成的 CBS 卷积模块处理，对不同尺度的特征进行提取。然后经过 C2f 模块和 CBS 模块的堆叠，最后经过 SPPF 模块，从主干网络中提取出 3 个不同尺寸的初级特征层。C2f 模块改善了模型的梯度流丰富度，增加了更多层的不同连接和额外的 Split 剪切操作。SPPF 模块结构如图 2 所示，通过在不同尺度上进行池化和卷积操作，自适应地融合多尺度的聚合特征信息，从而增强模型的特征提取能力。

Neck 部分对从主干网络提取到的初步特征层特征进行处理，使用路径融合网络（path aggregation network，PAN）和特征金字塔网络（feature pyramid network，FPN）通过自顶向下与自下向顶的跨层连接，使特征更充分融合。Head 部分输出预测结果，将分类和检测头分离，并且采用无锚框（anchor-free）思想，降低复杂度和训练难度，提高模型泛化性能。

2.2　FSO-YOLO 检测网络

防振锤缺陷在无人机航拍的图像中存在目标较

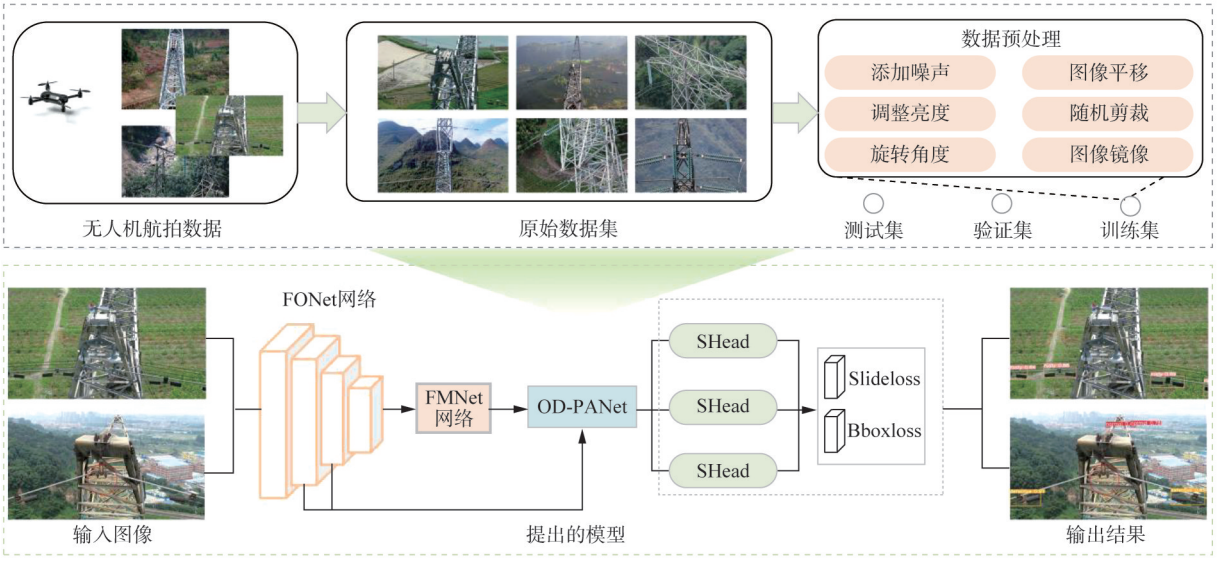


图 1　FSO-YOLO 工作流程

Fig. 1　Workflow of FSO-YOLO

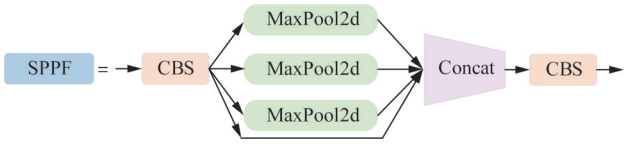


图 2 SPPF 结构图

Fig. 2 SPPF structure diagram

小、背景复杂、缺陷样本不平衡等问题。这类缺陷在远距离观察或小尺寸目标检测场景中难以被有效捕捉，传统检测方法很容易发生漏检。受 YOLO8s 的启发，本文利用 FONet 特征提取网络、聚焦调制网络 FMNet、OD-PANet 特征融合网络以及 SHead 分类预测网络构建防振锤缺陷检测网络 FSO-YOLO，如图 3 所示。

2.2.1 FONet 特征提取网络

无人机巡检的防振锤图像作为输入，尺寸设置为 640×640×3，经过卷积、标准化以及激活函数等操作对图像进行特征提取，FONet 主干特征提取网络由卷积模块 CBS 和 OD-C2f*i* 模块（其中 *i*=1、2、3、4）组成，并从 OD-C2f2 模块和 OD-C2f3 模块引出特征层 P1 和特征层 P2。

为了提高模型的特征提取能力，本文用 ODConv 全维动态卷积模块[24]将 C2f 模块里 Bottleneck 模块的 Conv 卷积替换，强化提取不同环境和不同型号的防振锤缺陷局部特征的能力，精准实现输电线路防振锤缺陷识别与检测，如图 4 所示。ODConv 动态卷积依次经过全局平均池化层（global average pooling，GAP）、全连接层（fully connected layers，FC）将特征向量映射至低维的空间中，再经过修正线性单元（rectified linear unit，ReLU）去除特征向量的负值，该模块采用并行策略，利用多维注意力机制，沿核空间的核尺寸、输入通道数、输出通道数和卷积核数量 4 个维度学习互补性注意力，对应其卷积的 4 类注意力标量，由此形成一个完整的模块。其中，4 个分支通过 FC 层依次输出 $n\times1$、$c_{out}\times1$、$c_{in}\times1$ 和 $k\times k$ 的特征向量。

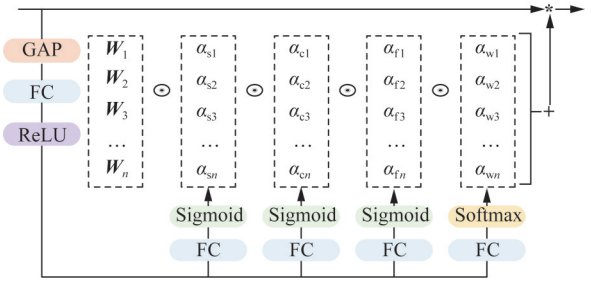


图 4 ODConv 结构图

Fig. 4 Structure diagram of ODConv

在输入特征对卷积核进行调制的基础上进一步进行卷积计算，以此确保模型能够充分提取不同防振锤的主要特征，从而提升系统检测的精度，计算公式如式（1）所示。

$$\boldsymbol{y}=\left(\sum_{i=1}^{n}\alpha_{wi}\odot\alpha_{fi}\odot\alpha_{ci}\odot\alpha_{si}\odot W_i\right)*\boldsymbol{x} \tag{1}$$

式中：$\boldsymbol{y}$ 为输出特征向量；$\boldsymbol{x}$ 为输入特征向量；i 为卷积核序号；n 为卷积核数量；W_i 为第 i 个卷积核；$\alpha_{wi}\in R^{n\times1}$ 为整个卷积核 W_i 的注意力标量；$\alpha_{fi}\in R^{c_{out}}$ 为一个沿着卷积核 W_i 输出通道维度而引入的注意力标量；$\alpha_{ci}\in R^{c_{in}}$ 为一个沿着卷积核 W_i 输入通道维度而引入的注意力标量；$\alpha_{si}\in R^{k\times k}$ 为一个沿着卷积核 W_i 空域维度引入的注意力标量；$\odot$ 为乘法运算，运算操作沿内核空间不同维度进行；$*$ 为卷积运算。

2.2.2 FMNet 聚焦调制网络

YOLOv8s 的空间金字塔池化模块 SPPF 在对不同尺度特征图进行池化操作过程中会损失一些空间信息，相关实验分析也表明，该模块最大池化操作本身会抑制细粒度特征表达，且存在金字塔层级间

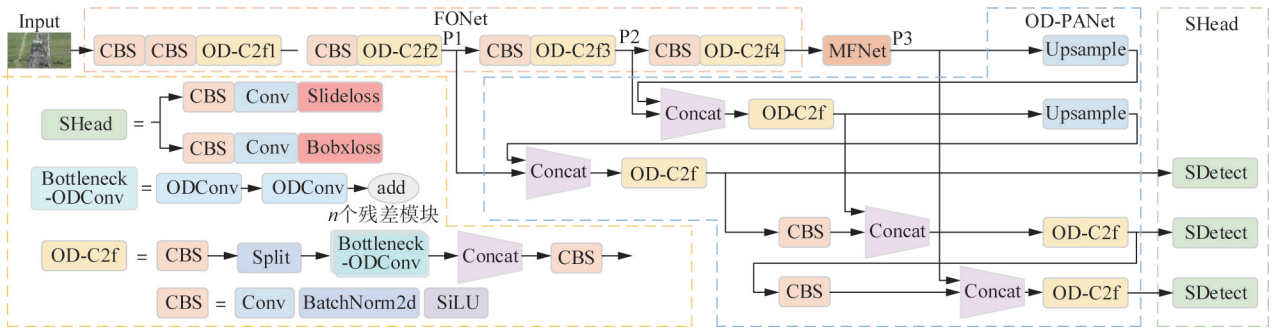


图 3 FSO-YOLO 网络结构图

Fig. 3 Network structure diagram of FSO-YOLO

特征交互不足、缺乏局部细节关注机制的问题，最终导致模型在处理一些需要详细空间信息的任务时性能下降。实测数据也验证了这一点：在 MS COCO 数据集上，替换了改进 SPPELAN 模块的 YOLOv8 相比原版 SPPF 实现了 1.2 %的 mAP 提升，小目标检测任务召回率更是提高了 3.5 %，侧面印证了原版 SPPF 存在空间信息损失带来的性能瓶颈。聚焦调制网络 FMNet[25]在每个感兴趣区域的基础上对特征图进行动态的调制，从而适应不同区域尺寸的特征重要性，对其进行精确调制，相比于 SPPF 模块具有更强的动态化、精准化适应性。

FMNet 聚焦调制网络的结构如图 5 所示，其基本原理是采用了聚焦调制技术，以获取图像的长距离相关性及上下文信息。聚焦调制技术首先在调制器中对其进行多粒度的聚集，再通过查询相关的方法将其注入查询标记中，从而简化了交互、聚合等操作，使得模型更加轻量化。

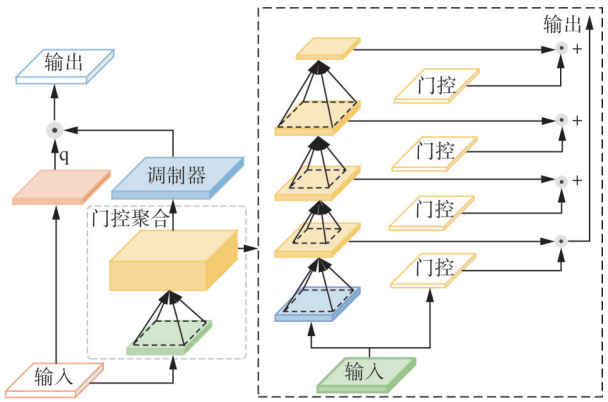


图 5　FMNet 结构图

Fig. 5　Structure of FMNet

FMNet 网络通过 3 个步骤实现：1)焦点上下文化：输入首先通过轻量级线性层进行处理，然后通过层级化的上下文化模块和门控机制(gate)选择性地聚合信息，最终通过调制器(modulator)查询 q 进行交互以生成输出；2)门控聚合(aggregate)通过门控机制选择性地将上下文信息聚合到每个查询令牌的调制器中；3)逐元素仿射变换：将聚合后的调制器通过仿射变换注注入个查询令牌中。

2.2.3　OD-PANet 特征融合网络

特征融合网络可以将不同大小的特征层进行融合，有利于提取出更好的图像特征。本文构建 OD-PANet 网络融合图像浅层与深层的特征，并在其 C2f 模块中加入 ODConv 卷积以更好地适应数据特征。ODConv 的结构在 FONet 特征提取网络中已说明。从 FONet 网络和 FMNet 网络引出的特征层 P1、特征层 P2、特征层 P3 输入 OD-PANet 网络进行自顶向下与自底向上的特征融合。

2.2.4　SHead 分类预测网络

分类预测网络由两条卷积支路组成，分别添加分类损失模块和预测框损失模块，根据分类和回归的分数加权得到的分数来确定正负样本。防振锤缺陷训练集中存在某些类别样本数量非常少，引入样本加权函数 SlideLoss[26]作为分类损失替换原本的分类损失，来缓解样本失衡，让模型训练时更加稳定，样本加权函数如式(2)所示。

$$f(x)=\begin{cases}1, x \leqslant \mu-0.1\\ \mathrm{e}^{1-\mu}, \mu-0.1<x<\mu\\ \mathrm{e}^{1-x}, x \geqslant \mu\end{cases} \tag{2}$$

式中μ为所有边界框的 IoU 值的平均值。首先通过参数μ将防振锤样本分为正例和负例，将小于μ的样本划分为负样本，大于μ的样本划分为正样本。然后通过加权函数 SlideLoss 对边界处的样本进行加强。损失曲线对比如图 6 所示，橙色曲线是在原模型上采用 SlideLoss 样本加权损失函数得到的损失曲线，蓝色曲线是原模型类别分类损失函数，结合 YOLOv9、YOLOv10 等多个目标检测模型的改进实践可以看出，针对难易样本不平衡问题设计的样本加权函数的加入，可以让模型在训练过程中更多关注对性能提升更关键的困难样本，减少简单样本对梯度更新的干扰，进而降低模型的损失，提升模型的收敛速度和检测精度。

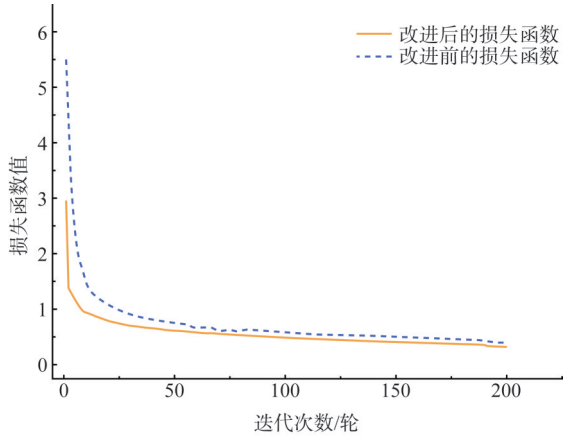


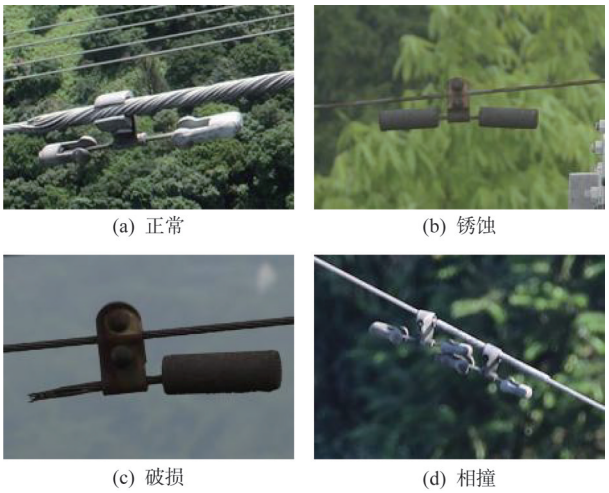
图 6　损失函数对比

Fig. 6　Loss functions comparison

3 实验结果与分析

3.1 数据集构建

本工作在无人机拍摄的输电线路图像的基础上，通过收集分类处理，建立了防振锤缺陷检测数据集——参考现有公开的同类数据集，已有多个可用于相关研究的公开数据集被发布：其中CSDN分享的公开数据集包含326张标注完成的防震锤缺陷图像，另有包含防震锤缺陷的标注数据集总计7 972余张，数据增强后包含防震锤脱落缺陷的图像达到1 050张，均已完成专业标注，可适配不同格式的深度学习模型训练需求。本文基于自行建立的防振锤缺陷检测数据集，完成防振锤缺陷检测研究。防振锤结构主要包含两个铁制锤头、一根钢绞线以及一个线夹，两个锤头之间通过钢钢绞线接，并通过线夹固定在输电线路上。由于其长期暴露在野外环境中，容易引发锈蚀缺陷，锈蚀严重也会导致钢绞线松动，从而出现锤头变形并掉落等情况，防振锤在振动过程中可能因受力不均或连接部件松动而发生移动相撞，导致防振性能下降甚至失效[27]。参考《架空输电线路隐患、缺陷及故障表象辨识图册》[28]，将防振锤数据集图像分为正常、锈蚀、破损和相撞4类，如图7所示。



(a) 正常 (b) 锈蚀

(c) 破损 (d) 相撞

图7 防振锤正常及3种缺陷示例

Fig. 7 Damper normal and three defect examples

将原始数据集扩充5倍，并去除在扩充中出现的质量较差的图片，最终包含图片总数为2 785张，采用标签制作工具Labelimg进行标签制作。标签共7 131个，各类标签数量统计如表1所示。

表1 数据集样本组成情况

Tab. 1 Data set sample composition conditions

类别	标签名	标签数量/个
正常	normal	3 182
锈蚀	rusty	2 610
破损	defective	841
相撞	Collide	498

3.2 实验环境及参数设置

本次验所使用设备型号如下。Python的版本是3.8.18，显卡类型为Nvidia GeForce GTX 1 660 Super，显存16 GB，操作系统为Visual Code 2017，使用深度学习框架Pytorch1.9.0对数据进行训练和测试。训练期间的参数设置为：使用随机梯度下降(tochastic gradient descent，SGD)化器，初始学习率为0.000 1，动量项为0.9，训练的每次迭代使用的样本数量batch_size为16，共进行200轮训练。

3.3 模型评价指标

本文采用的指标主要有：精确率(precision，P)召回率(recall，R)平均精确率AP、所有检测类别AP值的平均值mAP、计算量FPS。FPS指检测数量设置为1时，单张图片预测所需的时间。精确率P指在所有模型预测为正类别的样本中，实际为正类别样本的比例。P衡量了模型在正类别预测中的准确性。T_P表示模型预测正确的正样本；F_P表示模型预测错误的正样本；F_N表示模型未预测出的正样本；P计算公式如式(3)所示。

$$P = \frac{T_P}{T_P + F_P} \tag{3}$$

R衡量了模型是否能够有效地找到所有正类别样本。R计算公式如式(4)所示。

$$R = \frac{T_P}{T_P + F_N} \tag{4}$$

3.4 实验结果

3.4.1 防振锤各类缺陷检测结果

对防振锤的缺陷检测采用上述实验环境的训练模型，设置检测阈值为0.5(IoU值=0.5)，4种目标的测试结果如表2所示。

从表2可知，防振锤防震均精确度可以达到95.3%。防振锤相撞及破损缺陷的特征较为明显，因此其召回率和检测精度较高，出现误检和漏检的可能性也较小；防振锤正常和锈蚀缺陷标签数量较多，并且存在大量遮挡目标，因此相较于其他缺陷

表 2　防振锤缺陷检测结果

Tab. 2　Test results of anti-vibration hammer defects

序号	名称	标签	*P*/%	*R*/%	AP 值/%
1	正常	normal	92. 6	90. 6	92. 4
2	锈蚀	rusty	88. 9	93. 0	92. 5
3	破损	defective	96. 8	96. 8	97. 7
4	相撞	collide	93. 3	100	98. 7
5	所有类别		92. 9	95. 1	95. 3

表 3　消融实验结果

Tab. 3　Results of ablation experiment

模型	*P*/%	*R*/%	mAP 值/%	浮点计算量/G
YOLOv8s	90. 9	89. 4	91. 8	28. 4
YOLOv8s+O	91. 3	88. 7	91. 0	19. 0
YOLOv8s+F	92. 2	91. 7	93. 4	28. 8
YOLOv8s+S	92. 0	92. 3	94. 5	28. 4
FSO-YOLO	92. 9	95. 1	95. 3	19. 3

的检测精度和召回率稍低一些。为了更直观地展示地 SO-YOLO 对各类目标的检测效果，绘制了模型测试的 *P-R* 曲线，如图 8 所示。

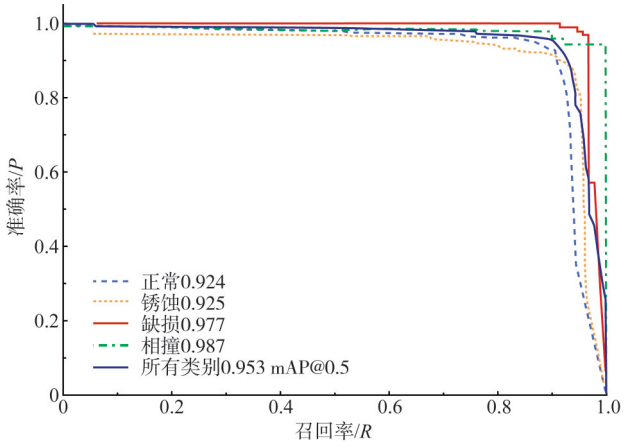


图 8　测试集中的 *P-R* 曲线

Fig. 8　*P-R* curves of the test dataset

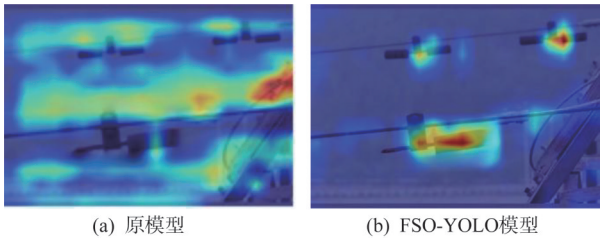
结合 mAP 为各类别 AP 平均值的定义（AP 值为 *P-R* 曲线下面积）可知，从 AP 值的定义出发，改进后模型收获了较高 AP 值，则其 mAP 值也将提升，识别精度更高。西安工程大学研究者针对防振锤缺陷检测提出的改进方法、基于 YOLOv11 的防振锤缺陷检测改进模型的实际测试结果也印证了这一点，其中基于 YOLOv11 的改进模型测试获得了 94. 2 % 的 mAP，表明合理改进后的方法可在防振锤缺陷检测方面展现出高效性与精确性。

3. 4. 2　消融实验

消融实验可以更好地展示模型改进对检测性能的影响，进而明确每个改进点对整个模型性能的贡献程度。O、F、S 分别代表使用 ODConv 动态卷积、FMNet 模块和 Slideloss 样本加权函数构建目标检测网络 FSO-YOLO 模型，其消融实验结果如表 3 所示。

从表中可以看出，YOLOv8s 模型未进行改进时，GFLOPs 为 28. 4，mAP 值为 91. 8 %。引入 ODConv 动态卷积模块后，浮点计算量降低 9. 4 G，mAP 值却仅仅降低了 0. 8 %，对检测性能的影响很小，说明 ODConv 的引入有效减少了计算资源消耗，在基线模型中加入 FMNet 聚焦调制网络后，模型 mAP 值增加了 1. 6 %，说明 FMNet 相较于元模型显著提升了复杂背景中目标的网络特征提取的综合能力，通过将原有分类损失函数替换成 Slideloss 损失函数后，mAP 值提升了 2. 7 %，表明 Slideloss 损失函数有效缓解了原有缺陷样本不平衡问题。各模块叠加后 FSO-YOLO 的整体检测精度提升 3. 5 %，准确率和召回率分别提升了 2 % 和 5. 7 %，浮点计算量 FLOPs 最终降低了 9. 1 %，可以得出 3 种改进方法的加入最终可以对模型检测效果和检测速度有很明显的提升。

如图 9 所示为输电线路防振锤图像的热力图，采用 FSO-YOLO 模型和原模型通过可视化工具 Grad-CAM 显示网络的决策区域[29-30]，该工具采用类激活图技术，能够以可视化形式阐释网络的决策逻辑。可以看出，FSO-YOLO 模型对防振锤缺陷部位具有更深层次的关注，可有效检测出图像缺陷。



(a) 原模型　　(b) FSO-YOLO模型

图 9　热力图对比

Fig. 9　Thermal maps comparison

3. 4. 3　对比实验

本文提出的 FSO-YOLO 防振锤缺陷检测模型为单阶段的无锚框检测模型。现阶段已有不少面向电力设备缺陷检测的 YOLO 系列改进研究，例如华晋焦煤等改进的 YOLOv5s 模型在整合了无人机影像、公开数据及网络爬取图像的数据集上实现了

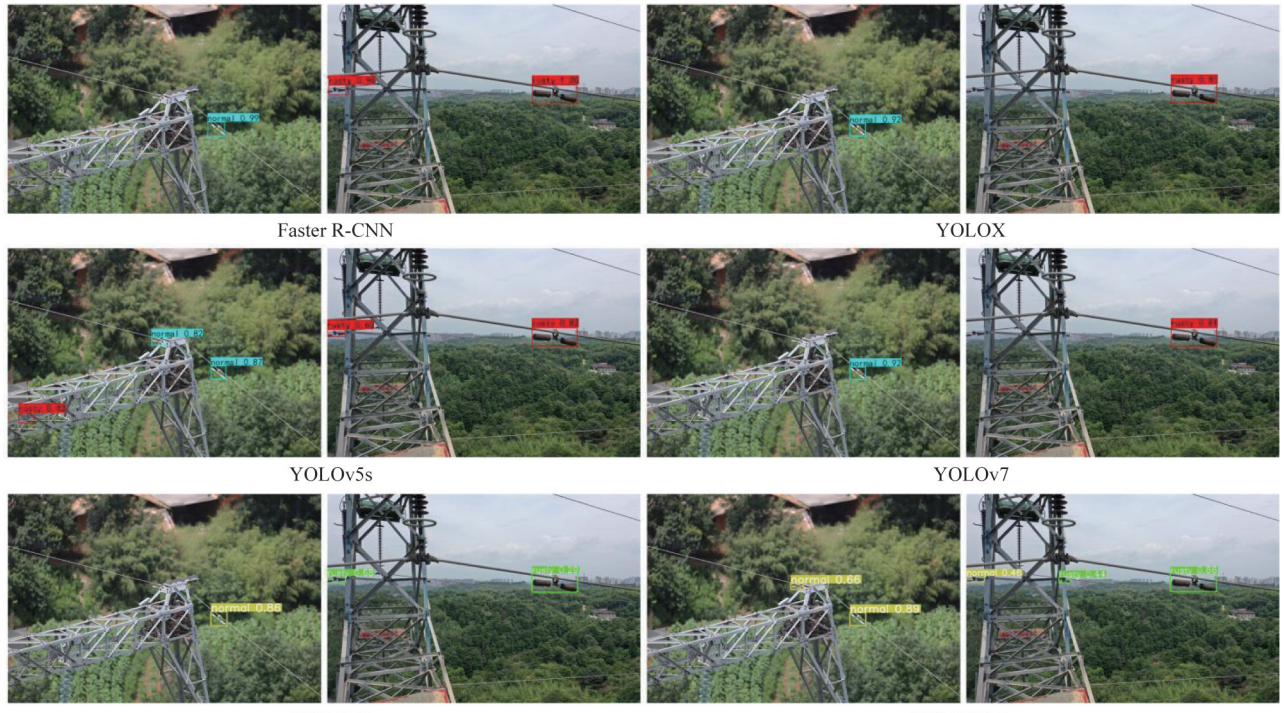
85.9 %的 mAP，同时将模型体积压缩 45 %。在电力设施缺陷中，电缆机械破损和雷电击打损伤两类问题占电网故障的 60% 以上，防振锤缺陷也是影响输电线路安全的常见缺陷类型。为了展示本文模型的优异性能，在原有数据集上与现有其他先进的目标检测网络进行对比实验，如 Faster R-CNN、YOLOv5s、YOLOX、YOLOv7、YOLOv8s，各对比模型均使用相同的训练参数，结果如表 4 所示。

由表 4 可知，经典二阶段目标检测算法 Faster R-CNN 由于存在 FPN 结构使得低层网络上的位置信息容易丢失，导致其 mAP 值较低，仅为 72.4 %，且检测速度仅为 17.5 帧/s，无法满足防振锤实时缺陷检测的需求，难以应用于现实场景。YOLOv5s 模型的参数量与浮点计算量均较低，但在检测精度与检测速度上表现一般，相关数据显示其检测精度仅为 74.7 %，检测速度仅为 25.2 帧/s，在与 Faster R-CNN、YOLOv3 的同场景精度对比中，YOLOv5 仅在部分类别检测中精度占优，整体性能与精度仍存在提升空间。YOLOX 模型和 YOLOv7 模型在检测精度上相较于 Faster RCNN 和 YOLOv5s 都有很大提升，但在检测速度上依然表现不佳；现有研究领域已围绕防振锤缺陷检测构建了千张规模的标注数据集用于算法训练，YOLOv8s 虽然在该任务中检测精度达到了 91.8 %，但较低的 FPS 值限制了其在实际电力线路巡检场景的应用。FSO-YOLO 模型展现了优异的性能，mAP 值达到了 95.3 %，FPS 值达到了 51.0 帧/s，这意味着该模型可以满足较高检测精度的同时对输入的图像进行实时快速处理。如图 10 所示，图 10 为不同模型的检测效果对比图，从图 10 可以看出，防振锤缺陷目标本身较小，且部

表 4　对比实验结果

Tab. 4　Comparative experimental results

模型	Parameters 值/M	GFLOPs 值/G	mAP 值/%	FPS 值
Faster R-CNN	137.1	41.2	72.4	17.5
YOLOv5s	7.3	16.6	74.7	25.2
YOLOX	9.7	33.5	91.3	22.4
YOLOv7	104.7	36.5	89.0	25.4
YOLOv8s	11.1	28.4	91.8	32.7
FSO-YOLO	11.6	19.3	95.3	51.0



模型	Faster R-CNN	YOLOX	YOLOv5s	YOLOv7	YOLOv8s	FSO-YOLO
误检数	0	0	1	0	0	0
漏检数	2	2	1	2	1	0

图 10　不同算法对防振锤缺陷检测效果的可视化对比

Fig. 10　Visual comparison of different algorithms on the detection effects of dampers defects

分目标存在遮挡情况，Faster R-CNN、YOLOX、YOLOv5s、YOLOv7、YOLOv8s 模型对远距离存在遮挡的防振锤目标均出现了漏检，YOLOv5s 模型还出现了误检问题，将输电线路杆塔螺栓部件误检测为锈蚀缺陷防振锤。

对于远距离的遮挡目标，FSO-YOLO 展现了较大的优势，成功实现了检测精度和检测速度之间的平衡。

4　结论

本文基于包含 4 类防振锤及其缺陷的图像数据集开展了图像预处理与模型训练工作，提出了融合全维动态卷积与聚焦调制网络的输电线路防振锤缺陷检测模型。通过算例实验验证了本文模型的有效性，得出结论如下。

1）主干特征提取网络和特征融合网络中使用全维动态卷积 ODConv 对 C2f 模块进行改进，既保障了检测精度也降低了模型的浮点计算量。

2）将主干网络的空间金字塔池化模块 SPPF 替换成聚焦调制网络 FMNet 提高模型聚焦关键区域的识别能力，并针对缺陷样本不平衡问题，将原模型损失函数替换成 Slideloss 样本加权函数，模型准确率与召回率相较于原模型提升了 2 %和 5. 7 %，实现了更少的误检与漏检。

3）FSO-YOLO 模型对于防振锤图像缺陷检测精度和速度都高于 Faster RCNN、YOLOX、YOLOv5s 等模型，4 类缺陷的 mAP 值可达 95. 3 %，检测速度为 51 帧/s，证明了本文模型的优越性。

参考文献

[1] 赵拥华，张鹏，段意，等. FD 型防振锤的动力特性研究[J]. 电力科学与工程，2021，37(5)：73 – 78.
ZHAO Yonghua，ZHANG Peng，DUAN Yi，et al. Research on dynamic characteristics of FD anti-vibration hammer [J]. Electric Power Science and Engineering，2021，37 (5)：73 – 78.

[2] 黄新波. 基于图像感知的输电线路智能巡检综述[J]. 高电压技术，2024，50(5)：1826 – 1841.
HUANG Xinbo. Survey of intelligent inspection based on image perception [J]. High Voltage Engineering，2024，50 (5)：1826 – 1841.

[3] 张毅，刘天立，刘越，等. 深度学习在输电线路无人机巡检中识别防振锤缺陷的应用[J]. 武汉大学学报(工学版)，2022，55(10)：1065 – 1071.
ZHANG Yi，LIU Tianli，LIU Yue，et al. Application of deep learning in vibration damper defect identification to UAV inspection of transmission line [J]. Engineering Journal of Wuhan University(Engineering Edition)，2022，55(10)：1065 – 1071.

[4] 刘传洋，吴一全，刘景景. 基于视觉的输电线路金具锈蚀缺陷检测方法研究进展[J]. 仪器仪表学报，2024，45(3)：286 – 305.
LIU Chuanyang，WU Yiquan，LIU Jingjing. Research progress of vision-based rust defect detection methods for metal fittings in transmission lines [J]. Chinese Journal of Scientific Instrument，2024，45(3)：286 – 305.

[5] 张烨，李博涛，尚景浩，等. 基于多尺度卷积注意力机制的输电线路防振锤缺陷检测[J]. 电工技术学报，2024，39(11)：3522 – 3537.
ZHANG Ye，LI Botao，SHANG Jinghao，et al. Defect detection of transmission line damper based on multi-scale convolutional attention mechanism [J]. Transactions of China Electrotechnical Society，2024，39(11)：3522 – 3537.

[6] 田毅，伍逸群，张烨，等. 基于融合色差和神经网络的防震锤故障识别[J]. 计算机技术与发展，2020，30(8)：103 – 108.
TIAN Yi，WU Yiqun，ZHANG Ye，et al. Fault identification of damper defect based on fused chromatic aberration and neural network [J]. Computer Technology and Development，2020，30(8)：103 – 108.

[7] 刘平原，姚隽雯，吴焱松，等.500 kV 单回输电线路无人机作业电场影响仿真研究[J]. 高压电器，2024，60(12)：180 – 187.
LIU Pingyuan，YAO Junwen，WU Yansong，et al. Simulation study on the influence of electric field of 500 kV single circuit transmission line on UAV[J].High Voltage Apparatus，2024，60 (12)：180 – 187.

[8] HUANG X B，ZHANG X L，ZHANG Y，et al. A method of identifying rust status of dampers based on image processing [J]. IEEE Transactions on Instrumentation and Measurement，2020，69(8)：5407 – 5417.

[9] 隋宇，宁平凡，牛萍娟，等. 面向架空输电线路的挂载无人机电力巡检技术研究综述[J]. 电网技术，2021，45(9)：3636 – 3648.
SUI Yu，NING Pingfan，NIU Pingjuan，et al. Review on mounted UAV for transmission line inspection [J]. Power System Technology，2021，45(9)：3636 – 3648.

[10] 李旭阳，王文峰，李凌云，等. 基于改进 YOLOv8 的轻量化输电线路异物检测模型[J]. 南方电网技术，2026，20(5)：123 – 135.
LI Xuyang，WANG Wenfeng，LI Lingyun，et al. Lightweight foreign object detection model for power transmission lines based on improved YOLOv8 [J]. Southern Power System Technology，2026，20(5)：123 – 135.

[11] 李振兴，刘凯，胡聪，等. 基于图像定位的输电线长动态修正及综合行波测距方法[J]. 电力系统保护与控制，2025，53(2)：125 – 135.
LI Zhenxing，LIU Kai，HU Cong，et al.Dynamic correction of transmission line length and an integrated traveling wave ranging method based on image location [J].Power System Protection and Control，2025，53(2)：125 – 135.

[12] 刘志颖，缪希仁，陈静，等. 电力架空线路巡检可见光图像智能处理研究综述[J]. 电网技术，2020，44(3)：1057 – 1069.
LIU Zhiying，MIAO Xiren，CHEN Jing，et al. Review of visible image intelligent processing for transmission line inspection [J]. Power System Technology，2020，44(3)：1057 – 1069.

[13] 王道累，张世恒，袁斌霞，等. 基于改进 YOLOv5 的轻量化玻

璃绝缘子自爆缺陷检测研究[J]. 高电压技术，2023，49(10)：4382－4390.
WANG Daolei，ZHANG Shiheng，YUAN Binxia，et al. Research on self-explosion defect detection of lightweight glass insulators based on improved YOLOv5 [J]. High Voltage Engineering，2023，49(10)：4382－4390.

[14] 姜香菊，王瑞彤，马彦鸿. 基于轻量级改进RT-DETR边缘部署算法的绝缘子缺陷检测[J]. 电工技术学报，2025，40(3)：842－854.
JIANG Xiangju，WANG Ruitong，MA Yanhong. Insulator defect detection based on lightweight improved RT-DETR edge deployment algorithm[J]. Transactions of China Electrotechnical Society，2025，40(3)：842－854.

[15] 张伟，张咪，金佳齐，等. 基于ResNet深度学习网络的隔离开关状态识别研究[J]. 高压电器，2024，60(6)：99－106.
ZHANG Wei，ZHANG Mi，JIN Jiaqi，et al. Research on status identification of disconnector based on ResNet deep learning network[J]. High Voltage Apparatus，2024，60(6)：99－106.

[16] 杨桢，刘易宸，李鑫，等. 基于深度学习的输电线路绝缘子故障检测方法[J]. 电气工程学报，2024，19(2)：325－334.
YANG Zhen，LIU Yichen，LI Xin，et al. Insulator fault detection method for transmission line based on deep learning[J]. Journal of Electrical Engineering，2024，19(2)：325－334.

[17] 李俊轩，邱志斌，石大寨，等. 基于X-DR图像与YOLO-MS模型的输电线路耐张线夹压接缺陷检测[J]. 南方电网技术，2024，18(11)：159－168.
LI Junxuan，QIU Zhibin，SHI Dazhai，et al. Crimping defect detection of transmission line strain clamp based on X-DR image and YOLO-MS model [J]. Southern Power System Technology，2024，18(11)：159－168.

[18] HAO Y P，LIANG W，YANG L，et al. Methods of image recognition of overhead power line insulators and ice types based on deep weakly-supervised and transfer learning[J]. IET Generation，Transmission & Distribution，2022，16 (11)：2140－2153.

[19] 徐业东，蔡亚恒，李严，等. 基于YOLOv5s的轻量化架空输电线路鸟巢检测网络[J]，电子测量技术，2024，47(7)：138－148.
XU Yedong，CAI Yaheng，LI Yan，et al. Lightweight overhead transmission line bird′s nest detection network based on YOLOv5s[J]. Electronic Measurement Technology，2024，47(7)：138－148.

[20] 赵云龙，田生祥，李岩，等. 基于注意力模型和Soft-NMS的输电线路小目标检测方法[J]. 电子科技大学学报，2023，52(6)：906－914.
ZHAO Yunlong，TIAN Shengxiang，LI Yan，et al. Attention model and soft-NMS-based transmission line small target detection method[J]. Journal of University of Electronic Science and Technology of China，2023，52(6)：906－914.

[21] 赵振兵，江爱雪，戚银城，等. 嵌入遮挡关系模块的SSD模型的输电线路图像金具检测[J]. 智能系统学报，2020，15(4)：656－662.
ZHAO Zhenbing，JIANG Aixue，QI Yincheng，et al. Fittings detection in transmission line images with SSD model embedded occlusion relation module[J]. CAAI Transactions on Intelligent Systems，2020，15(4)：656－662.

[22] LIANG H G，ZUO C，WEI W M. Detection and evaluation method of transmission line defects based on deep learning[J]. IEEE Access，2020(8)：38448－38458.

[23] 张可，乐全明，黄文礼，等. 联合剪枝和知识蒸馏的PCSA-YOLOs防振锤缺陷检测算法[J]. 电工电能新技术，2022，41(11)：59－69.
ZHANG Ke，YUE Quanming，HUANG Wenli，et al. PCSA-YOLOs vibration damper defect detection algorithm combined with pruning and knowledge distillation[J]. Advanced Technology of Electrical Engineering and Energy，2022，41(11)：59－69.

[24] REDMON J，DIVVALA S，GIRSHICK R，et al. You only look once：unified，real-time object detection[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition，June 27－30，2016，LasVegas，NV，USA. New York：IEEE，2016：779－788.

[25] LI C，ZHOU A J，YAO A B. Omni-dimensional dynamic convolution[EB/OL]. [2022－9－16]. http://arxiv.org/abs/2209.07947.

[26] FENG C J，ZHONG Y J，GAO Y，et al. TOOD：task-aligned one-stage object detection[C]//2021 IEEE/CVF International Conference on Computer Vision (ICCV)，October 10－17，2021，Montreal，QC，Canada. New York：IEEE，2021：3490－3499.

[27] ZHENG Z H，WANG P，REN D W，et al. Enhancing geometric factors in model learning and inference for object detection and instance segmentation[J]. IEEE Transactions on Cybernetics，2022，52(8)：8574－8586.

[28] 张昭，周立宪，刘胜春. 横向振动条件下防振锤螺栓松动关键影响因素[J]. 电网与清洁能源，2024，40(8)：11－17.
ZHANG Zhao，ZHOU Lixian，LIU Shengchun. A study on key factors affecting bolt looseness of aeolian vibration dampers under lateral vibration conditions[J]. Power System and Clean Energy，2024，40(8)：11－17.

[29] 苏奕辉，梁伟放. 架空输电线路隐患、缺陷及故障表象辨识图册[M]. 北京：中国电力出版社，2017.

[30] SELVARAJU R R，COGSWELL M，DAS A，et al. Grad-CAM：visual explanations from deep networks via gradient-based localization[C]//2017 IEEE International Conference on Computer Vision (ICCV)，October 22－29，2017，Venice，Italy. New York：IEEE，2017：618－626.

收稿日期：2024-09-01；**网络首发日期**：2024-12-16

作者简介：

蔡智雯(1998)，女，硕士研究生，研究方向为输电线路图像识别与智能运维，1960328694@qq.com；

邱志斌(1991)，男，通信作者，副教授，博士，研究方向为输变电设备外绝缘、电力视觉与人工智能、电磁场数值计算，qiuzb@ncu.edu.cn；

陈瑞婷(2000)，女，硕士研究生，研究方向为电力视觉缺陷检测，1420380271@qq.com。