DOI: 10.13382/j.jemi.B2407848

基于 ECSMNet 的风力发电机表面缺陷检测研究*

姜永祺[1] 单慧琳[2]

(1. 南京信息工程大学电子与信息工程学院 南京 210044;2. 无锡学院电子信息工程学院 无锡 214105)

摘 要:针对风力发电机表面缺陷检测中存在的背景环境复杂、小目标缺陷检测精度不够等问题,提出了一种高效的风力发电机表面缺陷检测方法。首先构建具有特征提取与融合能力的主干网络,并在残差部分引入改进的通道注意力,帮助网络更好地提取特征信息,其次,使用新一代卷积变形模块进行输出,使模型能够更好地捕捉输入数据中空间和时间的相关性,简化模型的同时提高检测速度。最后在模型下采样部分引入高效空间-深度信息转换模块,将输入特征图中的空间维度降维至通道维度,保留显著特征的同时减少细粒度信息丢失,进一步提高模型检测小目标的能力。实验结果表明,相较于 YOLOv7 网络,所提网络在图像环境较为复杂的数据集 1 上准确率提升了 3.5%,召回率提升了 2.3%,交并比(IoU)为 0.5 时平均精度提升 3.1%,在图片质量较好的数据集 2 上准确率达到 96%,召回率达到 94%,IoU 为 0.5 时平均精度达到 96.7%。所提模型在解决误检漏检问题方面有明显的优势,并且具有较快的检测速度,更适合在实际检测环境中应用,有良好的工程应用前景。

关键词: 风力发电机;深度学习;缺陷检测;注意力机制;残差网络

中图分类号: TP391;TN20 **文献标识码**: A **国家标准学科分类代码**: 520.2060

Research on surface defect detection of wind turbine based on ECSMNet

Jiang Yongqi[1] Shan Huilin[2]

(1. School of Electronic and Information Engineering, Nanjing University of Information Science and Technology, Nanjing 210044, China; 2. School of Electronic and Information Engineering, Wuxi University, Wuxi 214105, China)

Abstract: Aiming at the problems of complex background environment and insufficient detection accuracy of small target defects in surface defect detection of wind turbines, an efficient surface defect detection method for wind turbines is proposed. Firstly, a backbone network with feature extraction and fusion capabilities is constructed, and an improved channel attention is introduced in the residual part to help the network better extract feature information. Secondly, a new generation of convolution deformation module is used for output, so that the model can better capture the correlation between space and time in the input data, simplify the model and improve the detection speed. Finally, an efficient spatial-depth information conversion module is introduced in the down-sampling part of the model to reduce the spatial dimension in the input feature map to the channel dimension, retain the salient features while reducing the loss of fine-grained information, and further improve the ability of the model to detect small targets. The experimental results show that compared with the YOLOv7 network, the accuracy of the proposed network is improved by 3.5%, the recall rate is improved by 2.3%, and the average accuracy is improved by 3.1% when the intersection over union is 0.5. In the data set 2 with better image quality, the accuracy rate reaches 96%, the recall rate reaches 94%, and the average accuracy reaches 96.7% when IoU is 0.5. The proposed model has obvious advantages in solving the problem of false detection and missed detection, and has faster detection speed. It is more suitable for application in the actual detection environment and has good engineering application prospects.

Keywords: wind turbine; deep learning; defect detection; attention mechanism; residual network

收稿日期:2024-09-22 Received Date: 2024-09-22

*基金项目:国家自然科学基金(62071240,62106111)、江苏省研究生科研与实践创新计划项目(SJCX24_0448)、无锡市“太湖之光”科技攻关(基础研究)项目(K20241047)资助

0　引　言

随着全球范围内能源需求不断增长,传统能源如煤炭、石油和天然气等面临供给限制和环境压力。风能作为一种可再生能源,具有环保、经济、灵活等优势,发展潜力十足[1]。风力发电机作为风能发电的主要设备,在工作过程中容易受到雷击、冰雹等自然灾害的影响,而产生裂纹、砂眼等损伤,从而影响电机的性能并且造成安全隐患。因此,对风力发电机表面进行缺陷检测具有非常重要的意义[1-2]。

早期风力发电机表面缺陷检测主要依赖人工完成,存在检测效率低、检测时间长和检测成本高等缺点[3]。随着硬件领域的发展,国内外有关缺陷检测的方法相继出现了红外无损检测技术[4]、X 射线检测技术[5]、超声波检测技术[6]、声发射检测技术[7]和光纤传感器检测技术[8]等。但普遍存在检测设备要求高,对细节分辨能力差等缺陷。

当计算机视觉技术以及机器学习的思想广泛应用到工业领域后,Lin 等[9]提出对图像进行预处理后,根据灰度值的变化进行裂纹检测,但是只能检测裂纹类缺陷,无法实现其他类缺陷检测。Gao 等[10]针对风机叶片结冰的问题,提出使用 Canny 算子获取叶片表面冰层轮廓、厚度分布等信息,但在叶尖部分有误差,检测效率并不高。汤占军等[11]针对风力发电机表面中难以检测的细小缺陷,提出使用改进的萤火虫算法优化支持向量机(support vector machine,SVM)的检测模型。该模型通过增加混沌映射的方法生成种群的初始位置,采用自适应步长以获得最优价,增强了模型全局搜索能力。仇梓峰等[12]提出了一种基于 SVM 和决策树的多尺度分类方法,在模型中融入锥形特征网络,采用 LBP-ADA 方法对叶片表面缺陷进行建模,提高了识别的准确率。然而,该方法模型搭建复杂,对小目标缺陷检测效果不好。

随着无人机技术的发展,在红外热成像技术领域,Yu 等[13]提出一种基于 U 形神经网络(U-Net)的风力发电机叶片红外图像拼接方法,通过比较物体缺陷区和完整区的红外辐射差异来检测物体的内部缺陷。但采用语义分割技术增加了检测的成本和复杂度。此外,彭一誉等[14]提出了基于自然日光激励的动态热成像方法,但仅实现了对脱粘与积水两种经典缺陷的检测。在实际条件下需要综合多个时间点的信息才能确定风机叶片的内部缺陷的具体类型。

在光学检测方面,基于深度学习卷积神经网络的检测方法因其成本低、操作简单、无需先验知识而受到广泛关注。卷积神经网络(convolutional neural network,CNN)的检测方法又分为 Two-Stage 和 One-Stage 两种结构。

Two-Stage 是指模型先生成候选区域(region proposal),再对预测目标进行分类和定位;代表网络有 Faster-RCNN[15]、残差神经网络(ResNet)[16]等。向宽等[17]在 Faster-RCNN 主干网络中引入了特征金字塔网络(feature pyramid networks,FPN),并使用感兴趣区域校准(region of interest align,ROI Align)算法取得更适应缺陷目标的锚框,相比原网络平均精度均值(mean average precision,mAP)提高了约 16%。茅宇琳[18]采用了基于 ResNet-101 的级联 R-CNN 检测模型,并在风机表面缺陷检测中引入迁移学习的思想加快模型的收敛速度,然而,模型在训练后期不够稳定,容易导致图像失真。

One-Stage 则直接通过卷积神经网络提取特征,预测目标的分类与定位;如单次多框检测器(singleshot multibox detector, SSD)[19]和 YOLO(you only look once)[20-24]等。该类算法将目标检测看作回归问题,能够保证较高精度的同时满足实时性的需求。季利鹏等[25]提出一种基于改进 SSD 的风机叶片缺陷检测方法,将残差网络 ResNet50 引入到 SSD 主干提取网络,以获取更深层次的特征信息,提升模型整体检测效果。Qiu 等[26]在 YOLO 基础上提出了一种对风机叶片微小缺陷检测模型,具有较高的检测速度,可以满足实时性的要求。郝帅等[27]提出在 YOLO 中使用加权双向特征金字塔网络(bidirectional feature pyramid network,BiFPN)[28]结构,实现了目标多尺度特征融合,增强了模型检测被遮挡目标的能力。

虽然基于深度学习的风机叶片缺陷检测方法有较好的应用前景,但是在面对复杂环境以及微小目标缺陷时的检测能力有待提高。

目前在复杂环境条件下风机缺陷检测已经取得了很大的进展。张银胜等[29]提出的一种基于改进 YOLOv5s 的风机缺陷检测算法,通过在主干特征提取网络中改进 MobileNetv3 轻量级网络模型,提高了缺陷识别的精度和速度,但在恶劣天气等复杂环境中的泛化能力有待进一步研究。Lei 等[30]提出了两阶段渐进式风机检测模型训练策略,在第 1 阶段引入了多尺度数据增强算法,优化目标分配问题,提高了检测精度和泛化性能。在第 2 阶段引入了多场景负样本学习策略,使训练模型更好地理解和适应各种背景场景,从而减少背景中的错误识别。

现有的小目标定义方式主要分为以下两类,基于目标与图像比例的相对尺度定义和基于目标像素大小的绝对尺度定义。在风机表面缺陷数据集中,大多数图像缺陷像素较低,缺陷占比较小,属于小目标检测范畴。上述算法在面对图像中小目标缺陷时往往难以提取到有效的特征,普遍存在检测精度率低等问题。并且在野外实际检测场景下,强风、强紫外线等复杂环境会给图像的采集、图像中缺陷目标的捕捉造成干扰,对缺陷检测工作的

开展增加了难度。

为此,提出了多层级残差特征增强网络(ECSMNet)网络,针对背景环境复杂以及小目标叶片缺陷检测精度不够的问题,构建了高效的卷积模块(ECAMC),该模块通过引入 ECAM 注意力机制,使网络更加注重浅层特征图的信息,并且通过调整残差连接的方式,使网络对不同层级特征进行融合,获取不同尺度的信息,避免了浅层特征的丢失以及梯度消失问题,进一步提高模型整体检测小目标的能力。为了减少由于金属反射特性造成的低质量图像对检测效果的影响,在模型特征提取模块引入新一代卷积变形模块(convnext transform,CNT),该模块内部的使用的 ConvNext 模块采用多种特征融合、深度可分离卷积等技术使模型更加灵活。最后,针对由于步长卷积和池化层导致的小目标细粒度信息丢失,在特征提取网络的下采样部分使用高效空间-深度信息转换(maxpool and space-to-depth,MSPD)模块,进一步提高模型对风机叶片缺陷检测的召回率。实验结果表明,ECSMNet 网络在检测任务中有更加精准稳定的检测效果。

1 基本模型结构

ECSMNet 网络主要由以下 4 部分组成,即输入端(input)、主干提取网络(backbone)、特征提取网络(neck)和探测头(head)。图像在输入到网络之前需要通过一系列的数据增强和预处理操作。然后输入端将预处理后的图片裁剪为统一的大小后,输入到下一层网络进行特征提取。主干提取网络由 ECAMC、CBS 层和 MPConv 模块组成,其中 CBS 模块由卷积层(Conv)、BN(batch normalization)层和 SiLU 激活函数组成。ECAMC 模块可以对不同深度的特征进行融合,处理过的图像经过下采样结构在 backbone 网络不同的深度位置可以得到得到大、中、小 3 种尺寸的特征图,neck 层使用 SPPCSP(spatial pyramid pooling convolutional neural network and cascading spatial pooling convolutional neural network)对输入的特征图进行多尺度的空间金字塔池化,从而提高模型的感受野和特征表达能力,并且引入 ConvNext 网络提高网络的效率。为了进一步提高模型处理低分辨率图像和小对象时的性能,使用了 MSPD 模块。最后将融合后的特征送入 RepConv,经过检测层输出后得到预测结果。ECSMNet 的网络结构如图 1 所示。

1.1 ECAMC 模块

风力发电机通常暴露在沿海、山地等复杂环境中,相关的缺陷图像背景往往较为复杂,对模型特征的捕捉造成很大的干扰,并且标注图像中的缺陷目标大多数属于小目标,像素较低,需要模型具有较好的检测小目标的能力。为此,提出了一种高效的层聚合的 ECAMC 模块,允许模型在不同层次上融合特征,捕捉更多的上下文信息,通过多层特征融合,提高模型检测的准确率。ECAMC 实现过程大体如式(1)~(4)所示。

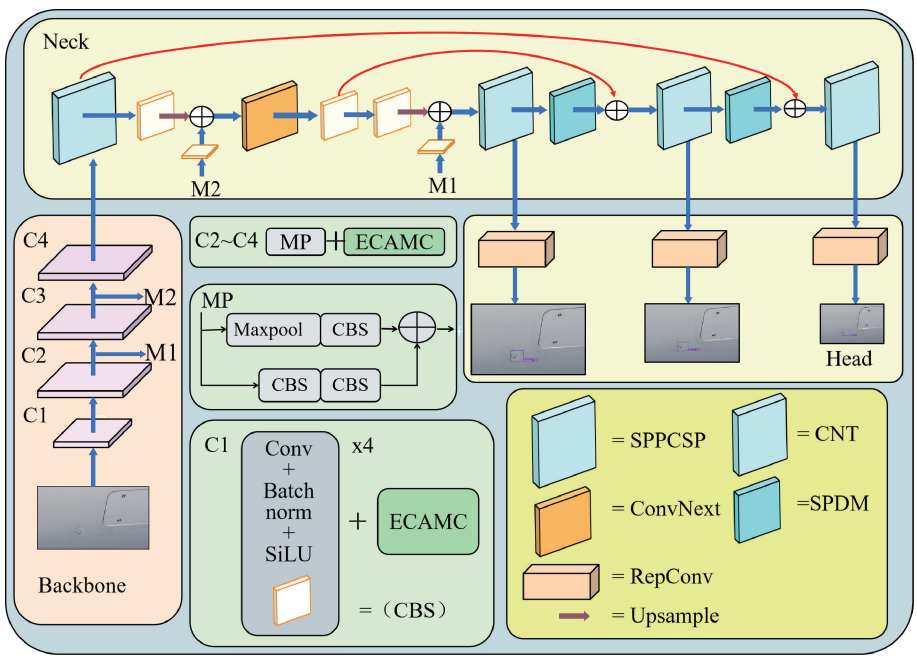

图 1 ECSMNet 网络结构

Fig. 1 The overall structure of ECSMNet

$$S1 = \mathrm{Concat}(CBS_1(Input) + CBS_3(CBS_3(CBS_1(Input)))) \tag{1}$$

$$S2 = \mathrm{ECAM}(CBS_1(Input)) \tag{2}$$

$$S3 = CBS_3(CBS_1(Input)) \tag{3}$$

$$Output = CBS_1(\mathrm{Concat}(S1, S2, CBS_3(CBS_3(S1)), S3)) \tag{4}$$

式中：$S1$ 表示第一个特征图拼接节点；$S2$ 表示注意力残差部分提取到的特征信息；$S3$ 表示第 2 个卷积块输出的特征信息。

ECAMC 结构的主要思想是通过逐级的卷积得到不同层级的图像特征，最终在 ConCat 层利用残差结构结合在一起，得到丰富的图像特征。该模块将网络中第 1 层和第 3 层卷积后的结果拼接后输入到第 4 层卷积中，这种结构提升了浅层网络中原始信息的比重，有效的提高网络检测小目标的能力。另外在残差网络部分采用了在 ECA[31] 注意力基础上改进的 ECAM 注意力机制。该模块具有较强的自适应性和高效性，为网络提供了强大的特征表示能力，通过调整不同通道的输出权重可以更好的实现模型对关键特征的筛选，有助于提升模型在复杂背景和噪声环境中对缺陷目标的检测能力。ECAMC 的结构如图 2 所示。

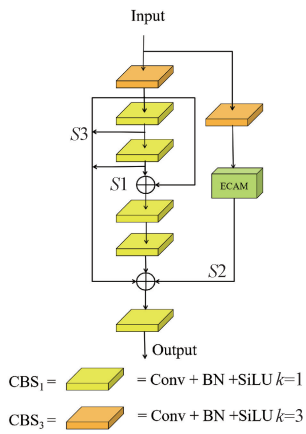

图 2　ECAMC 的结构

Fig. 2　The structure of ECAMC

因为单一的池化操作可能会丢失一些重要的信息，所以提出的 ECAM 注意力采用最大池化和平均池化的并联的方式进行通道权重计算。该注意力具体工作流程是首先分别对输入特征图进行全局最大池化（global max pooling，GMP）和全局平均池化（global average pooling，GAP），实现将 $\boldsymbol{W}\times\boldsymbol{H}\times\boldsymbol{C}$ 大小的特征向量转化为 $1\times1\times\boldsymbol{C}$ 大小。通过每个通道及其 k 个邻域进行局部跨通道交互信息得到每个通道相应的权重值，然后将归一化后的结果与原通道相乘得到具有通道注意力的特征，最后通过加和（Addition）操作融合在一起，生成新的特征图。其中，最大池化可以捕捉特征图中最显著的特征，而平均池化则提供了特征图的总体概况。两种池化操作通过并联可以互相补充，减少信息丢失，保留图像的显著特征和整体信息，增加了特征的丰富性。使模型更鲁棒地处理噪声和图像中的局部变化，提高模型的适应性和泛化能力，还不会显著增加计算量，实现计算效率和精度之间更好的平衡。ECAM 示意图如图 3 所示。

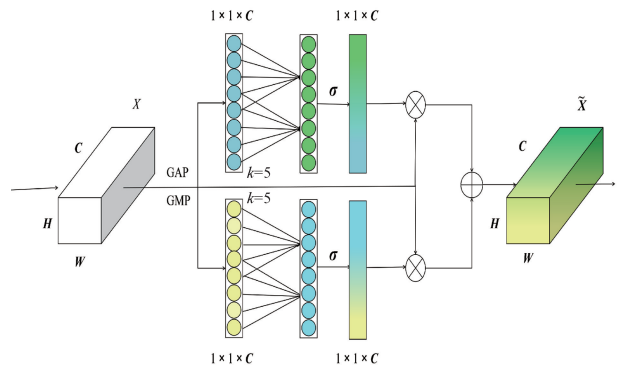

图 3　ECAM 示意图

Fig. 3　Schematic diagram of ECAM

1.2　CNT 输出模块

在风力发电机叶片表面缺陷检测过程中，相关缺陷数据集图片基本为无人机拍摄，除了背景环境复杂以外，部分风机叶片表面缺陷呈现出的金属色在不同光照条件下会表现出不同的反射特性，导致图像质量受到影响，为了保障检测的准确率和实时性，在特征提取部分提出了 CNT 模块。

CNT 模块中首先使用了 ConvNext 模块[32]，ConvNext 模块借鉴了（vision transformer，ViT）的一些设计思想，并且优化了传统的的 CNN 架构。通过引入 7×7 大小的深度可分离卷积（depthwise conv，DW），类似于 Transformer 中的多头自注意力机制，捕捉更广泛的上下文信息，提高了模型对图像中长距离依赖关系的理解能力。另外，在卷积块后使用层归一化（Layer Normalization）操作，有助于稳定训练过程并加速收敛。在结构方面，ConvNext 模块采用了类似于 ViT 中的多层感知机（modified mlp block，MLP）结构，即两层全连接层，中间夹带一个 GELU 激活函数，将这种结构融入到卷积网络中，代替了传统的卷积-归一化-激活函数的组合，增强了模型的表达能力。最后通过增加 LayerScale 层保证训练的稳定性。ConvNext 模块结构如图 4 所示。

CNT 模块通过整合上一层网络（ConCat 层）丰富的特征信息，可以输出到 head 层得到预测结果，由于直接使用 ConvNext 模块输出的结果并不理想，要达到更高的性能，则需要更复杂的数据预处理或增强步骤，鉴于此，所提出的 CNT 模块实现过程大体可以表示为：

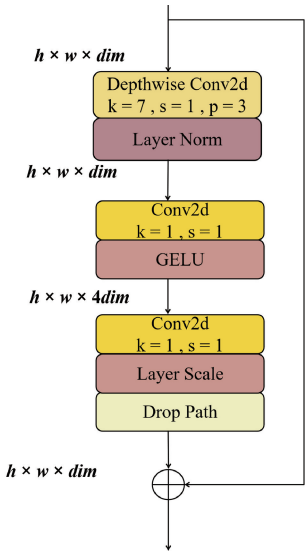

图 4　ConvNext 结构

Fig. 4　ConvNext structure

$$Output1 = CBS_1(\mathrm{ConvNext}(Input)) \tag{5}$$

$$C1 = CBS_1(CBS_1(\mathrm{ConvNext}(Input))) \tag{6}$$

$$Output2 = \mathrm{Concat}(C1 + Output1) \tag{7}$$

式中：$Output1$ 示经过一次 CBS 卷积提取到的特征信息；$C1$ 表示经过两次 CBS 卷积提取到的特征信息；$Output2$ 输出结果将输入到 head 层进行预测。

CNT 模块使用 ConvNext 模块的下一层卷积的输出作为第 1 部分，相较于使用 ConvNext 模块额外添加卷积进行输出，优势在于该部分的输出结果可以作为网络下一层的输入，尽可能减少参数量的同时并不会影响网络的整体运行，由于 ConvNext 的输入数据来源是由特征提取网络和浅层网络拼接后的 ConCat 层，该层含有丰富的特征信息，经过 ConvNext 输出后信息未得到充分整合，模块第 2 部分使用两次 CBS 模块进行特征融合的同时调整通道数，避免了拼接后的特征图送入 RepConv 网络导致计算量增大的问题，便于 head 网络进行预测操作。CNT 模块使图像特征得到充分的整合，有利于提高模型整体的泛化能力。CNT 模块示意图如图 5 所示。

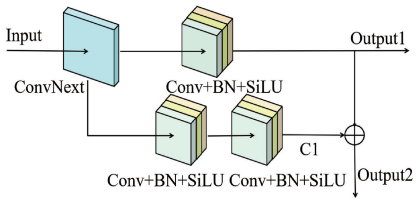

图 5　CNT 示意图

Fig. 5　Schematic diagram of CNT

1.3　MSPD 模块

由于风机叶片图片信息复杂，当需要检测的多个缺陷目标出现混叠现象时，容易造成漏检现象，并且特征提取网络经过一系列的上采样和下采样操作后，会造成图像中较小目标的信息丢失，为此，提出了 MSPD 模块，旨在降低模型复杂度的同时，增大特征图感受野，提高模型检测的召回率。

MSPD 模块实现过程大体可以表示为：

$$G1 = CBS_1(\mathrm{SPD}(CBS_1(Input))) \tag{8}$$

$$Output = G1 + CBS_1(\mathrm{Maxpool}(Input)) \tag{9}$$

式中：$G1$ 表示经过 SPD 卷积主干部分输出的特征信息。

MSPD 模块分为两部分组成，第 1 部分采用 SPD[33] 卷积代替传统 CNN 架构中的步长卷积和池化层，将输入特征图中的空间维度降维至通道维度，从而在不丢失信息的情况下增加特征图的深度，同时确保了通道信息的完整性，提高网络在处理低分辨率图像和小目标对象时的性能。

因为模型中使用的是 Scale 为 2 的 SPD 卷积。经过 SPD 卷积后特征图变为原来的 1/4 但通道数变为原来的 4 倍，因此增加了卷积核大小为 1×1 的非步长卷积对通道数进行调整。这种结合使用 SPD 层和非步长卷积层的方法，使得 CNN 能够更好地迎接小物体和低分辨率图像中的挑战，提高了模型在这些复杂场景下的性能和鲁棒性[34]。SPD 卷积示意图如图 6 所示。

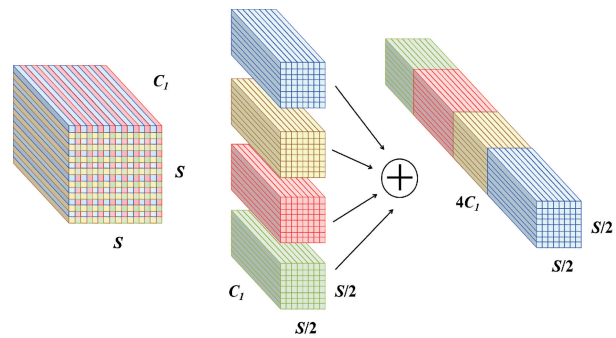

图 6　SPD 示意图

Fig. 6　Schematic diagram of SPD

在 MSPD 模块内部为了尽可能保留图像显著的特征，减少图像中噪声的影响，同时保证特征图的一致性方便特征融合，在模块第 2 部分添加了自适应最大池化操作。通过 SPD 卷积和自适应最大池化二者结合，模型可以更好地处理处于重叠下的待检测目标，获得更大感受野的同时，更加关注缺陷目标的空间结构，高效的捕捉风机缺陷图像中的关键特征，提升网络对目标的检测能力。MSPD 模块示意图如图 7 所示。

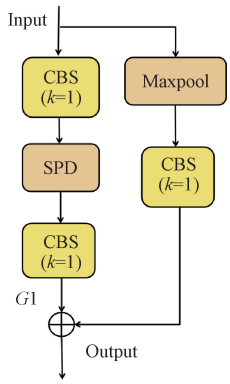

图 7　MSPD 示意图

Fig. 7　Schematic diagram of MSPD

2　实验结果与分析

2.1　实验环境

研究所用实验环境基于 64 位 Windows 10 操作系统和 Pytorch2.0 框架，使用的集成开发环境（integrated development，IDE）编程环境为 Pycham，其中 Python 版本为 3.8，并利用版本为 11.8 的 CUDA 进行 GPU 加速，每轮共训练 300 个 epoch，优化器使用 SGD，初始学习率设置为 0.001。实验以及消融实验所用设备配置如表 1 所示，训练参数如表 2 所示。

表 1　硬件平台和软件平台的参数

Table 1　Parameter configuration of hardware and software platforms

Configuration	模型
CPU	Intel(R) Xeon(R) Platinum 8352V CPU @ 2.10 GHz
GPU	NVIDIA GeForce RTX 4090
Operating system	Windows 10
Running memory	32 G
Video memory	24 G
Language and Framework	Anconda3 + Python3.8 + Pytorch2.0.0

表 2　训练参数配置

Table 2　Training parameter configuration

训练参数	Configuration
Momentum parameter	0.937
Initial Learning rate	0.001
Batch Size	16
Epochs	300
Optimizer	SGD

2.2　实验数据集

实验研究中用到的数据集 1 是由无人机巡检过程中拍摄的黄河风力发电公司的风力发电机图像。包含叶片以及轮毂等不同位置统一标注的单类别损伤（damage），该数据集中的图像存在单一和多目标损伤缺陷情况，在实验中用于测试模型的单分类多目标检测能力，图像尺寸为 586×371 大小，共计 2 191 张图片，6 480 个缺陷目标。该数据集为风机叶片缺陷检测提供复杂而真实的自然环境情况下的数据集。

数据集 2 是由根据 Roboflow 网站提供的无人机拍摄的风力发电机缺陷图像和部分室外场景无人机拍摄的图像，Roboflow 拍摄环境较好，图像具有较好的像素，包含 3 584 张 1 280×1 080 尺寸大小的图片，分为油污（oil-leakage）、脏污（dirt）、侵蚀（LE-erosion）、PU 胶皮损伤（PU-tape）、油漆剥落（paint）5 类共 5 371 个缺陷。数据集 2 标注后的样本数量分布情况如图 8 所示。

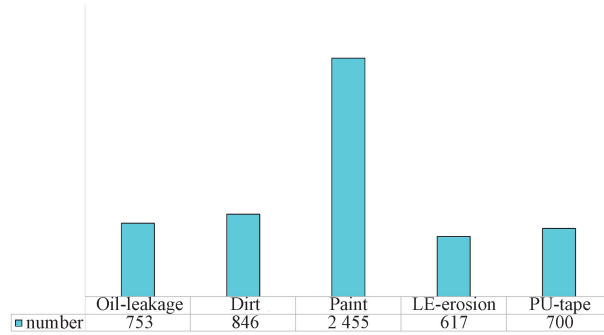

图 8　风力发电机数据集中各类缺陷数量及占比

Fig. 8　The number and proportion of various defects in the wind turbine data set

在实验中将数据集按照 7∶2∶1 的比例随机划分为训练集、验证集和测试集。数据集中部分示例图片如图 9 所示。

2.3　评价指标

ECSMNet 网络模型在完成训练后，在测试集上进行整体性的评估，主要采用了目标检测领域常用的准确率（precision）、召回率（recall）以及 mAP@0.5 作为评价指标。准确率是指所有检测出的缺陷目标中检测正确的概率，用于衡量模型的精确性，召回率是指所有缺陷目标中，模型预测正确的比例。mAP 是对准确率和召回率的综合考量，用于全面评估模型的有效性和可靠性。mAP@0.5 时的平均精度代表网络模型设置判断正负样本的交并比（intersection over union，IoU）阈值为 0.5，其中，T_P 是指正确的预测到缺陷的数量，F_P 则是将目标误检为缺陷的数量，F_N 表示未检测出的缺陷的数量。

准确率公式如式（10）所示。

$$P = \frac{T_P}{T_P + F_P} \tag{10}$$

图 9 风力发电机数据集图像示例

Fig. 9 Wind turbine data set image example

召回率公式如式(11)所示。

$$R = \frac{T_P}{T_P + F_N} \tag{11}$$

平均精度(AP)公式如式(12)所示。

$$AP = \int_0^1 P(R)\,\mathrm{d}R \tag{12}$$

mAP 公式如式(13)所示。

$$mAP = \frac{\sum_{i=1}^{N} AP_i}{N} \tag{13}$$

此外,将检测速度作为判断模型性能的关键性指标,通过每秒检测帧速(FPS)作为速度指标,其表达式如式(14)所示。

$$FPS = \frac{1}{Processing\ \ time\ \ per\ \ frame} \tag{14}$$

2.4 消融实验结果分析

为了验证 ECSMNet 模型的有效性,以 YOLOv7 为基准,对 3 处改进模块进行了消融实验,其中 Dataset 值为 1 或 2 分别代表使用数据集 1 和数据集 2 进行消融试验,实验 1 和实验 5 为两个数据集基准模型的测试数据,以下实验环境以及参数均保持一致,消融实验结果如表 3 所示。

从表 3 实验 1 可以看出使用数据集 1 进行测试,YOLOv7 基准模型的准确率为 73.8%,召回率为 67.7%,mAP@0.5 达到 73%。实验 2 在单独使用 ECAMC 模块的情况下,准确率提升了 1.1%,召回率提升了 2.2%,mAP 值也得到 1.4%的提升,从实验 5 和实验 6 的对比中也可以看出,在数据集 2 上使用 ECAMC 模块准确率也提升了 0.9%,这表明 ECAMC 模块将不同深度的特征融合,提高了网络学习特征的能力,其中的 ECAM 注意力可以结合输入数据和上下文信息生成相应的权重,帮助模型在处理数据的同时聚焦于待检测的缺陷部分,忽略无关的背景信息,提高模块的提取特征能力。

虽然 ECAM 注意力对计算量几乎没有什么影响,但是 ECAMC 模块为了取得召回率方面的提升,对不同深度网络进行残差连接,导致模型参数量增加,从帧率值可以看出检测速度有所下降。

表 3 消融实验各个改进点效果对比

Table 3 Comparison of the effects of various improvement points in ablation experiments

实验序号	Baseline	ECAMC	CNT	MSPD	Datasets	*P*/%	*R*/%	mAP@0.5/%	帧率/fps
1	√				1	73.8	67.7	73.0	53.6
2	√	√			1	74.9	69.9	74.4	48.2
3	√	√	√		1	75.7	69.5	75.4	56.2
4	√	√	√	√	1	77.3	70.0	76.1	55.8
5	√				2	94.4	93.5	95.6	69.5
6	√	√			2	95.3	93.8	96.2	63.2
7	√	√	√		2	95.5	93.8	96.5	72.8
8	√	√	√	√	2	96.0	94.0	96.7	72.2

注:√代表使用了此策略

从实验 3 和实验 7 的对比可以看出当引入 CNT 模块时数据集 1 上准确率得到 0.8%的提升,mAP 也得到 1%的提升,在数据集 2 上也有小幅度提升,这是因为 CNT 模块可以使模型更加关注上下文的信息,模块内部的 ConvNext 模块相较于 YOLOv7 降低了网络的复杂度,避免了复杂的计算过程,虽然牺牲了少许的召回率,但模块本身的反瓶颈结构让信息在不同维度特征空间之间转换时避免压缩维度带来的信息损失。使得网络整体检测效果得到一定的提升,FPS 也得到一定的提升,弥补了第一处改进方法导致检测速度下降的不足之处。

通过实验 4 和实验 8 的对比可以看出,ECSMNet 模型在使用 MSPD 模块情况下在两个数据集的准确率分别达到了 77.3%和 96.0%,这是因为 SPD 卷积在处理低分辨率图像和小物体时相比传统的 CNN 模型避免了步长卷积造成细粒度信息丢失现象,增大了图像感受野,在实现下采样操作的同时减少信息的损失,通过和自适应最

大池化的结合，保留了更多的细节和显著的特征信息，提高了模型鲁棒性以适应不同的场景，通过消融实验可以证明每一个改进模块的有效性。

由于数据集 2 中图像质量整体偏好，具有较高的像素分辨率，在油污、脏污、侵蚀、PU 胶皮 4 类损伤图像多为单一目标，数据集中缺陷数量相对较少，标注框较大，待检测缺陷目标显著，使用基准模型已经取得了很好的效果，所以 ECSMNet 模型的优势并不明显，针对缺陷目标中基数最大的油漆剥落类，AP 值从 83.1% 提高到 86.6%，原因是因为该类存在大量的小目标缺陷，单幅图像中存在多个缺陷，YOLOv7 算法容易出现漏检和误检现象，实验结果可以看出 ECSMNet 对该类存在的小目标检测效果更好。ECSMNet 与 YOLOv7 各类缺陷检测精度对比如图 10 所示。各类别缺陷检测效果对比如图 11 所示。

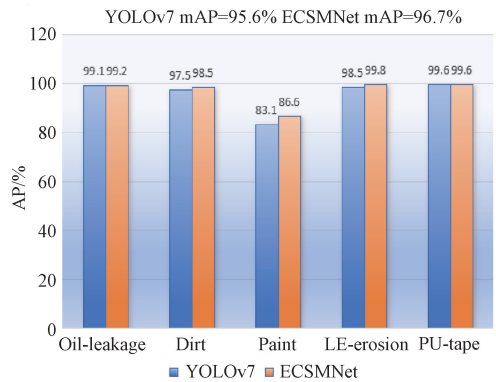

图 10　各类缺陷检测精度对比

Fig. 10　Comparison of various defect detection accuracy

2.5　对比实验分析

为了验证提出的 ECSMNet 模型的有效性，在保持配置环境以及其他参数保持一致的情况下，使用现有的风力发电机叶片数据集对 SSD、Faster R-CNN、YOLOv7、YOLOv8、YOLOv9、以及所提出的 ECSMNet 在各项指标进行对比实验，采用准确率、召回率、mAP@0.5 来评价模型的性能好坏，对比实验结果如表 4 所示。

表 4　ECSMNet 模型与主流模型对比

Table 4　The comparison diagram of ECSMNet model and mainstream model

模型	*P*/%	*R*/%	mAP@0.5/%
SSD	70.2	64.4	70.1
Faster R-CNN	67.4	60.5	68.9
YOLOv7	73.8	67.7	73.0
YOLOv8	74.5	68.2	73.8
YOLOv9	75.2	68.5	74.2
本文	77.3	70.0	76.1

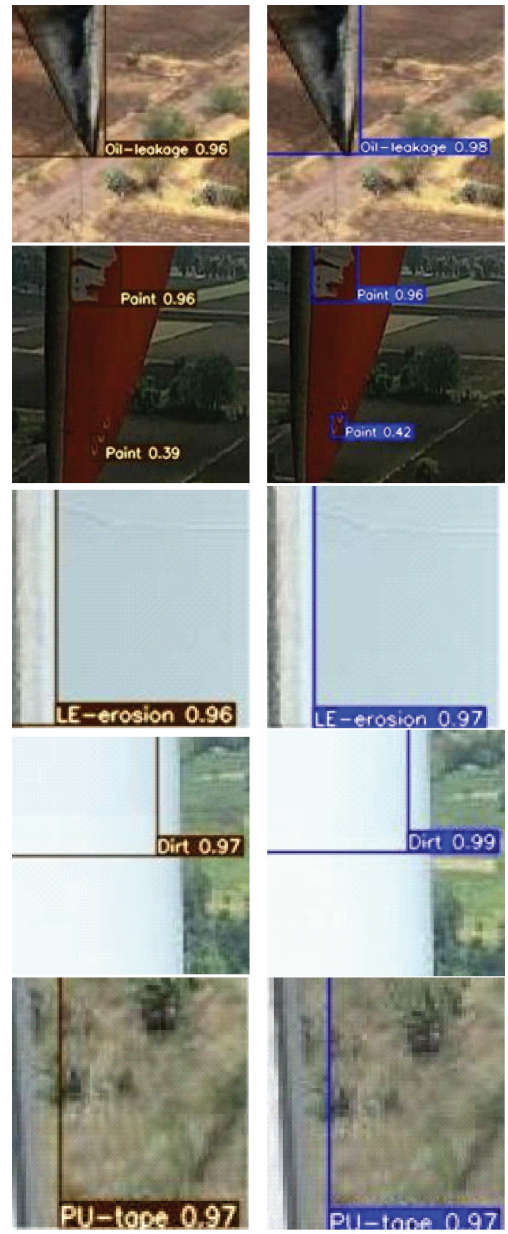

(a) YOLOv7　(b) ECSMNet

图 11　各类缺陷检测结果对比

Fig. 11　Comparison of various defect detection results

因为研究使用数据集环境较复杂，目前主流的算法在该数据集的检测精度并不高，其中作为单阶段目标检测算法的代表 SSD 算法具有良好的多尺度结构框架，但是其网络从浅层卷积层获取特征过少，容易忽略图像中的较小目标，虽然在准确率方面表现尚可，但召回率方面并不突出。Faster R-CNN 模型面对小目标的情况下很难提取到充分的特征信息，检测效果并不理想，在 YOLO 整体系列中，YOLOv8 网络相较于 YOLOv7 网络有小幅度的提升，YOLOv9 作为新型模型通过引入可编程梯度信息（PGI）和广义高效层聚合网络（GELAN），优化了学习

过程和网络结构,进而提升了模型在检测任务上的准确性,在实验中各个方面指标表现较好,mAP@0.5达到了74.2%,但是本文提出的ECSMNet模型有更明显的优势,这是因为模型使用了高效的特征提取模块,提升了网络整体的检测能力,通过引入注意力机制进一步提高了模型应对复杂环境的检测能力。

不同算法检测效果对比如图12所示,研究中使用的主流模型都能取得较好的检测效果,其中Faster R-CNN算法中的ROI Pooling操作将不同大小的候选区域映射到固定大小的特征图上,会对图像中较小目标区域造成信息的损失或扭曲现象,最终导致对小目标检测能力薄弱。SSD算法和YOLO系列算法在较大缺陷上与算法检测效果相当,面对图像中较小目标,检测效果并不好。而ECSMNet模型拥有良好的特征提取和多尺度特征融合能力,能够较好的融合浅层网络特征,对于细小的缺陷目标有一定的优势,可以更准确的检测出目标缺陷的位置和数量信息。

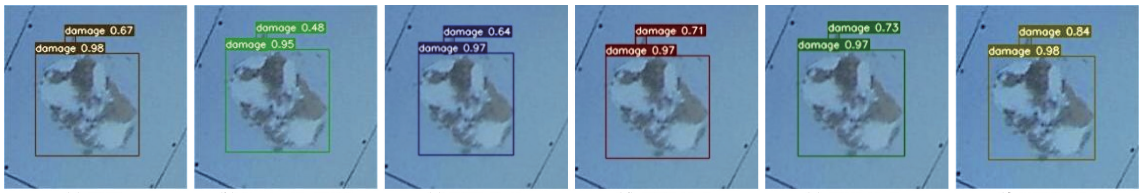

(a) SSD　(b) Faster R-CNN　(c) YOLOv7　(d) YOLOv8　(e) YOLOv9　(f) ECSMNet

图12　不同算法检测效果对比

Fig. 12　Comparison of detection effects of different algorithms

3　结　论

针对风力发电机叶片背景环境复杂,小目标缺陷多以及目标重叠等问题,提出了一种基于ECSMNet网络的缺陷检测方法。首先针对实际检测过程中遇到的各种复杂检测场景,提出改进的ECAM注意力机制,使得所用ECAMC主干提取网络能够更好的提取目标信息,关注图像中的较小目标,提高算法的检测效率。同时模型采用了ConvNext模块进行特征提取,提高了网络对低质量图像的检测能力,此外,提出的CNT模块可以融合不同网络深度中的特征信息,保证neck层综合深层信息和浅层信息的能力,提高模型的召回率。最后使用MSPD模块进行下采样,保留显著特征的同时,减少较小目标的信息丢失,使网络获得更多的细节信息,增强特征的获取能力,提高模型在相对较为复杂环境下风机叶片缺陷检测的稳定性。

实验结果表明,ECSMNet网络可以更好的提升检测的速度和精度,有效的提高对风机叶片中小目标的检测能力,减少缺陷的漏检,误检情况,具有良好的工程前景。在准确率、召回率、mAP等性能指标下相较于目前主流模型有更好的效果,在工业部署中有一定的应用价值,在未来的研究中将优化网络结构,扩充现有的数据集,提高模型的适应性和稳定性,更加适应实际应用中可能遇到的情况。

参考文献

[1] 谭兴国, 张高明. 基于无人机巡检的风机叶片表面缺陷检测技术[J]. 电测与仪表, 2025,62(3):183-189.
TAN X G, ZHANG G M. Surface defect detection technology of fan blade based on UAV inspection[J]. Electrical Measurement and Instrument, 2024, 2025, 62(3):183-189.

[2] 曾勇刚, 陈丽城, 申毅莉, 等. 海上风电场风机叶片巡检方法研究[J]. 装备维修技术, 2024(3):91-93,97.
ZENG Y G, CHEN L CH, SHEN Y L, et al. Research on inspection method of wind turbine blades in offshore wind farm [J]. Equipment Maintenance Technology, 2024(3): 91-93, 97.

[3] 丁博, 王涛, 张颖, 等. 风机叶片表面缺陷的小样本检测方法[J/OL]. 哈尔滨理工大学学报,1-10[2025-04-21]. http://kns.cnki.net/kcms/detail/23.1404.N.20240405.1707.008.html.
DING B, WANG T, ZHANG Y, et al. Small sample detection method for surface defects of wind turbine blades [J/OL]. Journal of Harbin University of Science and Technology, 1-10 [2025-04-21]. http://kns.cnki.net/kcms/detail/23.1404. N. 20240405.1707.008.html.

[4] CHEN L, ZHANG M Y, LI D J, et al. Infrared thermographic evaluation of thermal release phenomena in polycarbonate during plastic deformation[J]. Advanced Industrial and Engineering Polymer Research, 2023, 6(1): 39-48.

[5] YUE Y, HUO F, FAN Y, et al. Application of X-ray detection technology in routine tests of high voltage bushings and arresters[J]. IOP Conference Series: Earth

and Environmental Science, 2019, 237(3): 032097.

[6] ZUO H, YANG Z B, XU C B, et al. Damage identification for plate-like structures using ultrasonic guided wave based on improved music method [J]. Composite Structures, 2018(203): 164-171.

[7] GHOLIZADEH S, LEMAN Z, BAHARUDIN B. A review of the application of acoustic emission technique in engineering[J]. Structural Engineering and Mechanics, 2015, 54(6): 1075-1095.

[8] WANG K, DONG X, KOJLER M H, et al. Advances in optical fiber sensors based on multimode interference (MMI): A review[J]. IEEE Sensors Journal, 2020, 21(1): 132-142.

[9] LIN P, LIU J. Detection and analysis of large-scale WT blade surface cracks based on UAV-taken images[J]. IET Image Processing, 2018, 12(11): 2059-2064.

[10] CAO L Y, TAO T, LIU Y Q, et al. A field study of ice accretion and its effects on the power production of utility-scale wind turbines[J]. Renewable Energy, 2021, 167: 917- 928.

[11] 汤占军, 孙栋钦, 李英娜, 等. 改进 FA 优化 SVM 的风机叶片裂纹检测模型[J]. 可再生能源, 2022, 40(9): 1189-1194.
TANG ZH J, SUN D Q, LI Y N, et al. Fan blade crack detection model based on improved FA optimized SVM[J]. Renewable Energy, 2022, 40 (9): 1189-1194.

[12] 仇梓峰. 基于计算机视觉的风机叶片表面损伤检测研究[D]. 北京: 北京交通大学, 2019.
QIU Z F. Research on surface damage detection of wind turbine blades based on computer vision [D]. Beijing: Beijing Jiaotong University, 2019.

[13] YU J F, HE Y Z, ZHANG F, et al. An infrared image stitching method for wind turbine blade using UAV flight data and U-Net [J]. IEEE Sensors Journal, 2023, 23(8): 8727-8736.

[14] 彭一誉, 何赟泽, 虞俊锋, 等. 风机叶片内部缺陷日光激励动态热成像方法研究[J]. 电子测量与仪器学报, 2024, 38(1): 64-71.
PENG Y Y, HE Y Z, YU J F, et al. Research on solar-excited dynamic thermal imaging method for internal defects of wind turbine blades [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(1): 64-71.

[15] 周绍鸿, 方新建, 刘鑫怡, 等. 基于迁移学习和改进 Faster R-CNN 遥感影像飞机目标检测[J]. 机电工程技术, 2024, 53 (5): 172-177.
ZHOU SH H, FANG X J, LIU X Y, et al. Based on transfer learning and improved Faster R-CNN remote sensing image aircraft target detection [J]. Electromechanical Engineering Technology, 2024, 53(5): 172-177.

[16] 邓林峰, 王琦, 郑玉巧. 基于改进残差网络的风电轴承故障迁移诊断方法[J]. 振动工程学报, 2024, 37(2): 356-364.
DENG L F, WANG Q, ZHENG Y Q. Fault migration diagnosis method of wind power bearing based on improved residual network [J]. Vibration Engineering Journal, 2024, 37 (2) : 356-364.

[17] 向宽, 李松松, 栾明慧, 等. 基于改进 Faster RCNN 的铝材表面缺陷检测方法[J]. 仪器仪表学报, 2021, 42(1): 191-198.
XIANG K, LI S S, LUAN M H, et al. Surface defect detection method in aluminum based on improved YOLOv4[J]. Chinese Journal of Scientific Instrument, 2021, 42(1): 191-198.

[18] 茅宇琳. 基于无人机采集图像的风机叶片多种表面缺陷检测研究[D]. 北京: 北京交通大学, 2020.
MAO Y L. Research on detection of multi-type surface defects of wind turbine blades based on images collected by UAV[D]. Beijing: Beijing Jiaotong University, 2020.

[19] 周晓彦, 王珂, 李凌燕. 基于深度学习的目标检测算法综述[J]. 电子测量技术, 2017, 40(11): 89-93.
ZHOU X Y, WANG K, LI L Y. Review of object detection based on deep learning [J]. Electronic Measurement Technology, 2017, 40(11): 89-93.

[20] 龙乐云, 周腊吾, 刘淑琴, 等. 改进 YOLOv5 算法下的输电线路外破隐患目标检测研究[J]. 电子测量与仪器学报, 2022, 36(11): 245-253.
LONG L Y, ZHOU L W, LIU SH Q, et al. Identification of hidden damage targets by external forces based on domain adaptation and attention mechanism[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(11): 245-253.

[21] CHEN K, LI H T, LI C S, et al. An automatic defect detection system for petrochemical pipeline based on cycle-GAN and YOLOv5 [J]. Sensors, 2022, 22(20): 7907.

[22] WU H F, HU Y L, WANG W J, et al. Ship fire detection based on an improved YOLO algorithm with a lightweight convolutional neural network model[J]. Sensors, 2022, 22(19): 7420.

[23] SUN L S, XU Y, RAO Z K, et al. YOLO algorithm for long-term tracking and detection of escherichia coli at different depths of microchannels based on microsphere positioning assistance [J]. Sensors, 2022, 22(19): 7454.

[24] ZHANG Y, GUO Z Y, WU J Q, et al. Real-time vehicle

detection based on improved YOLOv5 [J]. Sustainability, 2022, 14(19): 12274.

[25] 季利鹏, 吴世龙, 聂涛, 等. 基于改进 SSD 的风机叶片表面缺陷检测方法[J]. 飞控与探测, 2023, 6(3): 63-71.
JI L P, WU SH L, NIE T, et al. Wind turbine blade surface defect detection method based on improved SSD [J]. Flight control and detection, 2023, 6(3): 63-71.

[26] QIU Z F, WANG S, ZENG Z, et al. Automatic visual defects inspection of wind turbine blades via YOLO-based small object detection approach [J]. Journal of Electronic Imaging, 2019, 28(4): 043023.

[27] 郝帅, 杨磊, 马旭, 等. 基于注意力机制与跨尺度特征融合的 YOLOv5 输电线路故障检测[J]. 中国电机工程学报, 2023, 43 (6): 2319-2331.
HAO SH, YANG L, MA X, et al. YOLOv5 transmission line fault detection based on attention mechanism and cross-scale feature fusion[J]. Proceedings of the CSEE, 2023, 43 (6): 2319-2331.

[28] ZHANG T, JIN B, JIA W J. An anchor-free object detector based on soften optimized bi-directional FPN[J]. Computer Vision and Image Understanding, 2022, 218: 103410.

[29] 张银胜, 杨宇龙, 吉茹, 等. 改进 YOLOv5s 的风力涡轮机表面缺陷检测[J]. 电子测量与仪器学报, 2023, 37(1): 40-49.
ZHANG Y SH, YANG Y L, JI R, et al. Improved YOLOv5s wind turbine surface defect detection [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37 (1) : 40-49.

[30] LEI M, WANG X, WANG M, et al. Improved YOLOv5 based on multi-strategy integration for multi-category wind turbine surface defect detection [J]. Energies, 2024, 17(8): 1796.

[31] WANG Q, WU B, ZHU P, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks[C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2020: 11531-11539.

[32] WANG CH T, WANG X M, ZHAI J L, et al. A lightweight convolutional medical segmentation algorithm based on ConvNeXt to improve UNet [J]. Journal of Intelligent & Fuzzy Systems, 2024, 46(2): 4077-4092.

[33] SUN R Y, FAN H, TANG Y J, et al. Research on small target detection algorithm for UAV inspection scene based on SPD-conv[C]. Donghua Univ. (China), 2024.

[34] ZHANG Y SH, YANG Y L, SHAN H L, et al. surface defect detection of wind turbine based on lightweight YOLOv5s Model[J]. Measurement, 2023, 222(10): 113222.

作者简介

姜永祺, 2022 年于鲁东大学获得学士学位, 现为南京信息工程大学硕士研究生, 主要研究方向为深度学习、图像处理。
E-mail: 1090251905@ qq. com

Jiang Yongqi received his B. Sc. degree from Ludong University in 2021. Now he is a M. Sc. candidate in Nanjing University of Information Science and Technology. His main research interests include deep learning and image processing.

单慧琳(通信作者), 2003 年于武汉大学获得学士学位, 2009 年于南京信息工程大学获得硕士学位, 现为南京信息工程大学和无锡学院副教授、硕士生导师, 主要研究方向为深度学习、图像处理等。
E-mail: shanhuilin@ nuist. edu. cn

Shan Huilin (Corresponding author) received her B. Sc. degree from WuHan University in 2003, M. Sc. degree from Nanjing University of Information Science and Technology in 2009. Now she is an associate professor and master's supervisor in Nanjing University of Information Science and Technology and Wuxi University. Her main research interests include deep learning and image processing.