

DOI: 10.13382/j.jemi.B2306928

基于改进 U-Net 的轻量级输电线分割算法*

胡冠华¹ 张永雷² 申立群²
(1. 东北大学机械工程与自动化学院 沈阳 110819; 2. 哈尔滨工业大学仪器科学与工程学院 哈尔滨 150001)

摘要: 为了提高输电线路的巡检效率, 保证输电线的分割精度和速度, 本文提出基于改进 U-Net 的轻量级网络 GU-Net。首先, 以 U-Net 网络为基础, 在编码器部分引入轻量化主干提取网络 Ghost-Net; 然后采用双线性插值方法完成上采样, 并利用深度可分离卷积代替部分普通卷积; 最后在训练过程引入多损失函数以解决输电线和背景像素占比不平衡问题, 并采用迁移学习策略训练模型。在 E-Wire 输电线数据集上测试, GU-Net 网络的 MIoU 和 F1-score 分别为 80.04% 和 87.77%, 与现有的轻量化输电线语义分割网络 Wire-Detection 相比分别提升了 4.26% 和 2.96%, 且分割速度几乎没有损失, 参数量约是它的 20%。实验结果表明, 本文提出的算法能够实现快速高效、轻量化地分割出复杂图像中的输电线。

关键词: 深度学习; 语义分割; 编解码网络; 轻量化; 输电线路

中图分类号: TP391.4; TN98 **文献标识码:** A **国家标准学科分类代码:** 520.6040

Lightweight transmission line conductor segmentation algorithm with improved U-Net

Hu Guanhua¹ Zhang Yonglei² Shen Liqun²
(1. School of Mechanical Engineering & Automation, Northeastern University, Shenyang 110819, China;
2. School of Instrumentation Science and Engineering, Harbin Institute of Technology, Harbin 150001, China)

Abstract: To improve the inspection efficiency of transmission lines and ensure the segmentation accuracy and speed of transmission lines, this paper proposes GU-Net, a lightweight network based on improved U-Net. Firstly, based on the U-Net network, the lightweight trunk extraction network Ghost-Net is introduced in the encoder part; then a bilinear interpolation method to complete the up-sampling and use the depth-separable convolution to replace part of the ordinary convolution; finally, introduce multiple loss functions in the training process to solve the imbalance between the transmission line and the background pixel occupancy, and train the model with a migration learning strategy. Tested on the E-Wire transmission line dataset, the MIoU and F1-score of the GU-Net network are 80.04% and 87.77%, respectively, which are 4.26% and 2.96% better than Wire-Detection, an existing semantic segmentation network for lightweight transmission lines, with almost no loss in the segmentation speed, and the number of references is about 20% of it. The experimental results show that the algorithm proposed in this paper can achieve fast, efficient and lightweight segmentation of transmission lines in complex images.

Keywords: deep learning; semantic segmentation; codec networks; light weighting; power line

0 引言

近年来, 随着我国电网快速建设, 输电线路架设覆盖地区辽阔, 尤其是超、特高压输电线路架设区域跨度广, 途径气候、地形错综复杂, 易受恶劣气象环境波及, 大规模的输电线路需要日常检修和故障排查, 对于确保电力传输安全具有重要意义^[1]。对于巡检过程中拍摄的输电线图像, 需要将图像存储到无人机存储设备上, 并且实时反馈给人工巡检人员进行分析, 但是由于该方式巡检效率低、时效性差且自动化和智能化程度低, 因此需要借助现有图像处理算法来保证输电线的检测速度和效率^[2]。

目前,常用的检测方法共分为两类,一类是基于传统图像处理方法的检测算法;另一类是基于深度学习方法的输电线检测算法。在传统图像处理领域,Zhu 等^[3]利用双边滤波器检测背景中的线性目标,借助 Radon 变换进行直线检测,但该方法对于复杂背景下的输电线图像,存在漏检误检等现象;杨亮^[4]利用 LSD 线特征提取算法和电力线的梯度对称性特征筛选算法,对航拍图像中的电力线进行自动识别和三维建模,但背景复杂时,受噪声影响大,检测效率不高;韦盛^[5]利用边缘绘制的线提取算法来提取输电线,并利用 K 均值聚类算法来消除干扰直线,但该方法对输电线边缘会出现异常检测,而不恰当的参数选择可能导致干扰直线和输电线被错误地归类或分割。

传统的图像巡检处理技术很难满足检测漏洞对于精确度的要求^[6],因此近年来,深度学习方法应用较为广泛,尤其深度卷积神经网络(deep convolutional neural network, DCNN)技术的快速发展,在图像处理和目标识别等领域表现出优秀性能^[7-8]。其中,通过语义分割实现输电线能够更精细的像素级别的分割^[9],现有的语义分割神经网络为全卷积网络(fully convolutional network, FCN)^[10]、U-Net^[11]、以及 DeepLab 系列^[12-13]等。谢倩楠^[2]基于 DeepLab v3+设计了一种轻量化的语义分割网络 MDeepLab v3+,检测速度相比于 DeepLab v3+网络提高了 11 倍左右;但是模型精度不高;黄巨挺等^[1]采用一种对称的轻量级编解码网络,使用最大池化层进行下采样,使用最大池化索引的非线性上采样;但分割过程未能考虑底层语义特征,导致图像恢复率不高;Madaa 等^[14]提出了一种适合于移动端电力线识别的网络结构,运用空洞卷积技术,实现多尺度信息提取,并利用 Grid Search,寻找出具有最佳精确度和效率的网络结构;但网络较为复杂,需要大量计算资源,而大量的超参数容易导致模型过拟合。

综上所述,本文提出基于深度学习的轻量级编解码网络 GU-Net,实现快速高效地分割出输电线路图像中的导线。该网络引入了轻量化主干提取网络 Ghost-Net^[15],用于大幅减小模型计算量的同时保持模型精度;采用双线性插值上采样和深度可分离卷积构成解码器部分;跳跃连接部分通过融合浅层和深层特征,提高分割精度。另外,采用多损失函数 FD-Loss 来解决图像中输电线和背景类别占比不平衡问题,以提高输电线分割效果。

1 输电线数据集构建

1.1 数据集获取

由于现有的适用于输电线分割的公开数据集较少,本文所使用的输电线数据主要来源于两个途径:一是由

工业相机拍摄的分率为 $7\,360 \times 4\,180$ 的输电线路图像,另一个是从视觉中国图库中获取的平均像素为 $5\,000 \times 3\,000$ 的输电线图像,一共获取了 200 张输电线图像。考虑到计算机内存和计算能力的限制,采用顺序裁剪方式将图像裁剪为 512×512 分辨率的子图像,行和列的跨度均为 256 pixels,裁剪过程如图 1 所示。



图 1 顺序裁剪过程示意图

Fig. 1 Schematic diagram of the sequential cutting process

1.2 数据集增强

为了提高深度神经网络的性能和泛化能力,对于输电导线检测任务,采用水平镜像、图像旋转、添加噪声的方式对数据集进行扩充,示例如图 2 所示。




图 2 输电线图像数据增强方式

Fig. 2 Transmission line image data enhancement method

图像增强之后,经过筛选得到数据集共 1 536 张输电线图像数据集 E-Wire,利用标注软件 Labelme3.16.7 对其进行标注,最后,按照 9:1 比例划分为训练集和测试集。

2 轻量级网络 GU-Net 的构建

2.1 总体网络结构

输电线路图像存在电线像占比小、宽度窄,背景复杂等问题,检测难度较大。为了更加快捷高效识别出输电

线,本文提出轻量级网络 GU-Net,该网络以 U-Net 网络为基础,采用编码-解码结构,如图 3 所示。主干提取网络引入轻量级网络 Ghost-Net,其提出的 Ghost 模块(Ghost Module)可以作为一个即插即用组件来升级现有的卷积神经网络,并对其进行改进;解码器部分采用双线性插值和深度可分离卷积进行升维和特征恢复^[15]。




图3 GU-Net 网络总体结构

Fig. 3 General structure of GU-Net network

2.2 编码器网络

编码器的主干提取网络在 Ghost-Net 网络上进行增减,保留第 1 层的标准卷积层以及前 11 个 G-bneck,并在第 1 层标准卷积层前新增一个含有 16 个滤波器的标准卷积层 (Stride = 1), 删除第 12 个 G-bneck 及以后的网络层。

改动后的编码器网络由 5 个阶段组成,如图 4 所示。第 1 阶段为含有 16 个卷积核的标准卷积层 (Stride = 1), 第 2 阶段为含有 16 个卷积核的标准卷积层 (Stride = 2), 第 3 阶段由一个 G-bneck 组成,第 4、5 阶段均由两个 G-bneck 组成。第 3、4 阶段的最后第 1 个 G-bneck 是 Stride=2 之外,其余 G-bneck 都是在 Stride=1 时应用的;第 5 阶段的最后一个 G-bneck 添加挤压和激励注意力机制 (squeeze-and-excitation, SE), 其余 G-bneck 均不采用。网络的每一层后均应用 BN 层和 ReLU6 激活函数。




图4 编码器网络结构

Fig. 4 Encoder network diagram

1) 轻量化网络模块 Ghost Module

Ghost Module 如图 5 所示。在与普通卷积相同输入、输出情况下, Ghost Module 的模型复杂度大大降低。与逐点卷积相比, Ghost Module 中的卷积核大小可以自定义;主流方法使用深度卷积处理特征图,然后使用逐点卷积融合空间信息, Ghost Module 使用普通卷积产生少量特征图,然后通过线性变换得到更多特征图;与使用深度卷积或移位操作来处理特征图相比, Ghost Module 中的线性变换大大减少模型计算量; Ghost Module 中的恒等映射可以有效保留特征图的信息^[15]。




图5 Ghost Module 结构

Fig. 5 Ghost Module structure

2) Ghost 瓶颈块

Ghost 瓶颈块 (Ghost bottleneck, G-bneck) 由 Ghost Module 堆叠而成,如图 6 所示。GhostNet 首先用常规卷积方法生成一组特征图,再用一种简单的线性变换方法生成多个特征图,通过这种方法,在保持输入、输出特征图基本不变的情况下,大大降低了模型训练所需的参数,降低了模型的运算量。




图6 Ghost Bottleneck 结构

Fig. 6 Ghost Bottleneck structure

2.3 解码器网络

解码器网络每层结构与编码器网络相对应,采用双

线性插值方法完成上采样,利用跳跃连接结构将浅层特征图与上采样后的深层特征进行拼接(Concat),然后利用深度可分离卷积进行特征提取,重复此过程 4 次,最后经过 1×1 卷积、BN 层以及 ReLU6 完成特征分类。

其中,解码器部分引入的深度可分离卷积(depth wise separable convolution, DS-Conv)是由逐深度卷积(depth wise convolution, DW-Conv)和逐点卷积(pointwise convolution, PW-Conv)两个部分组成^[16]。首先是逐深度卷积步骤,每个卷积核会对其中一个通道进行卷积运算,并生成一个输出通道,然后是逐点卷积步骤,每个卷积核会对输入特征的每个点(即每个像素)进行卷积运算,并生成一个输出特征点。这样的计算过程可有效提取输入特征的多通道信息,并通过逐点卷积实现输出特征的通道数调整。在引入深度可分离卷积后,能够实现网络模型参数和计算量的降低^[17]。

普通卷积的参数数量 N_1 和计算量 C_1 与深度可分离卷积层的参数数量 N_2 和计算量 C_2 的计算公式分别如下(不考虑偏置):

$$N_1 = K^2 C_i C_o \quad (1)$$

$$C_1 = C_i K^2 H_o W_o C_o \quad (2)$$

$$N_2 = K^2 C_i + C_i C_o \quad (3)$$

$$C_2 = C_i K^2 H_o W_o + C_i H_o W_o C_o \quad (4)$$

其中, K 为卷积核尺寸大小, C_i 为输入通道, C_o 为输出通道, H_o 、 W_o 分别为输出特征图的高和宽。

可以得出,在相同的输入输出下,深度可分离卷积的参数数量和计算量是普通卷积的 $(K^2 + C_o)/K^2$ 倍。说明,在引入深度可分离卷积后,能够实现网络模型参数和计算量的降低。

3 实验与结果分析

3.1 实验环境

实验平台选择 Dell Precision 5820 工作站,配置 Intel (R) Core(TM) i9-10900X CPU @ 3.70 GHz 处理器,同时搭载 NVIDIA GeForce RTX 3080Ti 显卡,内存 12 GB;选择 PyTorch 作为深度学习框架,以 PyCharm IDE 与 Python 语言作为网络搭建开发工具,运算平台选择 CUDA11.6 版本。

3.2 模型评价指标

本文采用类别平均交互比(mean intersection over union, MIoU)、平衡 F 分数(balanced F-score, F1-score)^[11] 指标、每秒浮点运算数(floating point operations, FLOPs)、每秒传输帧数(frames per second, FPS)和模型大小(module size)来验证导线分割性能;MIoU 是衡量数据集中每个类别的交并比平均值的指标;F1-score 是查准率

和查全率的调和平均数,衡量二分类模型准确率;FLOPs 用于对网络模型进行复杂性的度量,其值越小,说明模型计算速度越快;FPS 指标用于衡量模型每秒可以处理的图像帧数或推理速度,其指数越高,说明模型检测的实时性越好;Module Size 就是模型的大小,其值越小说明模型参数量越小。

MIoU 和 F1-score 的计算公式分别如下:

$$MIoU = \frac{1}{k} \sum \frac{TP}{FN + TP + FP} \quad (5)$$

$$F1 - score = \frac{2 \times P \times R}{P + R} \quad (6)$$

$$P = \frac{TP}{FP + TP} \quad (7)$$

$$R = \frac{TP}{FN + TP} \quad (8)$$

其中,MIoU 和 F1-score 是基于混淆矩阵进行计算,在实际应用中,将分类器的预测结果分成 4 类:TP, TN, FP, FN。TP(true positive)为正样本预测为正样本, TN(true negative)为负样本预测为负样本,FP(false positive)为负样本预测为正样本,FN(false negative)为正样本预测为负样本。 k 表示类别数;P 和 R 分别表示每个类被正确分类像素数的比例和模型预测正确的像素在所有真实正例像素中所占比例。

3.3 训练过程

采用迁移学习策略^[18],在 PASCAL VOC 数据集上训练好模型作为输电线数据集的预训练权重模型。网络训练过程从主干网络的预训练权重开始训练,分为冻结训练和解冻训练两个阶段。冻结训练阶段和解冻阶段的训练轮数均为 100 轮,批处理大小均为 4,均选择 Adam 优化器,冻结阶段初始学习率为 0.000 1,解冻训练阶段初始学习率为 0.000 01。解冻训练指的是在冻结训练后,解除参数的固定,并对整个网络进行训练^[19]。

为解决输电线和背景类别占比不平衡问题,损失函数选择多损失函数 FD-Loss,由焦点损失函数 FocalLoss^[17] 和骰子损失 DiceLoss^[20] 组成,计算公式如下:

$$FD - Loss = FocalLoss + DiceLoss \quad (9)$$

$$FocalLoss = -(\alpha \cdot (1 - y_i')^\gamma \cdot y_i \cdot \log(y_i') + (1 - \alpha) \cdot y_i'^\gamma \cdot (1 - y_i) \cdot \log(1 - y_i')) \quad (10)$$

$$DiceLoss = 1 - \frac{2 | Truth \cap Prediction |}{| Truth | + | Prediction |} \quad (11)$$


其中, y_i 输电线的真实像素值, y_i' 为模型预测为输电线的概率,输电线取 1,背景取 0; α 作用是给不同类别样本损失值加权重,正样本少,则加大正样本损失权重,按照背景像素数与输电导线像素数比例大概在 9 : 1 左右,因此实验中 α 取 0.9; γ 作用是调整易分样本的损失

函数,使模型更加重视困难样本和错分样本,从而提高在这些样本上的性能和鲁棒性, γ 取2。Truth 为真实值像元点集,Prediction 为预测值像元点集,且 Dice 的取值范围为 $[0,1]$,其值越大表示预测结果与真实结果越接近,识别越准确。


3.4 实验结果对比

本实验在构建的 E-Wire 输电线数据集上进行,为了验证本文提出网络的有效性,进行消融对比实验。在表 2 中,方法 1 主干提取网络不采用改进后的 GhostNet 网络,采用由文献[1]提出的方法;方法 2 在方法 1 引入深度可分离卷积,代替原来的普通卷积;方法 3 在方法 2 的基础上增加跳跃连接机制;方法 4 在方法 3 的基础上引入改进后的主干网络 GhostNet;方法 5 在方法 4 的基础上添加多损失函数 FD-Loss。由表 1 可得,方法 2 引入的深度可分离卷积实现了轻量化改进,模型复杂度降低但模型分割速度稍有下降;方法 3 说明跳跃连接的加入,提高了分割精度,能够更好地融合浅层和深层特征;方法 4 说明引入改进后的 GhostNet 网络进一步降低了模型复杂度,实现轻量化改进;方法 5 由于添加了 FD-Loss,提高了网络性能,说明本文提出的多损失函数能够较好地增加输电线产生的损失权重,使输电线为训练网络贡献更多的损失,从而提高输电线的分割精度。实验证明,方法 5 搭建的 GU-Net 模型分割效果最好,且分割速度与方法 1 相差不大,MIoU 和 F1-score 相比于方法 1 分别提升了 4.26%和 2.96%,模型计算量和参数量约是其 1/5。

训练过程中的损失函数曲线和 MIoU 指标变化曲线如图 7 所示,分割的可视化结果如图 8 所示,可以看出,其结果与量化分析结果一致。



(a) 损失函数随迭代次数变化曲线
(a) Curve of the loss function with the number of iterations



(b) MIoU 随迭代次数变化曲线
(b) Curve of MIoU with number of iterations

图 7 模型训练曲线

Fig. 7 Model training curve




图 8 模型消融实验可视化结果对比

Fig. 8 Model training curve

为了进一步验证 GU-Net 网络的优势,将本文提出的 GU-Net 网络与原始 U-Net 网络、PSPNet 网络、RefineNet

网络和 DeepLabV3+网络在相同实验环境、数据集和训练策略下进行对比实验。可视化结果如图 9 所示,量化分

析结果如表 2 所示。可以看出, GU-Net 网络的 MIoU 和 F1-score 分别为 80.04% 和 87.77%, 相比于其他网络没有较大损失且其余指标均优于其他网络, 分割速度约是原 U-Net 网络的 12 倍, 模型计算量和参数量分别是其

0.012 倍和 0.005 8 倍。实验表明, GU-Net 网络在保证分割精度没有过多损失的前提下, 分割速度有大幅度提升, 模型复杂度大大降低。

表 1 模型消融实验量化结果对比
Table 1 Comparison of quantitative results from model ablation experiments

分割指标	方法 1	方法 2	方法 3	方法 4	方法 5
MIoU/%	75.78	71.88	76.68	78.81	80.04
F1-score/%	84.81	80.92	85.18	86.94	87.77
帧率/fps	24.47	20.25	13.02	19.39	23.82
FLOPs/G	36.063	8.516	19.863	7.863	7.863
Module Size/M	0.850	0.332	0.740	0.229	0.229




图 9 GU-Net 与其他网络的可视化结果对比
Fig. 9 Visualisation results of GU-Net compared to other networks

表 2 GU-Net 和主流语义分割网络的量化结果对比
Table 2 Comparison of quantitative results between gu-net and mainstream semantic segmentation networks

分割指标	U-Net	PSPNet	RefineNet	DeepLabV3+	GU-Net
MIoU/%	84.58	54.52	84.14	83.93	80.04
F1-score/%	91.33	62.81	90.68	90.57	87.77
帧率/fps	1.99	1.98	1.73	4.27	23.82
FLOPs/G	643.591	118.427	775.321	52.867	7.863
Module Size/M	39.396	46.707	152.495	5.813	0.229

4 结 论

本文提出了一种名为 GU-Net 的网络架构, 旨在用于输电线图像的精确分割, 以有效提取输电线路图像中的导线特征。为实现轻量级改进, 该网络在编码器部分引入了轻量化主干提取网络 GhostNet, 以降低模型复杂度。解码器部分则采用双线性插值上采样和深度可分离卷积技术。此外, 利用跳跃连接机制来整合浅层和深层特征

信息, 以增强特征信息的表达和传递能力。该研究未来的工作方向包括扩充数据集, 针对不同源数据集进行测试, 旨在更复杂的背景下实现输电线的快速高效分割。此外, 研究还计划开展输电线的定位工作, 以进一步完善输电线的检测和定位能力。

参考文献

[1] 黄巨挺, 高宏力, 戴志坤. 基于编码解码结构的移动端电力线语义分割方法 [J]. 计算机应用, 2021, 41(10): 2952-2958.

- HUANG J T, GAO H L, DAI ZH K. A semantic segmentation method for powerline on mobile based on coding and decoding structure [J]. Computer Applications, 2021, 41 (10): 2952-2958.
- [2] 谢倩楠. 基于图像的输电设备检测技术研究[D]. 西安:西安电子科技大学, 2021.
- XIE Q N. Research on image-based detection technology of power transmission equipment [D]. Xi'an: Xi'an Electronic Science and Technology University, 2021.
- [3] ZHU L L, CAO W R, HAN J D, et al. A double-side filter based power line recognition method for UAV vision system [C]. 2013 IEEE International Conference on Robotics and Biomimetics (ROBIO). IEEE, 2013: 2655-2660.
- [4] 杨亮. 无人机航拍复杂背景影像中电力线的自动提取与匹配方法[D]. 武汉:武汉大学, 2017.
- YANG L. Automatic extraction and matching method of power lines in UAV aerial photography complex background images [D]. Wuhan: Wuhan University, 2017.
- [5] 韦盛. 基于图像处理的输电线识别与六旋翼巡检研究[D]. 合肥:合肥工业大学, 2020.
- WEI SH. Research on transmission line identification and hexacopter inspection based on image processing [D]. Hefei: Hefei University of Technology, 2020.
- [6] 向志威, 杨大伟, 景康, 等. 智能图像识别技术在输电线路巡检中的应用[J]. 电子技术, 2023, 52 (6): 240-241.
- XIANG ZH W, YANG D W, JING K, et al. Application of intelligent image recognition technology in transmission line inspection[J]. Electronic Technology, 2023, 52 (6): 240-241.
- [7] 伊欣同, 单亚峰. 基于改进 Faster R-CNN 的光伏电池内部缺陷检测[J]. 电子测量与仪器学报, 2021, 35 (1): 40-47.
- YI X T, SHAN Y F. Internal defect detection of photovoltaic cells based on improved Faster R-CNN[J]. Journal of Electronic Measurement and Instrumentation, 2021, 35 (1): 40-47.
- [8] 王凌云, 李婷宜, 李阳, 等. 基于 FEF-DeepLabV3+ 的电力金具锈蚀分割方法[J]. 电子测量与仪器学报, 2023, 37 (7): 166-176.
- WANG L Y, LI T Y, LI Y, et al. Segmentation method of power fixture corrosion based on FEF-DeepLabV3+ [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37 (7): 166-176.
- [9] 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. A semantic segmentation method for street scene images based on improved U-Net [J]. Electronic Measurement Technology, 2023, 46 (9): 117-123.
- [10] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015: 3431-3440.
- [11] RONNEBERGE O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation [C]. Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015: 18th International Conference, Munich, Germany, October 5-9, 2015, Proceedings, Part III 18. Springer International Publishing, 2015: 234-241.
- [12] CHEN L C, PAPANDREO G, KOKKINOS I, et al. Deeplab: 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] CHEN L C, ZHU Y, PAPANDREOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation [C]. Proceedings of the European Conference on Computer Vision (ECCV), 2018: 801-818.
- [14] MADAA R, MATURAN D, SCHERER S. Wire detection using synthetic data and dilated convolutional networks for unmanned aerial vehicles [C]. 2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). IEEE, 2017: 3487-3494.
- [15] HAN K, WANG Y, TIAN Q, et al. Ghostnet: More features from cheap operations [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 1580-1589.
- [16] 王盛, 吴浩, 彭宁, 等. 改进 U²-Net 的太阳能电池片缺陷分割方法[J]. 国外电子测量技术, 2023, 42 (2): 177-184.
- WANG SH, WU H, PENG N, et al. Improved U²-Net defect segmentation method for solar cell wafers [J]. Overseas Electronic Measurement Technology, 2023, 42 (2): 177-184.
- [17] LIN T Y, GOYA P, GIRSHIC R, et al. Focal loss for dense object detection [C]. Proceedings of the IEEE International Conference on Computer Vision, 2017: 2980-2988.
- [18] 谷峥岩, 魏利胜. 基于深度学习网络的轴承工件自动

检测[J]. 电子测量与仪器学报, 2021, 35(9): 80-88.


GU ZH Y, WEI L SH. Automatic inspection of bearing workpiece based on deep learning network[J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(9): 80-88.

- [19] 孙耀泽, 高军伟. 基于 DeepLabV3+ 的轮对踏面损伤分割算法[J]. 电子测量技术, 2022, 45(23): 113-118.

SUN Y Z, GAO J W. Damage segmentation algorithm for wheelset tread damage based on DeepLabV3+ [J]. Electronic Measurement Technology, 2022, 45 (23): 113-118.

- [20] MILLETAR F, NAVAB N, AHMAD S A. V-Net: Fully convolutional neural networks for volumetric medical image segmentation[J]. IEEE, 2016: 565-571.

作者简介



胡冠华, 现为东北大学本科, 主要研究方向为人工智能、机器视觉等。

E-mail: hu_guanhua@163.com

Hu Guanhua now is a B. Sc. candidate in Northeastern University. His main research interests include artificial intelligence and

machine vision.




张永雷 (通信作者), 2023 年于东北林业大学获得学士学位, 现为哈尔滨工业大学硕士研究生, 主要研究方向为自动检测与图像处理。

E-mail: zyl200109@yeah.net

Zhang Yonglei (Corresponding author)

received his B. Sc. degree from Northeast Forestry University in 2023. Now he is a M. Sc. candidate in Harbin Institute of Technology. His main research interests include automatic detection and image processing.



申立群, 2002 年于哈尔滨工业大学获得学士学位, 2004 年于哈尔滨工业大学获得硕士学位, 2008 年于哈尔滨工业大学获得博士学位, 现为哈尔滨工业大学副教授, 主要研究方向为自动检测与控制技术。

E-mail: shenliqun@hit.edu.cn

Shen Liqun received his B. Sc. degree from Harbin Institute of Technology in 2002, M. Sc. degree from Harbin Institute of Technology in 2004, and Ph. D. degree from Harbin Institute of Technology in 2008, respectively. Now he is an associate professor in Harbin Institute of Technology. His main research interests include automatic detection and control technology.