

基于 YOLOv5 的导线端点轻量化检测方法

张长勇¹, 张轩铖¹, 李玉洲², 方俊杰¹

(1. 中国民航大学 电子信息与自动化学院, 天津 300300;

2. 沧州航空职业学院 航空工程学院, 河北 沧州 061180)

摘要: 导线端点检测对于实现人工智能实验接线检查至关重要, 针对现有导线端点检测模型参数庞大、难以部署至移动端的问题, 提出一种基于 YOLOv5 的导线端点轻量化检测方法; 将 CSPDarkNet 替换为 PPLCNet 作为骨干网络, 保持较高检测精度的同时降低模型的复杂度, 在特征融合部分融入 ConvNeXt Block 加速网络提取和融合复杂目标的特征信息, 增强对目标的特征提取能力, 用更轻量的鬼影混洗卷积替换颈部网络中的卷积层, 降低计算成本; 实验结果表明, 改进模型相比未改进模型计算量、参数量、模型体积分别下降了 66.6%、68.4%、65.2%, mAP 提高了 0.9%, 保证轻量化的同时提高了检测精度。

关键词: 深度学习; 移动端部署; 轻量化; 实验导线; 导线端点检测; 接线检查; 鬼影混洗卷积

Lightweight Detection Method for Wire Endpoints Based on YOLOv5

ZHANG Changyong¹, ZHANG Xuancheng¹, LI Yuzhou², FANG Junjie¹

(1. College of Electronic Information and Automation, CAUC, Tianjin 300300, China;

2. College of Aeronautical Engineering, Cangzhou Aviation Vocational College, Cangzhou 061180, China)

Abstract: It is crucial for artificial intelligence to achieve experimental wiring inspection at wire endpoints. Existing wire endpoint detection models have the characteristics of large parameters and difficulty in deploying on mobile terminals, this paper proposes a lightweight wire endpoint detection method based on YOLOv5. CSPDarkNet is replaced by PPLCNet as the backbone network to maintain high detection accuracy while reducing the complexity of the model. ConvNeXt Block is integrated into the feature fusion part to accelerate network extraction and fuse the feature information of complex targets, thus enhancing the feature extraction capability of the target. The convolutional layer in the neck network is replaced by lighter convolutional GSConv to reduce computational cost. Experimental results show that compared with the unimproved model, the improved model reduces the calculation amount, parameter number and model volume by 66.6%, 68.4% and 65.2% respectively, and the mAP is increased by 0.9%, which ensures lightweight and improves detection accuracy.

Keywords: deep learning; mobile deployment; lightweight; experimental wire; wire endpoint detection; wiring check; ghost shuffle convolution

0 引言

导线^[1]是电学实验中各种仪表的连接元件, 是电气系统传输信号的重要载体。在电类实验教学中, 实验接线正确与否决定着实验能否正常进行。错误的接线可能会损坏实验设备, 对实验人员存在安全隐患, 因此必须进行接线检查工作。

目前, 接线检查往往依赖人工, 这会存在许多问

题。首先, 人工检查易受个体主观判断的影响, 导致主观误差; 其次, 人工检查需要花费大量时间, 影响实验效率和资源利用; 此外, 当接线情况复杂或检查人员注意力不足时, 可能会出现漏检错检的现象; 最后, 人工检查通常无法提供足够的实时反馈, 大大影响实验教学质量。所以, 电类实验教学中迫切需要高效快速且准确的手段来实现智能导线接线检查。

智能接线检查是一个综合性的过程, 包含导线识

收稿日期: 2024-07-02; 修回日期: 2024-08-06。

基金项目: 中国交通教育研究会教育科学研究重点课题(B类)(JT2024ZD066); 教育部产学研合作协同育人项目(23080467903-3239)。

作者简介: 张长勇(1978-), 男, 博士, 副教授。

引用格式: 张长勇, 张轩铖, 李玉洲, 等. 基于 YOLOv5 的导线端点轻量化检测方法[J]. 计算机测量与控制, 2025, 33(8): 22-28.

别和导线端点检测两个方面, 其中导线端点检测直接影响到接线的准确性评估, 端点识别的精确性决定了系统能否正确判断导线是否按照预定的方式连接到了正确的位置。近年来, 相关学者和专家针对导线这类线状柔性体的端点检测方法进行了一系列研究。文献 [2] 通过对线状柔性体端点部署增强现实标记来利用一种视觉方法实现端点检测; 在 Ariadne (对 DLO 检测、分割和建模的贡献最早的高级方法) 中^[3], 作者利用改进的 YOLOv2 视觉检测模型部署了一个外部检测器用作端点识别, 可以得到端点的大致位置; 文献 [4] 提出一种基于深度学习的方法来识别线状柔性体的拓扑状态, 其中利用 YOLOv3 视觉检测模型实现了对导线交叉点、端点等关键点的识别; 针对机器人识别线缆的问题, 文献 [5] 提出了一种两阶段视觉检测方法, 在第一阶段使用基于边缘的方法完成检测并计算线缆端点等抓取点坐标的任务; 文献 [6] 基于 Mask-RCNN 检测算法对线状柔性体分割和识别, 同样采用 YOLOv3 视觉检测算法直接识别导线的端点; Ariadne+^[7] 在优化线状柔性体的实例分割时, 采用了一种基于深度学习的柔性体端点检测方法, 通过使用卷积神经网络架构来进行实例分割, 并结合特征提取网络与预测网络, 实时准确地识别和分割可变性线性物体的端点; 在 FASTDLO^[8] 柔性体分割研究中, 作者使用浅层神经网络对经过骨架像素分类后的二值掩码图像进行预测端点对之间的连接概率, 并根据这些概率进行段的合并, 实现对端点的识别; 实时柔性体识别方法 mBEST^[9], 则通过检测柔性体各处曲率变化总和来识别端点; 在识别和处理线状柔性体缠绕问题时, 文献 [10] 采用了基于图像处理的端点检测方法, 在细化处理后的柔性体掩码图像中, 通过计算白色像素周围 0~1 的跳变次数 (白色像素为 1, 黑色像素为 0) 确定该白色像素是否为端点。

在众多学者专家的共同探索下, 线状柔性体端点检测方法研究已取得了一定的进展。其中, 利用计算机视觉目标检测技术对导线端点进行识别和定位, 无疑是更为便捷与有效的方法。然而, 要想将其应用于智能接线检查系统, 仍存在两方面的不足: 一方面, 在智能接线检查系统中, 需要利用边缘端设备作为载体, 以方便师生使用, 但由于高精度的目标检测模型往往拥有复杂的网络结构和巨大的参数计算量, 导致其难以部署到计算资源和存储空间均有限的智能边缘设备中, 所以必须使用轻量级的检测模型; 另一方面, 目前使用的轻量级模型 (如 YOLOv2、YOLOv3) 为了保持模型轻量化, 会牺牲部分准确度, 难以保证端点识别的精确性, 可能出现对导线端点错检、漏检的情况, 从而影响最终的接线检查效果。因此只有设计出

检测性能高且大小适中的导线端点检测模型才能满足智能接线检查系统的需求。

综上, 本文针对现有目标检测模型在识别导线端点时, 由于结构复杂、参数量多导致模型难以部署的问题, 开展关于实验导线端点轻量化检测模型的研究, 通过把 YOLOv5s 模型的 Backbone 层的骨干网络替换为 PPLCNet^[11], 实现模型更将轻量化; 同时, 构建新的 ConvNeXt Block 模块取代颈部网络中 C3 模块中的 Bottleneck, 增强网络对特征的提取; 最后, 采用轻量级卷积结构鬼影混洗卷积 (GSConv, ghost-shuffle convolution) 代替颈部网络中的普通卷积, 利用实验验证网络改进的有效性, 力求在降低模型参数与计算量的同时, 提高模型的检测精度。

1 YOLOv5s 网络模型结构

YOLOv5 算法^[12] 包括输入端 (Input)、骨干网络 (Backbone)、颈部网络 (Neck) 和检测头部分 (Head), YOLOv5 共 5 个版本, 按照模型大小对模型进行升序排列, 分别是 YOLOv5n、YOLOv5s、YOLOv5m、YOLOv5l、YOLOv5x。考虑到智能接线检查对于导线端点识别模型的实际需求, 本文选择原始模型较小、速度较快的 YOLOv5s 作为基础模型。YOLOv5s 的模型结构如图 1 所示。




图 1 YOLOv5s 结构图

网络输入端进行图像的预处理, 输入图像的尺寸是 640×640, 采用 Mosaic 数据增强提高训练样本的多样性, 通过自适应锚框计算和自适应图像缩放降低工作量。

Backbone 采用 CSPDarknet-53 实现特征提取, Backbone 的主要构成部分是卷积层、瓶颈层、快速金字塔池化 (SPPF, spatial pyramid pooling fast), 这些模块用于提取各种尺寸的图像特征。卷积模块由二维卷积 (Conv2d)、批量标准化 (Batch Normalization) 和激

活函数 (SiLU) 组成; 瓶颈层由 3 个 Conv 以及多个 Bottleneck 模块构成; SPPF 模块使用多个较小尺寸的池化核进行级联, 替代该模块中的单个大尺寸池化核。

Neck 由特征金字塔网络 (FPN, feature pyramid networks)^[13] 和路径聚合网络 (PAN, path aggregation network)^[14] 两部分组成, 深层特征图的语义信息经 FPN 自上向下地传递到浅层, 提高检测精度, 浅层特征图的位置信息经 PAN 自下向上地传递到深层, 提高检测的鲁棒性。

Head 层采用 CIOU 作为边界框回归预测的损失函数, 对 Neck 层的特征图通过 1×1 卷积扩张通道数, 输出 80×80 , 40×40 , 20×20 三种尺寸的分支, 再使用非极大抑制算法 (NMS) 获取最优检测框, 输出预测框的位置、类别概率和置信度信息。

2 轻量化改进方案

2.1 PPLCNet 轻量级骨干网络

由于原始主干网络中的 CSPDarknet-53 拥有较大的参数量和计算量, 导致模型对于存储空间和计算资源有了较高的要求。为了降低计算的复杂度和减小模型体积, 改进方案采用了 PPLCNet 作为骨干网络。PPLCNet 是一个基于百度开源深度学习框架 PaddlePaddle 开发的检测网络, 相比其他常用的识别检测网络, 它的参数量较小, 在存储和计算资源上更加高效。此外, PPLCNet 还支持多种优化策略的组合, 为模型性能的进一步提升提供了可能。这些优化策略包括但不限于模型剪枝、量化、知识蒸馏等, 它们不仅有助于减少模型的存储空间和计算资源需求, 实现模型轻量化的效果, 还能在保持模型性能的同时, 提高推理速度和降低能耗, PPLCNet 结构如图 2 所示。





图 2 PPLCNet 结构图

其设计思想包括两部分:

1) 通过堆叠模块构建类似 MobileNetv1^[15] 的骨干网络, 使用深度可分离卷积 (DepthSepConv) 来代替标准卷积, 从而更有效地提取特征信息。深度可分离卷

积由深度卷积 (DW Conv, depthwise convolution) 和逐点卷积 (PW Conv, pointwise convolution) 组成, 与传统卷积相比, 通过分解卷积的方式有效减少了模型的参数量和计算复杂度, 这种方式不仅取消了特征图相加的额外步骤, 还有助于模型推理过程的加速。浅层和深层信息特征分别使用 3×3 和 5×5 的卷积核进行深度可分离卷积的特征提取, 小的卷积核用以捕捉局部细节信息, 大的卷积核用以获得更大的感受野和更多的全局信息。深度可分离卷积如图 3 所示。



DepthSepConv, 深度可分离卷积; DWConv, 深度卷积; PWConv, 逐点卷积; BN 正则化; h-swish, 激活函数

图 3 深度可分离卷积结构图

2) 同时引入 H-Swish 激活函数和 SE 注意力模块^[16]。H-Swish 相比 ReLU 可以提升模型性能且不会造成较大的推理损耗。ReLU 函数在输入小于 0 时, 梯度会被完全置为 0, 可能导致训练过程中梯度消失, 从而影响模型的收敛和性能。H-Swish 在输入接近 0 的区域表现得更为平滑, 能够在反向传播过程中提供更精确的梯度信息, 有助于网络优化。此外, H-Swish 通过引入非线性阈值, 能更真实地模拟神经元被激活的过程, 从而增强模型的代表能力。H-Swish 的表达式为:

$$\text{H-Swish}(x) = x \frac{\text{ReLU6}(x+3)}{6} \quad (1)$$

SE 注意力模块包含 4 步操作: Transformation (转换)、Squeeze (压缩)、Excitation (激励) 和 Scale (缩放)。该模块首先通过全局平均池化对输入特征进行压缩, 求取每个特征通道的平均值 (表示特征层的特征); 接着, 利用两个全连接层对压缩后的特征图进行激励, 分别进行非线性处理, 并生成每个通道的权重; 最后, 将这些生成的权重与原始特征图逐通道相乘, 实现对原始特征的重新加权。改进网络选择将 SE 模块放在最后两个 DepthSepConv 层中, 以增强模型对不同特征通道的敏感性, 使得模型能够聚焦于对任务更为重要的特征通道, 从而提升模型的性能。SE 模块结构如图 4 所示。




图 4 SE 模块结构示意图

2.2 CNeB 模块

为了解决导线端点目标轮廓不清、边界模糊和遮挡等复杂背景情况下图像特征提取不充分的问题, 在 Neck 层中采用了 CNeB 结构, 以替换原有的 C3 结构。

CNeB 模块是在 ConvNeXt Block^[17]结构的基础上合并 3 个 Conv2d 卷积, 即对 C3 模块中 Bottleneck 结构的替换, CNeB 模块的引入有效减少了模型的参数量, 实现了特征融合网络的轻量化调整, 使得模型的感受野得以扩大, 提高了模型在复杂背景情况下对导线端点的特征提取能力。CNeB 模块如图 5 所示。




图 5 CNeB 模块结构图

ConvNeXt Block 的设计灵感来源于 ResNet 与 Swin Transformer 的结合, 形成了独特的 ConvNeXt 结构, 这种设计既保留了传统卷积的优势, 又有效避免了 Transformer 的潜在缺点, ConvNeXt Block 结构如图 6 所示。ConvNeXt Block 采用了一种反转瓶颈结构, 该结构由两个分支组成。其中一个分支首先通过卷积核大小为 7 的卷积操作, 以完成空间上的信息提取, 再通过两个 1×1 卷积进行升维和降维, 在 1×1 卷积前只保留 1 个归一化层, 此时通道数和初始输入的通道数相同。另一个分支将输入直接与上述分支相加再进行输出, 跳过了 3 个卷积运算, 残差块采用 LN (归一化) 代替 BN 进行归一化, ConvNeXt Block 结构在每个模块中使用了单个高斯误差线性单元 (GELU) 激活, LN 结果 y_i 和 GELU 的激活功能如下式所示:

$$y_i = \gamma x'_i + \beta = \text{LN}_{\gamma, \beta}(x_i) \tag{2}$$

$$f(x) = x \int_{-\infty}^x \frac{e^{-(x-\mu)^2 / -2\sigma}}{\sqrt{2\pi\sigma}} dX \tag{3}$$

式中, γ, β 表示学习参数; x'_i 为 x_i 归一化的值。 μ, σ 表示正态分布的均值和标准差, $96-d$ 表示输入通道数为 96。




图 6 ConvNeXt Block 模块结构图

2.3 引入 GSConv 模块

由于标准卷积同时作用于 3 个通道, 其卷积核数量与输出通道数相同, 通道数则与输入通道数一致。因

此, 在图像特征提取中过度使用标准卷积会导致参数累积、特征冗余, 且随着层数加深, 这种影响愈发显著。为解决上述问题, 改进模型引入了一种新卷积——鬼影混洗卷积 (GSConv, ghost-shuffle convolution)^[18] 替换普通卷积层, 相对于标准卷积, GSConv 的参数更少, 在降低模型复杂度的同时, 还能保持较高的准确率, 更适合构建轻量级模型。

GSConv 的结构如图 7 所示, 融合了标准卷积、深度可分离卷积 (DSC, DepthSepConv)^[19] 以及通道随机混合操作 (channel shuffle operation) 等多种技术。在 GSConv 中, 一部分特征图通过标准卷积进行直接提取, 而另一部分则通过简单的线性变换 (如恒等映射或 3×3 的线性卷积) 从已生成的特征图中“廉价”地生成, 这些通过简单变换得到的特征图被称为“鬼影”特征图, 可以在不显著牺牲模型性能的情况下, 大量减少模型中的参数数量和计算量。




图 7 GSConv 结构图

通道随机混合操作也叫做“重塑—转置—重塑”, 是 GSConv 中的另一个关键组成部分。其通过随机排列通道并混合 DSC 生成的特征图, 使标准卷积保留的增强特征信息融入 DSC 内部, 维持通道间的隐性关联, 丰富特征表达。这种操作不仅增强了特征之间的交互性, 还有助于提升模型的泛化能力。

经实验验证, 若模型各阶段均采用 GSConv, 将导致网络层数加深, 显著延长推理时间。因此, 仅针对 Neck 层, 将其中的标准卷积替换为 GSConv, 以降低网络的复杂度。

2.4 改进后的整体结构

改进后算法整体网络结构如图 8 所示。

3 实验结果与分析

3.1 实验环境

本文实验所采用的硬件与软件环境如表 1 所示。

表 1 实验环境

项目	版本环境
Operating System	Ubuntu20.04
CPU	Intel(R) Xeon(R) Platinum 8350C CPU @ 2.60 GHz
GPU	NVIDIA RTX 3090
Python	3.8.13
Pytorch	1.11.1
CUDA	11.3
cuDNN	8.0.5




图 8 改进后算法整体结构图

模型超参数设置如下：网络输入图像的尺寸为 640×640 ，训练迭代周期数 epoch 设置为 300，各批次处理的样本数量 batch size 设置为 32，权重参数优化器使用随机梯度下降 (SGD)，初始学习率为 0.01，采用余弦淬火策略调整学习率，学习率动量设置为 0.937，其他超参数均保持默认值。

3.2 数据集

由于网上没有关于实验导线的公共数据集，本研究中使用的数据集均来自实验台现场拍摄，更具实际意义。初始采集共 1 200 张接线图片，考虑到样本数量较少，利用平移、旋转、增加噪声等数据增强技术手段，将接线图片扩增至 8 500 张，以保证数据集的多样性，该数据集包含蓝、黑、黄、红和绿 5 种颜色的导线，对应 5 种导线端点标签，分别是蓝色端点 (blue-endpoint)、黑色端点 (black-endpoint)、黄色端点 (yellow-endpoint)、红色端点 (red-endpoint)、绿色端点 (green-endpoint)，数据集图片标注软件采用 LabelImg，生成 txt 格式的标签文件，训练集和测试集的划分比例为 8 : 2。部分数据集图片如图 9 所示。

3.3 评价指标

本文从模型参数量 (Parameters)、模型体积 (MB)、计算量 (GFLOPs) 和平均准确均值 (mAP) 这 4 方面评价模型的性能。模型参数量表示训练过程中总参数量；模型体积表示训练结束后生成权重文件的大小；计算量表示模型的复杂度，计算量越大，模型越复杂，也称为浮点运算次数；mAP 表示所有检测类别的识别准确率的均值，计算公式为：

$$P = \frac{TP}{TP + FP} \quad (4)$$

$$R = \frac{TP}{TP + FN} \quad (5)$$




图 9 部分数据示例及标注图片

$$AP = \int_0^1 P(R) dR \quad (6)$$

$$mAP = \frac{1}{n} \sum_{i=1}^n AP_i \quad (7)$$

其中，TP 为被预测为正的正样本数量，FP 表示被预测为正的负样本数量，FN 表示被预测为负的正样本数量，N 为检测目标的类别数，i 为其中一种被检测的类别，AP 在本实验中表示每一类导线的检测精度。

3.4 消融实验

为验证不同改进策略的有效性，以 YOLOv5s 为基线做消融实验，每个实验参数设置和数据集保持不变，实验数据如表 2 所示。第一列序号 1 表示未改进的 YOLOv5s 模型，“√”表示添加此种改进，由表 2 中所示。模型 2、3、4 中和模型 1 相比，模型更加轻量化，体积更小，mAP 均有所上升，而更换骨干网络为 PPLCNet 后，模型参数量、计算量、体积分别减少了 58.4%，63.2%，57.6%，mAP 提升了 0.6%，可以看出 PPLCNet 对模型轻量化影响最大，模型 3、4 和模型 1 相比，除 mAP 增加，其余指标均小幅度降低，证明改进的有效性，模型 5 在骨干网络为 PPLCNet 的同时 Neck 添加 CNeB 模块，参数量、计算量、模型体积和仅更换 PPLCNet 的模型 2 相比进一步减小，此时 mAP 达到 98.3%，相比模型 1 提升了 0.9%，信息提取能力进一步增强，在骨干网络为 PPLCNet 的同时改进 Neck 中的标准卷积为 GSConv，形成模型 6，模型 6 和模型 5 相比，参数量、计算量、体积进一步缩小，而模型 7 和改进的骨干网络的其他模型相比，参数量、计算量、模型体积的下降幅度放缓，相比模型 1 改进仍然有效；使用 3 种方案共同改进 YOLOv5s 模型，形成模型 8。其与初始 YOLOv5 模型对比，参数量为原始模型的 33.3%，计算量为原始模型的 31.6%，模型体积为原始模型的 34.8%，并且 mAP 提升了

0.9%, 能够在实现轻量化的同时提高模型对导线端点的识别精度。

表 2 消融实验

No.	PPLCNet	CNeB	GSConv	Parameters	GFLOPs	体积/MB	mAP@0.5/%
1				7 023 610	15.8	13.7	97.4
2	✓			2 920 098	5.8	5.8	98
3		✓		6 851 066	15.5	13.4	97.9
4			✓	6 583 418	15.2	12.9	98
5	✓	✓		2 747 554	5.4	5.5	98.3
6	✓		✓	2 512 674	5.2	5.1	97.9
7		✓	✓	6 410 874	14.9	12.5	98.2
8	✓	✓	✓	2 340 130	5.9	4.7	98.3

为验证改进前后网络的性能, 改进前后网络的损失函数变化曲线如图 10、11 所示, 横坐标为训练的 epoch, 纵坐标分别为定位损失、置信度损失和分类损失, 总体上两者随着训练迭代次数的增加, 损失值逐渐降低, 从训练开始到第 10 个 epoch 期间, 训练值降低最快, 之后缓慢降低, 最终逐渐趋于平稳, 而改进前网络在训练第 80~90 epoch 区间损失函数有较大波动, 改进后的网络定位损失稳定在 0.019, 置信度损失稳定在 0.017, 分类损失稳定在 0.001, 性能更优, 波动更小。




图 10 改进前网络损失曲线




图 11 改进后网络损失曲线

3.5 对比实验

对于导线端点检测模型的部署问题, 改进目标应是在保证较高准确率的前提下, 尽可能减小 GFLOPs 和模型体积。为进一步验证本文所提模型的精确性和轻量化性, 将其与另外几种典型的轻量化模型对比, 涵盖了 YOLO 系列中的 YOLOv3-tiny、YOLOv4s^[20]、YOLOv5n 及 YOLOv7-tiny^[21] 的官方版本, 以及具有代表性的轻量化改进模型如 YOLOv5Lite-c、YOLOv5-mobile3s、YOLOv5-ghost, 实验结果如表 3 所示。由表可知, 改进后的算法与其他 YOLO 系列的官方轻量化版本


YOLOv3-tiny、YOLOv4s 和 YOLOv7-tiny 相比, 在模型大小和计算复杂度方面均有大幅减小, 且准确率都有提升; 与同为 YOLOv5 系列的 YOLOv5n 版本相比, 则在 GFLOPs 降低了 0.6 的同时, 将模型体积缩减到了 0.5 MB, 并提升了 1.3% 的准确率; 即使与主流的轻量化改进模型 YOLO-Lite、YOLOv5-mobile3s、YOLOv5-ghost 相比, 不仅达到了最高的检测准确率 98.3%, 还实现了最小的模型体积 4.7 MB, 证明了改进网络的有效性、轻量化性和检测的精确性。综上所述, 本文所提出的算法在有效地提升导线端点检测准确性的同时, 显著降低了模型的复杂度和存储负担, 更加适合导线端点识别应用场景。

表 3 对比实验


模型	Parameters	GFLOPs	体积/MB	mAP@0.5/%
YOLOv3-tiny	8 678 242	12.9	17.5	97.2
YOLOv4s	9 149 763	20.6	18.7	98
YOLOv7-tiny	6 021 126	13.1	12.3	93.6
YOLOv5n	2 485 874	6.5	5.2	97
YOLO-Lite	4 379 715	8.6	9.2	97.5
YOLOv5-mobile3s	3 552 001	6.3	7.5	97.8
YOLOv5-ghost	3 698 027	8.2	7.8	98.2
本文算法	2 340 130	5.9	4.7	98.3

3.6 检测结果

本文采用 YOLOv5s 和改进模型的测试效果图进行分析, 测试效果如图 12 所示。从结果中可以看出, 总体上两种模型的检测准确率都保持在 80% 以上, 改进后的轻量化模型识别效果优于 YOLOv5s 模型, 能够准确识别出导线端点的位置, 置信度较高, 预测框能完整包裹住导线端点和识别出被其他导线遮挡的端点, 初始网络在两张图片中均有一个未检测到的绿色导线端点, 第一张图片的黑色导线端点被其他导线遮挡时, 虽然两种网络都能检测出来, 但初始网络置信度大幅度低于改



(a) 初始YOLOv5s网络



(b) 改进网络

图 12 测试效果图

进后的网络。改进后的模型在检测性能上有更高的优势,更适合完成复杂接线和复杂背景下的导线端点检测。

4 结束语

本文研究提出了一种基于改进 YOLOv5s 的轻量化导线端点识别方法,将现有的神经网络检测框架进行修改,更换骨干网络为 PPLCNet,在 Neck 层引入 GSConv 模块,并将 Neck 层的普通卷积替换为 GSConv 卷积,根据实验结果发现,本文提出的模型平均准确率保持小幅度提高的情况下,实现了模型的参数量、计算量、GFLOPs 和模型体积大幅度降低。综上所述,在实现轻量化的同时,模型也提高了检测精度,便于部署,满足了实际教学实验场景中对于智能接线检查系统的要求。下一步,我们将继续研究在导线更多、接线情况更复杂的场景下进行导线端点识别,并探索模型在嵌入式设备和边缘设备上的部署和应用。

参考文献:

- [1] SANCHEZ J, CORRALES J A, BOUZGARROU B C, et al. Robotic manipulation and sensing of deformable objects in domestic and industrial applications: a survey [J]. The International Journal of Robotics Research, 2018, 37 (7): 688 – 716.
- [2] XIN J, KYONG M K, KOHEI K, et al. Robotized assembly of a wire harness in car production line [C] //IEEE/RSJ International Conference on Intelligent Robots and Systems, Taipei, Taiwan: IEEE, 2010: 490 – 495.
- [3] DANIELE D G, GIANLUCA P, LUIGI D S. Let's take a walk on superpixels graphs: deformable linear objects segmentation and model estimation [C] //14th Asian Conference on Computer Vision, Perth, Australia: Springer, 2018: 662 – 677.
- [4] SONG Y, YANG K, JIANG X, et al. Vision based topological state recognition for deformable linear object untangling conducted in unknown background [C] //IEEE International Conference on Robotics and Biomimetics, Dali, China: IEEE, 2019: 790 – 795.
- [5] SARDELIS A, ZACHARAKI N C, ARKOULI Z, et al. 2-Stage vision system for robotic handling of flexible objects [J]. Procedia CIRP, 2021, 97: 491 – 496.
- [6] 林嘉煌. 柔性线缆智能检测和抓取规划研究 [D]. 哈尔滨: 哈尔滨工业大学, 2022.
- [7] ALESSIO C, RICCARDO Z, DANIELE D G, et al. Ariadne+: deep learning-based augmented framework for the instance segmentation of wires [J]. IEEE Transactions on Industrial Informatics, 2022, 18 (12): 8607 – 8617.
- [8] ALESSIO C, KEVIN G, RICCARDO Z, et al. FASTD-LO: fast deformable linear objects instance segmentation [J]. IEEE Robotics and Automation Letters, 2022, 7 (4): 9075 – 9082.
- [9] ANDREW C, DEZHONG T, BRIAN P, et al. mBEST: realtime deformable linear object detection through minimal bending energy skeleton pixel traversals [J]. IEEE Robotics and Automation Letters, 2023, 8 (8): 4863 – 4870.
- [10] HUANG X Z, CHEN D, GUO Y H, et al. Untangling multiple deformable linear objects in unknown quantities with complex backgrounds [J]. IEEE Transactions on Automation Science and Engineering, 2024, 21 (1): 671 – 683.
- [11] CUI C, GAO T, WEI S, et al. PP-LCNet: A lightweight CPU convolutional neural network [J/OL]. ArXiv, 2021, abs/2109.15099.
- [12] CHEN J, BAO E, PAN J. Classification and positioning of circuit board components based on improved YOLOv5 [J]. Procedia Computer Science, 2022, 208: 613 – 626.
- [13] DENG C, WANG M, LIU L, et al. Extended feature pyramid network for small object detection [J]. IEEE Transactions on Multimedia, 2021, 24: 1968 – 1979.
- [14] LIANG T, WANG Y, TANG Z, et al. Opanas: One-shot path aggregation network architecture search for object detection [C] //IEEE/CVF Conference on Computer Vision and Pattern Recognition, Nashville, TN, USA: IEEE, 2021: 10195 – 10203.
- [15] MIJWIL M, DOSHI R, HIRAN K, et al. MobileNetV1-based deep learning model for accurate brain tumor classification [J]. Mesopotamian Journal of Computer Science, 2023: 29 – 38.
- [16] MA H, HAN G, PENG L, et al. Rock thin sections identification based on improved squeeze-and-Excitation Networks model [J]. Computers & Geosciences, 2021, 152: 104780.
- [17] LIU Z, MAO H, WU C Y, et al. A convnet for the 2020s [C] //IEEE/CVF Conference on Computer Vision and Pattern Recognition, New Orleans, LA, USA: IEEE, 2022: 11976 – 11986.
- [18] LI H, LI J, WEI H, et al. Slim-neck by GSConv: a better design paradigm of detector architectures for autonomous vehicles [EB/OL]. ArXiv, 2022, abs/2206.02424.
- [19] LIU F, XU H, QI M, et al. Depth-wise separable convolution attention module for garbage image classification [J]. Sustainability, 2022, 14 (5): 3099.
- [20] BOCHKOVSKIY A, WANG C Y, LIAO H Y. Yolov4: Optimal speed and accuracy of object detection [EB/OL]. ArXiv, 2020, abs/2004.10934.
- [21] WANG C Y, BOCHKOVSKIY A, LIAO H Y. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for realtime object detectors [C] //IEEE/CVF Conference on Computer Vision and Pattern Recognition, Vancouver, BC, Canada: IEEE, 2023: 7464 – 7475.