

pyramid pooling, ASPP)加强小目标提取,替换 Xception 为 MBConv 进行轻量化操作,充分利用多尺度特征融合模块,缺陷分割率达 93.58%;文献[6](2022)针对芯片 X 线图像焊缝气泡缺陷整体与细节识别,采用 Mobile-Net 骨干的 U-Net 融合空间注意力机制 SAM、空间金字塔池化(space pyramid pool, SPP),平均像素精度达 88.50%,且对不同型号芯片具备较好泛化能力;文献[7](2023)针对发动机转子表面弱对比度微小缺陷,提出跳层连接、融合多尺度特征、添加注意力模块的 RCF 网络,像素提取准确率达 94.31%;文献[8](2024)提出全新多层次金字塔策略(multi-level pyramid strategy, MLPS)与邻居注意融合模块,分别加强特征信息交互、平衡空间与前后信息特征,在自制太阳能电池数据集、PSCDE 数据集上平均精度达 84.3%、98.35%。因此,根据对象特点优化提升相应语义分割方法可望达到较高像素提取率,也是各领域检测任务主流趋势^[9-10]。

为此,本文首先研究优化 VA-UNet 模型的 DR(digital radiography)图像缺陷分割方法,选用融合 VGG16^[5] 主干网络的 U-Net^[11]语义分割模型,通过添加 ASPP^[12]空间池化金字塔加强特征提取,设计结合 Dice^[13]损失 + BCE^[14](binary cross entropy)损失的混合损失函数改善优化效果,有效提高缺陷分割准确率。采用自制线夹数据集,验证优化 VA-UNet 语义分割模型科学性、有效性;最后,再结合模型预测分割结果与相关定量分析的等级评定方法,实现耐张线夹压接 DR 缺陷危害严重性评估^[15-17]。

1 应用 VA-UNet 的图像缺陷分割方法

图 1 为本文提出的应用 VA-UNet 耐张线夹 DR 图像缺陷分割流程图,包括数据集准备、模型训练、缺陷分割等 3 个步骤。其中数据集准备步骤中,在合作企业南方电网获取耐张线夹压接 DR 图像,经过标注与相关数据增强而获得缺陷数据集;模型训练步骤中,在数据集上应用优化 U-Net 模型训练、收敛,得到最优模型权重;缺陷分割步骤中,在待检线夹图片上推理预测,最终获得缺陷掩膜信息供后续分级评定。




图 1 应用 VA-UNet 耐张线夹 DR 图像缺陷分割流程图
Fig.1 Flowchart of defect segmentation of DR image using VA-UNet tension clamp

图 2 为 X 光图像耐张线夹检测区域图片,包括区域 A、B、C 三个检测区域,即钢锚与铝管压接区域 A、钢锚与芯线压接区域 B、铝管与钢芯绞线压接区域 C,根据它们的缺陷情况进行分类及评级。




图 2 X 光图像耐张线夹检测区域
Fig.2 X-ray image of the detection area of tension clamp

表 1 为缺陷严重程度分级示例,如 A 区有钢锚尾部漏压缺陷,根据凹槽未压数量占比 β_{NR} 判定为属于“一般缺陷(Minor)”、“重大缺陷(Major)”其中的一种,图例为“一般缺陷(Minor)”;B 区存在有钢锚管腔体空隙缺陷,根据空腔跨距占比 γ_{CS} 判定为属于“重大缺陷(Major)”、“紧急缺陷(Critical)”其中的一种,图例为“重大缺陷(Major)”;C 区存在有钢芯断裂缺陷,直接判定为“紧急缺陷(Critical)”。

表 1 缺陷严重程度分级示例
Table 1 Example of the defect severity rating

区域	缺陷样例	严重等级
A 区		一般缺陷 (Minor)
B 区		重大缺陷 (Major)
C 区		紧急缺陷 (Critical)

主流目标检测耐张线夹压接缺陷检测方法往往仅能定位与识别缺陷^[18-19],若要结合具体特征如凹槽漏压占比 β_{NR} 、空腔跨距占比 γ_{CS} 等进行危害严重程度评定,需采用更为细致目标提取方法,如语义分割方法,通过捕捉像素级区域并赋予语义标签,获得缺陷掩膜信息,利于后续图像后处理及量化缺陷特征,完成分级评定目标。

面向耐张线夹图像缺陷存在灰度图像目标与背景差异小、语义信息易丢失、缺陷目标对象小及长宽比较大等特性,这给高准确性语义分割带来难度,为此本文针对缺陷特征,开展 U-Net 基础模型上的创新结构设计、调整策略研究,达到精确提取缺陷掩膜目标。

1.1 面向缺陷语义分割的 VA-UNet 网络结构

图 3 为本文提出的面向缺陷语义分割的 VA-UNet 模型结构图。该模型基于 U-Net 模型^[11],主要是考虑其与生物学医学图像相似,具有数据量少、目标占比小、检测要求高

等特点。由于 U-Net 网络编码结构层次较浅,学习能力受限,为提高缺陷特征提取水平,采用 VGGNet 作为特征提取器。VGG16^[10]具备多层卷积结构来捕捉不同层次特征,并以逐步扩大感受野加强联系上下文信息,因而具有良好图像特征提取和分析能力,以及可利用大型数据集预训练权重进行迁移学习,促使模型更快收敛,能有效提高 U-Net 模型性能、泛化能力,故可选用 VGG16 作为 U-Net 主干网络形成包含解码器,与原编码器行成 VGG16-UNet 网络结构,完成线夹缺陷特征提取与形态分割工作。其中:

1) 编码器部分由 VGG16 前 13 个卷积层替换原 U-Net 作为特征提取网络。通过下采样方式,卷积核大小为

3×3 ,卷积核个数依次为 64、128、256 和 512,每个卷积步长(stride)为 1,填充(padding)为 1,不断提取输入图像特征。通过增加网络深度,引入非线性运算,增强网络非线性表达能力;使用 2×2 池化层减少参数量,从而简化网络结构又增强泛化能力^[20]。

2) 解码器部分采用双线性插值上采样模块,对应采样次数与编码器中池化层数目相同,并将 4 次上采样产生的特征图与编码器不同层级产生特征图进行拼接操作,完成高级语义特征与浅层特征相融合,改善上采样信息量,有效提升分割准确度。最后,用 1×1 卷积操作调整分割任务期望类别数,获得分割结果^[21]。




图 3 面向缺陷语义分割的 VA-UNet 模型结构图

Fig. 3 Structure diagram of VA-UNet model for defect semantic segmentation

1.2 添加 ASPP 模块多尺度特征提取

U-Net 基础模型针对尺寸跨度大、目标与背景相似的特征学习能力较差,且缺陷形态差异,如钢锚管凹槽压接缺陷为尺寸较小四边形、钢锚管芯线压接缺陷为跨度较大长方形,提升模型多尺度特征提取能力尤为重要。ASPP^[12]利用空洞卷积可有效捕获图像中多尺度上下文信息,提升模型对不同大小目标的分割能力,在图 3 中模型底层编码器末端融入 ASPP,适应不同尺度目标、进行多尺度特征融合,可实现模型特征提取多样性,丰富特征信息。图 4 为 ASPP 模块结构图^[11],由 1 个用于调整通道数量 1×1 标准卷积层、3 个用于单尺度提取的特征图信息重采样的扩张率分别为 2、4、6 且卷积核大小 3×3 的空洞卷积层、1 个用于下采样全局平均池化层并行组成。最后再利用双线性插值方法对图像上采样使 5 个分支分辨率相同,沿通道方向拼接叠加,经 1×1 卷积层融合,即可获取不同尺度缺陷特征。

1.3 L_{Dice} 与 L_{BCE} 混合损失函数构建

线夹缺陷掩膜占比较小,背景偏多,这里采用 Dice 损失函数 L_{Dice} 衡量目标与背景部分不平衡分割,令评估正类、负类相似程度用 Dice 系数表征,语义分割中人工分割真值图(Ground_truth)值与实际预测图值和二者交集分别为 $|X|$ 、 $|Y|$ 及 $|X \cap Y|$,则相似度量函数表示的 L_{Dice} 损




图 4 ASPP 模块^[11]

Fig. 4 ASPP module

失函数为^[13]:

$$L_{Dice} = 1 - Dice = 1 - \frac{2|X \cap Y|}{|X| + |Y|}, L_{Dice} \in [0, 1] \quad (1)$$

L_{Dice} 越接近 1,分割精度越高。

此外,耐张线夹钢锚管漏压缺陷部位在单张检测图片中占比小,数量多,若缺陷过小, L_{Dice} 训练结果值会发生剧烈震荡而影响训练过程,故可引入二元交叉熵 BCE 损失函数,即对数损失函数,常用于二元分类任务中用于衡量模型预测、真实标签二者差异,更着重于其中每个像素单元的预估概率,其计算值是目标和背景区域中所有像素交叉熵,则 L_{BCE} 损失函数为^[14]:

$$L_{BCE} = -|X| \log(|Y|) - (1 - |X|) \log(1 - |Y|) \quad (2)$$

这样若缺陷区域较小, L_{BCE} 受模型预测结果变化影响较小, 可缓解 L_{Dice} 带来影响; 若 L_{BCE} 训练时出现消失或爆炸问题, 则可由相对稳定 L_{Dice} 去平衡。为此, 本文提出一种 L_{Dice} 与 L_{BCE} 混合损失函数, 采用权重影响因子 μ 改变两个损失函数比重, 构造 $Loss$ 如下:

$$Loss = \mu L_{Dice} + (1 - \mu) L_{BCE}, \mu \in (0, 1) \quad (3)$$

上面从面向缺陷语义分割的 VA-UNet 网络结构、添加 ASPP 模块多尺度特征提取、 L_{Dice} 与 L_{BCE} 混合损失函数 3 个方面论述应用 VA-UNet 的图像缺陷分割方法, 具体效果如何, 下面将加以实验验证。

2 应用 VA-UNet 的图像缺陷分割实验

2.1 缺陷数据集制作与参数设置

本文初始数据图片采自南方电网合作公司, 由无人机搭载 DR 成像装备拍摄 X 光片, 地面终端计算机收集获得共 400 张图片, 作为耐张线夹缺陷原始数据集, 采用开源软件 Labelme 进行手动标记标签, 设置获得 json 格式文件。由于无人机和 X 射线机运行特性, 可能产生图片拍摄方向、背景亮度变化等问题, 为模拟真实图片情况并增强数据训练鲁棒性, 采用仿射变换、对比度变换、噪声扰动等数据增强方法获得图像共 1 120 张, 图 5 为部分数据集图片, 包含缺陷样例约 6 000 个, 标签为钢锚管压接、钢锚管芯线压接的缺陷与非缺陷共 4 种, 每张图像分辨率大小为 512×512 ; 训练集和测试集以 8:2 随机划分。




图 5 部分数据集图片
Fig. 5 Partial dataset images

实验采用搭载 NVIDIA GeForce RTX 3090 的 Pytorch 网络框架, 训练过程使用自适应矩估计优化器 (adaptive moment estimation, Adam)。设置初始学习率 Learning rate=0.000 1, 批量大小 Batchsize=8, 训练轮数 Epoch=300。

2.2 算法性能评价指标

语义分割中通常使用像素精度及 IoU (交并比) 的变体衡量算法精度^[22-23], 本文使用平均像素精度 (mean pixel accuracy, mPA)、平均交并比 (mean intersection over union, mIoU) 作为缺陷分割算法性能评价指标, 指标定义如下:

1) 设正样本检测为正样本数量、负样本误检为正样本数量、正样本误检为负样本数量分别为 TP 、 FP 、 FN , 类别数为 N , mIoU 有^[24]:

$$mIoU = \frac{1}{N+1} \sum_{n=0}^N \frac{TP_n}{TP_n + FP_n + FN_n} \times 100\% \quad (4)$$

mIoU 数值越大, 预测结果与真实标签重叠度越高。

2) mPA 是像素准确率 PA (pixel accuracy) 简单提升, 计算每个类别正确分类像素数占比的平均值, 适用于多分类的指标。设 P_{ii} 为第 i 类像素且被预测为第 i 类的像素数量, P_{ij} 为第 i 类像素但被预测为第 j 类像素的像素数量, 类别数为 N , mPA 有^[25]:

$$mPA = \frac{1}{N+1} \sum_{i=0}^N \frac{P_{ii}}{\sum_{j=0}^N P_{ij}} \times 100\% \quad (5)$$

mPA 数值越大, 各类别像素分类准确性高。

另外, 采用参数量 (Parameters) 反映模型大小、复杂程度; 每秒传输帧数 FPS (单位时间内处理的图片数量) 反映推理速度。

2.3 试验与结果分析

图 6 为损失函数 $Loss$ 随迭代次数变化线, 横坐标为迭代次数, 纵坐标为损失函数 $Loss$ 。可以看出, 次数增加, $Loss$ 趋于减少并在迭代次数接近 300 次时训练收敛, 图中上升和震荡现象, 可能是部分图像缺陷样本占比极小或添加噪声产生负面影响, 使得训练过程中有些批次训练效果不佳, 引起损失值起伏, 而随着迭代次数增加, 特征学习更加稳定, 数据信息利用更加全面, 最终各参数收敛, $Loss$ 值达到最小值, mIoU=84.14%、mPA=91.58%, 得网络模型最优参数。




图 6 损失函数 $Loss$ 随迭代次数变化曲线

Fig. 6 Loss function $Loss$ varies with the number of iterations

下面设计消融实验, 采用消融研究来描述去除网络某些部分过程, 更好地理解网络行为与性能, 证明本文 VA-UNet 的科学性、合理性、有效性。

消融实验用前面 2.1 节的数据集、参数设置, 对 U-net、VGG16-Unet、ASPP+VGG16-Unet、Loss+ASPP+VGG16-Unet (VA-UNet) 等模型模块行为进行研究, 表 2 为消融实验性能结果表。可以看出, U-Net 原始网络 mPA=84.13%、mIoU=76.82%; VGG16-Unet 将主干网络融合 VGG16, mPA=89.02%、mIoU=80.39%, mPA、mIoU 分别提高 4.89%、3.57%, 参数量少量增加, FPS 少许降低, 可见 VGG16 通过有效提高特征提取程度而大幅提升分割精度; ASPP+U-net 引入 ASPP 多尺度特征融合

模块, mPA = 89.27%、mIoU = 81.97%, mPA、mIoU 则分别提高 5.14%、5.15%, 几乎不增加参数量与减少 FPS, ASPP 自身卷积优势不仅不影响模型学习效率, 且通过丰富特征多样性、增强信息融合, 优化不同目标分割效果,; ASPP+VGG16-Unet 将二者同时融合, 则性能更优; 本文 VA-UNet 模型性能最优, mIoU = 84.14%、mPA = 91.58%, 分别提升 6.45%、7.32%, 添加混合 Loss 优化损失计算、调整训练过程, 有效提升检测精度并保持推理速度。由此表明 VA-UNet 在几乎不影响推理时间前提下, 各部分模型优化方法具备一定先进性, 总体检测精度、速度达到较高水平, 有望实现较为便捷高效模型部署。

表 2 消融实验性能结果

Table 2 Performance of ablation experiment				
模型名称	mPA/ %	mIoU/ %	参数量/ M	FPS/ fps
U-net	84.13	76.82	27.8	147.2
VGG16-Unet	89.02	80.39	29.4	144.6
ASPP+U-net	89.27	81.97	28.0	145.8
ASPP+VGG16-Unet	90.14	82.26	29.6	145.0
VA-UNet	91.58	84.14	29.6	144.6

为进一步验证 VA-UNet 模型泛化能力, 在公共数据集 VOC2012、MVTec AD 上开展实验。VOC2012 为自然图像数据集, 包含共 20 个不同类别的动物、交通工具等, MVTec AD 为工业表面缺陷检测的数据集, 包含 15 种不同类别工业产品的不同缺陷。表 3 为泛化实验性能结果, 由表可知 U-net、VA-UNet 的 mPA、mIoU 表现优良, 均在 80% 左右, 且 VA-UNet 各性能指标均优于 U-net, 证明本文模型兼备检测性能和泛化性能。

表 3 泛化实验性能结果

Table 3 Performance of generalization experiment			
数据集	模型	mPA/%	mIoU/%
VOC2012	U-net	83.54	78.80
	VA-UNet	86.17	81.28
MVTec AD	U-net	82.56	77.44
	VA-UNet	84.70	79.05

下面与目前主流模型检测应用效果比较, 验证本文 VA-UNet 先进性、实用性。表 4 为对比实验性能结果, 应用前面 2.1 节的数据集、参数设置对 FCN^[26]、SegNet^[27]、DABNet^[28]、ResUNet++^[29]、TransUnet^[30] 开展对比实验, 分别获得 mPA、mIoU 指标, 可见 VA-UNet 模型性能最优。FCN 的性能指标表现不及其他网络, 可能缘由为该模型较为适合于数据集类型多样、数据量较多的对象样本; SegNet、DABNet 同样基于编码-解码结构, 性能指标表现良好, 但针对耐张线夹数据集特点存在局限, 次于 U-

net; ResUNet++、TransUnet 作为 U-net 模型变体具备较优性能结果, 但针对耐张线夹缺陷特征适应性相对欠缺, 不及本文 VA-UNet 模型。

表 4 对比实验性能结果

Table 4 Performance of comparative experiment		
模型名称	mPA/%	mIoU/%
U-net ^[10]	84.13	76.82
FCN ^[26]	75.41	70.12
SegNet ^[27]	80.44	74.20
DABNet ^[28]	80.27	74.48
ResUNet++ ^[29]	84.80	77.81
TransUnet ^[30]	86.56	78.26
VA-UNet	91.58	84.14

为了直观体现不同模型分割效果, 选取四幅图像进行定性结果分析, 图 7 为不同模型可视化分割结果。可以看出, 针对凹槽压接区域(图中大实线框为小实线框放大图), VA-UNet 能准确区分并分割缺陷(放大图中虚线圆框部分)与非缺陷部位(放大图中虚线方框部分), 较基准 U-Net 更为精细准确, 而其它部分网络存在错误判断背景或缺少判断凹槽等问题; 针对钢锚管芯线压接情况, VA-UNet 能更为精确、规则分割出已压区域(深灰色区域②)、漏压区域(浅白色区域①), 其他网络存在边缘检测不清晰、压接部位识别缺失等问题。在本次分割任务中, VA-UNet 表现出一定优越性。

3 缺陷分级评定

经过 VA-UNet 模型预测分割获得较高准确度的缺陷掩膜, 而缺陷分级评定才是最终目标。根据电力工程实际检测与评估标准^[30-31], 耐张线夹缺陷危害严重性可定级为“一般缺陷(Minor)”、“重大缺陷(Major)”、“紧急缺陷(Critical)”三类, “一般缺陷(Minor)”不影响线路正常运行, 建议下次检修时整改耐张线夹缺陷部位; “重大缺陷(Major)”不影响线路正常运行, 但具有潜在安全隐患, 建议一周内加以消除; 急缺陷(Critical)”影响线路正常运行, 存在重大安全隐患, 建议立即解决。结合钢锚管压接、钢锚管芯线压接缺陷特点, 提出运用数量统计法、最小外接矩形法等辅助缺陷分级判断^[32-33]。

3.1 数量统计法

若得到钢锚管压接分割样本的缺陷凹槽数 N_d 与正常凹槽数 N_a , 则凹槽漏压占比 β_{NR} 为:

$$\beta_{NR} = \frac{N_d}{N_d + N_a} \times 100\% \tag{6}$$

当 $0 < \beta_{NR} < 50\%$, 判定为“一般缺陷(Minor)”; 当 $\beta_{NR} \geq 50\%$, 判定为“重大缺陷(Major)”。应用本文优化 U-Net 网络, 通过训练获得最优参数, 进而检测待检图片,




图 7 不同模型可视化分割结果

Fig. 7 Visualization of segmentation results for different models

可获得正常凹槽数 N_a 与缺陷凹槽数 N_d ，图 8 为钢锚管压接分割结果示例，图 8(a) 所示 $\beta_{NR} = 1/3$ 判定为“一般缺陷 (Minor)”、图 8(b) 所示 $\beta_{NR} = 1/2$ 判定为“重大缺陷 (Major)”。

3.2 最小外接矩形法

钢锚管芯线压接分割样本的已压区域、漏压区域其形状近似于长方形，可对预测所得掩膜进行边缘检测^[15]，结合最小外接矩形法获得对应区域最小外接矩形，进而测量得到矩形长边长度。令已压长度 L_a 、漏压长度 L_d ，则空腔




图 8 钢锚管压接分割结果示例

Fig. 8 Example of a steel anchor pipe crimp split result

跨距占比 γ_{CS} 为:

$$\gamma_{CS} = \frac{L_a}{L_a + L_d} \times 100\% \quad (7)$$

当 $\gamma_{CS-limit} < \gamma_{CS} < 30\%$, 判定为“重大缺陷(Major)”, $\gamma_{CS-limit}$ 为; 当 $\gamma_{CS} \geq 30\%$, 判定为“紧急缺陷(Critical)”。图 9 为钢锚管芯线分割结果示例, 求 L_a 、 L_d 参数值, 得 $\gamma_{CS} = 28\%$, 可判定为“重大缺陷(Major)”。



图 9 钢锚管芯线分割结果示例

Fig. 9 Example of the result of the segmentation of the core line of the steel anchor pipe

通过以上两种定量分析策略, 可有效达到针对钢锚管尾部压接、芯线压接的缺陷危害程度分级, 为后续开展线夹缺陷处理工作提供依据。

4 结 论

由于缺陷图像存在灰度图像目标与背景差异小、语义信息易丢失、缺陷目标对象小及长宽比较大等特性, 给高准确性语义分割带来难度, 为此本文针对缺陷特征, 开展 U-Net 基础模型上的创新结构设计、调整策略研究, 达到精确提取缺陷掩膜目标。创新提出一种优化 VA-UNet 网络的语义分割方法, 选用具有数据量少、目标占比小、检测要求高等特点的 U-Net 基础模型, 运用 VGG16 网络有效地提升缺陷特征提取能力, 融合 ASPP 模块增强了多尺度特征信息融合, 引入 L_{Dice} 与 L_{BCE} 混合损失函数提高像素分割准确率; 消融实验表明, 本文提出的优化 VA-UNet 网络在自制数据集上的评价指标 $mIoU = 84.14\%$ 、 $mPA =$

91.58%, 较原始模型分别提升 7.32%、6.45%, 提升效果明显。结合钢锚管压接、钢锚管芯线压接缺陷特点, 运用数量统计法、最小外接矩形法等辅助缺陷分级判断表明了方法的有效性。

本文研究工作量较大, 目前仅处于实验室阶段, 在线 X 射线自动化检测将是未来的研究方向及工作重点。

参考文献

- [1] 刘纯, 陈红冬, 欧阳克俭, 等. 碳纤维复合芯导线耐张线夹断裂分析[J]. 中国电力, 2015, 48(10): 97-100, 106. LIU CH, CHEN H D, OUYANG K J, et al. Analysis on the strain clamp fracture of ACCC[J]. Electric Power, 2015, 48(10): 97-100, 106.
- [2] 王昕, 赵飞, 蒋佐富, 等. 迁移学习和卷积神经网络电力设备图像识别方法[J]. 中国测试, 2020, 46(5): 108-113. WANG X, ZHAO F, JIANG Z F, et al. Power equipment image recognition method based on transfer learning and convolutional neural network[J]. China Measurement & Test, 2020, 46(5): 108-113.
- [3] 赵恩玄, 何云勇, 沈宽, 等. 基于深度学习的铸件 CT 图像分割算法[J]. 仪器仪表学报, 2023, 44(11): 176-184. ZHAO EN X, HE Y Y, SHEN K, et al. Casting CT image segmentation algorithm based on deep learning[J]. Chinese Journal of Scientific Instrument, 2023, 44(11): 176-184.
- [4] 刘国特, 周锦辉, 宋新明, 等. 基于超分辨率注意力机制改进的 GIS 内部细微缺陷 X-DR 图像检测方法[J]. 高电压技术, 2021, 47(11): 3803-3809. LIU G T, ZHOU J H, SONG X M, et al. Improved X-DR image detection method for GIS internal defects based on super-resolution attention mechanism[J]. High Voltage Engineering, 2021, 47(11): 3803-3809.
- [5] 曹富强, 王明泉, 张俊生, 等. 基于深度学习的铸件 X 射线图像分割研究[J]. 应用光学, 2021, 42(6): 1025-1033. CAO F Q, WANG M Q, ZHANG J SH, et al. Casting X-ray image segmentation based on deep learning[J]. Journal of Applied Optics, 2021, 42(6): 1025-1033.
- [6] 李可, 吴忠卿, 吉勇, 等. 改进 U-Net 芯片 X 线图像焊缝气泡缺陷检测方法[J]. 华中科技大学学报(自然科学版), 2022, 50(6): 104-110. LI K, WU ZH Q, JI Y, et al. Detection method of weld bubble defect in chip X-ray image based on improved U-Net network[J]. Journal of Huazhong University of Science and Technology(Natural Science Edition, 2022, 50(6): 104-110.

- [7] 陈星寰,吴静静,安伟.基于改进 RCF 模型的转子表面缺陷检测[J].传感技术学报,2023,36(4):575-582.
CHEN X H, WU J J, AN W. Defect detection using rotor image with improved RCF model[J]. Chinese Journal of Sensors and Actuators, 2023, 36 (4): 575-582.
- [8] ZHOU P, WANG R, WANG C, et al. SIIF: Semantic information interactive fusion network for photovoltaic defect segmentation[J]. Applied Energy, DOI:10.1016/j.apenergy.2024.123643.
- [9] CHOI H, YUN J P, KIM B J, et al. Attention-based multimodal image feature fusion module for transmission line detection[J]. IEEE Transactions on Industrial Informatics,2022,18(11):7686-7695.
- [10] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional networks for biomedical image segmentation[C]. International Conference on Medical Image Computing and Computer-Assisted Intervention, Berlin: Springer, 2015:234-241.
- [11] KAREN S, ANDREW Z. Very deep convolutional networks for large scale image recognition [C]. International Conference on Learning Representations, 2015:1-14.
- [12] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. Deep Lab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 40 (4): 834-848.
- [13] ZHAO R J, QIAN B Y, ZHANG X L, et al. Rethinking dice loss for medical image segmentation[C]. 2020 IEEE International Conference on Data Mining. Sorrento: IEEE, 2020: 851-860.
- [14] 李博,刘会斌,王胜辉,等.基于 GANR-UNet 的绝缘子红外图像分割及低零值故障诊断研究[J/OL].华北电力大学学报(自然科学版),1-11[2025-02-18].
<http://kns.cnki.net/kcms/detail/13.1212.tm.20240115.1750.002.html>.
LI B, LIU H B, WANG SH H, et al. Defect Detection Using Rotor Image With Improved RCF Model[J/OL]. Journal of North China Electric Power University(Natural Science Edition), 1-11[2025-02-18].
<http://kns.cnki.net/kcms/detail/13.1212.tm.20240115.1750.002.html>.
- [15] GAO W, ZHANG X, YANG L, et al. An improved sobel edge detection [C]. 3rd IEEE International Conference on Computer Science and Information Technology, 2010: 67-71.
- [16] 熊乐超,姚晖,张震,等.基于 DR 的封头电子束焊缝缺陷自动识别方法研究[J].中国测试,2023,49(S1):91-96.
XIONG L CH, YAO H, ZHANG ZH, et al. Research on automatic identification method of dome electron beam weld defects based on DR[J]. China Measurement & Test, 2023,49(S1):91-96.
- [17] 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 CH Y, WU Y Q, LIU J J. 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.
- [18] 熊炜,黄玉谦,孟圣哲.基于改进 YOLOv8 算法的绝缘子缺陷检测模型[J].电子测量技术,2024,47(12):132-139.
XIONG W, HUANG Y Q, MENG SH ZH. Insulator defect detection model based on improved YOLOv8 algorithm[J]. Electronic Measurement Technology, 2024,47(12):132-139.
- [19] 汪灵姿,刘桂雄,钟飞,等.应用 EW+YOLOv8 耐张线夹 DR 图像缺陷检测识别技术[J].激光杂志,2024,45(7):71-77.
WANG L Z, LIU G X, ZHONG F, et al. Application in DR image defect detection and identification technology of tension clamp based on EW-YOLOv8[J]. Laser Journal, 2024,45(7):71-77.
- [20] 韩建峰,张静,宋丽丽,等.改进 U-Net 的无人机航拍路面破损检测方法[J].电子测量技术,2024,47(19):137-145.
HAN J F, ZHANG J, SONG L L, et al. Improved pavement damage detection method of UAV based on U-Net [J]. Electronic Measurement Technology, 2024,47(19):137-145.
- [21] 徐晓龙,俞晓春,何晓佳,等.基于改进 U-Net 的街景图像语义分割方法[J].电子测量技术,2023,46(9):117-123.
XU X L, YU X CH, HE X J, et al. Semantic segmentation method of street view image based on improved U-Net [J]. Electronic Measurement Technology, 2023,46(9):117-123.
- [22] 田萱,王亮,丁琪.基于深度学习的图像语义分割方法综述[J].软件学报,2019,30(2):440-468.
TIAN X, WANG L, DING Q. Review of image semantic segmentation based on deep learning [J]. Journal of Software, 2019,30(2):440-468.
- [23] ZHANG J, ZHU W. Research on Algorithm for

- Improving Infrared Image Defect Segmentation of Power Equipment[J]. Electronics, 2023; 12(7):1588.
- [24] 严毅,邓超,李琳,等. 深度学习背景下的图像语义分割方法综述[J]. 中国图象图形学报, 2023, 28(11): 3342-3362.
- YAN Y, DENG CH, LI L, et al. Survey of image semantic segmentation methods in the deep learning era[J]. Journal of Image and Graphics, 2023, 28(11): 3342-3362.
- [25] SHELHAMER E, LONG J, DARRELL T. Fully convolutional networks for semantic segmentation[J]. IEEE Trans. on Pattern Analysis & Machine Intelligence, 2014, 39(4):640-651.
- [26] BADRINARAYANAN V, KENDALL A, CIPOLLA R. SegNet: A deep convolutional encoder-decoder architecture for image segmentation [J]. IEEE transactions on pattern analysis and machine intelligence, 2017, 39(12): 2481-2495.
- [27] LI G, KIM J. DABNet: Depth-wise asymmetric bottleneck for real-time semantic segmentation[C]. 30th British Machine Vision Conference 2019, Cardiff: BMVA Press, 2019.
- [28] JHA D, SMEDSRUD P H, JOHANSEN D, et al. A comprehensive study on colorectal polyp segmentation with ResUNet++, conditional random field and test-time augmentation[J]. IEEE Journal of Biomedical and Health Informatics, 2021, 25(6):2029-2040.
- [29] CHEN J, LU Y, YU Q, et al. Transunet: Transformers make strong encoders for medical image segmentation [J]. ArXiv preprint arXiv: 2102.04306, 2021.
- [30] 中华人民共和国住房和城乡建设部. 110~750 kV 架空输电线路施工及验收规范:GB 50233—2014[S]. 中国计划出版社, 2014.
- China's Ministry of Housing and Urban-Rural Development. Code for construction and acceptance of overhead transmission lines of 110 ~ 750 kV: GB 50233—2014[S]. China Planning Press, 2014.
- [31] 国家电力科学研究院. 架空输电线路检测技术导则: GB/T7714[S]. 中国计划出版社, 2021.
- State Key Laboratory of Power System Engineering. Technical Guidelines for X-ray Inspection of Overhead Transmission: GB/T7714 [S]. China Planning Press, 2021.
- [32] 李寒峥,周城嘉,张强,等. 基于机器视觉的轴承跑合带检测方法研究[J]. 中国测试, 2024, 50(S1):15-22.
- LI H ZH, ZHOU CH J, ZHANG Q, et al. Research on the evaluation of running-in belt quality of bearings based on machine vision[J]. China Measurement & Test, 2024, 50(S1):15-22.
- [33] 臧春华,周介祺,刘桂雄. 基于 Mask R-CNN 实例分割的机械零件识别方法研究[J]. 电子测量技术, 2021, 44(22):32-36.
- ZANG CH H, ZHOU J Q, LIU G X. Research on recognition method of mechanical parts based on Mask R-CNN instance segmentation [J]. Electronic Measurement Technology, 2021, 44(22):32-36.

作者简介

汪灵姿, 硕士研究生, 主要研究方向为现代传感与人工智能。

E-mail: w190119@163.com

刘桂雄(通信作者), 博士, 教授, 博士生导师, 主要研究方向为先进传感与仪器研究。

E-mail: megxliu@scut.edu.cn

张国才, 博士研究生, 主要研究方向为智能检测与仪器。

E-mail: 202210180398@mail.scut.edu.cn

钟飞, 教授级高级工程师, 主要研究方向为电力设备及材料检测。

E-mail: 1882083721@139.com